Харківський національний університет внутрішніх справ Міністерство внутрішніх справ України

Національний університет «Львівська політехніка» Міністерство освіти і науки України

> Кваліфікаційна наукова праця на правах рукопису

ВЛАДОВ СЕРГІЙ ІГОРОВИЧ

УДК 621.438.3:004.021.5

ДИСЕРТАЦІЯ

МЕТОДИ ТА ЗАСОБИ МОНІТОРИНГУ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕРТОЛЬОТІВ НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ ПІД ЧАС ЇХ ЕКСПЛУАТАЦІЇ

01.05.03 – математичне та програмне забезпечення обчислювальних машин і систем 05 – технічні науки

Подається на здобуття наукового ступеня доктора технічних наук

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

Ідентичність всіх примірники дисертації ЗАСВІДЧУ Вчений секретар спе ізованої вченої ради Д 35.052.05 Ростислав Львів - 2025

инин Х. Владов

АНОТАЦІЯ

Владов С. І. Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації. – Кваліфікаційна наукова праця на правах рукопису.

Дисертаційна робота на здобуття наукового ступеня доктора технічних наук за спеціальністю 01.05.03 – Математичне та програмне забезпечення обчислювальних машин і систем. – Національний університет «Львівська політехніка», Міністерство освіти і науки України, Львів, 2025.

У дисертації вирішено важливу науково-прикладну проблему підтримки безпеки польотів вертольотів в реальному часі шляхом розробки математичного і програмного забезпечення моніторингу і управління експлуатацією ГТД вертольотів в умовах льотної експлуатації часі.

У роботі запропоновано метод моніторингу технічного стану та управління експлуатацією ГТД вертольотів у режимі льотної експлуатації. Метод базується на аналізі сучасного математичного та програмного забезпечення, типової архітектури експертних систем моніторингу та їх адаптації до вимог сучасних технологій. Розроблена експертна система моніторингу та управління експлуатацією ГТД вертольотів складається з декількох підсистем, що інтегруються в єдиний комплекс. Основою є нейромережева підсистема моніторингу, яка виконує класифікацію, ідентифікацію, контроль, діагностику, прогнозування, нагадування та тренд-аналіз. Система базується на базах знань, включаючи аналітичні дані, експертні знання та прецеденти. Зібрані сенсорами параметри двигуна обробляються та зберігаються у базі даних випробувань. Дані використовуються для ухвалення рішень через спеціальний модуль, який взаємодіє з автоматизованою підсистемою управління та командиром екіпажу через інтерфейс користувача.

Запропоновано метод побудови нейромережевої моделі моніторингу ГТД вертольотів, який за рахунок алгоритму формування однорідної і репрезентативної навчальної і тестової вибірок, дозволяє збільшити достовірність визначення можливості здійснення польоту. Математично доведено, якщо навчальна і тестова вибірки є однорідними та репрезентативними, то приймається, що обидві вибірки готові для застосування в прикладних задачах моніторингу технічного стану ГТД вертольотів з високою ймовірністю успіху.

Розроблено нейромережеві методи класифікації, ідентифікації, контролю, діагностики, прогнозування, налагодження та тренд-аналізу параметрів двигунів на основі модифікованих алгоритмів навчання і архітектур нейронних мереж, що забезпечує достовірність визначення можливості здійснення польоту на рівні 99 %. Зокрема, вперше створено нову архітектуру РБФ-мережі – поліморфну РБФ-мережу, яка відрізняється від традиційної РБФ-мережі тим, що за рахунок окремого прихованого шару для кожної незалежної змінної і різною кількістю багатовимірних радіально-базових функцій у кожній групі та застосування елемента множення замість підсумовування радіальних елементів, дозволяє нівелювати її недоліки та обмеження. Також науково обґрунтовано особливість переходу від тришарового персептрона до гібридної мережі NARX з радіально-базисним шаром в задачі нейромережевої ідентифікації багаторежимної моделі ГТД вертольотів за реєстрованими на борту вертольоту параметрами.

Удосконалено методи класифікації, контролю, діагностики, прогнозування, налагодження, тренд-аналізу технічного стану ГТД вертольотів на основі модифікованих алгоритмів навчання і архітектур нейронних мереж, в яких, на відміну від існуючих, застосовано гібридні комбінації адаптивних елементів, що дозволило досягти точності 99,5 % зі зменшенням абсолютної похибки до 4,5 разів. Розроблено модель триканальної адаптивної підсистеми управління (АПУ) із додатковим каналом регулювання частоти обертів ротора, що дозволило покращити показники якості каналів управління до 64,29 % порівняно з традиційними системами.

Розвинуто нейро-нечіткі методи моніторингу, які дозволяють з високою точністю визначати зміни параметрів двигунів, зокрема витрату палива (99,2 %) і зміну ККД компресора (99,62 %). Зокрема, у рамках розроблених нейро-нечітких методів моніторингу розроблено метод навчання гібридних мереж, який ґрунтується на технології розподілених і паралельних обчислень та відрізняється від існуючих впровадженням параметра градієнта функції втрат замість вектора часткових градієнтів функцій належності, що дозволяє оновлювати параметри гібридної мережі на основі градієнтного спуску після розрахунку градієнта. Це забезпечує паралельне виконання задач на різних процесорах і вузлах обчислювального кластера, що значно прискорює процес навчання в розподіленому середовищі, підвищуючи продуктивність і гнучкість системи. Вперше розроблено нейро-нечіткий метод визначення робочого стану ГТД вертольотів у режимі польоту на основі динаміки змін ефективності компресора двигуна, що базується на ансамблі нейронних мереж «RBF – Персептрон – Нейронечіткий класифікатор» і дозволяє визначати поточний стан двигуна з точністю 99,62 %, оперативно приймаючи рішення щодо можливості виконання або продовження польоту. Реалізація методу з використанням цього ансамблю забезпечує зниження помилок першого та другого роду у 1,23–5,96 рази порівняно з іншими архітектурами нейронних мереж.

Удосконалено методи відновлення даних у разі відмови сенсорів за допомогою автоасоціативних нейронних мереж (автоенкодерів), РБФ-мереж та фільтра Калмана, що забезпечує реконструкцію параметрів у реальному часі з похибкою не більше 0,762 %. Зокрема, удосконалено підхід нейронних мереж до відновлення втрачених даних у випадках відмови сенсорів у складних динамічних системах шляхом використання автоасоціативної нейронної мережі (автоенкодера), що забезпечує відновлення даних із точністю 99 %. Це підтверджують метрики Precision, Recall і F-міра, значення яких для нормальних даних становлять 0.989, 0.987 і 0.988 відповідно, а для аномальних – 0.967, 0.967 і 0.968 відповідно. Удосконалено базовий алгоритм навчання автоенкодера шляхом додавання регуляризації до функції втрат та оновлення ваг, що зменшує ризик перенавчання моделі, зберігаючи її здатність до узагальнення нових даних. Експериментально доведено, що при використанні вдосконаленого алгоритму максимальне значення функції втрат не перевищує 0.025 (2.5 %), що свідчить про мінімальний ризик перенавчання. Вперше сформульовано і доведено гіпотезу про оновлення ваг в автоенкодері за допомогою градієнтного спуску з регуляризацією, що підтверджує доцільність удосконалення базового алгоритму навчання, дозволяючи контролювати складність моделі та знижувати ризик її перенавчання.

Удосконалено метод діагностики та усунення відмов вимірювальних каналів, який відрізняється від існуючих використанням багатовимірного фільтра Калмана з точками Чебишева, реалізованого модифікованою рекурентною нейронною мережею, що забезпечило виявлення та локалізацію відмов датчиків із середньою точністю 99.8 %. Вперше запропоновано реалізацію багатовимірного фільтра Калмана з точками Чебишева за допомогою модифікованої рекурентної нейронної мережі, що включає вхідний шар, шар діагностики відмов, шар усунення відмов, шар фільтрації та згладжування, а також шар агрегування результатів. Цей підхід дозволяє вирішувати основні завдання діагностики та усунення відмов із точністю діагностики 0.99802, усунення 0.99796 та оцінки стану системи 0.99798. Експериментально доведено, що використання модифікованої рекурентної нейронної мережі для реалізації багатовимірного фільтра Калмана з точками Чебишева зменшує помилки 1-го та 2-го роду у 1.24–1.71 рази порівняно з нейронною мережею радіально-базисних функцій та у 1.70–2.90 рази – порівняно з відсутністю нейронних мереж, що підтверджено на прикладі вирішення задачі діагностики та усунення відмов вимірювальних каналів автоматичної системи керування двигуном TV3-117.

Розроблено програмний засіб «MONITOR» для оперативного аналізу стану двигунів і прототип експертної системи, яка поєднує адаптивні модулі моніторингу та управління. Її застосування дозволило досягти рівня прийняття рішень щодо можливості експлуатації двигунів у 99,2 %, сприяючи підвищенню безпеки та ефективності експлуатації авіаційної техніки.

Ключові слова: математичне і програмне забезпечення, експертна система, нейронна мережа, алгоритм навчання, моніторинг і управління експлуатацією, прийняття рішень, газотурбінний двигун вертольоту.

ANNOTATION

S. Vladov. Methods and means of monitoring helicopter turboshaft engines based on neural network technologies during their operation. – Manuscript.

Thesis for a Doctoral degree in Technical Science, speciality 01.05.03 – Mathematical and software support of computing machines and systems. – Lviv Polytechnic National University, Ministry of Education and Science of Ukraine, Lviv, 2025.

The dissertation addresses a significant scientific and applied problem of ensuring realtime flight safety for helicopters through the mathematical and software tools development for the helicopter turboshaft engines operation monitoring and managing under flight conditions.

The research proposes a method for monitoring the helicopter turboshaft engines operation technical condition and managing during flight. This method relies on analyzing advanced mathematical and software solutions, typical architectures of expert monitoring systems, and adapting them to modern technological requirements. The developed expert system integrates several subsystems into a unified framework, with its core being a neural network-based monitoring subsystem. This subsystem performs classification, identification, control, diagnostics, predicting, reminders, and trend analysis using knowledge bases that incorporate analytical data, expert knowledge, and precedents. Parameters collected by sensors are processed and stored in a test database, which serves as a foundation for decision-making through a specialized module that interacts with the automated management subsystem and the crew commander via a user interface.

A method for constructing a neural network model for helicopter turboshaft engines monitoring has been proposed. By employing algorithms for creating homogeneous and representative training and test datasets, this method increases the determining flight feasibility reliability. It is mathematically proven that if both datasets are homogeneous and representative, they are ready for use in applied tasks for the helicopter turboshaft engines technical condition monitoring with high success probability.

Neural network methods for classification, identification, control, diagnostics, forecasting, adjustment, and trend analysis of engine parameters have been developed based on modified training algorithms and neural network architectures, ensuring 99 % reliability in determining flight feasibility. A novel architecture for radial basis function networks, termed polymorphic RBF networks, has been created. This architecture features separate hidden layers for each independent variable and varying quantities of multidimensional radial basis functions in each group, using summation multiplication instead for radial elements. This approach mitigates the limitations of traditional RBF networks. Additionally, a transition from three-layer perceptrons to hybrid NARX networks with a radial basis layer has been scientifically substantiated for the helicopter turboshaft engines multi-mode models neural network-based identification using onboard parameter recordings.

The methods for classification, control, diagnostics, predicting, adjustment, and trend analysis of the helicopter turboshaft engines technical condition have been refined. Unlike existing approaches, hybrid combinations of adaptive elements were applied, achieving 99.5 % accuracy while reducing absolute error by up to 4.5 times. A three-channel adaptive management subsystem model was developed with an additional rotor speed regulation channel, improving control channel quality indicators by up to 64.29 % compared to traditional systems.

Neuro-fuzzy monitoring methods have been enhanced to detect engine parameter changes, such as fuel consumption (99.2 %) and compressor efficiency variation (99.62 %), with high precision. As part of these methods, a hybrid network training approach was developed using distributed and parallel computation technology. Introducing a gradient loss function parameter instead of membership functions partial gradients allowed gradient-based parameter updates for hybrid networks, enabling parallel task execution on multiple processors and computational nodes. This approach significantly accelerated training in distributed environments, improving system productivity and flexibility.

A neuro-fuzzy method for determining the helicopter turboshaft engines technical condition during flight was developed based on compressor efficiency dynamics. Using a neural network ensemble of "RBF – Perceptron – Neuro-Fuzzy Classifier", the system achieves 99.62 % accuracy in determining engine status and rapidly decides on flight feasibility. Implementing this method reduced type I and II errors by 1.23–5.96 times compared to other neural network architectures. Methods for data restoring in sensor failure scenarios were refined using auto-associative neural networks (autoencoders), RBF networks, and the Kalman filter, ensuring realtime parameter reconstruction with an error not exceeding 0.762 %. The autoencoder-based approach provides 99 % accuracy in restoring lost data in complex dynamic systems. This is supported by precision, recall, and F-measure metrics of 0.989, 0.987, and 0.988 for normal data and 0.967, 0.967, and 0.968 for abnormal data, respectively. The autoencoder's training algorithm was improved by adding regularization to the loss function and weight updates, reducing overfitting risks while preserving the model's ability to generalize new data. Experimentally, the maximum loss function value did not exceed 0.025 (2.5 %), indicating minimal overfitting risks. A hypothesis about weight updates in autoencoders using gradient descent with regularization was formulated and proven, confirming the improving feasibility the basic training algorithm and enabling model complexity control while minimizing overfitting risks.

A method for diagnosing and addressing measurement channel failures was refined. It features a multidimensional Kalman filter with Chebyshev points implemented via a modified recurrent neural network. This approach achieves sensor failure detection and localization with an average accuracy of 99.8 %. A novel implementation of the Kalman filter was proposed using a recurrent neural network with layers for failure diagnostics, addressing, filtering, smoothing, and results aggregation. It ensures diagnostic accuracy of 0.99802, failure addressing of 0.99796, and system state evaluation of 0.99798. Experiments demonstrated a reduction in type I and II errors by 1.24–1.71 times compared to radial basis function networks and 1.70–2.90 times compared to approaches without neural networks. This was validated on the TV3-117 engine measurement channel failure scenario.

The "MONITOR" software tool was developed for real-time engine condition analysis, along with an expert system prototype combining adaptive monitoring and management modules. Its application achieved a 99.2% decision-making reliability regarding engine operation feasibility, enhancing aviation safety and operational efficiency.

Keywords: mathematical and software support, expert system, neural network, training algorithm, monitoring and operation control, decision making, helicopter turboshaft engine.

9

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у наукових виданнях, що індексуються у наукометричній базі Scopus:

 Vladov S. Cognitive method for the fuzzy controller mathematical model synthesising, utilising a genetic algorithm for tuning. *Big Data and Cognitive Computing*. 2025. Vol. 9. Issue 1.
 17. doi: 10.3390/bdcc9010017 (квартиль Q1 відповідно до SCImago Journal)

2. Vladov S., Bulakh M., Baranovskyi D., Sokurenko V., Muzychuk O., Vysotska V. Helicopter turboshaft engines combustion chamber monitoring neural network method. *Measurement*. Vol. 242. Part E. 2025. 116267. doi: 10.1016/j.measurement.2024.116267 (квартиль Q1 відповідно до SCImago Journal, Elsevier) *(автором розроблено нейромережевий метод моніторингу камери згоряння ГТД вертольотів)*

3. Vladov S., Vysotska V., Sokurenko V., Muzychuk O., Chyrun L. The Intelligent Data Measurement System Using Neural Network Technologies and Fuzzy Logic Under Operating Implementation Conditions. *Big Data and Cognitive Computing*. Vol. 8. Issue 12. 2024. 189. doi: 10.3390/bdcc8120189 (квартиль Q1 відповідно до SCImago Journal) *(автором отримано результати відновлення втраченої інформації в період перерви в роботі датчика температури газів перед турбіною компресора ГТД вертольотів)*

4. Vladov S., Yakovliev R., Vysotska V., Nazarkevych M., Lytvyn V. The Method of Restoring Lost Information from Sensors Based on Auto-Associative Neural Networks. *Applied System Innovation*. Vol. 7. Issue 3. 2024. 53. doi: 10.3390/asi7030053 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено метод відновлення інформації при відмовах датчиків з використанням автоасоціативної нейронної мережі)

5. Vladov S., Vysotska V., Sokurenko V., Muzychuk O., Nazarkevych M., Lytvyn V. Neural Network System for Predicting Anomalous Data in Applied Sensor Systems. *Applied System Innovation*. Vol. 7. Issue 5. 2024. 88. doi: 10.3390/asi7050088 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережеву систему для прогнозування аномальних даних)

6. Vladov S., Lytvynov O., Vysotska V., Vasylenko V., Pukach P., Vovk M. The helicopter turboshaft engines' innovative applied control system based on a neuro-fuzzy networks. *Applied System Innovation*. Vol. 7. Issue 6. 2024. 118. doi: 10.3390/asi7060118 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено вбудовану нейро-нечітку систему керування ГТД вертольотів)

7. Vladov S., Yakovliev R., Vysotska V., Uhryn D., Ushenko Y. Universal On-board Neural Network System for Restoring Information in Case of Helicopter Turboshaft Engine Sensor Failure. *International Journal of Computer Network and Information Security (IJCNIS)*. Vol. 16. No.

4. 2024. Р. 65–87. doi: 10.5815/ijcnis.2024.04.05 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережевий метод відновлення інформації при параметричній відмові одного з датчиків)

8. Vladov S., Scislo L., Sokurenko V., Muzychuk O., Vysotska V., Osadchy S., Sachenko A. Neural Network Signal Integration from Thermogas-Dynamic Parameter Sensors for Helicopters Turboshaft Engines at Flight Operation Conditions. *Sensors*. 2024. Vol. 24, Issue 13, 4246 doi: 10.3390/s24134246 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережевий метод інтеграції сигналів датчиків ГТД вертольотів)

9. Vladov S., Banasik A., Sachenko A., Kempa W., Sokurenko V., Muzychuk O., Pikiewicz P., Molga A., Vysotska V. Intelligent Method of Identifying the Nonlinear Dynamic Model for Helicopter Turboshaft Engines. *Sensors*. 2024. Vol. 24, Issue 19, 6488 doi: 10.3390/s24196488 (квартиль Q1 відповідно до SCImago Journal) *(автором удосконалено архітектуру нейронної мережі Елмана шляхом уведення до неї динамічної стекової пам'яті)*

10. Vladov S., Scislo L., Szczepanik-Ścisło N., Sachenko A., Perzyński T., Vasylenko V., Vysotska V. Helicopter Turboshaft Engines' Neural Network System for Monitoring Sensor Failures. *Sensors*. 2025. Vol. 25, Issue 4, 990. doi: 10.3390/s25040990 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережеву систему моніторингу відмов датчиків ГТД вертольотів)

11. Vladov S., Sachenko A., Sokurenko V., Muzychuk O., Vysotska V. Helicopters turboshaft engines neural network modeling under sensor failure. *Journal of Sensor and Actuator Networks*. 2024. Vol. 13. Issue 5. 66 doi: 10.3390/jsan13050066 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережеву модель відмов датчиків ГТД вертольотів)

12. Vladov S., Yakovliev R., Bulakh M., Vysotska V. Neural Network Approximation of Helicopter Turboshaft Engine Parameters for Improved Efficiency. *Energies*. 2024. Vol. 17, Issue 9, 2233 doi: 10.3390/en17092233 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережеву модель для апроксимації параметрів ГТД вертольотів)

13. Vladov S., Scislo L., Sokurenko V., Muzychuk O., Vysotska V., Sachenko A., Yurko A. The helicopter turboshaft engines gas-generator rotor r.p.m. neuro-fuzzy on-board controller. *Energies*. 2024. Vol. 17, Issue 16, 4033 doi: 10.3390/en17164033 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейро-нечітку систему керування частотою обертів ротора турбокомпресора ГТД вертольотів)

14. **Vladov S.**, Bulakh M., Vysotska V., Yakovliev R. Onboard Neuro-Fuzzy Adaptive Helicopter Turboshaft Engines Automatic Control System. *Energies*. 2024. Vol. 17, Issue 16, 4195 doi: 10.3390/en17164195 (квартиль Q1 відповідно до SCImago Journal) *(автором розробено нейро-нечітку адаптивну АПУ ГТД вертольотів)* 15. Vladov S., Bulakh M., Czyżewski J., Lytvynov O., Vysotska V., Vasylenko V. Method for Helicopter Turboshaft Engines Controlling Energy Characteristics Through Regulating Free Turbine Rotor Speed and Fuel Consumption Based on Neural Networks. *Energies*. 2024. Vol. 17, Issue 22, 5755 doi: 10.3390/en17225755 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейро-нечіткий регулятор витрати палива ГТД вертольотів)

16. Vladov S., Bulakh M., Baranovskyi D., Kisiliuk E., Vysotska V., Romanov M., Czyżewski J. Application of the Integral Energy Criterion and Neural Network Model for Helicopter Turboshaft Engines' Vibration Characteristics Analysis. *Energies*. 2024. Vol. 17, Issue 22, 5776 doi: 10.3390/en17225776 (квартиль Q1 відповідно до SCImago Journal) (автором розроблено нейромережевий метод діагностики вібраційного стану ГТД вертольотів)

17. Baranovskyi D., **Vladov S.**, Bulakh M., Vysotska V., Vasylenko V., Czyżewski J. Method of Helicopter Turboshaft Engines' Protection During Surge in Starting Mode. *Energies*. 2025. Vol. 18, Issue 1, 168. doi: 10.3390/en18010168 (квартиль Q1 відповідно до SCImago Journal) *(автором розроблено нейромережевий метод визначення помпажу ГТД вертольотів)*

18. Vladov S., Vysotska V., Vasylenko V., Lytvyn V., Nazarkevych M., Fedevych O. Influence of the Neural Network Morphology Symmetry on the Complex Dynamic Objects' Diagnostics. *Symmetry*. Vol. 17. Issue 1. 2025. 35. doi: 10.3390/sym17010035 (квартиль Q1 відповідно до SCImago Journal) (автором експериментально доведено доцільності застосування симетричних нейронних мереж в задачах моніторингу ГТД вертольотів)

19. **Vladov S.**, Kovtun V., Sokurenko V., Muzychuk O., Vysotska V. Helicopter Turboshaft Engine Residual Life Determination by Neural Network Method. *Electronics*. 2024. Vol. 13, Issue 15, 2952 doi: 10.3390/electronics13152952 (квартиль Q2 відповідно до SCImago Journal) *(автором розроблено ісрархічну нейромережеву систему для визначення залишкового ресурсу ГТД вертольотів)*

20. Vladov S., Kovtun V., Sokurenko V., Muzychuk O., Vysotska V. The Helicopter Turboshaft Engine's Reconfigured Dynamic Model for Functional Safety Estimation. *Electronics*. 2024. Vol. 13, Issue 17, 3477 doi: 10.3390/electronics13173477 (квартиль Q2 відповідно до SCImago Journal) (автором розроблено динамічну реконфігуровану модель динамічної АПУ ГТД вертольотів)

21. Vladov S., Sachenko A., Vysotska V., Volkanin Y., Kukharenko D., Severynenko D. The reliably stable neural network controllers' synthesis with the transient process parameters optimization. *Radioelectronic and Computer Systems*. No. 4 (112). 2024. P. 178–191. doi: 10.32620/reks.2024.4.15 (квартиль Q3 відповідно до SCImago Journal) (автором розроблено нейромережеву систему регулювання витратою палива ГТД вертольотів)

22. Vladov S., Yakovliev R., Vysotska V., Uhryn D., Ushenko Y., Karachevtsev. A.

11

Polymorphic Radial Basis Functions Neural Network. *International Journal of Intelligent Systems and Applications (IJISA)*. Vol. 16. No. 4. 2024. P. 1–21. doi: 10.5815/ijisa.2024.04.01 (квартиль Q3 відповідно до SCImago Journal) *(автором розроблено поліморфну нейронну мережу і оптимізовано параметри робочого процесу ГТД вертольотів)*

23. Vladov S., Muzychuk O., Vysotska V., Yurko A., Uhryn D. Modified Kalman Filter with Chebyshev Points Based on a Recurrent Neural Network for Automatic Control System Measuring Channels Diagnosing and Parring Off Failures. *International Journal of Image, Graphics and Signal Processing (IJIGSP)*. Vol. 16. No. 5. 2024. P. 36–61. doi: 10.5815/ijigsp.2024.05.04 (квартиль Q3 відповідно до SCImago Journal) (автором удосконалено багатовимірний фільтр Калмана шляхом застосування поліному Чебишева)

24. Vladov S., Avkurova Z., Lytvyn V., Zhovnir Y. Analytical Neural Network System for the Helicopter Turboshaft Engines Operating Modes Classification. *International Journal of Computing*. Vol. 23. Issue 3. 2024. P. 342–359. doi: 10.47839/ijc.23.3.3653 (квартиль Q4 від-повідно до SCImago Journal) (автором розроблено нейромережеву систему класифікації станів ГТД вертольотів)

25. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Helicopters Turboshaft Engines Parameters Identification Using Neural Network Technologies Based on the Kalman Filter. *Communications in Computer and Information Science* (CCIS) book series. Vol. 1980. 2023. P. 82–97. doi: 10.1007/978-3-031-48325-7_7 (квартиль Q4 відповідно до SCImago Journal) (автором реалізовано багатовимірний фільтр Калмана рекурентною нейронною мережею)

26. Sachenko A., Vysotska V., **Vladov S.**, Vasylenko V., Dobrowolski M. Hybrid method for restoring missing sensor data with adaptive control based on neuro-fuzzy networks. *CEUR Workshop Proceedings*. Vol. 3899. 2024. P. 186–200. (автором реалізовано метод відновлення втраченої інформації з датчиків нейро-нечіткою мережею)

27. Vysotska V., Lytvyn V., **Vladov S.**, Vasylenko V., Kryshan O. The optimal controller parametric synthesis using variational calculus for a dynamic system general mathematical model. *CEUR Workshop Proceedings*. Vol. 3896. 2024. P. 217–234. (автором експериментально отримано динаміку перехідних процесів частоти обертів ротора турбокомпресора ГТД вертольотів)

28. Vladov S., Yakovliev R., Hubachov O., Rud J., Stushchanskyi Y. Neural Network Modeling of Helicopters Turboshaft Engines at Flight Modes Using an Approach Based on "Black Box" Models. *CEUR Workshop Proceedings*. Vol. 3624. 2024. P. 116–135. (автором створено нейромережеву модель ГТД вертольотів у вигляді «чорного ящика»)

29. **Vladov S.**, Yakovliev R., Hubachov O., Rud J. Neuro-Fuzzy System for Detection Fuel Consumption of Helicopters Turboshaft Engines. *CEUR Workshop Proceedings*. Vol. 3628.

2024. Р. 55–72. (автором розроблено нейро-нечітку систему моніторингу витратою палива ГТД вертольотів)

30. **Vladov S.**, Yakovliev R., Hubachov O., Rud J. On-board Hybrid Neural Network Classifier of Helicopters Turboshaft Engines Operational Status. *CEUR Workshop Proceedings*. Vol. 3628. 2024. P. 262–281. (автором створено нейромережевий класифікатор дефектів у вузлах ГТД вертольотів)

31. Vysotska V., **Vladov S.**, Yakovliev R., Yurko A., Voronin A. Neuro-Fuzzy Methods for Detecting Sensor Failures in Helicopters Turboshaft Engines. *CEUR Workshop Proceedings*. Vol. 3664. 2024. P. 105–123. (автором створено нейро-нечітку мережу для виявлення відмов датчиків ГТД вертольотів)

32. Vysotska V., **Vladov S.**, Yakovliev R., Yurko A. Hybrid Neural Network Identifying Complex Dynamic Objects: Comprehensive Modelling and Training Method Modification. *CEUR Workshop Proceedings*. Vol. 3702. 2024. P. 124–143. (автором удосконалено алгоритм Левенберга-Маркгвардта для навчання гібридної NARX-мережі)

33. Vysotska V., Lytvyn V., Nazarkevych M., **Vladov S.**, Yakovliev R., Yurko A. Training Neural Network Method Modification for Forward Error Propagation Based on Adaptive Components. *CEUR Workshop Proceedings*. Vol. 3711. 2024. P. 138–168. (автором удосконалено алгоритм навчання нейронних мереж прямого поширення шляхом застосування адаптивних компонентів)

34. Vysotska V., Lytvyn V., **Vladov S.**, Yakovliev R., Volkanin Y. Neural network method for identifying potential defects in complex dynamic objects. *CEUR Workshop Proceedings*. Vol. 3742. 2024. P. 44–65. (автором удосконалено нейромережевий метод прогнозування потенційних дефектів вузлів ГТД вертольотів)

35. Vysotska V., Lytvyn V., **Vladov S.**, Muzychuk O., Kryshan O. The controller synthesis automation using a dynamic mathematical model and genetic algorithms. *CEUR Workshop Proceedings*. Vol. 3842. 2024. P. 1–18. (автором здійснено нейромережеву реалізацію PID-контролера та отримано динаміку перехідних процесів частоти обертів ротора вільної турбіни ГТД вертольотів)

36. Vysotska V., **Vladov S.**, Volkanin Y., Siora A., Bulakh M., Muzychuk O., Koren O. The helicopter turboshaft engines parametric debugging using neural network technology. *CEUR Workshop Proceedings*. Vol. 3861. 2024. P. 1–15. (автором створено нейронну мережу для налаштування параметрів ГТД вертольотів)

37. Vysotska V., **Vladov S.**, Pukach P., Lavrut O., Muzychuk O., Baranovskyi D., Severynenko D. The dual-channel logic controller synthesis for controlling complex dynamic objects. *CEUR Workshop Proceedings*. Vol. 3861. 2024. P. 28–41. (автором отримано динаміку перехідних процесів витрати палива ГТД вертольотів)

38. **Vladov S.**, Shmelov Y., Yakovliev R., Petchenko M. Modified Neural Network Method for Trend Analysis of Helicopter Turboshaft Engine Parameters at Flight Modes. *CEUR Workshop Proceedings*. Vol. 3347. 2023. P. 11–29. (автором удосконалено архітектуру нейронної мережі Джорана шляхом уведення до неї динамічної стекової пам'яті)

39. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Modified Neural Network Fault-Tolerant Closed Onboard Helicopters Turboshaft Engines Automatic Control System. *CEUR Workshop Proceedings*. Vol. 3387. 2023. P. 160–179. (автором модифіковано закриту бортову систему керування ГТД вертольотів)

40. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Neural Network Method for Parametric Adaptation Helicopters Turboshaft Engines On-Board Automatic Control System Parameters. *CEUR Workshop Proceedings*. Vol. 3403. 2023. P. 179–195. (автором отримано динаміку перехідних процесів частоти обертів ротора вільної турбіни ГТД вертольотів при параметричній адаптації АПУ)

41. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Neural Network Method for Detecting and Diagnostics Helicopters Turboshaft Engines Surge at Flight Modes. *CEUR Workshop Proceedings*. Vol. 3392. 2023. P. 86–105. doi: 10.32782/cmis/3392-8 (автором здійснено моделювання передпомпажного стану ГТД вертольотів за допомогою нейронної мережі)

42. Vladov S., Shmelov Y., Yakovliev R., Stushchankyi, Y., Havryliuk Y. Neural Network Method for Controlling the Helicopters Turboshaft Engines Free Turbine Speed at Flight Modes. *CEUR Workshop Proceedings*. Vol. 3426. 2023. P. 89–108. (автором реалізовано контур управління частотою обертів ротора вільної турбіни ГТД вертольотів нейронною мережею з лінійними та нелінійними нейронами)

43. **Vladov S.**, Shmelov Y., Yakovliev R., Kozlovskaya T., Petchenko M. Helicopters Turboshaft Engines Intelligent Control Algorithms Synthesis, Taking into Account Required Quality Provision. *CEUR Workshop Proceedings*. Vol. 3468. 2023. P. 71–90. *(автором створено нейронечітку мережу для розв'язання задачі управління витратою палива ГТД вертольотів)*

44. **Vladov S.**, Shmelov Y., Yakovliev R. Parameter Debugging (Regulation) Method of Helicopters Aircraft Engines in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. Vol. 3179. 2022. P. 1–14. (автором створено метод налаштування параметрів ГТД вертольотів)

45. Vladov S., Shmelov Y., Yakovliev R. Helicopters Aircraft Engines Self-Organizing Neural Network Automatic Control System. *CEUR Workshop Proceedings*. Vol. 3137. 2022. P. 28–47. doi: 10.32782/cmis/3137-3 (автором модифіковано систему керування ГТД вертольотів шляхом відокремлення моделей двигуна та агрегату дозування палива)

46. **Vladov S.**, Shmelov Y., Yakovliev R. Methodology for Control of Helicopters Aircraft Engines Technical State in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. Vol. 3137. 2022. P. 108–125. doi: 10.32782/cmis/3137-10 (автором створено метод контролю стану ГТД вертольотів)

47. **Vladov S.**, Shmelov Y., Yakovliev R. Method for Forecasting of Helicopters Aircraft Engines Technical State in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. Vol. 3171. 2022. P. 974–985. (автором експериментально здійснено прогнозування температури газів перед турбіною компресора ГТД вертольотів)

48. **Vladov S.**, Shmelov Y., Yakovliev R. Optimization of Helicopters Aircraft Engine Working Process Using Neural Networks Technologies. *CEUR Workshop Proceedings*. Vol. 3171. P. 1639–1656. (автором експериментально здійснено оптимізацію параметрів робочого процесу ГТД вертольотів)

49. **Vladov S.**, Shmelov Y., Yakovliev R. Modified Helicopters Turboshaft Engines Neural Network On-board Automatic Control System Using the Adaptive Control Method. *CEUR Workshop Proceedings*. Vol. 3309. 2022. P. 205–224. (автором реалізовано метод адаптивного контролю частоти обертів ротора вільної турбіни ГТД вертольотів)

50. Vladov S., Shmelov Y., Yakovliev R. Control and Diagnostics of TV3-117 Aircraft Engine Technical State in Flight Modes Using the Matrix Method for Calculating Dynamic Recurrent Neural Networks. *CEUR Workshop Proceedings*. Vol. 2864. 2021. P. 97–109. doi: 10.32782/cmis/2864-9 (автором здійснено навчання рекурентної нейронної мережі матричним методом)

51. Vladov S., Shmelov Y., Petchenko M. A Neuro-Fuzzy Expert System for the Control and Diagnostics of Helicopters Aircraft Engines Technical State. *CEUR Workshop Proceedings*. Vol. 3013. 2021. P. 40–52. (автором реалізовано FDI-метод нейро-нечіткою мережею Ванга-Менделя)

52. **Vladov S.**, Shmelov Yu., Shmelova T. Modeling of the TV3-117 aircraft engine technical state as part of the helicopter power plant in the form of the Markov process of death and reproduction. *CEUR Workshop Proceedings*. Vol. 2740. 2020. P. 400–407. *(автором отримано значення ймовірностей переходу з одного в інший стан ГТД вертольотів)*

Статті у наукових виданнях, включених до категорії «Б» Переліку фахових видань України та включені до міжнародних наукометричних баз:

53. Владов С. І., Москалик В. М., Подгорних Н. В., Гусарова О. В., Назаренко Н. П. Використання нечітких нейронних мереж в задачах контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах. *Вісник Херсонського національного технічного університету*. 2021. № 1 (76). С. 77–86. doi: 10.35546/kntu2078-

4481.2021.1.10 (автором реалізовано діагностичну матрицю ГТД вертольотів нейро-нечіткою мережею Ванга-Менделя)

54. Владов С. І., Пилипенко Л. М., Тутова Н. В., Дєрябіна І. О., Яніцький А. А. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 шляхом аналізу тренду його параметрів. Вісник Херсонського національного технічного університету. 2021. № 1 (76). С. 87–98. doi: 10.35546/kntu2078-4481.2021.1.11 (автором здійснено порівняльний аналіз методів аналізу тренду параметрів авіаційного двигуна ТВЗ-117)

55. Владов С. І., Дєрябіна І. О., Гусарова О. В., Пилипенко Л. М., Пономаренко А. В. Ідентифікація багаторежимної моделі авіаційних двигунів вертольотів у польотних режимах з використанням модифікованого градієнтного алгоритму навчання радіально-базисних нейронних мереж. *Вісник Херсонського національного технічного університету*. 2021. № 4 (79). С. 52–63. doi: 10.35546/kntu2078-4481.2021.4.6 (автором модифіковано градієнтний алгоритм навчання RBF-мережі)

56. Владов С. І., Дєрябіна І. О., Подгорних Н. В., Грибанова С. А., Яніцький А. А. Проблеми і перспективи застосування нейронних мереж у задачах моніторингу технічного стану авіаційних двигунів вертольотів у польотних режимах. Вісник Херсонського національного технічного університету. 2021. № 4 (79). С. 64–73. doi: 10.35546/kntu2078-4481.2021.4.7 (автором реалізовано приклад застосування нейронних мереж в задачах управління ГТД вертольотів)

57. Vladov S., Kotliarov K., Hrybanova S., Husarova O., Derevyanko I., Gvozdik S. Neuromechanical methods of control and diagnostics of the technical state of aircraft engine TV3-117 in film regions. *Visnyk of Kherson National Technical University*. 2020. No. 1 (72). Part 1. P. 141– 154. doi: 10.35546/kntu2078-4481.2020.1.1.17 (автором отримано розподіл метрики Чебишева та Евклідової метрики для визначення технічного стану ГТД вертольотів)

58. Владов С. І., Шмельов Ю. М., Грибанова С. А., Гусарова О. В., Подгорних Н. В. Метод підвищення робасності нейромережевої моделі контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 в польотних режимах. Вісник Кременчуцького національного університету імені Михайла Остроградського. 2020. Вип. 1/2020 (120). С. 113–119. doi: 10.30929/1995-0519.2020.1.113-119 (автором обґрунтовано застосування алгоритму покрокового багатокритеріального навчання нейронної мережі задля оінювання робаст-ності моделі)

59. Владов С. І., Назаренко Н. П., Тутова Н. В., Москалик В. М., Пономаренко А. В. Багатовимірна система автоматичного управління авіаційним двигуном ТВЗ-117 на базі нейромережевого регулятора. Вісник Кременчуцького національного університету імені Михайла Остроградського. 2020. Вип. 2/2020 (121). С. 79–84. doi: 10.30929/1995-

0519.2020.2.79-84 (автором отримано результати перехідних процесів параметрів ГТД вертольотів за допомогою еталонної і досліджуваної моделі)

60. Владов С. І., Шмельов Ю. М., Сіора А. С., Яніцький А. А., Пономаренко А. В. Підвищення надійності системи автоматичного управління авіаційного двигуна ТВЗ-117 з використанням його бортової нейромережевої моделі. Вісник Кременчуцького національного університету імені Михайла Остроградського. 2020. Вип. 2/2020 (121). С. 91–96. doi: 10.30929/1995-0519.2020.2.91-96 (автором отримано результати фільтрації сигналів в контурі дозувальної голки ГТД вертольотів багатовимірним фільтром Калмана)

61. Владов С. І., Сіора А. С., Яніцький А. А., Дятловська В. Л. Шмельова Т. Ф. Нейромережевий аналіз прийняття рішень екіпажом повітряного судна щодо можливості здійснення польоту за результатами контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. Вісник Кременчуцького національного університету імені Михайла Остроградського. 2020. Вип. 3/2020 (122). С. 84–90. doi: 10.30929/1995-0519.2020.3.84-90 (автором визначено чинники оцінювання можливості здійснення польоту вертольоту)

62. **Vladov S.** Algorithms for diagnostic and parameter of failures of channels of measurement of TV3-117 aircraft engine automatic control system in flight modes Based of neural network technologies. *Proceedings of the National Aviation University*. 2020. No. 3 (84). P. 27–37. doi: 10.18372/2306-1472.84.14950

63. Владов С. І., Долударєва Я. С., Сіора А. С., Пономаренко А. В., Яніцький А. А. Нейромережевий обчислювач задля відновлення втраченої інформації зі штатних датчиків бортової системи контролю і діагностики авіаційного двигуна ТВЗ-117. Сучасний стан наукових досліджень та технологій в промисловості. 2020. № 4 (14). С. 147–154. doi: 10.30837/ITSSI.2020.14.147 (автором здійснено відновлення втраченої інформації автоасоціативною нейронною мережею за різних типах відмов датчиків ГТД вертольотів)

64. Владов С. І., Ковальський В. С., Дятловська В. Л., Яніцький А. А., Вакуленко Р. А. Відмовостійкий алгоритм ідентифікації бортової математичної моделі авіаційного двигуна ТВЗ-117 в складі його системи автоматичного управління. Вісник Херсонського національного технічного університету. 2020. № 4 (75). С. 11–19. doi: 10.35546/kntu2078-4481.2020.4.1 (автором проведено моделювання вимірювальних канали двоканального датчика ГТД вертольотів за його справності та несправності)

65. Владов С. І., Москалик В. М., Сіора А. С., Дєрябіна І. О., Гвоздік С. Д. Аналіз динаміки авіаційного двигуна ТВЗ-117 із використанням нейронної мережі Елмана. Вісник Херсонського національного технічного університету. 2020. № 4 (75). С. 42–52. doi: 10.35546/kntu2078-4481.2020.4.5 (автором здійснено навчання нейронної мережі Елмана)

66. Vladov S., Shmelov Yu., Samoilenko M., Podhornykh N., Shmelova T. Development

17

of a complex of functional models for the process of control and diagnostics of the TV3-117 aircraft engine technical state at flight modes. *Proceedings of the National Aviation University*. 2019. No. 4 (81). P. 19–28. doi: 10.18372/2306-1472.81.14597 (автором удосконалено функціональну модель IDEF0 моніторингу технічного стану і управління експлуатацією ГТД верто-

67. Shmelov Yu., **Vladov S.**, Derevyanko I., Dieriabina I., Chyzhova L. The problem of identification of TV3-117 aircraft engine dynamic multi-model in flight envelope. *Transactions of Kremenchuk Mykhailo Ostrohradskyi National University*. 2019. Issue 1/2019 (114). P. 27–32. doi: 10.30929/1995-0519.2019.1.27-32 (автором досліджено нейромережеві і класичні методи ідентифікації зворотної багаторежимної моделі авіаційного двигуна TB3-117)

льотів у режимі льотної експлуатації)

68. Shmelov Yu., **Vladov S.**, Derevyanko I., Dieriabina I., Chyzhova L. Identification of rear model of TV3-117 aircraft engine based on the basis of neuro-multi-functional technologies. *Innovative technologies and scientific solutions for industries*. 2019. No. 1 (7). P. 43–49. doi: 10.30837/2522-9818.2019.7.043 (автором створено нейромережеву зворотну модель для ідентифікації параметрів ГТД вертольотів)

69. Vladov S., Shmelov Yu., Kotliarov K., Hrybanova S., Husarova O., Derevyanko I., Chyzhova L. Onboard parameter identification method of the TV3-117 aircraft engine of the neural network technologies. *Transactions of Kremenchuk Mykhailo Ostrohradskyi National University*. 2019. Issue 5/2019 (118). P. 90–96. doi: 10.30929/1995-0519.2019.5.90-96 (автором здійснено порівняльний аналіз похибок нейромережевих і класичного методів ідентифікації параметрів авіаційного двигуна TB3-117 на тестовій вибірці)

70. Vladov S., Kotliarov K., Hrybanova S., Husarova O., Chyzhova L. On-board information restoring method in case of failure of one of the sensors of the aircraft engine TV3-117 based on neural network technologies. *Transactions of Kremenchuk Mykhailo Ostrohradskyi National University*. 2019. Issue 6/2019 (119). P. 91–98. doi: 10.30929/1995-0519.2019.6.91-98 (*aвтором обтрунтовано застосування автоасоціативних нейронних мереж для відновлення втраченої інформації при відмові датчиків ГТД вертольотів*)

71. Шмельов Ю. М., **Владов С. І.**, Клімова Я. Р. Застосування нейронних мереж у задачі прогнозування технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах. *Авіаційно-космічна техніка і технологія* : науково-технічний журнал. 2018. № 3 (147). С. 30–38. doi: 10.32620/aktt.2018.3.04 (автором отримано результати прогнозу температури газу за турбіною компресора ГТД вертольотів)

Монографії:

72. Vladov S. Vysotska V. Neural network methods for monitoring dynamic objects (Neural network methods for monitoring helicopter turboshaft engines at flight operation mode :

monograph). London : Lambert Academic Publishing, 2024. 210 р. (автором створено нейромережеві моделі ідентифікації параметрів ГТД вертольотів)

73. Інтелектуальні системи автоматизації : монографія / Аврунін О. Г., **Владов С. І.**, Петченко М. В., Семенець В. В., Татарінов В. В., Тельнова Г. В., Філатов В. О., Шмельов Ю. М., Шушляпіна Н. О. Кременчук : ПП Щербатих О. В., 2021. 322 с. doi: 10.30837/978-617-639-347-4 (автором розроблено нейромережеві системи автоматизації моніторингу технічного стану бортових систем ГТД вертольотів)

74. Владов С. І., Шмельова Т. Ф., Шмельов Ю. М. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах за допомогою нейромережевих технологій : Монографія. Кременчук : ПП Щербатих А. В., 2020. 200 с. *(автором створено нейромережеві моделі контролю і діагностики ГТД вертольотів)*

Статті у матеріалах конференцій, індексованих у наукометричній базі Scopus:

75. Vladov S., Sokurenko V., Muzychuk O., Sachenko A., Sachenko S., Kopamia L., Vysotska V. The Fuzzy Logic Application in Helicopter Turboshaft Engines Automatic Control Systems. 2024 IEEE 17th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET), Lviv, Ukraine, October 08–12, 2024. P. 253–256 doi: 10.1109/TCSET64720.2024.10755839 (автором створено структурну схему нечіткої АПУ витратою палива ГТД вертольотів)

76. **Vladov S.**, Yakovliev R., Hubachov O., Mykolenko K., Drodova S., Stushchanskyi Y. Neural Network Method for Helicopters Turboshaft Engines Dynamic Efficiency Monitoring. 2023 IEEE 4 th KhPI Week on Advanced Technology, Kharkiv, Ukraine, October 02–06, 2023. pp. 160–165. doi: 10.1109/KhPIWeek61412.2023.10312883 (автором створено нейро-нечіткий класифікатор значень ККД компресора ГТД вертольотів)

77. Vladov S., Yakovliev R., Hubachov O., Mykolenko K., Drodova S., Rud J. Modified Neuro-Fuzzy Failure Classifier of Helicopters Turboshaft Engines. 2023 IEEE 18th International Conference on Computer Science and Information Technologies (CSIT), Lviv, Ukraine, October 19–23, 2023. 4 p. doi: 10.1109/CSIT61576.2023.10324287 (автором створено нейромережеву модель класифікації відмов датчиків ГТД вертольотів)

78. **Vladov S.**, Yakovliev R., Hubachov O., Rud J., Drodova S., Perekrest A. On-Board Method for Helicopters Turboshaft Engines Neuro-Fuzzy Fuel Consumption Control. *2023 IEEE 5th International Conference on Modern Electrical and Energy System (MEES)*, Kremenchuk, Ukraine, September 27–30, 2023. P. 495–500. doi: 10.1109/MEES61502.2023.10402511 (*автором розроблено нейро-нечітку модель моніторингу витрати палива ГТД вертольотів*)

79. **Vladov S.**, Yakovliev R., Hubachov O., Rud J., Drodova S., Perekrest A. Modified Discrete Neural Network PID Controller for Controlling the Helicopters Turboshaft Engines Free

Turbine Speed. 2023 IEEE 5th International Conference on Modern Electrical and Energy System (MEES), Kremenchuk, Ukraine, September 27–30, 2023. P. 797–802. doi: 10.1109/MEES61502.2023.10402433 (автором удосконалено нейронну мережу з лінійними та нелінійними нейронами для управління частотою обертів ротора вільної турбіни ГТД вертольотів)

80. **Vladov S.**, Shmelov Y., Yakovliev R. Modified Searchless Method for Identification of Helicopters Turboshaft Engines at Flight Modes Using Neural Networks. 2022 IEEE 3rd KhPI Week on Advanced Technology, Kharkiv, Ukraine, October 03–07, 2022. P. 257– 262. doi: 10.1109/KhPIWeek57572.2022.9916422 (автором отримано динаміку перехідних процесів частоти обертів ротора вільної турбіни ГТД вертольотів при сигнальній адаптації АПУ з налаштовувальною моделлю)

81. Vladov S., Shmelov Y., Yakovliev R. Modified Neural Network Method for Diagnostics the Helicopters Turboshaft Engines Operational Status at Flight Modes. *IEEE International Conference on System Analysis & Intelligent Computing (SAIC)*, Kyiv, Ukraine, October 04–07, 2022. P. 224–229. doi: 10.1109/SAIC57818.2022.9923025 (автором обтрунтовано ансамбль нейронних мереж в класифікаторі дефектів вузлів ГТД вертольотів)

82. Vladov S., Shmelov Y., Yakovliev R. Modified Neural Network Method for Classifying the Helicopters Turboshaft Engines Ratings at Flight Modes. 2022 IEEE 41st International Conference on Electronics and Nanotechnology (ELNANO), Kyiv, Ukraine, October 10–14, 2022. P. 535–540. doi: 10.1109/ELNANO54667.2022.9927108 (автором здійснено моделювання класифікації режимів роботи ГТД вертольотів)

83. Vladov S., Shmelov Y., Yakovliev R. Modified Method of Identification Potential Defects in Helicopters Turboshaft Engines Units Based on Prediction its Operational Status. 2022 IEEE 4th International Conference on Modern Electrical and Energy System (MEES), Kremenchuk, Ukraine, October 20–22, 2022. P. 556–561. doi: 10.1109/MEES58014.2022.10005605 (автором розроблено метод ідентифікації потенційних дефектів у вузлах ГТД вертольотів)

84. **Vladov S.**, Shmelov Y., Yakovliev R., Petchenko M., Drozdova S. Neural Network Method for Helicopters Turboshaft Engines Working Process Parameters Identification at Flight Modes. 2022 IEEE 4th International Conference on Modern Electrical and Energy System (MEES), Kremenchuk, Ukraine, October 20–22, 2022. P. 604–609. doi: 10.1109/MEES58014.2022.10005670 (автором експериментально обтрунтовано алгоритм навчання нейронної мережі)

85. Vladov S., Shmelov Y., Yakovliev R., Petchenko M., Drozdova S. Helicopters Turboshaft Engines Parameters Identification at Flight Modes Using Neural Networks. *IEEE 17th International Conference on Computer Science and Information Technologies (CSIT)*, Lviv, Ukraine, November 10–12, 2022. Р. 5–8. doi: 10.1109/CSIT56902.2022.10000444 (автором здійснено моделювання контрольованих параметрів ГТД вертольотів)

86. Shmelova T., Shmelov Yu., **Vladov S**. Concept of building intelligent control systems for aircraft, unmanned aerial vehicles and aircraft engines. 2020 IEEE 6th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC), Kyiv, Ukraine, October 2020. P. 14–19. doi: 10.1109/MSNMC50359.2020.9255509 (автором адаптовано загальні вимоги до розробки АПУ для класу ГТД вертольотів)

87. Shmelov Y., **Vladov S.**, Klimova Y., Kirukhina M. Expert system for identification of the technical state of the aircraft engine TV3-117 in flight modes. *System Analysis & Intelligent Computing : IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)*, 08–12 October 2018. P. 77–82. doi: 10.1109/SAIC.2018.8516864 (автором розроблено архітектуру експертної системи моніторингу ГТД вертольотів)

Додаткові праці:

88. Музичук О. М., Владов С. І., Яковлєв Р. П., Губачов О. І., Козловська Т. Ф., Онищенко Ю. М., Воронін А. В. Спосіб діагностики дефектів основних вузлів проточної частини газотурбінних двигунів вертольотів : пат. 157813 Україна : B64C 27/04, B64D 27/00, G01M 15/14. № u 2024 01481 ; заявл. 20.03.2024 ; опубл. 28.11.2024, Бюл. № 48. 9 с. (автором створено метод бінарної класифікації дефектів вузлів ГТД вертольотів)

89. Владов С. І., Шмельова Т. Ф., Шмельов Ю. М. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 в польотних режимах за допомогою нейромережевих технологій : свідоцтво про реєстрацію авторського права на твір № 103633 від 31 березня 2021 року.

90. Аврунін О. Г., **Владов С. І.**, Петченко М. В., Семенець В. В., Татарінов В. В., Тельнова Г. В., Філатов В. О., Шмельов Ю. М., Шушляпіна Н. О. Інтелектуальні системи автоматизації : свідоцтво про реєстрацію авторського права на твір № 119010 від 11 травня 2023 року.

3MICT

BC	ТУП	26
PO	ЗДІЛ 1. АНАЛІЗ СУЧАСНОГО СТАНУ ПРОБЛЕМИ СТВОРЕННЯ МА-	
TE	МАТИЧНОГО ТА ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ МОНІТОРИНГУ	
ТЕ	ХНІЧНОГО СТАНУ ГАЗОТУРБІННИХ ДВИГУНІВ	34
	1.1. Загальна характеристика проблеми моніторингу технічного стану газоту-	
	рбінних двигунів	34
	1.2. Основні передумови розроблення математичного і програмного забезпе-	
	чення газотурбінного двигуна вертольоту як складного технічного об'єкт мо-	
	ніторингу	38
	1.3. Аналіз сучасного математичного і програмного забезпечення моніторингу	
	технічного стану газотурбінних двигунів	42
	1.4. Створення методу побудови системи моніторингу і управління експлуата-	
	цією газотурбінних двигунів вертольотів	50
	1.5. Аналіз передумов застосування нейромережевих технологій у системі мо-	
	ніторингу і управління експлуатацією газотурбінних двигунів вертольотів	56
Вис	сновки до першого розділу	61
PO	ЗДІЛ 2. ПЕРЕДУМОВИ ВИКОРИСТАННЯ НЕЙРОМЕРЕЖЕВИХ ТЕХ-	
но	ЛОГІЙ ДЛЯ МОНІТОРИНГУ ТЕХНІЧНОГО СТАНУ ГАЗОТУРБІН-	
HИ	IX ДВИГУНІВ ВЕРТОЛЬОТІВ	62
	2.1. Створення методу побудови нейромережевої моделі для розв'язання при-	
	кладних задач моніторингу газотурбінних двигунів вертольотів	62
	2.2. Розробка методу формування навчальної і тестової вибірок у задачах мо-	
	ніторингу технічного стану газотурбінних двигунів вертольотів	65
	2.3. Розробка нейромережевого методу оптимізації параметрів робочого про-	
	цесу газотурбінних двигунів вертольотів	72
	2.4. Розробка нейромережевих методів ідентифікації параметрів газотурбін-	
	них двигунів вертольотів	87
	2.4.1. Розробка нейромережевого методу ідентифікації багаторежимної	

моделі газотурбінних вертольотів за параметрами, що реєструються на							
борту вертольоту							
2.4.2. Розробка нейромережевого методу ідентифікації багаторежимної							
моделі газотурбінних вертольотів за параметрами, що обчислюються за							
математичною моделлю	100						
2.4.3. Розробка нейромережевого методу ідентифікації зворотної багато-							
режимної моделі газотурбінних вертольотів за параметрами, що обчис-							
люються за математичною моделлю	103						
2.5. Розробка нейромережевого методу класифікації режимів роботи газотур-							
бінних двигунів вертольотів	106						
Висновки до другого розділу	114						
РОЗДІЛ З. НЕЙРОМЕРЕЖЕВІ МЕТОДИ РОЗВ'ЯЗАННЯ ПРИКЛАДНИХ							
ЗАДАЧ МОНІТОРИНГУ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕРТОЛЬОТІВ	117						
3.1. Розробка методу ідентифікації динамічної багаторежимної моделі газоту-							
рбінного двигуна вертольоту	117						
3.2. Розробка методу контролю технічного стану газотурбінного двигуна вер-							
тольоту	124						
3.3. Розробка методу діагностики дефектів в основних вузлах проточної час-							
тини газотурбінного двигуна вертольоту	131						
3.4. Розробка методу прогнозування динаміки зміни термогазодинамічних па-							
раметрів газотурбінних двигунів вертольотів	142						
3.5. Розробка методу налагодження дозатора палива газотурбінного двигуна							
вертольоту	164						
3.6. Розробка методу тренд-аналізу параметрів газотурбінного двигуна верто-							
льоту	173						
Висновки до третього розділу	182						
РОЗДІЛ 4. МОДИФІКОВАНА БОРТОВА ЗАКРИТА НЕЙРОМЕРЕЖЕВА							
АВТОМАТИЗОВАНА ПІДСИСТЕМА УПРАВЛІННЯ ГАЗОТУРБІННИХ							
ДВИГУНІВ ВЕРТОЛЬОТІВ	184						
11 Перецилови розроби бортової автоматизораної ніланатоли удровніция							

4.1. Передумови розроби бортової автоматизованої підсистеми управління

газотурбінних двигунів вертольотів	184
4.2. Базова модифікація бортової автоматизованої підсистеми управління га-	
зотурбінних двигунів вертольотів	187
4.3. Нейромережева реалізація базової бортової автоматизованої підсистеми	
управління газотурбінних двигунів вертольотів	195
4.4. Забезпечення відмовостійкості бортової автоматизованої підсистеми уп-	
равління газотурбінних двигунів вертольотів з нейромережевим контролером.	203
4.5. Модифікація бортової автоматизованої підсистеми управління газотур-	
бінних двигунів вертольотів шляхом введення каналу управління частотою	
обертів ротора вільної турбіни	211
4.6. Синтез модифікованої закритої бортової автоматизованої підсистеми уп-	
равління газотурбінних двигунів вертольотів	223
Висновки до четвертого розділу	225
РОЗДІЛ 5. АЛЬТЕРНАТИВНІ ПІДХОДИ ДО МОНІТОРИНГУ І УПРАВ-	
ЛІННЯ ЕКСПЛУАТАЦІЄЮ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕРТОЛЬО-	
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ-	
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ	227
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ . 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких ме-	227
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж.	227 227
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких ме- реж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних	227 227
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів.	227227230
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких ме- реж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів вертольотів.	227227230
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких ме- реж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів ве- ртольотів з урахуванням забезпечення необхідної якості.	227227230241
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких ме- реж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів ве- ртольотів з урахуванням забезпечення необхідної якості. 5.4. Розробка методу нейро-нечіткого моніторингу витрати палива газотурбінних	227227230241
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів вертольотів з урахуванням забезпечення необхідної якості. 5.4. Розробка методу нейро-нечіткого моніторингу витрати палива газотурбінних двигунів вертольотів.	 227 227 230 241 252
 ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ	 227 227 230 241 252
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів вертольотів з урахуванням забезпечення необхідної якості. 5.4. Розробка методу нейро-нечіткого моніторингу витрати палива газотурбінних двигунів вертольотів. 5.5. Розробка методу нейро-нечіткого моделювання динамічного коефіцієнта корисної дії газотурбінних двигунів вертольотів.	 227 227 230 241 252 257
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів вертольотів з урахуванням забезпечення необхідної якості. 5.4. Розробка методу нейро-нечіткого моніторингу витрати палива газотурбінних двигунів вертольотів. 5.5. Розробка методу нейро-нечіткого моделювання динамічного коефіцієнта корисної дії газотурбінних двигунів вертольотів. 5.6. Розробка нейро-нечіткого регулятора частоти обертів несучого гвинта ве-	 227 227 230 241 252 257
ТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕ- ЧІТКИХ МЕРЕЖ. 5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж. 5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів. 5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів вертольотів з урахуванням забезпечення необхідної якості. 5.4. Розробка методу нейро-нечіткого моніторингу витрати палива газотурбінних двигунів вертольотів. 5.5. Розробка методу нейро-нечіткого моделювання динамічного коефіцієнта корисної дії газотурбінних двигунів вертольотів. 5.6. Розробка нейро-нечіткого регулятора частоти обертів несучого гвинта вертольотів.	 227 227 230 241 252 257 263

24

РОЗДІЛ 6. МЕТОДИ ВІДНОВЛЕННЯ ВТРАЧЕНОЇ ІНФОРМАЦІЇ ПРИ ВІД-	
МОВІ ДАТЧИКІВ ТА ЕКСПЕРТНА СИСТЕМА МОНІТОРИНГУ ГАЗОТУ-	
РБІННИХ ДВИГУНІВ ВЕРТОЛЬОТІВ	290
6.1. Розробка нейромережевого методу відновлення інформації при парамет-	
ричній відмові одного з датчиків	290
6.2. Розробка методу відновлення інформації при відмовах датчиків з викори-	
станням автоасоціативної нейронної мережі	300
6.3. Розробка методу парирування відмов в каналах вимірювань системи авто-	
матичного управління газотурбінних двигунів вертольотів за допомогою фі-	
льтрації Калмана	313
6.4. Формування і доведення теореми про структурну реконфігурацію автома-	
тизованої підсистеми управління газотурбінних двигунів вертольотів	334
6.5. Розробка бортової нейромережевої експертної системи моніторингу газо-	
турбінних двигунів вертольотів	342
6.6. Розробка програмного забезпечення моніторингу газотурбінних двигунів	
вертольотів «MONITOR»	350
Висновки до шостого розділу	359
ВИСНОВКИ	361
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	361
ДОДАТОК А. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 1	421
ДОДАТОК Б. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 2	424
ДОДАТОК В. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ З	444
ДОДАТОК Г. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 4	458
ДОДАТОК Д. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 5	469
ДОДАТОК Ж. ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 6	485
ДОДАТОК К. АКТИ, ДОВІДКИ ЩОДО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ	
ДИСЕРТАЦІЇ	504

ВСТУП

Актуальність теми. Безпека польотів вертольотів в реальному часі є важливою складовою загальної авіаційної безпеки, що полягає у необхідності забезпечення оперативного моніторингу, аналізу та реагування на різноманітні чинники. Одним із них, що впливають на безпеку, є газотурбінний двигун (ГТД), який вимагає постійного моніторингу його технічного стану, оскільки це пов'язано з багатопараметричністю, багатопов'язаністю, нелінійністю процесів, багаторежимністю застосування, а більшість відмов формується і проявляється в процесі експлуатації ГТД вертольоту як відновлювального об'єкту. Трудомісткість моніторингу технічного стану ГТД вертольотів залежить від рівня автоматизації та інформатизації процесів отримання, обробки, зберігання, документування інформації про поточний його технічний стан та інших задач, послідовність і методи виконання яких визначають інтелектуальну прикладну програмну систему моніторингу. Засобом його реалізації є математичне і програмне забезпечення, на які покладається задача визначення ступеня відповідності об'єкта пропонованим вимогам – моніторингу його технічного стану.

Зазвичай інтелектуальні прикладні програмні системи моніторингу технічного стану ГТД вертольотів призначені під конкретну задачу є закритим (наприклад, Turbine Watch, Heli Turbine Monitor, Rotor Turbine Track, Turbine Care, Heli Turbine Insight, Aero Turbine Monitor, Rotor Engine Watch, Turbo Flight Monitor, Flight Turbine Guard тощо), що унеможливлює доступ IT-фахівців до їх математичного та програмного забезпечення для подальшого аналізу, вдосконалення чи інтеграції в інші системи. Це обмежує їх можливість інтеграції, налаштування, адаптації під специфічні потреби користувачів та їх застосування в інших умовах або на інших типах вертольотів. За відсутності відкритості та адаптивності витрати на підтримку, налаштування або оновлення таких систем можуть бути значними. Оскільки системи часто створюються для специфічних задач, їх функціональність не повністю відповідає вимогам операторів, що призводить до необхідності постійної адаптації і модифікації математичного і програмного забезпечення.

Проблемам створення математичного і програмного забезпечення моніторингу технічного стану, а також управління експлуатацією складних об'єктів, у тому числі, ГТД, присвячені роботи А. А. Ardebili, F. Bazmi, L. Jaw, A. de Voogt, S. Sina Tayarani-Bathaie, K. Khorasani, S. Szrama, X. Zhang, Z. Cui, Z. Yan, Z. Chen, G. Zhou, Л. Г. Бойко, В. I. Васильєва, П. Вербоса, А. В. Внукова, А. В. Гончаренка, С. О. Дмитрієва, О. М. Дмітрієва, В. І. Дубровіна, Н. Г. Дубравского, І. В. Єгорова, С. В. Єпіфанова, С. В. Жернакова, I. I. Ідрісова, Б. Г. Ільясова, М. П. Кравчука, О. Ф. Машошина, І. І. Муслухова, О. В. Попова, В. І. Петуніна, С. О. Субботіна тощо. Теоретичні основи створення математичного і програмного забезпечення, а також фундаментальні наукові дослідження щодо створення автоматичних систем управління (АСУ), у тому числі, ГТД вертольотів і їх вузлів, розглядаються в роботах J. Saridis, Z. Wei, Y. Chen, Н. П. Бурау, С. В. Єнчева, А. С. Куліка, Є. П. Нечипорука, Ю. М. Терещенка, Ю. В. Черкасова, О. С. Якушенка тощо. Разом з тим, існуючі методи мають недоліки, оскільки створення математичного і програмного забезпечення моніторингу і управління експлуатацією ГТД вертольотів передбачає застосування різноманітних методів розв'язання задач обробки та аналізу інформації про технічний стан двигуна, прийняття рішень для досягнення цілей моніторингу та управління його експлуатацією. Не повністю розкрито значення інформаційного потенціалу контрольованих параметрів, які дозволяють швидше визначати несправності або відмови. Однак підходи до ефективних обчислень прикладних задач моніторингу технічного стану ГТД вертольотів, а також відповідні інтелектуальні прикладні програмні системи є мало дослідженими і недосконалими внаслідок роз'єднаності баз даних випробувань, моніторингу, контроля і діагностики, обмеженості інтелектуальних компонент, що дозволяють якісно і ефективно здійснювати підтримку прийняття відповідальних рішень і, як наслідок, зменшувати загальний час, що витрачається на моніторинг двигуна.

Наведене свідчить про актуальність досліджень під час вирішення важливої *науково-прикладної проблеми* розроблення математичного і програмного забезпечення моніторингу і управління експлуатацією ГТД вертольотів в умовах льотної експлуатації задля підтримки безпеки польотів вертольотів в реальному часі.

Зв'язок роботи з науковими програмами, планами, темами, грантами. Робота виконана у рамках Угоди між Урядом України та Урядом Французької Республіки щодо офіційної підтримки зі створення єдиної системи авіаційної безпеки та цивільного захисту в Україні з метою підвищення безпеки польотів вертольотів, що використовуються в державній авіації України. Робота ґрунтується відповідно до основних положень Національної транспортної стратегії України на період до 2030 року (затверджена розпорядженням Кабінету Міністрів України від 30 травня 2018 року № 430-р). Робота виконана в межах науково-дослідної роботи Харківського національного університету внутрішніх справ з державною реєстрацією «Теоретичні та прикладні аспекти розвитку авіаційної сфери» (номер 0123U104884, терміни: 02.2024–12.2025).

Мета і завдання дослідження. Метою дослідження є розроблення математичного і програмного забезпечення моніторингу технічного стану і управління експлуатацією ГТД вертольотів в умовах льотної експлуатації задля підтримки безпеки польотів вертольотів в реальному часі за невизначеності впливаючих чинників для запобігання їх виходу на критичний режим. Метою дисертаційної роботи визначено необхідність виконання таких основних задач досліджень.

1. Провести аналіз специфіки побудови математичного і програмного забезпечення, що дасть змогу розробити архітектуру експертної системи моніторингу ГТД вертольотів у режимі льотної експлуатації.

2. Розробити метод побудови нейромережевої моделі процесів класифікації, контролю, діагностики, прогнозування, налагодження тренд-аналізу параметрів двигуна, що дасть змогу удосконалити методи розв'язання прикладних задач моніторингу.

3. Створити математичне та програмне забезпечення нейромережевої бортової ПАУ задля оптимізації й підвищення ефективності управління та регулювання з метою забезпечення їх оптимального функціонування.

4. Удосконалити нейро-нечіткі методи моніторингу з використанням гібридних нейро-нечітких класифікаторів задля адаптації до змінних умов експлуатації при неод-нозначності даних.

5. Удосконалити нейромережеві методи відновлення даних за відмови штатних сенсорів, що базуються на використанні як лінійних, так і автоасоціативних нейронних мереж, а також фільтра Калмана з поліномом Чебишева, застосування яких дозволить зменшити похибку реконструкції значень параметрів двигуна.

6. Розробити прототип бортової експертної системи моніторингу з наступною оцінкою ефективності розробленого математичного і програмного забезпечення і отримати рекомендації щодо прийняття рішень в умовах неповноти і невизначеності інформації для запобігання виходу експлуатованого двигуна на критичний режим з урахуванням можливих відмов апаратурного та програмного забезпечення.

7. Провести апробацію отриманих результатів шляхом застосування розробленого математичного і програмного забезпечення моніторингу і управління експлуатацією двигуна у режимі льотної експлуатації.

Об'єкт дослідження – процеси інтелектуального моніторингу технічного стану і управління експлуатацією ГТД вертольотів у режимі льотної експлуатації.

Предмет дослідження – нейромережеві методи і моделі моніторингу технічного стану і управління ГТД вертольотів в умовах льотної експлуатації.

Методи дослідження. Для досягнення поставленої мети використано: системний підхід, що включає аналіз існуючих рішень, методів обробки даних і визначення вимог до моніторингу ГТД вертольотів для аналізу специфіки побудови математичного і програмного забезпечення; нейромережеві методи для створення моделей моніторингу, що дозволяють удосконалити обчислювальні методи для класифікації, контролю, діагностики, прогнозування та аналізу трендів; методи нечіткої логіки, нечітких правил та нейро-нечітких мереж для обробки даних в умовах неопределеності та нечіткості вхідних даних, що дозволяє забезпечити адаптивність і стабільність підсистеми управоіння ГТД вертольотів в умовах змінних експлуатаційних параметрів; методи об'єктно-орієнтованого та системного аналізу і проектування для проектування та розроблення бортової нейромережевої експертної системи моніторингу ГТД вертольотів; методи штучного інтелекту, об'єктно-орієнтоване програмування для програмної реалізації розроблених методів і моделей для розв'язання прикладних задач моніторингу ГТД вертольотів.

Наукова новизна полягає у вирішенні важливої науково-прикладної проблеми розроблення нових та удосконалення відомих методів, математичного та програмного забезпечення моніторингу і управління експлуатацією ГТД вертольотів задля підтримки безпеки польотів в реальному часі. Отримано такі нові наукові результати:

ynepue:

– створено архітектуру експертної системи моніторингу і управління експлуатацією ГТД вертольотів, яка за рахунок комбінування нейромережевої підсистеми моніторингу та автоматизованої підсистеми управління (АПУ), дозволяє підвищити рівень автоматизації, оперативності та достовірності моніторингу і управління їх технічним станом у режимі льотної експлуатації вертольоту;

– розроблено метод побудови нейромережевої моделі моніторингу, який за рахунок алгоритму формування однорідної і репрезентативної навчальної і тестової вибірок, дозволяє збільшити достовірність визначення технічного стану ГТД вертольотів;

удосконалено:

– методи класифікації, контролю, діагностики, прогнозування, налагодження, тренд-аналізу технічного стану ГТД вертольотів на основі модифікованих алгоритмів навчання і архітектур нейронних мереж, в яких, на відміну від існуючих, застосовано гібридні комбінації адаптивних елементів, що дозволили підвищити точність розв'язку прикладних задач моніторингу;

– модель триканальної АПУ для побудови архітектури експертної системи, в яку, на відміну від існуючих, введено канал управління частотою обертів ротора вільної турбіни та програмні модулі адаптивного управління шляхом відокремлення параметрів двигуна та агрегату дозування палива, що дозволило покращити показники якості каналів управління;

 – нейромережеві моделі програмних модулів експертної системи, в яких, на відміну від існуючих, застосовано розроблені методи організації ефективних обчислень прикладних задач моніторингу, що дозволяє підвищити ефективність моніторингу їх основних вузлів двигуна в режимі експлуатації;

набули подальшого розвитку:

– нейро-нечіткі методи моніторингу, в яких, на відміну від існуючих, застосовано гібридні нейро-нечіткі класифікатори з еволюційною діагностичною матрицею з модернізованими нечіткими правилами, що дало змогу підвищити впевненість прийняття рішень щодо наявності дефектів й підвищити точність отримання основних параметрів робочого процесу двигуна в умовах неоднозначності;

– методи відновлення інформації за відмови штатних сенсорів, які, відрізняються від існуючих тим, що за рахунок байєсової нейронної мережі, навчання автоасоціативної нейронної мережі на площині помилок та рекурентної нейронної мережі алгоритмом багатовимірного фільтра Калмана з поліномом Чебишева, дозволяє зменшити похибку реконструкції значень параметрів двигуна.

Практичне значення отриманих результатів полягає у тому, що їх можна

використати для побудови бортової експертної системи моніторингу ГТД вертольотів. Зокрема, практично цінними є такі результати:

– розроблено для впровадження в авіаційну галузь архітектуру експертної системи моніторингу і управління експлуатацією ГТД вертольотів за рахунок інтелектуалізації основних процесів класифікації, контролю, діагностики, прогнозування, налагодження, тренд-аналізу з використанням кількісних і якісних моделей двигунів, включаючи розроблене математичне і програмне забезпечення;

– розроблено алгоритм формування однорідної і репрезентативної навчальної і тестової вибірок на основі масиву даних реєстрованих на борту термогазодинамічних параметрів двигуна, застосування якого в нейромережевій моделі дозволив збільшити достовірність визначення можливості здійснення польоту на рівні 99 %;

– удосконалено алгоритми навчання і архітектур нейронних мереж, що забезпечило середню точність розв'язання прикладних задач моніторингу на рівні 99,5 %;

– розроблено програмне забезпечення «MONITOR» v. 0.1, що здійснює обчислення параметрів, застосування якого надало можливості обчислювати та передбачати розвиток сценаріїв польотних ситуацій у випадку виникнення непередбачуваних обставин, зумовленими технічним станом двигуна;

– створено прототип бортової бортової експертної системи моніторингу, використання якої дозволяє збільшити якість прийняття рішення щодо можливості експлуатації двигуна до 99,2 %;

 – запропоновано практичні рекомендації для покращення кваліфікації командира екіпажу, другого пілота та бортового інженера, що включають використання розробленої експертної системи моніторингу, що дозволяє підвищити ефективність роботи екіпажу та безпеку експлуатації вертольоту;

– за результатами експериментального дослідження в умовах ТОВ «ЕЙР ТАУРУС» та військової частини 2269 Національної гвардії України Міністерства внутрішніх справ України установлено, що застосування розробленого математичного і програмного забезпечення у складі експертної системи дозволило збільшити на 20 % якість прийняття рішення щодо здійснення польоту порівняно із традиційними статистичними критеріями.

Результати роботи апробовані та впроваджені в ТОВ «ЕЙР ТАУРУС», у військову частину 2269 Національної гвардії України Міністерства внутрішніх справ України у

вигляді бортової системи моніторингу авіаційних двигунів, що застосовуються на вертольотах державної авіації України, а також в Департамент авіаційної безпеки Міністерства внутрішніх справ України у вигляді інтелектуальної системи моделювання системи підтримки прийняття рішень командиром екіпажу повітряного судна (вертольоту). Результати роботи впроваджено в освітній процес таких закладів вищої освіти: Національний аерокосмічний університет ім. М. Є. Жуковського «Харківський авіаційний інститут»; Харківський національний університет радіоелектроніки; Льотна академія Національного авіаційного університету; Національний університет «Львівська Політехніка»; Кременчуцький національний університет імені Михайла Остроградського; Кременчуцький льотний коледж Харківського національного університету внутрішніх справ; Ряшівська політехніка ім. Ігнатія Лукасевича, Польща (Rzeszów University of Technology (Politechnika Rzeszowska im. Ignacego Łukasiewicza)); Університет Економіки, Бидгощ, Польща (Wyższa Szkoła Gospodarki w Bydgoszczy). Результати дисертації також впроваджені в науково-дослідну діяльність Харківського національного університету внутрішніх справ й використовуються під час підготовки окремих розділів (глав) навчальних посібників, посібників, що стосуються питань системного аналізу, обробки великих масивів даних, а також використання засобів штучного інтелекту, зокрема, нейронних мереж – архітектур та алгоритмів навчання.

Досягнутим ефектом є скорочення часу на виявлення експлуатаційних дефектів ГТД двигунів вертольотів за рахунок машинного обчислення необхідних параметрів двигуна з наданням інформацію щодо вузла, в якому присутній дефект шляхом використання розробленої бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів. Кінцевим результатом попереднього моніторингу технічного стану ГТД вертольоту перед та/або після вильоту є відмова від візуального огляду усього двигуна та усунення несправностей, які були виявлені нейромережевою експертною мережею, а також скорочення витрат на моніторинг технічного стану ГТД вертольотів і утримання технічного персоналу обслуговування.

Особистий внесок здобувача. Усі положення дисертації, що виносяться на захист, основні результати аналітичних та експериментальних досліджень, отримані автором самостійно. В опублікованих у співавторстві роботах автором розроблено та удосконалено нейромережеві та нейро-нечіткі методи, моделі та системи для моніторингу, діагностики, прогнозування, відновлення втраченої інформації, класифікації відмов датчиків, оптимізації параметрів робочого процесу та керування ГТД вертольотів, зокрема шляхом модифікації нейронних мереж, удосконалення алгоритмів навчання та інтеграції сучасних підходів до автоматизованого управління. З наукових досліджень, оприлюднених у співавторстві, у дисертації використано лише ті методи, моделі та обчислення, які є результатом особистої праці здобувача і становлять його власний внесок.

Апробація матеріалів дисертації. Основні результати та положення роботи доповідалися та обговорювалися на 39 наукових семінарах і конференціях як загально-соціальної, так і технічної спрямованості протягом 2018–2024 років, зокрема: IEEE International Conference on System Analysis & Intelligent Computing (SAIC) (Київ, 2018 і 2022 роки); 2020 IEEE 6th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC) (Київ, 2020 рік); 2022 and 2023 IEEE 3rd and 4th KhPI Week on Advanced Technology (Харків, 2022 і 2023 роки); 2022 IEEE 41st International Conference on Electronics and Nanotechnology (ELNANO) (Київ, 2022 рік); 2022 and 2023 IEEE 4th and 5th International Conference on Modern Electrical and Energy System (MEES) (Кременчук, 2022 і 2023 роки); IEEE 17th–19th International Conference on Computer Science and Information Technologies (CSIT) (Львів, 2022–2024 роки), Telecommunications and Computer Engineering (TCSET) (Львів, 2024 рік).

Публікації. Основні положення та результати дисертації опубліковані у 100 наукових працях, з них: З монографії (1 – за кордоном), 50 наукових статей у зарубіжних виданнях, що мають індексацію у наукометричній базі Scopus, 20 наукових статей у наукових виданнях, включених до категорії «Б» Переліку фахових видань України та включених до міжнародних наукометричних баз даних (Google Scholar, «Index Copernicus», «Polish Scholarly Bibliography» тощо), 14 тезах доповідей на міжнародних науково-практичних конференціях, що мають індексацію у наукометричній базі Scopus, 2 свідоцтвах про реєстрацію авторського права на твір, 1 патенті України на корисну модель.

Структура та обсяг дисертації. Дисертація складається зі вступу, шести розділів, висновків, списку використаних джерел і семи додатків. Дисертація викладена на 515 сторінках друкованого тексту, із них 336 сторінок основного тексту, містить 183 рисунків, 13 таблиць, 548 найменувань у списку літературних джерел на 58 сторінках і сім додатків на 95 сторінках.

РОЗДІЛ 1

АНАЛІЗ СУЧАСНОГО СТАНУ ПРОБЛЕМИ СТВОРЕННЯ МАТЕМАТИЧ-НОГО ТА ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ МОНІТОРИНГУ ТЕХНІЧ-НОГО СТАНУ ГАЗОТУРБІННИХ ДВИГУНІВ

1.1 Загальна характеристика проблеми моніторингу технічного стану газотурбінних двигунів

На теперішній час під час льотної експлуатації повітряних суден технічний стан ГТД контролюється безперервно, завдяки використанню не тільки наземного обладнання, але і бортових систем контролю. У зв'язку з цим практично зникло поняття «час між перевірками» [1–3]. Існує два види контролю [4–6] (табл. 1.1), на яких базується система технічної експлуатації для підтримки справного стану ГТД вертольотів.

Таблиця 1.1 – Види контролю справності станів ГТД вертольотів [5]

Профілактичний контроль	Дефектація кожної деталі						
Складається з перевірок, що дозволяють виявити в	При візуальному огляді і інструментальному контролі						
будь-якому вузлу, агрегаті або системі відхилення	кожної деталі оцінюється її стан і можливість подаль-						
від встановлених норм і оцінити їх життєздатність.	шої експлуатації (а за необхідності намітити її моди-						
	фікацію).						
Висновок: підбір і аналіз даних для отримання	Висновок: можливий лише при повному розби-						
інформації, на підставі якої можна прийняти	ранні двигуна в умовах ремонтного підприємств						
про справність двигуна							

На теперішній час більш широке використання знаходить профілактичне техобслуговування як більш економічна форма експлуатації. Задля цієї мети удосконалюються методи визначення стану окремих деталей, агрегатів і робочих параметрів двигуна. До них відносять: метод ендоскопії, використання магнітних уловлювачів у паливній і масляній системах, радіоізотопний метод, методи вихрових струмів, ультразвукової і магнітної дефектоскопії, спектрометричний контроль масла тощо. Основним видом контролю роботи двигунів є інструментальний контроль за приладами, розташованими на панелях приладів кабіни (додаток А, табл. А.1).

За допомогою показника обертів оцінюють зміну потужності, нормальний тепловий процес у двигуні, справність підшипників і проточної частини двигуна [5, 7]. Для контролю частоти обертання турбокомпресорів використовуються двострілочні тахометри, які показують обертання роторів турбокомпресорів обох двигунів. На сталих режимах різниця обертів турбокомпресорів не повинна перевищувати 2 %. Під час польоту перевищення цього допуску вказує на перенавантаження одного двигуна, що негативно впливає на його роботу та вертолітний редуктор. Причинами такої ситуації можуть бути несправності системи синхронізації потужності, засмічення паливних фільтрів або часткова відмова двигуна.

Температура газів відображає процес згоряння палива і стан деталей газоповітряного тракту. Нормальна температура свідчить про відповідність теплового режиму розрахунковим значенням, а її підвищення може сигналізувати про обрив лопаток, помпаж компресора, руйнування підшипників чи обмерзання двигуна [8–10]. Зниження температури газів може бути ознакою несправності паливних форсунок або самовимкнення двигуна. Особливо небезпечне перевищення температури при запуску або максимальному режимі, що призводить до руйнування деталей камери згоряння і турбін. Підвищення температури масла свідчить про його нестачу або зношення деталей, а різке підвищення може вказувати на прорив газів у масляну систему. Падіння тиску масла може бути пов'язане з витоками, засміченням фільтрів або руйнуванням компонентів.

Контроль справності двигуна здійснюється за допомогою сигнальних ламп, звукових і вібраційних ознак. Наявність сторонніх звуків чи сильних вібрацій може вказувати на обрив лопаток або інші несправності, наприклад, руйнування підшипників чи потрапляння сторонніх предметів [10, 11]. Несправності також можна виявити за запахом гасу, масла або диму, що свідчить про витоки чи пожежу. Вибіг ротора турбокомпресора, який визначається під час вимкнення двигуна, дозволяє оцінити стан підшипників, лопаток і загальну роботу двигуна.

Отже, моніторинг сучасного ГТД вертольоту під час експлуатації додає збільшення числа контрольованих параметрів, аналіз яких пов'язаний з численними помилками контролю та прийняття рішень. У свою чергу, експлуатація ГТД вертольоту базується на трьох ключових підходах: використання до повного вичерпання ресурсу, до настання відмови або до досягнення передвідмовного стану. Кожен із цих підходів дозволяє обрати найбільш результативні методи обслуговування та відновлення, які характеризуються максимальною ефективністю. Вибір оптимальної стратегії технічного обслуговування та ремонту ГТД безпосередньо пов'язаний із підходами до його експлуатації. В багатьох ситуаціях найефективнішим рішенням є застосування стратегії, що орієнтується на поточний технічний стан двигуна.

Аналіз показує, що експлуатація газотурбінних двигунів (ГТД) за технічним станом

може зменшити оборотний фонд двигунів на 15-20 %, кількість капітальних ремонтів на 15-20 %, транспортні витрати - на 25-30 %, забезпечуючи загальний економічний ефект у 40-50 % від вартості парку двигунів, за винятком витрат на впровадження системи, які становлять до 5 % від економічного ефекту [12-20]. Така стратегія технічного обслуговування включає два етапи: експлуатацію в межах фіксованого ресурсу та після його вичерпання, де подальше напрацювання досягається завдяки контролю технічного стану і діагностиці. Цей підхід базується на регулярній оцінці параметрів вузлів і агрегатів двигуна, що дозволяє використовувати ГТД до появи ознак небезпечного зниження надійності [21-24]. Переваги полягають у ранньому виявленні несправностей, зменшенні витрат на обслуговування, збільшенні надійності і використанні потенційних можливостей кожного двигуна з урахуванням його індивідуальних особливостей [25, 26]. Необхідними умовами є контроль стану елементів ГТД, діагностика під час польотів і наземного обслуговування, а також облік основних показників, таких як тяга та витрата палива [27–30]. Експлуатація ГТД в рамках його життєвого циклу може бути наведена часовою віссю (рис. 1.1), на якій позначено: І – приймально-здавальні випробування; ІІ – льотні випробування; III – державні випробування; IV – експлуатація; V – ремонт (регламентні роботи); VI – експлуатація; VII – ремонт; VIII – випробування; IX – експлуатація; Х – зняття з експлуатації [31–34].

τ_0) I	τ_1 II	τ ₂	III	τ_3 IV	τ ₄	V	τ ₅	VI a	6 	VII	t7 	VIII a	г ₈ І	IX	τ ₉ Ι	Х	τ ₁₀
Т	Δt_1	Δt_2		Δt_3	Δt_4		Δt_5		Δt_6		Δt_7		Δt_8		Δt_9		Δt_{10}	Критерії:
ļ	$P_1(\Delta t_1)$	$P_2(\Delta t_2)$)	$P_3(\Delta t_3)$	$P_4(\Delta t_4)$	1	$P_5(\Delta t_5)$	ļ	$P_6(\Delta t_6)$	1	$P_7(\Delta t_7)$		$P_8(\Delta t_8)$	1	$P_9(\Delta t_9)$		$P_{10}(\Delta t_{10})$	і ймовірнісні
	$T_1 = M(\Delta t_1)$	$T_2 = M(\Delta$	Δt_2	$T_3 = M(\Delta t_3)$	$T_4 = M(\Delta t_4)$	1	$T_5 = M(\Delta t_5)$	12	$T_6 = M(\Delta t_6)$	1	$T_7 = M(\Delta t_7)$	1	$T_8 = M(\Delta t_8)$	1	$T_9 = M(\Delta t_9)$	T	$M_{10} = M(\Delta t_{10})$	часові
	C_1	C_2	l I	C_3	C_4	ļ	C_5	ļ	C_6	ļ	C_7	1	C_8	!	C_9	l	C_{10}	витрати

Рисунок 1.1 – Основні критерії процесу експлуатації ГТД [31–34]

Часовій осі *t* відповідають величини $\tau_0...\tau_{10}$ – випадкові події; $\Delta t_1...\Delta t_{10}$ – інтервали часу, що описують характерні ділянки експлуатації двигуна; $P_i(\Delta t_i)$, i = 1, 2, ..., 10 – ймовірності безвідмовної роботи двигуна на виділених ділянках експлуатації; $T_1...T_{10}$ – середній час безвідмовної роботи двигуна на виділених ділянках експлуатації; $C_1...C_{10}$ – витрати на виконання робіт у процесі експлуатації двигуна; $L_1...L_{10}$ – необхідна оперативна пам'ять для виконання операції; Z – ризики. Отже, життєвий цикл авіаційного двигуна, пов'язаний з його експлуатацією, характеризується трьома основними критеріями: імовірнісними, часовими та витратними. При цьому у процесі експлуатації
авіаційних двигунів прагнуть зменшити час випробувань: $t_i = \Delta t_1 + \Delta t_2 + \Delta t_3 + \Delta t_5 + \Delta t_7 + \Delta t_8 \rightarrow min, a час експлуатації збільшити: <math>t_j = \Delta t_4 + \Delta t_6 + \Delta t_9 \rightarrow max$, a узагальнений критерій *R* подається у вигляді [31]:

$$R = P(t_{\Sigma}) = P_1(\Delta t_1) P_2(\Delta t_2) \dots P_{10}(\Delta t_{10}) = \prod_{i=1}^n P_i(\Delta t_i) \to \max; \qquad (1.1)$$

при цьому $T_{\delta} = \sum_{i} \Delta t_{i} \rightarrow \min; T_{\xi} = \sum_{j} \Delta t_{j} \rightarrow \max; C = \sum_{i=1}^{n} C_{i} \rightarrow \min.$

У [31] оптимізаційна задача технічного стану ГТД наведена у формі:

$$\begin{cases} R \to \max; \sum_{i} L_{i} \leq L_{3a\partial}; \\ T_{\Sigma} \geq (T_{\Sigma})_{3a\partial}; \sum_{i} Z_{i} \leq Z_{3a\partial}^{*}; \\ C \leq C_{3a\partial}. \end{cases}$$
(1.2)

Зростання кількості контрольованих параметрів є ключовою тенденцією в розвитку авіаційних двигунів. Для ГТД п'ятого покоління, наприклад фірми Rolls-Royce, кількість цих параметрів досягає кількох тисяч [35]. Це створює потребу в розвитку нових інформаційних технологій для ідентифікації параметрів технічного стану двигуна. Застосування інтелектуальних методів – експертні системи [36–41], нечітка логіка [42– 47] і нейронні мережі [48–56] – стає необхідним для ефективного моніторингу і управління експлуатацією. Це особливо важливо в умовах бортової експлуатації [57, 58], де наземно-бортова система контролю і діагностики може значно скоротити час технічного обслуговування шляхом розумного розподілу ресурсів і прийняття якісних рішень щодо технічного стану ГТД.

Сучасні системи моніторингу та управління експлуатацією ГТД, такі як Turbine Watch, Heli Turbine Monitor, Rotor Turbine Track, Turbine Care, Heli Turbine Insight, Aero Turbine Monitor, Rotor Engine Watch, Turbo Flight Monitor i Flight Turbine Guard, здатні контролювати до 150–200 параметрів одночасно. Вони вирішують широкий спектр завдань діагностики і контролю, включаючи оцінку ключових термогазодинамічних параметрів: температури та тиску повітряного потоку на вході й виході з двигуна, температури і тиску газів у камері згоряння та турбіні, частоти обертання ротора компресора, витрати палива тощо. Дані про номінальні значення параметрів та їхні відхилення

використовуються для автоматичного розрахунку, наприклад, за методом допускового контролю. Попри високу ефективність таких систем, їх закритість обмежує можливість адаптації до специфічних умов експлуатації, інтеграції з іншими платформами та доступу до алгоритмів обробки даних, що ускладнює оптимізацію під конкретні потреби користувача. Крім того, із збільшенням кількості вимірюваних параметрів, умовами неповноти й неоднозначності інформації, а також впливом шумів вимірювань, метод допускового контролю стає менш ефективним і потребує альтернативних підходів [59–62].

Проведений аналіз свідчить, що сучасні системи моніторингу та управління ГТД не мають інтелектуальної компоненти, що обмежує їхню ефективність. Основні задачі цих систем включають отримання оперативної інформації, прогнозування відмов, їх локалізацію і вироблення рішень щодо обслуговування. Проте існуючі системи потребують модернізації через застарілі концепції, відсутність єдиного банку даних, різнорідність і неструктурованість збережених даних, відсутність системи підтримки рішень і базуються на застарілій апаратурі.

Отже, існуючі методи визначення стану окремих компонентів і систем, хоча й забезпечують певну ефективність, не дозволяють повністю вирішити проблему оптимального вибору стратегії технічного обслуговування та ремонту. Це вимагає розробки нового математичного і програмного забезпечення, яке враховуватиме взаємозв'язок експлуатаційних параметрів, мінімізуватиме помилки контролю і підвищуватиме точність прогнозування технічного стану двигунів, забезпечуючи більш ефективне і економічне управління їх експлуатацією.

1.2 Основні передумови розроблення математичного і програмного забезпечення газотурбінного двигуна вертольоту як складного технічного об'єкт моніторингу

ГТД вертольоту як об'єкт з відновлюваними характеристиками протягом експлуатації потребує постійного моніторингу, що визначає його технічний стан. Аналіз існуючих підходів демонструє, що математичне та програмне забезпечення для систем моніторингу, контролю, діагностики, ідентифікації та управління ГТД вертольотів є багаторівневими, причому рівні часто не взаємодіють між собою. Роздільне проєктування цих підсистем призводить до застосування різних методик і стандартів на кожному рівні, що



Рисунок 1.2 – Функціональна схема багаторівневої системи моніторингу технічного стану ГТД вертольотів [63–72]

спричиняє суттєву надмірність даних і значні витрати обчислювальних ресурсів. Цю проблему можна ефективно вирішити шляхом інтеграції інформації на різних рівнях управління ГТД (рис. 1.2, табл. 1.2) [63–72]. Згідно з рис. 1.2 ГТД вертольоту розглядається в рамках системи моніторингу його параметрів і експлуатації, де $Y = \{Y_1,...,Y_n\}$ – множина вимірюваних параметрів ГТД вертольотів; n = 1, 2, ..., K – кількість вимірювань; $U = \{U_1, ..., U_n\}$

– множина керуючих впливів на ГТД вертольоту; $Y' = \{Y'_1, ..., Y'_w\}$ – множина параметрів, які оцінюються системою моніторингу; w = 1, 2, ..., q – кількість параметрів, що аналізуються; $U' = \{U'_1, ..., U'_w\}$ – множина керуючих впливів з боку системи моніторингу; $Y'' = \{Y''_1, ..., Y''_u\}$ – множина параметрів, яка необхідна для моніторингу параметрів двигуна; L = 1, 2, ..., s – число параметрів, що аналізуються; $U'' = \{U''_1, ..., U''_L\}$ – множина параметрів для управління експлуатацією двигуна [63–72].

Рівень	Опис			
«нульовий»	формує об'єкт моніторингу його технічного стану – ГТД вертольоту, що			
	складається з вузлів (агрегатів) і підсистем			
рівень управління (І)	відбувається безпосередня взаємодія з двигуном через датчики і вико-			
	навчі механізми			
рівень контролю і діагностики	здійснюється спостереження за роботою двигуна і системи управління і,			
(II)	в разі виявлення несправностей відмов, дефектів цей факт фіксується, на			
	підставі чого і приймається рішення про зміну конфігурації системи			
рівень управління експлуата-	відбувається управління процесом експлуатації двигуна (прогноз, плану-			
цією (III)	вання прийнятих рішень) із забезпеченням максимального вироблення			
	ресурсу авіацій-ного двигуна (збільшення часу його експлуатації) і своє-			
	часним (обгрунтоване) зняттям його з експлуатації			
Висновок: кожен з перелічених рівнів може бути описаний формальними і неформальними (кількі-				
сними та якісними) математичними моделями				

Таблиця 1.2 – Характеристики рівнів управління ГТД вертольотів [63–72]

У процесі розроблення математичного і програмного забезпечення для моніторингу

технічного стану ГТД вертольоту реалізується виділення знань із даних («Data Mining») на рівнях від нульового до третього. На третьому та нульовому рівнях відбувається оптимальний розподіл даних, необхідних для своєчасної та якісної ідентифікації показників двигуна, що відповідає принципу Capiдica [73], згідно з яким інтелектуальність системи зростає від одного рівня управління до іншого. В умовах змінної внутрішньої обстановки, часто пов'язаної з відмовами двигуна, забезпечення прийнятного рівня якості моніторингу покладається на третій рівень ієрархії, який виконує функцію координатора [74]. Цілі управління, критерії ефективності, а також методи формування керуючих впливів для кожного рівня управління ГТД відображено у табл. А.2 додатку А. У табл.



Рисунок 1.3 – Зображення двигуна ТВЗ-117 у вигляді «чорного ящика» [76–78]

А.3 додатку А наведено огляд математичних моделей, що застосовуються на різних рівнях управління, підкреслюючи їхню роль у забезпеченні інтегрованого моніторингу та адаптивного управління. Відповідно до [76–78] координаторами системи моніторингу технічного стану ГТД вертольотів виступають рівні з II по III (рис. 1.3). Тоді $u_1(t)...u_N(t)$ – координати *N*-мірного вектору $u(t) = ||u_i(t)||_{N \times 1}$

– керуючих впливів; $y_1(t)...y_M(t)$ – координати *M*-мірного вектору $y(t) = ||y_i(t)||_{M\times 1}$ керуючих координат; $w_1(t)...w_k(t)$ – координати *k*-мірного вектору $w(t) = ||w_i(t)||_{K\times 1}$ зовнішніх впливів. Для наочності узагальнена схема системи моніторингу технічного стану авіаційних ГТД вертольотів представляється у вигляді, показаного на рис. 1.3. Тоді величини $y_i(t), i \in \{\overline{1,M}\}, u_i(t), i \in \{\overline{1,N}\}, w_i(t), i \in \{\overline{1,K}\}, з урахуванням динаміки процесів в ГТД вертольотів можуть змінюватися у режимі реального часу$ *t* $. Позначимо множину значень цих величин через <math>Y_i(t), i \in \{\overline{1,M}\}, U_i(t), i \in \{\overline{1,N}\}, \Omega_i(t), i \in \{\overline{1,K}\}$. Як і у [77], введено в розгляд множини

$$Y = Y_1 \times Y_2 \times \dots \times Y_M; \tag{1.3}$$

$$U = U_1 \times U_2 \times \dots \times U_N; \tag{1.4}$$

$$\Omega = \Omega_1 \times \Omega_2 \times \dots \times \Omega_{\kappa}; \tag{1.5}$$

де символ «×» означає декартовий добуток, а з урахуванням цих множин ГТД вертольоту як об'єкт моніторингу може бути описаний як

$$W: T \times T \times U \times \Omega \to Y, \tag{1.6}$$

яке у загальному вигляді задає стан авіаційного двигуна в момент часу $t \in T$, де T – множина інтервалів часу $t \ge 0$, коли на двигун одночасно впливають як керувальні, так і збурювальні впливи в момент $0 \le \tau \le t$.

Якщо вважати деяку підмножину $Y^{(0)} \subseteq Y$ як деяку область ідентифікації параметрів технічного стану ГТД вертольоту, тоді метою координувальної частини системи є формування таких значень $u_1(t)...u_N(t)$, для яких сукупність $(y_1(t),...,y_M(t)) \in Y^{(0)}$.

Дана задача може розглядатися як загальна стосовно всієї системи моніторингу технічного стану ГТД вертольотів. Для розв'язку подібних задач важливо врахувати інформацію про поведінку керованих координат, задавальних і збурювальних впливів. Процес отримання даної інформації в узагальненому вигляді може бути описаний виразом [79]:

$$M: T \times T \times Q \times Y \times \Omega \to D, \tag{1.7}$$

де *Q* і *D* – декартові добутки множини значень відповідних впливів і вхідних координат керувальної частини системи.

Отже, глобальна задача інтелектуального моніторингу і управління експлуатацією технічного стану ГТД вертольотів розкладається на низку часткових задач, що вирішуються окремими підсистемами, кожна з яких може бути, у свою чергу, приведена як

$$M: T \times T \times D_i^{(s)} \to Y_i^{(s)}; \ i \in \left\{\overline{1, B_R}\right\},$$
(1.8)

де B_R – число підсистем у керувальній частині двигуна; $D_i^{(s)}$ і $Y_i^{(s)}$ – декартові добутки множин значень відповідно до вхідних і вихідних координат *i*-ї підсистеми управління.

Найчастіше у пакетах моделювання зустрічається модель, побудована відповідно до схеми нульового рівня (рис. 1.4). Її вихідними даними є дросельні та витратні висотно-швидкісні характеристики. Робота ГТД вертольоту у такій моделі описується залежністю:

$$A = \delta_{C\Gamma} \cdot \left(\frac{V}{V_0}\right)^{k_1} \cdot \left(\frac{H}{H_0}\right)^{k_2}; \qquad (1.9)$$

де $\delta_{C\Gamma}$ – положення сектора газу (безрозмірна величина), V_0 , H_0 – розрахункові значення швидкості і висоти польоту, k_1 , k_2 – коефіцієнти, що відображають динаміку системи.





Модель у вигляді (1.9) є більш простою у реалізації, але не дозволяє наочно уточнити внесок окремих вузлів до роботи авіаційного двигуна, а, оскільки динамі-

чні характеристики двигуна пов'язані з характеристиками кожного вузла окремо, вона не може використовуватися для точного моделювання поведінки авіаційного двигуна на перехідних режимах (перш за все, прийомистості і дроселювання, а також найбільш цікавих аварійних режимах). Модель першого рівня дозволяє досліджувати внесок кожного окремого вузла в роботу авіаційного двигуна. При цьому його всі вузли характеризуються математичними моделями нульового рівня, що дозволяє зберегти порівняльну простоту реалізації.

На підставі викладеного вище можна стверджувати, що проблема розроблення математичного і програмного забезпечення моніторингу і управління експлуатацією ГТД вертольотів може бути вирішеною на теоретико-множинному рівні і складатися з низки підзадач, до яких належать методи розв'язання прикладних задач моніторингу за тим чи іншим показником.

1.3 Аналіз сучасного математичного і програмного забезпечення моніторингу технічного стану газотурбінних двигунів

Аналіз сучасного математичного і програмного забезпечення для моніторингу та управління експлуатацією газотурбінних двигунів (ГТД) вказує на недостатність «інтелектуальності» таких систем [80–85], оскільки вони зазвичай базуються на автоматизації через автоматизовані системи управління (АСУ) випробуваннями, що використовують класичні методи моніторингу параметрів ГТД. Однак, як зазначено в [86, 87], необхідно розвивати та застосовувати інтелектуальні методи, такі як нечітка логіка, генетичні алгоритми, нейронні мережі та експертні системи [88–96], оскільки класичні методи виявляються неефективними при неповній інформації, неточних математичних моделях, нечітких уявленнях про процеси у двигуні та можливих збоїв у навколишньому середовищі («НІ-чинниках»). У [97–104] підкреслюється, що зі збільшенням обсягу інформації про структуру та параметри ГТД, а також із застосуванням програмних і апаратних засобів для реалізації алгоритмів та отримання даних з математичних моделей, напівнатурних і натурних випробувань, рівень невизначеності зменшується. Джерелами цієї невизначеності є спрощений характер математичних моделей, що не завжди адекватно відображають реальні процеси через нелінійності, зміни характеристик вузлів двигуна, варіації вихідних параметрів моделей вузлів та підсистем, а також відмови функціональних вузлів чи елементів апаратного і програмного забезпечення [105].

Згідно з [106], автоматизовані системи управління (АСУ) газотурбінними двигунами (ГТД) стикаються з аварійним відключенням двигуна у 60 % випадків та близько третини льотних пригод, що призводить до 40 % витрат на технічне обслуговування двигуна протягом усього періоду експлуатації. Аналіз джерел [107–114] показує, що традиційні методи моніторингу і управління ГТД в умовах значної невизначеності не є ефективними, а інтелектуальні методи мають обмежену ефективність при низькій невизначеності. Оптимальним підходом є поєднання класичних методів при малій невизначеності та інтелектуальних методів при значній. Ідея інтеграції інтелектуальних методів стає особливо актуальною в ситуаціях, де класичні методи не справляються з поставленими завданнями. Сучасне математичне і програмне забезпечення моніторингу і управління експлуатацією ГТД включають експертні системи з розподіленими базами знань, зокрема гібридні, нечіткі, концептуальні, нейронні мережі та бази знань прецедентів. Вони використовують потужні алгоритми логічного виведення для аналізу задач з передбаченням і вибором оптимального рішення. У випадку з ГТД вертольотів математичне і програмне забезпечення повинно включати відстеження несправностей, аналіз статистичних даних з експлуатації та обслуговування відмов, а також коригувальні заходи для забезпечення надійності двигуна. Оскільки статистичні методи менш ефективні в умовах обмеженої вибірки, вони використовуються для перевірки гіпотез і для базового

аналізу, що є основою оперативної аналітичної обробки даних (OLAP) [115].

Відповідно до вищевикладеного, на рис. 1.5 приведено графічне зображення зміни ефективності контролю в умовах невизначеності, таких як шуми вимірювань, неповнота та недостовірність інформації, структурна і параметрична невизначеність та інше [115, 116]. Згідно з рис. 1.5 класичні методи (рис. 1.5, а) успішно вирішують завдання контролю в умовах «малої» невизначеності, тоді як використання інтелектуальних методів на цьому етапі виявляється надто енергозатратним та неефективним. З іншого боку, інтелектуальні методи (рис. 1.5, б) ефективно справляються з умовами «великої» невизначеності, у той час як застосування класичних методів на цьому етапі виявляється малоефективним. Отже, рис. 1.5 демонструє, що оптимальним рішенням є поєднання класичних та інтелектуальних методів (рис. 1.5, в). Ця комбінація дозволяє досягти оптимального рівня ефективності та якості при здійсненні моніторингу ГТД вертольотів.



Рисунок 1.5 – Зміна ефективності моніторингу технічного стану ГТД вертольотів в умовах НІ-чинників: *а* – класичні методи; *б* – інтелектуальні методи [116]

Автоматизація випробувань та управління експлуатацією ГТД вертольотів передбачає розв'язання численних задач. Сучасне математичне і програмне забезпечення моніторингу та управління ГТД вертольотів, характеризуються низкою недоліків, таких як обмежений обмін інформацією між підприємствами, відсутність єдиного інформаційного простору, відсутність міжнародних стандартів та єдиного формату даних [115, 116]. Також відзначається змен-

шення обсягу випробувань, втрата інформації при переході на нову обчислювальну техніку та відсутність інтелектуалізації управлінських процесів [117–119]. Система підтримки управлінського прийняття рішень для експлуатації ГТД вертольотів повинна базуватися на SCADA-системі, що забезпечує оперативний збір та обробку інформації [120]. Розподілені системи інформаційного моніторингу та управління

можуть бути реалізовані через мережу Інтернет з використанням СУБД Oracle або Informix, які підтримують міжнародні стандарти ISO 9000 та CALS-технології проектування інформаційних ресурсів [121]. Цей підхід дозволяє ефективно вирішувати задачі моніторингу та управління експлуатацією, пов'язані з контролем, діагностикою та прогнозуванням стану ГТД вертольотів. З використанням нових інформаційних технологій, зокрема методів штучного інтелекту, можна отримати якісно нове та ефективне рішення проблем моніторингу та управління експлуатацією ГТД вертольотів. Отже, застосування нових інформаційних технологій, що використовують методи штучного інтелекту, призведе до створення якісно нового та ефективного рішення для контролю, діагностики та управління експлуатацією ГТД вертольотів [122]. При аналізі функціонування системи ГТД вертольотів, особливу увагу викликає її структурна організація та принцип роботи. Взаємодія взаємопов'язаних елементів і їхні властивості є важливими для ефективності інтелектуальної системи моніторингу і управління експлуатацією ГТД вертольотів.

Перехід від традиційних автоматичних засобів до цифрових перетворювачів змінює характер інформаційно-управляючих систем, що сприяє розвитку інтелектуальних систем управління (ICV) [122]. Однак на сьогодні ці системи не досягли достатнього рівня інтелектуальності, не виправдовуючи свого призначення. У цій роботі розглядається математичне і програмне забезпечення задля підвищення ефективності управління такими системами через застосування новітніх досягнень у сфері штучного інтелекту, зокрема нейромережевих та генетичних алгоритмів, а також логічних підходів до представлення знань у системах управління і формування цільових керувань. Використання штучного інтелекту розширює можливості проектування і управління динамічними системами, зокрема в задачах, де рівняння динаміки можуть бути недостатньо ефективними (наприклад, у виборі каналів управління для об'єктів з реконфігурацією), або де моделі штучного інтелекту є кращими або доцільними у комбінації з класичними моделями для вирішення завдань, таких як планування дій в змінному середовищі (див. табл. А.4 додатку А [122]).

Протиріччя між різними засобами інтелектуального аналізу зумовлені необхідністю балансування між перевагами і недоліками кожного підходу. Нейромережеві методи, зокрема, забезпечують високу розпаралелюваність і здатність до навчання, але їхня ефективність обмежується потребою в великих навчальних даних і тривалим процесом навчання. Еволюційні алгоритми здатні до самоорганізації, але їхня повільна адаптація знижує швидкість прийняття рішень, що може бути критичним у реальних задачах. Продукційні системи, попри здатність до представлення знань через природні правила, стикаються з труднощами при обробці великих баз правил і забезпеченні коректності висновків. Об'єктно-орієнтовані методи характеризуються високою швидкодією, але складність програмування та недостатня виразність можуть ускладнити їх застосування. Логічні засоби мають високу виразність і здатність до вирішення складних задач, але їх низька швидкодія та обмежена сумісність з евристиками заважають застосуванню в динамічних умовах. Об'єктно-логічні системи поєднують переваги попередніх підходів, проте зберігають їх недоліки, що ускладнює їх ефективне використання в реальних додатках. Таким чином, кожен з цих методів має свої внутрішні протиріччя, які вимагають подальшого розвитку та інтеграції для підвищення загальної ефективності систем.

Ці протиріччя підтверджуються роботами ряду науковців, зокрема, А. А. Ardebili, F. Bazmi, L. Jaw, A. de Voogt, S. Sina Tayarani-Bathaie, K. Khorasani, S. Szrama, X. Zhang, Z. Cui, Z. Yan, Z. Chen, G. Zhou, а також вітчизняними дослідниками, такими як Л. Г. Бойко, В. І. Васильєва, П. Вербоса, А. В. Внукова, А. В. Гончаренко, С. О. Дмитрієва, О. М. Дмітрієва, В. І. Дубровіна, Н. Г. Дубравський, І. В. Єгоров, С. В. Жернакова та іншими, які досліджують питання створення математичного та програмного забезпечення для моніторингу технічного стану складних об'єктів, зокрема, газотурбінних двигунів (ГТД) вертольотів. У своїх роботах ці науковці підкреслюють необхідність застосування різноманітних методів для обробки та аналізу інформації про технічний стан двигунів, а також для прийняття рішень, спрямованих на досягнення цілей моніторингу та управління експлуатацією ГТД. Проте, виявлені протиріччя, зокрема обмеженість інтелектуальних компонентів систем, роз'єднаність баз даних та недостатня ефективність методів обчислень, що використовуються в моніторингу та управління віснуючі недоліки в розробці інтелектуальних програмних систем для моніторингу та діагностики ГТД. Ці недоліки обмежують

ефективність систем, які повинні забезпечити швидке виявлення несправностей і підтримку прийняття важливих рішень у процесі експлуатації, що, у свою чергу, впливає на зниження часу, витраченого на моніторинг двигунів і підвищення їх надійності.

Незважаючи на общирне дослідження у зазначених галузях, включаючи концепції, методології, методи, алгоритми та програмне забезпечення інформаційного моніторингу авіаційних турбореактивних двигунів, розроблені О. Ф. Машошиним і С. В. Жернаковим [123, 124], інформаційні системи моніторингу технічного стану ГТД вертольотів залишаються малодослідженими та неідеальними. Це зумовлено роз'єднаністю баз даних випробувань і моніторингу, недосконалістю інтелектуальних компонентів, які важливі для якісної підтримки процесу прийняття рішень, а також зменшенням загального часу, витраченого командиром повітряного судна на прийняття відповідних рішень щодо можливості польоту. Такі недоліки зумовлюють необхідність у вдосконаленні математичного і програмного забезпечення інформаційного контролю та діагностики ГТД вертольотів, особливо в умовах великої невизначеності, обумовленої складністю математичного опису, залежністю технічних характеристик від зовнішніх умов, обмеженим обсягом вимірюваних параметрів, технологічним розкидом тощо.

Варто відзначити, що дослідження Машошина О.Ф. спрямовані на застосуванні методів узагальненої оцінки технічного стану ГТД (зокрема, турбореактивних) з використанням інформаційної ентропії К. Шеннона $H_0 = -\sum_{j=0}^{r} P(D_j) \ln P(D_j)$ як інформаційного критерію [125, 126]. Використовуючи методи оптимізації набору контрольованих параметрів, Машошиним О.Ф. створено методику визначення інтенсивності відмов турбореактивних ГТД, отримано графіки залежностей інформаційної ентропії від напрацювань ГТД та інформаційності ознаки «підвищена вібрація» від напрацювань ГТД за результатами їх контролю [127]. У [128–134], використовуючи результати досліджень Машошина О.Ф. [125–127], показана можливість використання енропійного підходу для контролю технічного стану ГТД вертольотів (на прикладі авіаційного двигуна ТВ3-117). У [135, 136] створена інформаційно-діагностична система ГТД вертольотів, в якій основним діагностичним критерієм є інформаційна ентропія К. Шеннона. Недоліками інформаційної ентропії К. Шеннона у режимі реального часу є висока обчислювальна

складність та потреба в швидкій адаптації до змін в потоці даних, а також необхідність ефективного керування пам'яттю та ресурсами для забезпечення швидкості обчислень при обробці неперервних потоків інформації.

У дисертаційній роботі І. І. Муслухова [137] розроблене математичне і програмне забезпечення контролю та діагностики технічного стану ГТД на основі інтелектуального аналізу даних, що дозволяє значно підвищити ефективність бортових алгоритмів контролю параметрів ГТД. Це стало можливим завдяки застосуванню нейронних мереж для ідентифікації бортових моделей ГТД, зокрема в умовах неповноти виміряної інформації. Алгоритми визначення відмов вимірювальних каналів, розроблені І. І. Муслуховим [138–140], дозволяють відновлювати параметри та втрату інформації, а також коригувати нейронні мережі з урахуванням індивідуальних характеристик конкретного ГТД. У контексті математичного і програмного забезпечення значний внесок у розвиток цієї галузі вніс І. І. Ідрісов [141–143], який запропонував синтез алгоритмів для супервізорних нейронних мереж та адаптивних багаторежимних нейромережевих регуляторів ГТД. Ці алгоритми, включаючи регулятори з селекцією каналів управління, дозволяють забезпечити стійкість системи автоматичного управління авіаційними двигунами, а також відмовостійкість за допомогою використання нейронних мереж в режимі реального часу. Математичне і програмне забезпечення для адаптивного регулювання ГТД є важливою частиною в розробці інтелектуальних систем управління авіаційними двигунами [144].

Дисертаційна робота С. В. Єнчева [145] також зосереджена на розробці інтелектуальних систем управління турбореактивними двигунами, що використовують нейронні мережі та нечіткі адаптивні алгоритми для автоматичного управління. Однак, подібні дослідження для ГТД вертольотів не знайдені в роботах Єнчева [146–156]. В. І. Петунін [157] запропонував нове математичне і програмне забезпечення для відмовостійких АСУ ГТД, яке використовує логіко-динамічні моделі з селективним вибором каналів управління. Однак, цей підхід має високі обчислювальні вимоги, що ускладнює його реалізацію в умовах бортової експлуатації ГТД вертольотів [158–163].

У циклі робіт Трунева А.П. [164–168] досліджено аспекти моделювання турбулентних течій над шорсткою поверхнею, включаючи неізотермічні потоки з урахуванням сили плавучості та загальне співвідношення для щільності, швидкості та тиску в турбулентних потоках, що дозволяє регуляризувати систему рівнянь Нав'є-Стокса при числі Маха, що прагне динамічними параметрами. На підставі цих даних здійснено опис робочих процесів реального термодинамічного циклу турбокомпресора ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117), виконуються фундаментальні закони збереження енергії, маси, імпульсу тощо. На підставі рівняння Нав'є-Стокса в узагальненій формі $\frac{\partial \mathbf{U}}{\partial t} = \frac{\partial \mathbf{F}_1}{\partial x_1} + \frac{\partial \mathbf{F}_2}{\partial x_2} + \frac{\partial \mathbf{F}_3}{\partial x_2} = 0$, що описує рух стиснутого теплопровідного газу, отри-

мано систему рівнянь Нав'є-Стокса, що описує рух теплопровідного газу, що стискається. Використано чисельну реалізацію різницевої апроксимації рівнянь Нав'є-Стокса, отримано алгоритм реалізації різницевої апроксимації рівнянь перебігу робочих процесів турбокомпресорів ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) [169-174]. Використовуючи паралельні версії алгоритму SIMPLE для високопродуктивних обчислювальних систем з паралельною архітектурою, принцип неодномірної геометричної декомпозиції, «червоно-чорного» упорядкування при обході вузлів сітки і метод релаксації [175, 176] для розв'язання сіткових рівнянь Нав'є-Стокса, підтверджена властивість паралельних алгоритмів дозволила забезпечити прискорення в обчисленнях на сітках з більш ніж 106 вузлів у кілька десятків разів, зменшуючи ефективно кількість арифметичних операцій на одному процесорі/ядрі при збільшенні кількості використовуваних обчислювальних процесорів (ядер) [169, 177]. Використовуючи методики досліджень Трунева А.П. [164], здійснено чисельне моделювання двовимірного і тривимірного руху газодинамічного потоку в порожнині турбокомпресора ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117), отримано графіки просторово-часового розподілу складових швидкості потоку й залежності кінетичної енергії потоку від часу (у двовимірній площині та тривимірному просторі) [178, 179]. Аналітично доведено раніше отримані викладки [169] щодо виникнення звуку при дозвуковому обтіканні різних заглиблень на лопатях і у фюзеляжі вертольоту. Отримані результати досліджень шляхом застосування перетворень Гілберта дозволили створити дослідний прототип віртуального приладу на платформі Labview [180] (рис. 1.6), що візуалізує результати моделювання двовимірного і тривимірного руху газодинамічного потоку в порожнині

турбокомпресора ГТД вертольотів. Для підтвердження адекватності отриманих результатів [169–174, 177–180] запропоновано використання спектральних методів (спектру Фур'є) для оцінювання інтервальної достовірності [181]. Але проаналізовані літературні джерела з цього питання вивили обмеженість цього математичного забезпечення у контексті моніторингу параметрів лише за одним турбокомпресором ГТД вертольотів, а для комплексного моніторингу у режимі льотної експлуатації цього недостатньо.



Рисунок 1.6 – Інтерфейс користувача віртуального приладу обробки результатів моделювання [180]

1.4 Створення методу побудови системи моніторингу і управління експлуатацією газотурбінних двигунів вертольотів

Аналіз досліджень у галузі розробки математичного і програмного забезпечення моніторингу сучасних газотурбінних двигунів в Україні та за кордоном вказує на постійну тенденцію вдосконалення та перехід від пасивного контролю до активного, що дозволяє не лише виявляти відмови, а й ефективно їх усувати [182–185]. Сучасне математичне і програмне забезпечення моніторингу здатне вирішувати складні завдання в режимі реального часу з високою якістю та ефективністю. Воно взаємодіють із АСУ ГТД,

що підвищує надійність і якість управління в процесі експлуатації. Однак, чинники невизначеності та потреба в оперативних рішеннях створюють додаткові труднощі, зокрема обмежені обчислювальні ресурси, складнощі формалізації алгоритмів і необхідність використання мов низького рівня, а також ускладнюють відновлення інформації в разі відмови датчиків [186]. Зважаючи на вищевикладене, концептуально система моделювання динаміки польоту вертольоту повинна містити всі блоки (рис. 1.7).



Рисунок 1.7 – Концептуальна структурна схема системи [186]

Математичне і програмне забезпечення моніторингу технічного стану ГТД вертольотів повинно базуватись на моделях, що описують взаємодію вузлів двигуна, зокрема, модель атмосфери, що надає кількісну характеристику зовнішніх факторів, що впливають на повітряне судно [186]. Модель вертольоту прогнозує його реакції на зміни зовнішніх і внутрішніх сил, включаючи модель АСУ, руху, приладів тощо, а модель ГТД описує його динамічну поведінку для розрахунку роботи двигуна. Математичне і програмне забезпечення АСУ ГТД визначає керуючі сигнали та відстежує ефективність роботи, запобігаючи небезпечним режимам. Оцінка впливу різної комплектації ГТД, зокрема ККД компресора та турбіни, на параметри роботи двигуна вимагає введення додаткових змінних у математичні моделі, що описують взаємодію вузлів. Це дозволяє враховувати взаємозв'язок між «первинними» і «вторинними» параметрами, такими як температура газу, витрати повітря і палива, потужність тощо, що необхідно для забезпечення точних прогнозів стану ГТД [186]. Існує відоме математичне і програмне забезпечення [187– 193], але для вивчення впливу на параметри ГТД вертольотів необхідно введення додаткових змінних у математичні моделі. Це може бути досягнуто шляхом включення в початкову систему рівнянь, що описують взаємодію вузлів двигуна, додаткових рівнянь

для апроксимації конкретних характеристик, з наступним розв'язанням отриманої системи для «первинних» параметрів.

Одним із прикладів вирішення розглянутих вище питань є система рівнянь [194–200], що описує процеси, які перебігають в основних вузлах турбовального двигуна з вільною турбіною, що застосовуються виключно на вертольотах: у вхідному пристрої, компресорі, камері згоряння, турбіні компресора, вільній турбіні, вихідному пристрої. Блок-схема моделі зазначеного двигуна показана на рис. 1.8.



Рисунок 1.7 – Блок-схема математичної моделі турбовального двигуна з вільною турбіною (авіаційного двигуна ТВЗ-117) [201–204]

Згідно з наведеною на рис. 1.8 блок-схемою взаємозв'язок між основними вузлами двигуна, такими як, вхідним пристроєм, компресором, камерою згоряння, турбіною компресора, вільною турбіною, вихідним пристроєм, обумовлена нерозривністю потоку, що призводить до певного значення тиску за відповідним вузлом, позначений стрілками P_{CB}^* , P_{TK}^* , P_{Γ}^* , P_{K}^* . Баланс потужностей на валу турбокомпресора і залежність температури T_{Γ}^* від потрібної потужності привода компресора позначена на блок-схемі відповідними зв'язками N_K і T_{Γ}^* . Таким чином, зв'язки P_{CB}^* , P_{TK}^* , P_{Γ}^* , P_{K}^* , T_{Γ}^* , n_K , N_K на блок-схемі є внутрішніми, що відображають взаємний вплив вузлів двигуна. Параметри P_H і T_H є вхідними, а $n_{\Sigma CB}$, P_C^* , T_C^* – вихідними [201–204].

У зазначені рівняння згідно з [201-204] введені характеристики компресора і

турбіни. За даною математичною моделлю визначаються основні термогазодинамічні показники авіаційного турбовального двигуна з вільною турбіною.

Згідно з [201–204] режим роботи двигуна задається параметром n_{Knp} . Атмосферні умови і вхідний пристрій визначає параметри повітря на вході в компресор. Характеристики компресора і умови на вході визначають витрату повітря. Температура газів перед турбіною компресора визначається балансом потужностей на валу згідно з (A.23). Витрата повітря і температура потоку на підставі рівнянь нерозривності визначають тиск газу у відповідних перерізах проточної частини. Густина струму $q(\lambda)$ в соплових апаратах багатоступеневих турбін може вважатися незалежною величиною від перепаду тиску в турбіні компресора.

Розробка математичного і програмного забезпечення моніторингу ГТД вертольотів, яке є основою експертної системи (рис. 1.9), передбачає інтеграцію моделювання динаміки польоту вертольоту та взаємодії вузлів двигуна. Система повинна забезпечувати активний контроль, що не лише виявляє відмови, а й дозволяє їх усунути в реальному часі. Математичне забезпечення повинно прогнозувати реакції вертольоту на зміни зовнішніх і внутрішніх сил, а також описувати динамічну поведінку двигуна. Програмне забезпечення реалізує алгоритми, які визначають керуючі сигнали, моніторить ефективність роботи та запобігають небезпечним режимам. Крім того, необхідно введення додаткових змінних у математичні моделі для точнішого прогнозування параметрів ГТД, що досягається через включення рівнянь для апроксимації характеристик вузлів двигуна. У результаті, таке математичне і програмне забезпечення забезпечує високоякісну та ефективну експлуатацію ГТД, враховуючи обмеження обчислювальних ресурсів та складноці у відновленні інформації при відмові датчиків.

Розроблена експертна система моніторингу та управління експлуатацією ГТД вертольотів складається з декількох підсистем, що інтегруються в єдиний комплекс. Основою є нейромережева підсистема моніторингу, яка виконує класифікацію, ідентифікацію, контроль, діагностику, прогнозування, нагадування та тренд-аналіз. Система базується на базах знань, включаючи аналітичні дані, експертні знання та прецеденти. Зібрані сенсорами параметри двигуна обробляються та зберігаються у базі даних випробувань. Дані використовуються для ухвалення рішень через спеціальний модуль, який взаємодіє з автоматизованою підсистемою управління та командиром екіпажу через ін-





Рисунок 1.9 – Загальна архітектура розробленої експертної системи (авторський доробок)

Структура розробленої експертної системи моніторингу (рис. 1.10) включає: збір вхідних даних, постановку задачі моніторингу, аналіз і оптимізацію параметрів робочого циклу двигуна, моніторинг технічного стану та прийняття рішень. На першому етапі відбувається реєстрація параметрів двигуна під час експлуатації. Другий етап передбачає аналітичне обчислення термогазодинамічних параметрів та оптимізацію їх значень. Третій етап спрямований на розв'язання практичних задач, зокрема класифікацію, ідентифікацію, контроль, діагностику, прогнозування, нагадування та тренд-аналіз. Завершальним етапом є ухвалення рішень щодо технічного стану двигуна та визначення можливості подальшої експлуатації, що забезпечує підвищення надійності та безпеки польотів

(рис. 1.10, А.1, табл. 1.3).



Рисунок 1.10 – Структура розробленої експертної системи (авторський доробок)

Таблиця 1.3 – Опис функціонування розробленої експертної системи (авторський

доробок)

Етап	Опис				
Етап I	Фіксуються параметри ГТД вертольоту, реєстрація яких здійснюється інструментальним ме-				
	тодом безпосередньо на борту вертольоту				
Етап II	1. Ставиться задача комплексного моніторингу технічного стану ГТД вертольотів у режим				
	реального часу безпосередньо на борту вертольоту.				
	2. За математичною моделлю ГТД вертольотів обчислюються параметри робочого процесу				
	двигуна.				
	3. Здійснюється оптимізація параметрів робочого циклу двигуна (за необхідністю).				
Етап III	Здійснюється, безпосередньо, розв'язання прикладних задач комплексного моніторингу тех-				
	нічного стану ГТД вертольотів, до яких належать: класифікація, ідентифікація, контроль, ді-				
	агностика, прогнозування, налагодження, тренд-аналіз.				
	Поправка: при виявленні параметричної відмови одного чи декількох каналів вимірювання				
	(датчиків), здійснюється діагностики і парирування відмов каналів вимірювання (датчиків) з				
	метою відновлення інформації при параметричній відмові каналів вимірювання (датчиків)				
	(рис. 1.9).				
Етап IV	Здійснюється безпосередньо прийняття рішення щодо технічного стану ГТД вертольотів та				
	можливості здійснення польоту вертольоту, зважаючи на отриманий результат кожної прик-				
	ладної задачі моніторингу як окремо, так і в сукупності.				
Висновок	1. Політ можливий відповідно до польотної місії				
(рекомен-	2. Політ можливий, але через певний час рекомендовано здійснити посадку вертольоту				
дації ко-	3. Політ не рекомендований				
мандиру	4. Політ заборонений, негайно треба здійснити посадку вертольоту				
екіпажу)					

1.5 Аналіз передумов застосування нейромережевих технологій у системі моніторингу і управління експлуатацією газотурбінних двигунів вертольотів

У роботах професора Жернакова С.В. визначено, що для ефективного моніторингу технічного стану ГТД необхідно розробити розподілену систему автоматизованих робочих місць (АРМів) для збору і обробки інформації про стан двигуна, створити експертні системи для діагностики його несправностей, установити взаємодію між базами даних і знань на локальному та глобальному рівнях, визначити необхідні ресурси для реалізації задач моніторингу, а також застосувати системне моделювання для розв'язання зазначених задач. Для цього доцільно використовувати сучасні САЅЕ-засоби та методи системного моделювання, зокрема на етапі проєктування інтелектуальної системи моніторингу технічного стану ГТД вертольотів з використанням SADT-методології та IDEF-технології. Професором Жернаковим С.В. розроблено функціональні моделі для опису задач експертної системи, інформаційні моделі для логічної структури баз даних і знань, а також динамічну модель для визначення правил взаємодії експертної системи з користувачем і базами даних [205, 206]. У [207, 208] показана можливість адаптації цих моделей стосовно ГТД вертольотів, що на теоретико-множинному рівні описано у такій формі:

$$J = \langle V, W, L, Q, T \rangle; \tag{1.10}$$

де V – множина параметрів ГТД вертольотів, W – множина нормативно-директивних документів, необхідних для якісного та ефективного моніторингу технічного стану двигуна; L – множина програмно-апаратних та людських ресурсів для проведення моніторингу технічного стану ГТД вертольотів; Q – множина результатів оцінки технічного стану ГТД вертольотів; T – поточний час процесу моніторингу технічного стану ГТД вертольотів.

Визначено, що функціональна модель (рис. А.2) є основою процесу моніторингу технічного стану ГТД вертольотів *J*, яка у загальному випадку характеризується сукупністю розв'язуваних задач J_i та їх кінцевими результатами $J = \{J_i\}$, де $i \in [\overline{1,I}]$. Кожна із задач на локальному рівні описана як $J_i = \{LJ_{ij}\}$, де $i \in [\overline{1,I}]$, $j \in [\overline{1,m}]$, на локальному рівні

 LJ_{ij} конкретизовані як $LJ_{ij} = \{kJ_{js}\}$, де $j \in [\overline{1,m}]$, $s \in [\overline{1,k}]$, kJ_{js} – підзадачі – аналітичний вираз (1.10). Це дозволяє здійснити моніторинг технічного стану і управління експлуатацією ГТД вертольотів [205–208]:

$$\boldsymbol{J}_{i} = \bigcup_{s=1}^{k} k \boldsymbol{J}_{js}; \tag{1.11}$$

де $i \in \left[\overline{1,I}\right], j \in \left[\overline{1,m}\right], s \in \left[\overline{1,k}\right].$

Професором Жернаковим С.В. показано можливість декомпозиції функціональної моделі IDEF0 (Integrated Definition for Function Modeling) (рис. 1.12) на ієрархію діаграм з утворенням функціональних блоків [124]. Процес оцінювання та виявлення технічного стану ГТД вертольотів у межах узагальненої функціональної моделі дозволяє визначати технічний стан двигуна як «в нормі» для справного або «не придатний» для несправного, враховуючи можливість помилок І роду (рішення «не придатний» для справного двигуна) та II роду (рішення «в нормі» для несправного двигуна). Якість виконання задач моніторингу визначається такими показниками: ймовірністю помилки P_{ij} , $i \neq j$ – ймовірність спільного настання двох подій: об'єкт знаходиться в стані і, а вважається, що знаходиться в стані j, апостеріорною ймовірністю помилки P_{ij}^A , $i \neq j$ – ймовірність знаходження об'єкта в стані і за умови, що отриманий результат – об'єкт – знаходиться в стані j, ймовірністю правильного розв'язання задачі моніторингу P_{∂} – що відображає повну ймовірність правильної оцінки стану об'єкта. У [124, 205, 206] визначено, що помилки II роду на етапі експлуатації можуть спричиняти непередбачені ситуації, адже технічний стан ГТД вертольотів передбачається повністю контрольованим. Ймовірність помилок II роду $P_{\rm II}$ обчислюється як:

$$P_{\rm II} = (1 - P_{\partial \theta})(1 - P_{\partial})^{\theta}, \qquad (1.12)$$

де $P_{\partial s}$ – ймовірність відповідності двигуна технічними умовами; *s* – показник помилок ІІ-го роду. Водночає помилки І роду, які збільшують кількість модифікацій ГТД на етапі проєктування та повторних втручань під час виробництва, ремонту й раннього вилучення двигуна з експлуатації, також впливають на життєвий цикл системи. Ймовірність вилучення працездатного двигуна визначається як ймовірність одночасного виникнення події працездатності двигуна та помилок І роду як [124, 205, 206]:

$$P_{\rm II} = (1 - P_{\rm d})^{a}, \tag{1.13}$$



Рисунок 1.12 – Схема взаємодії різнорідних баз знань і бази даних у процесі моніторингу технічного стану ГТД вертольотів експертною системою [124, 205–208] де *а* – показник помилок І-го роду.

Помилки І-го і ІІ-го роду в умовах експлуатації ГТД вертольотів призводять до повторного проведення всіх типів випробувань згідно з їх технологічним описом та, як наслідок, до збільшення тривалості життєвого циклу в цілому. У [124] приймається, що поставлена задача повинна бути розглянута так: в умовах невизначеності необхідно розробити бортову експертну систему моніторингу технічного стану ГТД вертольотів із забезпеченням високої

якості і ефективності виконання кожної її функції. Інформаційні моделі [207, 208] для динамічних баз даних і знань спільно з вирішувачем і планувальником є основою майбутньої експертної системи і визначають інформаційно-логічну взаємодію файлів даних у базах даних і знань системи – вказують на послідовність виконання певних дій з окремими файлами в базі даних експертної системи. Взаємодія різноманітних баз знань у системі моніторингу технічного стану ГТД вертольотів ґрунтується на вирішувачі, який спільно з планувальником керує процесом взаємодії між системами управління базами даних і знань (рис. 1.12). Цей вирішувач управляє інформацією про випробування серійних ГТД вертольотів, індивідуальні характеристики окремих двигунів, нормативні документи, протоколи випробувань тощо. Реляційна, багатовимірна та часова база даних зберігає результати льотних і стендових випробувань серійних та окремих двигунів.

Відповідно до [124, 205–208], динамічна модель здійснює аналіз логіки роботи та взаємодії планувальника, вирішувача й баз знань експертної системи під час моніторингу ГТД вертольотів (сценарій функціонування динамічної моделі наведено в [207, 208]). Як зазначено у [34, 144], задачі обробки результатів вимірювань включають визначення фізичних параметрів через набір вихідних даних і відповідну процедурну

обробку; задачі реєстрації та відображення передбачають фіксацію в базі даних експертної системи відліків, даних вимірювань, прямих і непрямих параметрів; задача моніторингу спрямована на формування інформації про функціонування двигуна, локалізацію можливих відмов і прогнозування змін його параметрів у процесі експлуатації.

Комплекс функціональних, інформаційних і динамічних моделей для моніторингу технічного стану ГТД вертольотів визначає надійність і безпеку їх експлуатації, що зумовлює необхідність впровадження ідеології FDI (Fault Detection and Identification) як методу виявлення та ідентифікації відмов у технічних системах. Ця ідеологія успішно реалізована професором Жернаковим С.В. [124] для створення експертної системи контролю й діагностики турбореактивних ГТД в умовах стендових випробувань, а її адаптація до польотних режимів ГТД вертольотів дозволяє виявляти потенційні проблеми й точно визначати їх причини. Ідеологія FDI забезпечує комплексний підхід до моніторингу через інтеграцію наявних функціональних, інформаційних і динамічних моделей, ефективно локалізує відмови, забезпечує швидке реагування й визначення оптимальних стратегій ремонту або технічного обслуговування. Цей підхід, що базується на порівнянні термогазодинамічних параметрів ГТД вертольотів у реальному часі з формулярними даними (рис. 1.13), стає ключовим елементом забезпечення надійності експлуатації [208].



Рисунок 1.13 – Схема реалізації FDI-методу (відповідно до [124, 209, 210]): ψ – вектор керуючих впливів; \overline{Y}_m – вектор параметрів, отриманих за результатами математичного моделювання газодинамічних процесів у режимі реального часу; \overline{Y}_g – вектор формулярних значень, які являють собою дані вимірювань, отримані за допомогою датчиків, $\overline{\varepsilon} = \overline{Y}_g - \overline{Y}_m$ – нев'язка, яке отримане у процесі покомпонентного порівняння векторів \overline{Y}_g і \overline{Y}_m

На підставі [124, 207–210] обґрунтовано, що процес впровадження FDI-методу передбачає розробку та програмну реалізацію моделі ГТД вертольотів шляхом обчислення неузгодженості значень термогазодинамічних параметрів задля визначення технічного стану ГТД вертольотів та прийняття відповідних рішень.

У цьому контексті виникає необхідність у застосуванні нейронних мереж [211– 220], що дозволяє класифікатору поділити класи технічного стану ГТД вертольотів в умовах обмеженої інформації та з урахуванням конструктивної і параметричної невизначеності характеристик реального двигуна.

На теперішній час актуальною є розробка математичного і програмного забезпечення моніторингу ГТД за об'єктно-орієнтованим підходом з використанням варіаційних методів для дослідження різних експлуатаційних сценаріїв у задачах моніторингу. Вони найчастіше розв'язуються за допомогою компонентної математичної моделі на основі семантичних мереж – структурованих графічних моделей, що відображають взаємозв'язки між основними вузлами багаторівневої структури ГТД із забезпеченням ефективного контролю та ідентифікації несправностей задля оперативного реагування на них та прийняття оптимальних рішень щодо льотної експлуатації вертольоту, незважаючи на свідоме зменшення точності та надійності отриманих результатів. У [221] показана модифікація запропонованої моделі Жернакова С.В. у [124] стосовно ГТД вертольотів. Отримана мережа може розширюватися шляхом включення нових параметрів до складу додаткових елементарних блоків відповідно до закономірностей, які визначають робочі процеси та взаємозв'язки у вузлах ГТД вертольотів.

У контексті впровадження FDI-методу [208, 209] актуальним залишається на теперішній час використання нейромережевих технологій [210–220]. Вони дозволяють ефективно моделювати та враховувати складні нелінійні взаємозв'язки та властивості ГТД вертольотів, володіють здатністю автоматичного вивчення та адаптації до змін у вхідних даних, що робить їх ефективними для розв'язання прикладних задач моніторингу.

Застосування нейронних мереж в FDI-методі дозволяє покращити точність і робастність експертних систем моніторингу ГТД вертольотів, що є важливим при роботі з обмеженими даними та врахуванні невизначеності конструкційних і параметричних характеристик реального двигуна.

Враховуючи сучасний рівень розвитку нейронних мереж та їх успішні застосування в задачах розпізнавання та класифікації, перехід до використання нейронних мереж у FDI-методі стає логічним кроком. Вони дозволяють покращити якість аналізу та забезпечити більш точне визначення стану ГТД вертольотів, що, в свою чергу, призведе до більш ефективних та надійних рішень щодо підвищення безпеки польотів вертольотів.

Висновки до першого розділу

У результаті проведеного аналізу проблематики моніторингу технічного стану і управління експлуатацією ГТД вертольотів установлено таке:

1. Сучасні математичне і програмне забезпечення моніторингу та управління експлуатацією сучасних ГТД є багаторівневим, причому ці рівні мало пов'язані між собою, відсутній єдиний програмний супровід, що призводить до суттєвої інформаційної надмірності і необхідності залучення значних обчислювальних ресурсів.

2. Існуюче математичне і програмне забезпечення моніторингу та управління експлуатацією ГТД функціонує відокремлено; відсутній віддалений доступ; немає єдиного банку даних випробувань; збережені дані різнорідні за своєю суттю; відсутня система підтримки та прийняття рішень; застаріла система контролю і діагностики; програмнотехнічне обслуговування погано адаптується до швидкоплинних умов експлуатації.

3. Математичне і програмне забезпечення моніторингу та управління експлуатацією ГТД потребують суттєвих доопрацювань. Це пов'язано із застарілими методами, які в сучасних умовах динамізму розвитку інформаційних технологій часто не витримують гідної конкуренції на світовому ринку авіаційної техніки і технологій. Процес моніторингу ГТД вже не може бути стандартно представлений в рамках «частинних» програм технічного обслуговування і ремонту.

4. Пропоноване математичне і програмне забезпечення моніторингу та управління експлуатацією ГТД вертольотів на основі експертних систем і нейромережевих технологій дозволяє ефективно і якісно вирішувати широкий спектр комплексних задач моніторингу на основі кількісних і якісних моделей, об'єднаних єдиним інформаційним простором, а також можливість використання даних підходів при вирішенні подібних задач у польотних режимах.

Основні результати досліджень, викладені у розділі, опубліковано у наукових працях [32, 33, 57, 58, 72, 128–136, 169–174, 177–181, 185, 187–189, 201–204, 207–221].

РОЗДІЛ 2

ПЕРЕДУМОВИ ВИКОРИСТАННЯ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ ДЛЯ МОНІТОРИНГУ ТЕХНІЧНОГО СТАНУ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕР-ТОЛЬОТІВ

2.1. Створення методу побудови нейромережевої моделі для розв'язання прикладних задач моніторингу газотурбінних двигунів вертольотів

При використанні нейронних мереж щодо моніторингу технічного стану авіаційних двигунів вертольотів, апріорна інформація подається у вигляді готових рішень для навчання [209–217, 222–226], що відображено на рис. Б.1 додатку Б. Наведена структурнологічна схема визначає взаємодію компонентів системи, включає етапи ідентифікації систем і ГТД вертольоту безпосередньо, створення нейромережевого блоку для аналізу функціональних параметрів, навчання мережі на основі статистичних даних, перевірку на адекватність та апаратну реалізацію в електронних мікросхемах. Ця схема дозволяє системі ефективно розв'язувати прикладні задачі моніторингу технічного стану ГТД вертольотів у режимі польоту шляхом забезпечення надійності і швидкості обробки інформації з урахуванням видів змін технічного стану ГТД вертольотів (додаток Б, табл. Б.1).

Слід зазначити, що оцінка роботи мережі здійснюється за тестовою вибіркою, де вона обчислює вектор відхилень. Нейронні мережі мають переваги у розв'язанні погано формалізованих задач, можливості роботи в реальному часі, стійкість до пошкоджень і самонавчання.

У зв'язку із вище зазначеним, розроблено узагальнену структурну схему процесу настройки параметрів нейромережевої моделі ГТД вертольотів (рис. 2.1), де **U** = (u_1 , u_2 ..., u_m)^{*T*} – вектор вхідних (керуючих) впливів; **Y** = (y_1 , y_2 ..., y_m)^{*T*} – вектор вихідних параметрів двигуна; **Y**^{HM} = (y_1^{HM} , y_2^{HM} ,..., y_n^{HM})^{*T*} – вектор виходів нейронної мережі; ΔW_{ij} – приріст ваг синаптичних зв'язків нейронної мережі.



Рисунок 2.1 – Схема навчання нейромережевої моделі ГТД вертольотів (авторський доробок [204, 209–217])

Перетворення вектору управляючих впливів на вектор вихідних параметрів визначається оператором **F** [204, 209–211], що описує статичну або динамічну модель ГТД вертольоту, відповідно до виразу:

$$\mathbf{Y} = \mathbf{F}(\mathbf{U}). \tag{2.1}$$

Універсальна задача моніторингу ГТД вертольотів за допомогою нейронної мережі формулюється як пошук оптимального оператора \mathbf{F}^{HM} в класі нейромережевих архітектур, що найкраще відображає (апроксимує) оператор \mathbf{F} [204, 209–211]. Апроксимація \mathbf{F} оператором \mathbf{F}^{HM} вважається найкращою, якщо функціонал від різниці ($\mathbf{Y} - \mathbf{Y}^{\text{HM}}$) не перевищує заданого значення ε_{dod} , що визначає точність апроксимації оператора \mathbf{F} :

$$E = \left\| \mathbf{Y} - \mathbf{Y}^{\mathbf{H}\mathbf{M}} \right\| = \sum_{i}^{n} \varepsilon_{i}^{2} \le \varepsilon_{\partial o \partial};$$
(2.2)

Відповідно до [204, 209–211] забезпечення виконання умови (2.2) здійснюється через процес навчання нейронної мережі, що включає налаштування її параметрів за допомогою навчальної вибірки {(U, Y)} та перевірку на спеціально організованій «тестовій вибірці». Зважаючи на викладене вище, створено метод безпосередньої побудови нейронної мережі, що подана у вигляді табл. 2.1. Таблиця 2.1 – Розроблений метод поетапної побудови нейромережевої моделі моні-

Етап	Опис
Етап 1	Розробка унікальних критеріїв і метрик для оцінки ефективності моніторингу технічного стану ГТД вертольотів. Обґрунтування необхідності визначення цілей для забезпечення точності та об'єктивності оцінки.
Етап 2	Обґрунтування вибору конкретної структури нейронної мережі та визначення місця її включення у систему моніторингу технічного стану ГТД вертольотів.
Етап 3	Аналіз і обгрунтування вибору алгоритму навчання нейронної мережі з урахуванням специ- фіки моніторингу технічного стану ГТД вертольотів для досягнення оптимального адаптив- ного навчання.
Етап 4	Опис проведення експериментів на цифровій моделі з використанням результатів польотних даних для створення навчальної вибірки. Врахування нових критеріїв і метрик для поліпшення точності моделі.
Етап 5	Опис процесу навчання мережі з використанням сформованої навчальної вибірки та алгоритму навчання.
Етап 6	Обґрунтування процесу редукції та спрощення нейронної мережі для забезпечення оптимального збереження інформації та ефективної роботи при мінімальній кількості параметрів.
Етап 7	Обґрунтування заходів, спрямованих на підвищення робастності функціонування навченої нейромережевої моделі з урахуванням можливих викликів і неочікуваних ситуацій.
Етап 8	Опис процесу моделювання та тестування алгоритмів моніторингу технічного стану і управління експлуатацією ГТД вертольотів, включаючи САУ з використанням нейронної мережі.
Етап 9	Обґрунтування вибору програмної або апаратної реалізації нейронної мережі для впровадження у реальну систему моніторингу технічного стану ГТД вертольотів.

торингу ГТД вертольотів (авторський доробок)

Запропоновано метод поетапного створення нейронної мережі для розв'язання завдань моніторингу технічного стану ГТД вертольотів визначає чіткі етапи розробки та впровадження інтелектуальної системи. Результати роботи кожного етапу, такі як розробка критеріїв оцінки, вибір структури мережі, аналіз алгоритмів навчання та експериментальні дослідження на цифровій моделі, формують надійну базу для створення ефективної системи інтелектуальної моніторингу. Зокрема, обґрунтована редукція нейронної мережі та заходи для підвищення робастності моделі свідчать про прагнення до оптимальної ефективності. Завершальні етапи, такі як моделювання та тестування алгоритмів, а також можливість вибору програмної чи апаратної реалізації, підкреслюють практичну придатність методу для впровадження у реальну систему моніторингу технічного стану ГТД вертольотів.

Особливістю запропонованого методу є додаткове застосування алгоритму покрокового багатокритеріального навчання нейронної мережі задля оінювання робастності моделі, визначеної через міру Вапніка–Червоненкіса (VCdim), яка обернено пропорційна кількості синаптичних ваг [227, 228]. Цей алгоритм забезпечує підвищену здатність нейронної мережі до узагальнення шляхом мінімізації абсолютних значень ваг і редукції незначущих зв'язків. Алгоритм навчання, представлений як багатокритеріальна оптимізаційна задача, включає дві умови: мінімізацію помилки на навчальній множині та зменшення вагових коефіцієнтів. Задача розв'язується методом послідовних поступок, де пріоритет віддається мінімізації помилки, а спрощення моделі досягається шляхом видалення малозначущих ваг і непов'язаних нейронів. Оптимізація параметрів реалізується через метод змінної метрики, спрямовану мінімізацію і градієнтний спуск, а навчання завершується при досягненні заданої похибки або максимальної кількості епох.

2.2. Розробка методу формування навчальної і тестової вибірок у задачах моніторингу технічного стану газотурбінних двигунів вертольотів

На базі всього вищевикладеного у даній роботі обґрунтована необхідність розробки методу формування навчальної і тестової вибірок у задачах моніторингу технічного стану ГТД вертольотів. Підставою для цього стали дослідження професора Жернакова С.В. [229, 230], в яких прийнято, що множина сталих режимів роботи турбореактивних ГТД описується сукупністю функціональних залежностей вигляду $y_{i_{np}} = f_i (G_{T_{np}})$, де $G_{T_{np}}$ – приведена витрата палива. Отже, у результаті аналітико-експериментальних досліджень було встановлено функціональні залежності термогазодинамічних параметрів робочого процесу ГТД вертольотів як вхідних даних (табл. Б.2).

Відповідно до теорії газодинамічної подібності [229–233] процес переходу від фізичних (термогазодинамічних) параметрів двигуна до приведених значень (і навпаки)



Рисунок 2.2 – Схема переходу від нейромережевої моделі ГТД вертольотів у наведених параметрах до моделі у фізичних величинах (відповідно до [229–233]) може бути здійснено за допомогою нейромережевої моделі ГТД вертольоту показано на рис. 2.2 [229–233], де $F(\bullet)$ – оператор перетворення виміряних (фізичних) параметрів

двигуна до приведених (від повідають стандартним атмосферним умовам $T_{H}^{*} = 288,15 \text{ K}$

, $P_H^* = 760$ мм рт. ст.). Це здійснюється шляхом ідентифікації характеристик ГТД вертольотів на сталих режимах роботи, а зворотний перехід – за допомогою оператора $F^1(\bullet)$ за виразами газодинамічної подібності [229–233]:

$$n_{TK_{np}} = n_{TK} \cdot \sqrt{\frac{288}{T_{H}^{*}}}; \ G_{i_{np}} = \frac{G_{i} \cdot 760}{P_{H}^{*}} \cdot \sqrt{\frac{288}{T_{H}^{*}}}; \ P_{i_{np}}^{*} = P_{i}^{*} \cdot \frac{760}{P_{H}^{*}}; \ T_{i_{np}}^{*} = T_{i}^{*} \cdot \frac{288}{T_{H}^{*}}; \ X_{i_{np}} = X_{i} \cdot \frac{760}{P_{H}^{*}};$$
(2.3)

де *X_i* – інші параметри робочого процесу ГТД вертольотів (наприклад, ККД компресора, потужність на валу турбіни компресора тощо).

Вплив умов польоту вертольоту на параметри повітря на вході до двигуна враховується у вигляді [229–233]:

$$T_{H}^{*} = T_{H} \left(1 + \frac{k-1}{2} M^{2} \right); P_{H}^{*} = P_{H} \sigma_{s} \left(1 + \frac{k-1}{2} M^{2} \right)^{\frac{\kappa}{k-1}};$$
(2.4)

де T_H і P_H – відповідно температура (К) і тиск (кПа) повітря на заданій висоті польоту; T_H^* і P_H^* – загальмовані значення цих параметрів на деякій висоті польоту; k – показник адіабати; M – число Маха польоту; σ_{ex} – коефіцієнт відновлення повного тиску у вхідному пристрої. Вхідними параметрами універсальної математичної моделі ГТД вертольотів є значення параметрів атмосфери (h, T_H , P_H , ρ), параметрів, зареєстрованих на борту вертольоту (n_{TK} , T_T^* , n_{CB}), приведених до абсолютних значень відповідно до (2.4) (табл. Б.3 [234]). Параметри атмосфери приймаються сталими за умови знехтувано малих їх змін (табл. 2.2).

	\sim	•		••			•	4	
1 aonung 7.7 –	()CHORH	і припушення	шоло	постіиних	значень	параметт	MB ATMOCO	her	N
т аблици 2.2	COND	припущения	щодо	movinnin	Silu lelib	mapaner		PYP	,11

Припущення	Випадок	Пояснення	
Короткі періоди	Короткочасний політ – зміни в параметрах атмосфери	1. Динаміка змін параметрів атмосфери вра-	
часу	невеликі і суттєво не впливають на польотні умови.	ховується у аналітичних виразах для обчис-	
Обмежений	Обмежений діапазон висот зміни температури і тиску	лення термогазодинамічних характеристик	
діапазон висот	атмосфери є несуттєвими.	ГТД вертольотів.	
Сталі	Політ зі сталими метеорологічними умовами – зміни	2. Експеримент із моделювання ГТД верто-	
метеорологічні	параметрів атмосфери є несуттєвими.	льотів проводиться у злітному режимі за	
умови		сталих метеорологічних умов і обмеженому	
		діапазоні висот у режимі «весіння».	

На наступному етапі здійснюється перевірка адекватності моделі тестовою вибіркою, яка може розглядатись як показова (важливо використовувати індикатори для цілеспрямованої оптимізації налаштувань). Якщо точність в рішеннях відрізняється між навчальною і тестовою вибірками, то це свідчить про неадекватність моделі (відсутність однорідності) [235-240].

Оцінка однорідності є важливим питанням створення навчальної та тестової вибірок. Для цього використовується критерій Фішера-Пірсона χ^2 [241–243] з r - k - 1 ступенями свободи:

$$\chi^{2} = \min_{\theta} \sum_{i=1}^{r} \left(\frac{m_{i} - np_{i}(\theta)}{np_{i}(\theta)} \right);$$
(2.5)

де θ – оцінка максимальної дійсності, знайдена за частотами $m_1, ..., m_r; n$ – кількість елементів у вибірці; $p_i(\theta)$ – ймовірності елементарних результатів з точністю до деякого невизначеного *k*-вимірного параметра θ . Наступним етапом обробки статистичних даних є їх нормалізація відповідно до [244]:

$$y_{i} = \frac{y_{i} - y_{i\min}}{y_{i\max} - y_{i\min}};$$
(2.6)

де *y_i* – безрозмірна величина в діапазоні [0; 1]; *y_{imin}* і *y_{imax}* – мінімальне та максимальне значення змінної *y_i*.

Критерій Фішера-Пірсона дозволяє встановити однорідність вибіркових факторів, що містяться в статистичній моделі. Поле прийнятності критерію – $\chi^2 \leq \chi_{n-m,\alpha}$, де α – рівень значущості критерію. Результати розрахунків згідно з (2.5) наведені в табл. Б.4.

Розрахунок значення критерія Фішера-Пірсона на основі спостережуваних частот $m_1, ..., m_r$ (підсумовуючи рядок за рядком ймовірності результатів кожного виміряного значення) і порівнюючи його з критичними значеннями критерія Фішера-Пірсона χ^2 з кількістю ступенів свободи r - k - 1. При числі ступенів свободи r - k - 1 = 13 і $\alpha = 0,05$ випадкова величина $\chi^2 = 3,588$ не перевищила критичне значення 22,362, що означає, що гіпотеза нормального розподілу закон може бути прийнятим і вибірки є однорідними.

Підтвердженням висновку про однорідність навчальної вибірки слугує використання критерію Фішера-Снедекора [245, 246]. Отримані результати наведені у табл. Б.5, аналіз яких показує, що відношення більшої дисперсії σ_{max}^2 до меншої σ_{min}^2 дорівнює 1,28 (менше стандартизованого критичного значення $F_{\kappa p} = 3,44$). Отже, вибірки є однорідними. Для забезпечення репрезентативності навчальної та тестової вибірок було проведено кластерний аналіз початкових даних (табл. Б.3), під час якого було виділено вісім класів (рис. 2.3, а). Після застосування процедури рандомізації були сформовані



Рисунок 2.3 – Результати кластеризації: а – вихідна дослідна вибірка (І...VIII – класи); б – навчальна вибірка (авторський доробок [236–240])

навчальна (контрольна) та тестова вибірки у співвідношенні 2:1 (відповідно 67 і 33 %). Процес кластеризації для навчальної (рис. 2.3, б) і тестової вибірок показав, що обидві вони, як і контро-

льна вибірка, складаються із восьми класів. Відстані між кластерами є майже ідентичними в кожній з розглянутих вибірок, що свідчить про репрезентативність навчальної і тестової вибірок [236–240].

Відповідно до досліджень Бакулевського В.Л. [249–251] репрезентативність навчальної і тестової вибірок залежить не тільки від обсягу, але й від структури навчальної вибірки, тобто наскільки повно представлені всі категорії об'єктів генеральної сукупності (класи) і наскільки повно вони описані (табл. Б.6).

Для перевірки достатності обсягу навчальної вибірки аналогічно до [249–251] застосовано теорію «кривих навчання» [252]: інтерполяцію та екстраполяцію графіків помилок навчання та узагальнення, що базуються на кількох експериментальних точках, а також пошуку областей мінімумів та асимптотичних наближень. У випадку, якщо обсяг навчальної вибірки недостатній для зведення помилок навчання та узагальнення до єдиного асимптотичного рівня, рекомендується збільшити обсяг навчальної вибірки менш складну модель.

Для проведення експерименту, подібного до [249–251], у програмі Statistica Neural Network побудовано тестову нейронну мережу (архітектура тришарового

персептрону) з параметрами, що ідентичні табл. 2.6 з вивчення вхідних змінних. Набір даних для нейронної мережі (з 256 спостереженнями) був розподілений на три частини: навчальний набір даних (редагувався вручну), контрольний та тестовий набори (автоматично змінювалися залежно від обсягу навчальної вибірки).

Висновок про відповідність обсягів вибірок нейронною мережею зроблено на основі мінімальних СКВ, обчислених для навчальної E_{HB} , контрольної E_{KB} і тестової вибірок E_{TB} . Ефективність моделі визначається значенням помилки навчальної вибірки E_{HB} . Результати експерименту наведено в табл. Б.7, рис. 2.4. Висновки за результатами проведених досліджень показані в табл. Б.8.



Рисунок 2.4 – Похибки реєстрації термогазодинамічних параметрів ГТД вертольотів в залежності від обсягу навчальної вибірки: 1 – навчальна вибірка, 2 – контрольна вибірка, 3 – тестова вибірка (авторський доробок)

Зауваження 1. Якщо навчальна та тестова вибірки за одним із критеріїв Фішера-Пірсона або Фішера-Снедекора не є однорідними, то використовуються альтернативні метрики оцінювання масиву даних термогазодинамічних параметрів ГТД вертольотів (табл. Б.9), що можуть бути менш чутливими до різниці в розподілі даних між навчальною і тестовою вибірками. Важливо враховувати це при виборі оціночних показників для забезпечення надійності та адаптованості моделі. Якщо мінімум дві альтернативні метрики не показали однорідності навчальної і тестової вибірок, то застосовується відповідна послідовність етапів щодо модифікації масиву даних термогазодинамічних параметрів ГТД вертольотів (табл. Б.10).

Зауваження 2. Якщо навчальна і тестова вибірки за результатами кластеризації не є репрезентативними, то застосовується відповідна послідовність етапів щодо модифікації

масиву даних термогазодинамічних параметрів ГТД вертольотів (табл. Б.11).

На підставі вищевикладеного створена універсальна методика формування однорідних і репрезентативних навчальної і тестової вибірок із застосуванням масиву даних, реєстрованих на борту вертольоту, термогазодинамічних параметрів ГТД вертольотів для класу турбовальних двигунів (ГТД з вільною турбіною) (рис. 2.5).



Рисунок 2.5 – Блок-схема реалізації універсальної методики формування однорідних і репрезентативних навчальної і тестової вибірок на основі масиву даних реєстрованих на борту вертольоту термогазодинамічних параметрів ГТД вертольотів (авторський доробок)

Відповідно до отриманих результатів досліджень для заданих навчальної S_{ha64} і тестової S_{mecm} вибірок, обидві з яких складаються з *n* спостережень, а для перевірки однорідності яких застосовуються критерії Фішера-Пірсона і Фішера-Снедекора, а для їх репрезентативності – кластерний аналіз, можна сформулювати теорему однорідності та репрезентативності вибірок. Ця теорема стверджує: якщо навчальна S_{ha64} і тестова S_{mecm} вибірки є однорідними та репрезентативними, то можна вважати, що ці вибірки готові для застосування в практичних задачах моделювання, класифікації, прогнозування тощо (зокрема, прикладних задачах моніторингу технічного стану ГТД вертольотів), з високою ймовірністю успіху. Ця теорема відображає важливість якісної підготовки вибірок для аналізу та моделювання, забезпечуючи їхню однорідність та репрезентативність, що в свою чергу сприяє надійності та точності результатів розв'язання прикладних задачах моніторингу технічного стану ГТД вертольотів.

Для доведення цієї теореми позначається $S_{HaBY} = \{x_1, x_2, ..., x_n\}$ і $S_{mecm} = \{y_1, y_2, ..., y_n\}$, де n – кількість спостережень у кожній вибірці. Припускається, що критерії Фішера-Пірсона і Фішера-Снедекора підтверджують однорідність. Приймається, що $H(S_{HaBY})$ і $H(S_{mecm})$ є мірами однорідності навчальної S_{HaBY} і тестової S_{mecm} вибірок. Тоді можна сформулювати рівняння, що характеризують міру однорідності навчальної S_{HaBY} і тестової S_{mecm} вибірок:

$$\begin{cases} H(S_{_{HABY}}) = H_{_{HABY}}; \\ H(S_{_{mecm}}) = H_{_{mecm}}. \end{cases}$$
(2.7)

Якщо S_{mecm} була б значно відмінною від S_{haby} , то міра однорідності для S_{mecm} не виконувалася б, тобто $H(S_{mecm}) \neq H_{mecm}$ і $H_{mecm} \neq H_{haby}$, що суперечить передумові однорідності. На етапі оцінювання репрезентативності навчальної S_{haby} і тестової S_{mecm} вибірок результати їх кластерного аналізу є C_{haby} і C_{mecm} . Якщо C_{mecm} показує, що S_{mecm} є репрезентативною для популяції, тобто кластери S_{mecm} відображають розподіл популяції, то S_{mecm} є репрезентативною. При цьому репрезентативність описується як:

$$\begin{cases} C_{\mu a B 4} = P_{nony,n g \mu i g}; \\ C_{mecm} = P_{nony,n g \mu i g}; \end{cases}$$
(2.8)

де $P_{nonyляція}$ – розподіл у популяції. Якщо кластери C_{mecm} показує не відповідають $P_{nonyляція}$, то S_{mecm} не є репрезентативною.

Отже, математично доведено, якщо навчальна S_{haby} і тестова S_{mecm} вибірки є однорідними та репрезентативними, то можна прийняти, що обидві вибірки готові для застосування в практичних задачах моделювання, класифікації, прогнозування тощо (зокрема, прикладних задачах моніторингу технічного стану ГТД вертольотів) з високою ймовірністю успіху.

2.3. Розробка нейромережевого методу оптимізації параметрів робочого процесу газотурбінних двигунів вертольотів

Відповідно до запропонованого методу моніторингу технічного стану ГТД вертольотів на другому етапі здійснюється оптимізація параметрів робочого процесу ГТД вертольотів (відповідно до розділу 1). Робочий процес ГТД вертольотів визначається декількома десятками параметрів. Хоча цей комплекс досить великий, вибір значної частини параметрів з якого (σ_{ex} , $\sigma_{\kappa c}$, η_{τ}^* , η_{κ}^* , φ_c тощо) для розрахункового режиму здійснюється у настільки вузьких межах, що оцінка їх найбільш ймовірних значень в умовах експлуатації зазвичай не є особливими труднощами. Значення таких параметрів, необхідних для розрахунку не оптимізуються, а прогнозуються [253, 254]. Тому для оптимізації відбирають лише ті параметри робочого процесу, які визначають замкнену систему рівнянь термогазодинамічного розрахунку двигуна і можуть змінюватися у широкому діапазоні значень.

У робочому процесі ГТД вертольотів з вільною турбіною, як відомо, задача розподілу вільної енергії між гвинтом і соплом не є актуальною, тому тут мова йде про оптимізацію або тільки одного параметра – π_K^* (у разі обраного рівня T_{Γ}^* при досягнутому конструктивно-технологічному рівні «гарячої» частини двигуна), або двох параметрів робочого процесу – T_{Γ}^* і π_K^* , якщо задається температура деталей турбіни для отримання найвигідніших (раціональних) показників підсистеми.

Оскільки залежності критеріїв оцінювання ефективності від параметрів робочого процесу мають вигляд близький до квадратичного [255], в якості апроксимуючої поверхні доцільно обрати модель другого порядку, що є еліптичним параболоїдом. Для
розв'язання поставленої задачі апроксимації доцільним є обрання МНК [256–259], що обумовлено простотою його реалізації і достовірністю наближення функцій. Можливе застосування робастних методів оцінювання результатів розрахункового експерименту, що дозволяють знизити кількість грубих помилок експерименту. Модельована за МНК регресійна модель має вигляд [260, 261]:

$$y = ax_1^2 + bx_2^2 + cx_1x_2 + dx_1 + ex_2 + j;$$
(2.9)

де x_1 – незалежна змінна, що відповідає рівню підвищення тиску в компресорі π_K^* ; x_2 – незалежна змінна, що відповідає температурі газу перед турбіною компресора T_{Γ}^* ; a, b, c, d, e, f – коефіцієнти моделі, що визначаються за допомогою МНК.

Знаходячи частинні похідні від функції у, визначають її мінімум (максимум) і відповідні їй величини x₁ і x₂ відповідно до системи рівнянь:

$$\begin{cases} y'_{x_1} = 2ax_1 + cx_2 + d = 0\\ y'_{x_2} = 2bx_2 + cx_2 + e = 0 \end{cases}$$
(2.10)

Для оптимізації однопараметричних задач такий підхід дозволяє використовувати функції $y = f(T_{\Gamma}^{*})$ або $y = f(\pi_{K}^{*})$ (рис. Б.2).

Спільне рішення рівняння цільової функції і площини, віддаленої від екстремумів на величину ΔY дозволяє отримати у проекції на площину $x_1 - x_2$ ($\pi_K^* - T_{\Gamma}^*$) для кожної критеріальної функції Y_i замкнуту лінію близьку до еліпса. Ці лінії фактично є межами областей раціональних значень параметрів робочого процесу.

Як і в [262–264], у загальному вигляді задача багатокритеріальної мінімізації з *m* незалежними змінними, *n* цілями, *p* обмеженнями розглядається у вигляді нерівностей і *q* обмеженнями у вигляді рівностей [262–264]: «мінімізувати *f*(*x*) за умови *g*(*x*) > 0, *h*(*x*) = 0», де *x* = (*x*₁...*x_m*) \in *X* є вектором рішень (незалежних змінних), *X* – простір параметрів, *f*(*x*)^{*T*} = [*f*₁(*x*)...*f_n*(*x*)] – цілі, *g*(*x*)^{*T*} = [*g*₁(*x*)...*g_p*(*x*)] – обмеження у вигляді нерівностей, *h*(*x*)^{*T*} = [*h*₁(*x*)...*h_q*(*x*)] – обмеження у вигляді рівностей. Вектор рішень *a* \in *X* є домінуючим над вектором *b* \in *X*, тобто *a* \prec *b*, якщо виконується умова

$$\forall i \in \{1, ..., n\} : f_i(a) \le f_i(b) \land \exists j \in \{1, ..., n\} : f_j(a) < f_j(b).$$
(2.11)

Вектор *a* є недомінованим на множині $X' \subseteq X$, якщо в X' немає вектору, що домінує над *a*. Множина рішень X', для якої виконується умова [262–264]:

$$\forall a' \in X' : \neg \exists a \in X : a \prec a' \land ||a - a'|| < \varepsilon \land ||f(a) - f(a')|| < \delta.$$

$$(2.12)$$

де $\|...\|$ – метрика відстані, при $\varepsilon > 0$, $\delta > 0$ називається локальним Парето-оптимальною множиною. $X' \in \Gamma$ лобальною Парето-оптимальною множиною, якщо $\forall a' \in X' : \neg \exists a \in X : a \prec a'$ [262–264].

Отже, задача багатокритеріальної оптимізації є задача пошуку глобальної Парето-оптимальної множини рішень. На етапі льотної експлуатації ГТД вертольотів ця множина надається командиру екіпажу вертольоту, який вибирає один із законів регулювання і, як наслідок, подальші варіанти здійснення польоту. У [262, 263] для пошуку глобальної Парето-оптимальної множини рішень запропоновано метод багатокритеріальної оптимізації з використанням евристичних підходів – еволюційних і генетичних алгоритмів (рис. Б.3, табл. Б.12).

Ключовим питанням успіху методу багатокритеріальної оптимізації з використанням евристичних підходів – еволюційних і генетичних алгоритмів є вибір ефективного способу побудови наближеної моделі або моделі поверхні відгуку (RSM). Зокрема, для побудови наближених функціональних залежностей використовується метод групового урахування аргументів [264], багатошарові персептрони та інші моделі. У [262–264] для розв'язання багатокритеріальної задачі оптимізації для моделювання типу «мінімізувати f(x) за умови g(x) > 0, h(x) = 0» запропоновано використання RBF-мережі, побудованих за допомогою еволюційних алгоритмів [265].

Основною особливістю методу еволюційних алгоритмів [265], що відрізняє його від аналогічного методу генетичних алгоритмів, є відмова від використання кросоверної операції. У [262, 265] на основі аналізу багатьох джерел було зроблено висновок, що для проблеми генерування нейронних мереж еволюційні алгоритми є більш ефективним методом, оскільки операція кросовера часто призводить до погіршення придатності нащадків. Еволюційний метод створення RBF-мережі є недостатньо ефективним з кількох причин. По-перше, висока обчислювальна складність еволюційних алгоритмів може призвести до значних затрат ресурсів під час оптимізації параметрів RBF-мережі. Подруге, в умовах невеликої збіжності та склокування в локальних мінімумах еволюційні методи можуть виявити складність у досягненні глобально оптимальних конфігурацій RBF-мережі. Крім того, потреба у великій кількості експериментів та варіантів параметрів може ускладнити процес знаходження оптимальних гіперпараметрів. З урахуванням цих обмежень важливо виважено вибирати методи створення RBF-мереж, особливо в задачах, де важлива ефективність та точність моделі. Однією з можливих математичних модифікацій еволюційного методу створення RBF-мережі може бути впровадження гібридного підходу, який поєднує еволюційні методи з градієнтним спуском для оптимізації параметрів (табл. 2.3).

Таблиця 2.3 – Запропонована модифікація еволюційного методу створення RBF-ме-

Найменування	Опис			
Цільова функція	Приймається <i>f</i> (<i>x</i>) – цільова функція, де <i>x</i> – вектор параметрів RBF-мережі.			
Еволюційний алгоритм	Використання еволюційного алгоритму для генерації та оновлення популяції параметрів			
	мережі.			
Градієнтний спуск	Введення кроку градієнтного спуску для кожного індивіда популяції. Оновлення парамет-			
	рів може відбуватися відповідно до: $x_{_{HOB}} = x - \eta \nabla f(x)$, де η – крок градієнтного спуску, а			
	∇ƒ(x) – градієнт цільової функції в поточній точці.			
Об'єднання методів	Кожен індивід в популяції може випадковим чином вибирати, чи використовувати еволю-			
	ційний алгоритм для мутацій, чи використовувати градієнтний спуск для оновлення пара-			
	метрів. Це може здійснюватися з ймовірністю, яка адаптивно регулюється в ході оптимі-			
	зації.			
Висновок	Такий гібридний підхід дозволяє використовувати переваги обох методів, забезпечу-			
	ючи ефективну оптимізацію параметрів RBF-мережі з врахуванням локальних та			
	глобальних структур цільової функції.			

режі (авторський доробок)

Структура традиційної РБФ-мережі є простою зовні, що становить її перевагу. Проте, при врахуванні багатовимірності вектору вхідних змінних варто зазначити, що обчислення в прихованому шарі може виявитися високозатратним. З урахуванням цього в даній роботі пропонується альтернативна архітектура РБФ-мережі, яка використовує одновимірні радіально-базисні функції.

У [266] запропонована нова структура RBF-мережі, в якій кожен сигнал незалежної змінної подається в окремий прихований шар з групою одномірних радіальних елементів. Кількість радіально-базових функцій цього шару відрізняється в кожній групі ($m \neq q$). У другому шарі, що складається з k нейронів, виходи радіальних елементів з кожної групи підсумовуються у всіх можливих комбінаціях з подальшим піднесенням до квадрату. Вагові коефіцієнти нейронів вихідного шару розраховуються аналогічно до традиційних РБФ-мереж.

Запропонована у [266] архітектура РБФ-мережі з окремим прихованим шаром для кожної незалежної змінної і різною кількістю радіально-базових функцій у кожній групі,

несе в собі кілька недоліків. По-перше, це призводить до значного збільшення обчислювальної складності мережі та збільшення кількості параметрів, що може викликати проблеми перенавчання та вимагати великої кількості тренувальних даних. Додатково, складніше налаштування розподілу радіально-базових функцій та збереження структурної простоти можуть ускладнити процес проектування та оптимізації мережі.

З метою усунення вищезазначених недоліків пропонується така модифікація архітектура РБФ-мережі з окремим прихованим шаром для кожної незалежної змінної і різною кількістю радіально-базових функцій у кожній групі (поліморфна РБФ-мережа):

1. У прихованому шарі замість одномірних радіально-базових функцій використовувати багатовимірні. Це дозволить мережі краще апроксимувати складні функції, що залежать від кількох незалежних змінних.

2. У другому шарі замість підсумовування виходів радіальних елементів по одному з кожної групи використовувати множення. Це дозволить РБФ-мережі краще виявляти взаємозв'язки між незалежними змінними.

Отже, пропонована нова структура РБФ-мережі (рис. 2.41) на вході має вектор вхідних параметрів $x = (x_1, x_2, ..., x_n)$. Прихований шар містить *m* нейронів, кожен з яких є багатовимірною радіально-базисною функцією, а ваги кожного нейрона прихованого шару розраховуються як:

$$w_{ij} = \varphi(||x - c_i||) = e^{-\frac{(||x - c_j||)^2}{2 \cdot \sigma_i^2}}; \qquad (2.13)$$

де $||x - c_i|| = \sqrt{\sum_{j=1}^{N} (x_j - c_{ij})^2}$ – евклідова відстань між вектором вхідних сигналів $x = (x_1...x_n)$ і центром *i*-го нейрона $c_i = (c_{i1}...c_{iN}), i = 1...L; L$ – число нейронів в прихованому шарі; N – число нейронів у вхідному шарі; c_i, σ_i – параметри радіальної базисної функції *i*-го нейрона. Сигнал нейрона вихідного шару визначається зваженим підсумовуванням виходів нейронів прихованого шару $f_k = \sum_{i=1}^{L} w_i \cdot y_i$, де w_i – вага зв'язку від *i*-го нейрона прихованого чикуваних значень функції (p – кількість навчальних вибірок), $\mathbf{w} = (w_1...w_L)^T$ – вектор ваг, \mathbf{G} – радіальна матриця, яка, відповідно до [261, 262], має вигляд:

$$G = \begin{pmatrix} \varphi \| x_1 - c_1 \| & \varphi \| x_1 - c_2 \| & \dots & \varphi \| x_1 - c_L \| \\ \varphi \| x_2 - c_1 \| & \varphi \| x_2 - c_2 \| & \dots & \varphi \| x_2 - c_L \| \\ \dots & \dots & \dots & \dots \\ \varphi \| x_p - c_1 \| & \varphi \| x_p - c_2 \| & \dots & \varphi \| x_p - c_L \| \end{pmatrix};$$
(2.14)

Відповідно до (2.20) вектор ваг може бути обчислений як:

$$\mathbf{w} = \mathbf{G}^+ \cdot \mathbf{z}; \tag{2.15}$$

де $\mathbf{G}^+ = (\mathbf{G}^T \mathbf{G}^{-1}) \mathbf{G}^T -$ псевдоінверсія прямокутної матриці \mathbf{G} .

Отже, *i*-й нейрон прихованого шару повністю може бути описаний рядком з (N + 2) дійсних чисел, яка містить вектор $c_i = (c_{i1}...c_{iN})$, величину σ_i і значення w_i . Отже, для опису всієї мережі цілком необхідна матриця *R* розміром $L \times (N+2)$. Оскільки відповідно до [261, 262] доцільним є застосування самоадапативного способу настройки ваг, до опису нейрона додається матриця *v* такого ж розміру, що містить варіації (стратегічні параметри еволюційного алгоритму). Вихідний шар містить *k* нейронів, а вихід кожного нейрона вихідного шару розраховується як:

$$y_k = w_k \cdot \sum_{p=1}^{m} \left(w_p \cdot f_p(x) \right)^2;$$
 (2.16)

де x – вектор вхідних даних, f_p – багатовимірна радіально-базисна функція *i*-го нейрона прихованого шару, c_p – центр p-ї радіально-базисної функції, σ – ширина гаусової функції, w_k – вага k-го нейрона вихідного шару.

Запропонована поліморфна РБФ-мережа (рис. 2.6) дозволить покращити її здатність до апроксимації складних функцій, що залежать від кількох незалежних змінних. Це з тим, що використання багатомірних радіально-базисних функцій дозволяє мережі краще враховувати просторову структуру даних, а використання множення у другому шарі дозволяє мережі краще виявляти взаємозв'язку між незалежними змінними.

У [267] констатовано, що будь-яка RBF-мережа не може досягти сталого стану у процесі навчання у випадках, коли існують елементи з близькими значеннями координат центрів c_{ij} та ширини радіальної функції елементів мережі σ_i . Поява таких ситуацій багато в чому залежить від обраної кількості елементів та їх початкових параметрів. Причина погіршення якості навчання у тому, що у градієнтному алгоритмі передбачається, що у вихідне значення будь-якої RBF-мережі у кожній точці робочої області переважно впливає лише один елемент. За наявності кількох елементів в одній ділянці робочої області зміна їх параметрів відповідно до градієнтного алгоритму не завжди призводить до зменшення помилки навчання.



Рисунок 2.6 – Запропонована поліморфна РБФ-мережа (авторський доробок)

З метою визначення ситуацій, коли параметри деяких елементів стають близькими один до одного, у [267] запроваджено поняття коефіцієнта взаємного перетину елементів. Для обчислення цього коефіцієнта для деякого елемента будь-якої RBFмережі необхідно знайти другий елемент, центр якого розташований ближче до центру аналізованого елемента. Значення коефіцієнта взаємного перетину визначається як сума вихідної величини поточного елемента у центрі другого елемента та вихідної величини другого елемента у центрі поточного елемента:

$$o_{i} = e^{-\frac{\sum_{j=1}^{n} (c_{ij} - c_{dj})^{2}}{2 \cdot \sigma_{i}^{2}}} + e^{-\frac{\sum_{j=1}^{n} (c_{ij} - c_{dj})^{2}}{2 \cdot \sigma_{d}^{2}}}; \qquad (2.17)$$

де i – номер елемента, для якого обчислюється значення коефіцієнта взаємного перетину; d – номер елемента, центр якого розташований ближче до центру елемента з номером i, що визначається згідно з виразом:

$$d = \arg\min_{k} \sqrt{\sum_{j=1}^{n} (c_{ij} - c_{kj})^{2}}.$$
 (2.18)

Відповідно до [267] значення коефіцієнта взаємного перетину знаходиться в інтервалі (0; 2]. Коефіцієнт приймає максимальне значення в тому випадку, коли центри аналізованих елементів збігаються. коефіцієнта взаємного перетину перевищує 1,95 тому для досягнення максимальної якості навчання нейронної мережі RBF необхідно обмежити максимальне значення коефіцієнта взаємного перетину величиною 1,95.

У [261, 262] запропоновано еволюційний алгоритм навчання РБФ-мережі, основні недоліки якого наведено у табл. Б.14.

Однією з можливих модифікацій алгоритму може бути вдосконалення процесу ініціалізації параметрів, використовуючи більш ефективні стратегії, такі як методи генерації вагових коефіцієнтів згідно з конкретними характеристиками задачі. Також, можна розглянути оптимізацію механізму відбору для мутації та покращення функції пристосованості (табл. Б.15).

На основі вищевикладеного можна констатувати створення нового алгоритму навчання поліморфної РБФ-мережі – еволюційно-градієнтного алгоритму навчання РБФмереж, що базується на створеному у [267] модифікованому градієнтному алгоритмі навчання і запропонованому модифікованому еволюційному алгоритмі (рис. Б.4).

Запропонований еволюційно-градієнтний алгоритм навчання РБФ-мереж, з урахуванням [267], передбачає зменшення обчислювальні витрати, необхідних для кожного циклу навчання. Це досягається зміною параметрів не всіх елементів, як у класичному алгоритмі, а тільки елементів, вихідна величина яких у точці, що розглядається, більше величини θ_{3M} (блоки 4 і 5 на рис. Б.4). Також передбачається виключення можливості виникнення ситуації, коли параметри деяких елементів практично збігаються. Для цього обчислені величини Δc_{ij} та $\Delta \sigma_i$ зменшуються, якщо коефіцієнт взаємного перетину елементів перевищує граничну величину ρ_{cp} , що дорівює 1,95 (блоки 7, 8, 12, 13 на рис. Б.4).

На наступному етапі обчислювального експерименту відповідно до даних вхідної вибірки здійснюється апроксимація залежності, що описує ступінь підвищення повного тиску в компресорі:

79

$$f(x_1, x_2) = \frac{x_1^{\frac{k-1}{k}} - 1}{x_1^{\frac{k-1}{k} \cdot x_2} - 1}$$
(2.19)

при зміні змінних у межах $0 \le x_1 \le 20$ і $0 \le x_2 \le 20$, де k = 1,4 (має фізичний зміст показника адіабати).

Цей вираз було взято як тестовий приклад з міркувань, що він є аналітичним виразом для розрахунку ККД компресора ГТД вертольотів – одного з найважливіших показників робочого стану двигунів [204].

На основі навчальної вибірки з 625 груп даних ($[x_1, x_2], d$), згенерованих з рівномірним розподілом змінних x_1 та у у їх доменах, у [260, 268] побудовано мережу зі структурою 2–36–1 (2 вхідних нейрона, 36 радіальних нейронів типу Гауса і один вихідний лінійний нейрон). Використовувався гібридний алгоритм навчання; в результаті максимальна похибка апроксимації після 200 ітерацій склала 0,06. За цією методикою [260, 268] на основі однієї і тієї ж навчальної вибірки для 20 поколінь було згенеровано нейронну мережу з 26 радіальних нейронів, похибка апроксимації якої становить 0,02.

Графіки апроксимованої функції наведено на рис. 2.7, а, похибка її апроксимації за цим методом наведена на рис. 2.7, б. Отже, використання розробленої поліморфної RBFмережі може значно скоротити час обчислень і забезпечити більш ефективні мережі (з меншою кількістю нейронів і меншою кількістю помилок) порівняно з традиційним методом.



Рисунок 2.7 – Графік впливу незалежних змінних на цільові функції і обмеження (авторський доробок [260, 268])

На наступному етапі обчислювального експерименту здійснювалось навчання поліморфної РБФ-мережі за експериментальним набором даних значень ступеню підвищення повного тиску в компресорі і температури газів перед турбіною компресора. Оскільки обсяг навчальної вибірки (табл. 2.6) складає 256 значень, то і обсяг експериментального набору значень параметрів ступеню підвищення повного тиску в компресорі і температури газів перед турбіною компресора теж складає 256 значень. З експериментального набору було обрано 36 вузлових точок в якості центрів радіально-базових функцій. Єдиний вихід символізував результуюче значення одномірної залежності. Навчання проводилося на 32 прикладах, наведених у табл. Б.16. Для налаштування поліморфної РБФ-мережі застосовано значення параметра насичення, що дорівнює 0,3 [269].

З табл. Б.16 визначено, що похибка отриманих значень ступеню підвищення повного тиску в компресорі Δy , отриманими за аналітичних виразом відповідно до [204] $y_{\mu a \beta y}$ і за допомогою поліморфної РБФ-мережі y_{RBF} , не перевищує 0,32 %, що свідчить про високу здатність пропонованої поліморфної РБФ-мережі апроксимувати складні аналітичні залежності. Результати порівняльного аналізу навчання поліморфної РБФмережі з іншими архітектурами РБФ-мереж з адитивної перешкодою у вигляді білого шуму з нульовим математичним очікуванням $\sigma_i = 0,025$, що відповідає 2,5 % (класична, РБФ-мережа з окремим прихованим шаром для кожної незалежної змінної і різною кількістю радіально-базових функцій у кожній групі [266], РБФ-персептрон [269]) однакової структури 2–36–1 наведено у табл. Б.17.

З табл. Б.17 визначено, що помилка навчання поліморфної РБФ-мережі складає 0,38 %, що у 17,5 разів є нижчою, ніж помилка навчання класичної РБФ мережі, у 12,8 разів є нижчою, ніж помилка навчання РБФ-мережі з окремим прихованим шаром для кожної незалежної змінної і різною кількістю радіально-базових функцій у кожній групі [266], у 1,2 разів є нижчою, ніж помилка навчання мережі РБФ-персептрон [269].

Також з табл. Б.17 визначено, що помилка тестування поліморфної РБФ-мережі складає 0,73 %, що у 10,1 разів є нижчою, ніж помилка тестування класичної РБФ мережі, у 8,4 разів є нижчою, ніж помилка тестування РБФ-мережі з окремим прихованим шаром для кожної незалежної змінної і різною кількістю радіально-базових функцій у кожній групі [266], у 10,2 разів є нижчою, ніж помилка тестування мережі

РБФ-персептрон [269]. Час навчання РБФ-мереж зазначених архітектур є однаковим і складає 1 мс. Таким чином, ключовою перевагою у виборі поліморфної РБФ-мережі для розв'язання задач оптимізації параметрів робочого процесу ГТД вертольотів є найнижчі значення помилки навчання і тестування.

Для перевірки ефективності поліморфної РБФ-мережі у задачі оптимізації параметрів робочого процесу ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117), у [260] визначено сім відповідних незалежними параметрів: π_{K}^{*} , T_{Γ}^{*} , λ_{B} , λ_{K} , λ_{Γ} , λ_{CT} – наведені швидкості течії газу за вхідним пристроєм, компресором, камерою згоряння, турбіною компресора і вільною турбіною відповідно. При виборі допустимого поєднання незалежних параметрів обмеженнями є h_{z} – висота лопатки останнього ступеня компресора і σ_{p} – напруга розтягнення в лопатці робочого колеса останньої ступені турбіни. Ця модель дозволяє варіювати значення π_{K} і T_{Γ} для отримання оптимальних параметрів робочого процесу. Залежності C_{num} (кг/Н·год), и σ_{p} (кг/мм²) від π_{K} і T_{Γ} (K) наведені на рис. 2.8, *а* і δ відповідно.



Рисунок 2.8 – Графік впливу незалежних змінних на цільові функції та обмеження (авторський доробок [260, 268])

У задачі пошуку Парето-оптимальної множини робочого процесу авіаційного двигуна ТВЗ-117 цільовими змінними, які необхідно мінімізувати, визначається питома витрата палива C_e , наприклад, на злітному режимі. Задамо інтервали зміни для незалежних змінних: ступінь стиснення в компресорі $\pi_K = 4...20$, температура газу $T_{\Gamma} = 1300...1800$ K, наведені швидкості течії газу $\lambda_B = 0, 6...0, 7, \lambda_K = 0, 25...0, 35, \lambda_{\Gamma} = 0, 15...0, 25, \lambda_T = 0, 4...0, 65,$ $\lambda_{CT} = 0, 5...0, 7$ і обмеження: висота лопатки останнього ступеня компресора $h_z > 15$ мм, напруги розтягнення в лопатці останнього ступеня турбіни $\sigma_p > 25$ кг/мм² і $\varepsilon = 0,005$ в умови закінчення обчислень (табл. Б.13, етап 6). Процес розв'язання задачі пошуку Парето-оптимальної множини відповідно до еволюційно-градієнтного алгоритму навчання поліморфної РБФ-мережі наведено у табл. Б.18. На першому кроці згенеровано навчальну вибірку з 45 векторів рішень $\mathbf{x} = (\pi_K, T_\Gamma, \lambda_B, \lambda_K, \lambda_\Gamma, \lambda_T, \lambda_{CT})$ відповідно до центрального композитного плану експерименту з центрами на гранях (ССГ). З цих 45 рішень 9 задовольняли обмеженням і 7 були недомінованими. На підставі даної вибірки були побудовані наближені моделі для цільових змінних і обмежень на основі поліморфної RBFмережі відповідно до методу, описаного вище. Також у табл. Б.18 для кожної моделі наведені кількість нейронів в прихованому шарі N_h і пристосованість e_m .

На підставі отриманих моделей за допомогою алгоритму NSGA-II [261, 262] (розмір популяції – 100 особин, 500 поколінь навчання) було знайдено множину з 100 Парето-оптимальних рішень, сумарна відносна похибка при цьому склала e = 0,0065. Після перевірки даних рішень на точній моделі, вони були додані до навчальної вибірки, розмір якої тепер склав 140 векторів (з них задовольняли обмеженням – 45, належали множині Парето-оптимальних – 15), і весь цикл обчислень був повторений заново (друга ітерація). Всього було виконано три ітерації, для чого потрібно було 320 викликів функцій мінімізації. Сумарна відносна похибка моделей, побудованих на другий ітерації, склала e = 0,0054, на третій ітерації – e = 0,0037. Деякі зі знайдених Парето-оптимальних параметрів робочого процесу авіаційного двигуна ТВЗ-117 представлені у табл. Б.19.

Результати всіх ітерацій наведено на рис. 2.9, а ("O" – початкова навчальна вибірка (50/8), "×" – перша ітерація (140/15), "□" – друга ітерація (230/24), «Δ» – третя ітерація (320/40) – рішення на основі точної моделі (50000/100)); На цьому малюнку також показано оптимальний за Парето набір (фронт Парето), отриманий методом NSGA-II [260, 270] (з розміром популяції 100 особин і 500 поколінь) на основі точної моделі. Щоб знайти цей набір, було зроблено 50000 викликів функцій мінімізації. На рис. 2.9, б ("O" – наближена модель, "×" – точна модель: 5 поколінь, "■" – точна модель: 500 поколінь) здійснюється порівняння трьох оптимальних за Парето наборами рішень: отримані на основі на запропонованій наближеній моделі (з 320 зверненнями точної моделі), а також набори,



отримані на основі точної моделі з 500 зверненнями (при чисельності популяції 100 особин і 5 поколінь) і 50000 викликів (при чисельності популяції 100 осіб і 500 поколінь).

Рисунок 2.9 – Еволюція Парето-оптимальних множин рішень у процесі обчислень (а) та порівняння трьох Парето-оптимальних множин рішень (б) (авторський доробок [268])

Значення ступеня підвищення повного тиску в компресорі та питомої витрати палива нормалізовані (у %). Цільові функції можуть бути оптимізовані при певних значеннях параметрів упорскування палива та вибору закону регулювання двигуна. Оскільки завжди є компромісне рішення між метою оптимізації, остаточний вибір оптимальних значень параметрів упорскування повинен визначатися умовами експлуатації двигуна. Так, якщо метою є максимальне зниження питомої витрати палива, слід вибрати режим роботи двигуна, який визначається точкою P, проте в цьому випадку значення ступеня підвищення повного тиску в компресорі збільшиться на 5,0 %. Однак у цьому випадку є ризик пошкодження лопаток компресора і, як наслідок, зниження продуктивності роботи двигуна та ризик виникнення аварійних ситуацій. Якщо метою є мінімізація питомої ефективної витрати палива, то режим роботи двигуна визначатиметься точкою F зі зниженим значенням ступеня підвищення повного тиску в компресорі на 1,0 %. Компромісним рішенням буде режим роботи двигуна, що визначається точкою C, де значення ступеня підвищення повного тиску в компресорі є нормальним, при цьому питома витрата палив підвищується несуттєво порівняно зі значенням у точці F – на 10,5 %. Оскільки командир екіпажу вертольоту заздалегідь знає, які з критеріїв його цікавлять більше, то отриманому фронті Парето розглядаються окремі рішення, оптимальні за найбільш значущими критеріями [271, 272]. Таким чином, командир екіпажу вертольоту отримує підтримку у прийнятті рішення щодо вибору режиму роботи двигуна: з мінімальним значенням питомої витрати палива, з максимальним ступенем підвищення повного тиску компресору або компромісний варіант залежно від умов польоту вертольоту.

Для оцінювання ефективності результатів розв'язання задачі багатокритеріальної оптимізації на основі створеної поліморфної РБФ-мережі проведено порівняльні обчислювальні експерименти із застосуванням багатоцільового еволюційного алгоритму (Self-Organizing Multiobjective Evolutionary Algorithm, SMEA) [273] і багатокритеріального диференціального у Self-Learning algorithm, MDESL) [274]. В алгоритмі SMEA в процесі навчання для встановлення сусідства використовуються карти, що самоорганізуються (SOM). Алгоритм MDESL для отримання знань про відносини сусідства застосовує кластеризацію *k*-середніх для подальшого спарювання об'єктів. Алгоритм кластеризації k-середніх супроводжується високими обчислювальними витратами за рахунок використання ітеративної стратегії. Як еталонні завдання використані тестові набори TEST_1 – TEST_8, по 32 значення параметрів авіаційного двигуна TB3-117. Тестові набори TEST_1 – TEST_8 отримані шляхом розподілу загальної навчальної вибірки (табл. 2.6) на 8 рівних частин. Для проведення порівняльних обчислювальних експериментів було обрано такі параметри для кожного з алгоритмів з урахуванням особливостей тестових наборів даних TEST_1 – TEST_8:

1. Загальні параметри: чисельність популяції N = 500 для двокритеріальної оптимізації, розмірність змінних (об'єктів) n = 8, максимальна кількість еволюційних поколінь T = 320, число запусків тестів – 32 запуску кожного екземпляра тесту, умова зупинки – всі алгоритми припинення обчислень функції. 2. Параметри алгоритму багатокритеріальної оптимізації з використанням евристичних підходів – еволюційних та генетичних алгоритмів із застосуванням створеної поліморфної РБФ-мережі: кількість компонентів $K_{max} = 8$, ймовірність використання e = 0,6, константи кросовера CR = 1 та диференціювання F = 0 [275].

3. Параметри алгоритму SMEA: структура SOM – розмірність карти 1-D, кількість нейронів 1*100 для двокритеріальної оптимізації, початкова швидкість навчання: $\tau_0 = 0.9$, розмір околиці сусідства T = 5, можливість обмеження спарювання $\beta = 0.7$.

4. Параметри алгоритму MDESL [275]: максимальна кількість кластерів: $K_{max} = 10$. Довжина історії H = 5, константи кросовера CR = 1 та диференціювання F = 0,6.

Для кількісної оцінки якості отриманих у результаті наближень Парето-фронтів використано два показники якості: інвертовану відстань між поколіннями (IGD) [276] та гіпероб'єм (HV) [277]. Орієнтир оптимальності представляється вектором $r^* = (r_1^*, r_2^*, ..., r_k^*)$, де $r_j^* = \max f_j(x) + 1$, j = 1 ... k, k -число цільових функцій задачі. Відповідно до [275], зменшення значення метрики *IGD* покращує наближення *P* в апроксимації реального Парето-фронту *P*^{*}, а метрика *IGD* визначається згідно з виразом:

$$IGD(P^{*}, P) = \frac{\sum_{x^{*} \in P^{*}} d(x^{*}, P)}{|P^{*}|};$$
(2.20)

де P – наближений апроксимований Парето-фронт, P^* – набір оптимальних точок у істинному Парето-фронті, $d(x^*, P)$ – мінімальна відстань між рівномірно розподіленими оптимальними точками x^* та будь-якою точкою наближення P, $|P^*|$ – потужність P^* .

Також у роботі застосована метрика HV, збільшення значення якої покращує наближення P в апроксимації реального Парето-фронту P^* . Згідно з [275], метрика HV розраховується як різниця між точками P, що апроксимуються, і опорними точками r^* у цільовому просторі згідно з виразом:

$$HV = \left(P, r^*\right) = VOL\left(\bigcup_{x \in P} \left(f_1(x), r_1\right) \times \dots \times \left(f_k(x), r_k\right)\right);$$
(2.21)

де $r^* = (r_1^*, r_2^*, ..., r_k^*)$ – точка орієнтиру оптимальності в цільовому просторі, яка домінує для будь-якої Парето-оптимальної точки, *VOL*(•) – міра Лебега.

Розроблений алгоритм багатокритеріальної оптимізації з використанням

евристичних підходів – еволюційних та генетичних алгоритмів із застосуванням створеної поліморфної РБФ-мережі порівнювався з алгоритмами SMEA та MDESL, кожен із яких запускається 32 рази незалежно на заданих наборах тестів, та обчислювалися метрики *IGD* середні значення яких наведені в табл. Б.20 і Б.21 відповідно.

З табл. Б.20 і Б.21 визначено, що розроблений алгоритм багатокритеріальної оптимізації з використанням евристичних підходів – еволюційних та генетичних алгоритмів із застосуванням створеної поліморфної РБФ-мережі показав найкращі результати для всіх восьми тестових наборів TEST_1 – TEST_8 згідно з метриками *IGD* і *HV*, у всіх випадках запропонований алгоритм показав свою перевагу перед класичними алгоритмами SMEA і MDESL. Варто зазначити, що алгоритми SMEA і MDESL демонстрували середні чи низькі результати у всіх серіях експериментів.

На рис. Б.5 показано розраховані апроксимаційні фронти Парето із середніми значеннями IGD, отримані двома найкращими за середнім ранжуванням у табл. Б.20 і Б.21 розробленим алгоритмом та алгоритмом SMEA ("O" – алгоритм MDESL, "×" – алгоритм SMEA, "■" – розроблений алгоритм). Фронти апроксимації, розраховані розробленим алгоритмом, збігаються до реальних фронтів Парето в усіх випадках, тоді як фронти апроксимації, обчислені алгоритмом SMEA, не повністю збігаються на наборах даних TEST_5 – TEST_8. Крім того, на фронтах алгоритму SMEA відсутні сегменти справжніх фронтів Парето на наборах даних TEST_1 – TEST_4. Отже, можна зробити висновок, що продуктивність запропонованого алгоритму значно краща, ніж алгоритм SMEA.

На рис. Б.6 наведено залежність показника ефективності ІГД від кількості еволюційних поколінь порівнюваних алгоритмів. Видно, що розроблений алгоритм вимагає найменшої кількості обчислень з усіх алгоритмів ("O" – алгоритм MDESL, "×" – алгоритм SMEA, "■" – розроблений алгоритм). Це доводить, що ефективність пошуку запропонованого алгоритму є вищою за алгоритми порівняння для всіх тестових наборів TEST_4 – TEST_8.

2.4. Розробка нейромережевих методів ідентифікації параметрів газотурбінних двигунів вертольотів

У сучасних умовах досягнення високої точності та продуктивності результатів

розв'язання задач ідентифікації є достатньо складним, оскільки виникають труднощі з точністю результатів застосування математичних моделей, потребою у значних обсягах апріорної та апостеріорної інформації про характеристики ГТД вертольотів, а також через наявність факторів невизначеності та обмеженості інформаційних ресурсів [277, 278]. Серед класичних методів ідентифікації характеристик ГТД вертольотів найбільш поширеними є взаємно-кореляційний, стохастичної апроксимації, максимальної правдоподібності, максимізації апостеріорної ймовірності й МНК [257-261]. Також існує значна кількість публікацій з ідентифікації характеристик ГТД, описуючи різні методи, зокрема нейромережеві [279–288]. Однак отримані результати не завжди є ідеальними, оскільки часто використовується метод проб і помилок, відсутні рекомендації для вибору алгоритмів навчання та структури нейронних мереж [279–288]. Щодо ГТД вертольотів також відсутній метод розв'язання схожих задач у нейромережевому контексті. Аналіз показує, що нейронним мережам властива універсальність при розв'язанні подібних задач, оскільки вони можуть бути навчені як універсальні апроксиматори. Порівняно з класичними методами ідентифікації МНК є найбільш застосовуваним у різних сферах, оскільки застосовується, коли графічна залежність заздалегідь відома [265, 266].

На теперішній час результати розв'язання задач ідентифікації турбореактивних ГТД в умовах стендових випробувань належать професору Жернакову С.В. [289–293]: отримані розв'язки вищенаведених задач з ідентифікації багаторежимної моделі ГТД, зворотної багаторежимної моделі ГТД, динамічної багаторежимної моделі ГТД.

Відповідно до зазначених досліджень задача ідентифікації ГТД вертольотів на сталих режимах роботи описується рівняннями вигляду [229, 230, 294–298]:

$$f_1(A, U) = 0;$$
 (2.22)

$$Y = f_2(A, X);$$
 (2.23)

де f₁ й f₂ – нелінійні вектор-функції; А й U – вектори параметрів двигуна.

Задача ідентифікації зводиться до знаходження такої функції f^* , яка із заданим ступенем точності відповідала б залежності

$$Y^* = f^*(A, X).$$
(2.24)

У цій роботі задача нейромережевої ідентифікації ГТД вертольотів розв'язується у таких постановках:

ідентифікація багаторежимної моделі ГТД вертольотів за параметрами, що реєструються на борту вертольоту;

 ідентифікація багаторежимної моделі ГТД вертольотів за математичною моделлю;

 ідентифікація зворотної багаторежимної моделі ГТД вертольотів за математичною моделлю;

ідентифікація динамічної багаторежимної моделі ГТД вертольотів (перехідні режими роботи двигуна).

2.4.1. Розробка нейромережевого методу ідентифікації багаторежимної моделі газотурбінних вертольотів за параметрами, що реєструються на борту вертольоту

Нейромережева ідентифікація параметрів робочого процесу ГТД вертольотів у режимі реального часу (польоту вертольоту) здійснюється шляхом обчислення значення всіх зазначених параметрів на основі даних, що реєструються на борту верто-



Рисунок 2.10 – Загальний вид фрагмента математичної моделі ГТД вертольотів (ГТД із вільною турбіною) у програмі Matlab/Simulink (авторський доробок [299, 300]) льоту (n_{TK} , T_{Γ}^* , n_{CB}) у програмі Matlab/Simulink (рис. 2.10) [299, 300].

Оскільки головною метою ідентифікації є отримання параметрів робочого процесу ГТД вертольотів у режимі реального часу, вибір архітектури нейронної мережі визначаються основним критерієм – швидкістю отримання їх значень. З метою спрощення архітектури та прискообчислень рення для даної задачі обрано тришаровий персептрон [299, 300]:

– вхідний шар містить 7 нейронів із зазначенням атмосферних і бортових параметрів (висота польоту *h*, температура T_H , тиск повітря P_H , густина повітря ρ , частота обертання ротора турбокомпресора n_{TK} , частота обертання ротора вільної турбіни n_{CB} і температура газів перед турбіною компресора T_{Γ}^*);

– вихідний шар має 36 нейронів, де містяться значення всіх необхідних параметрів робочого процесу двигуна.

В якості активаційних функцій нейронів для тришарового персептрону широкого



поширення набула сигмоїдна функція ак-

тивації нейрона виду $f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$ [299–302].

З метою визначення оптимальної кількості нейронів у прихованому шарі побудовано експериментальну залежність E = f(N), наведену на рис. 2.11, де E – помилка навчання нейронної мережі; N – кількість нейронів у прихованому шарі (передбачасться, що кількість нейронів у вхідному шарі – 7, у вихідному шарі – 36). Найменша помилка навчання нейронної мережі спо-

стерігається при 53 нейронах у прихованому шарі за оптимальної структури нейронної мережі 7–53–36 [299, 300].

В якості алгоритмів навчання використано [299, 300]: алгоритм зворотного поширення помилки (Back Propagation), алгоритм швидкого розповсюдження (Quick Propagation), алгоритм сполучених градієнтів (Conjugate Gradients), квазиньютонівський алгоритм (Quasi Newton), алгоритм Левенберга-Марквардта. Результати порівняльного аналізу навчання пропонованого тришарового персептрона, де в якості алгоритму навчання обрано алгоритм зворотного поширення помилки, із забезпеченням високої швидкості збіжності і точності процесу навчання наведено у табл. Б.22.

У ході експерименту витрата палива в камері згоряння контролюється

функціональним блоком «Побудовник_сигналів» з визначенням даних вхідного параметра на кожен момент часу. Решта сигналів виводиться на нуль для установки умов наземних випробувань двигуна. Моделюван ня виконувалося протягом 30 с. На вхід моделі (рис. 2.12) подається значення параметрів n_{TK} , n_{CB} , T_{Γ}^* , швидкості польоту M і висоти польоту H (рис. 2.12). Потім параметри атмосфери надходять до блоку розрахунку пристрою введення, де обчислюється значення витрати палива G_T , що також використовується в подальшому як вхідний параметр для нейронної мережі.



Рисунок 2.12 – Залежність витрати палива у камері згоряння від часу, як керуючого випливу, та параметрів швидкості польоту *M* і висоти польоту *h* як збуджуючих впливів (авторський доробок [299, 300])

У процесі моделювання застосовано характер впливів подібних до пили [299, 300] (рис. 2.13) для максимізації очікуваного діапазону змін умов польоту та умов роботи двигуна. В якості вихідного сигналу обрано параметри: ККД компресора (C_EFF), ступінь підвищення загального тиску в компресорі (Pi_C), потужність на валу турбіни компресора (N_TC) і робота турбіни компресора (A_TC).



Рисунок 2.13 – Залежність витрати палива у камері згоряння від часу, як керуючого випливу, та параметрів швидкості польоту *M* і висоти польоту *h* для валідації нейромережевої моделі ГТД вертольотів (авторський доробок [299, 300])

Значення параметрів двигуна для навчання були нормалізовані як $Y_{HOPM} = \frac{Y}{Y_1}$ з

використанням відносних значень, де *Y* відображає вихідні сигнали двигуна, а Y_1 є вихідними сигналами при $n_{Hopm} = 1, H = 0, M = 0$. Важливим етапом є відтворюваність результатів навчання нейронної мережі, яка була досягнута шляхом нормалізації вхідних і вихідних сигналів [299, 300].

У результаті моделювання універсальної математичної та нейромережевої моделей ГТД вертольотів отримано графіки перехідних процесів (рис. 2.14, а, де 1 – нейромережева модель, 2 – універсальна математична модель). Рис. 2.14, б відображає значення похибки нейромережевої моделі порівняно з універсальною математичною моделлю ГТД вертольотів, а рис. 2.14, в – значення похибки для універсальної математичної моделі ГТД вертольотів. Для решти вихідних параметрів було отримано аналогічний характер кривих.



Рисунок 2.14 – Результати моделювання універсальної математичної та нейромережевої моделей ГТД вертольотів (авторський доробок [299, 300])

На рис. 2.15 наведено графіки похибки навчання нейронної мережі з часом для ідентифікованого параметра ступеня підвищення загального тиску в компресорі (а – на навчальній вибірці, б – на тестовій вибірці). Отже, помилка навчання нейронної мережі за визначеним параметром як на навчальній вибірки, так і на тестовій не перевищує 1 %. За результатами експериментальних досліджень встановлено, що для решти 35 параметрів робочого процесу двигуна помилка навчання нейронної мережі (на навчальній і тестовій вибірках) також залишалася на рівні не більше 1 %.



Рисунок 2.15 – Графік залежності від часу похибки навчання нейронної мережі для ідентифікованого параметра ступеня підвищення загального тиску в компресорі (на злітному режимі) (Matlab) (авторський доробок [299, 300])

Середні значення помилок і величини відхилення за наведеними вище графіками для кожного вихідного параметра відображені в табл. Б.23, де M_1 – розроблена нейромережева модель, M_2 – модель з наведеними параметрами.

Аналіз отриманих результатів свідчить про те, що середнє відхилення помилки розробленої нейромережевої моделі складало від 0,766 до 0,923 %, тоді як для універсальної математичної та нейромережевої моделей ГТД вертольотів це значення варіювалося від 2,162 до 2,401 %. Виявлено, що відхилення для другої моделі є в 2,342...3,053 рази вищим, ніж для першої. Варто зазначити, що час розрахунку для першої моделі становив 5,12 с, тоді як для другої цей час становив 33,61 с, що в 6,56 разів перевищує час розрахунку для розробленої нейромережевої моделі.

Досліджено точність порівняльного аналізу нейромережевого (тришаровий персептрон архітектури 7–53–36) і класичного (універсальна математична модель ГТД вертольотів) методів реалізації ідентифікації параметрів робочого процесу ГТД вертольотів. Максимальна абсолютна похибка ідентифікації при використанні тришарового персептрона архітектури 7–53–36 у 3,06 рази менша, ніж для універсальної математичної моделі ГТД вертольотів. Водночас тришаровий персептрон архітектури 7–53–36 забезпечує похибку ідентифікації не більше 0,64 %.

На відміну від [303], де для моделювання руху повітряного судна запропоновано використовувати стандартні нейромережеві архітектури типу NARX (навчання проводилось у пакетному режимі та в реальному часі), у [304] використовується

модифікована гаусова архітектура NARX з регресором вхідних даних вибору на основі модифікованого градієнтного алгоритму [304]. Ця модифікація виправдана застосуванням достатньо застарілих моделей NARX із неактуальними моделями машинного навчання [305]. Структура запропонованої у [304] нейронної мережі складається з двох частин: нелінійного та лінійного блоків (рис. 2.16, де $u_1, u_2, ..., u_n$ – вхідні сигнали; $c_{i1}, c_{i2}, ..., c_{in}$ – координати центра *i*-го елемента; σ_i – ширина радіальної функції *i*-го елемента). Нелінійний блок приймає лише вхідні регресори, вибрані модифікованим градієнтним алгоритмом [304]. Лінійний блок – це один нейрон, що приймає всі вхідні та вихідні регресори.



Рисунок 2.16 – Модифікована структурна схема нейронної мережі для ідентифікації термогазодинамічних параметрів ГТД вертольотів, створена на основі архітектури типу NARX з радіально-базисним нелінійним шаром (авторський доробок [304])

Обґрунтування переходу від тришарового персептрона до гібридної мережі NARX з радіально-базисним шаром ґрунтується на кількох чинниках (табл. Б.24), а

наукові особливості цього переходу – у табл. Б.25.

Як і у [303], нейромережева модель реалізує динамічне відображення, що описується різницевим рівнянням такого виду:

$$y(t) = \psi \Big(y(t-1), y(t-2), \dots, y(t-N_y), u(t-1), u(t-2), \dots, u(t-N_u) \Big); \quad (2.25)$$

де значення вихідного сигналу y(t) для заданого часу t обчислюється на основі значень $y(t-1), y(t-2), ..., y(t-N_y)$ цього сигналу для послідовності попередніх моментів часу, а також значень зовнішнього по відношенню до моделі NARX вхідного (керуючого) сигналу $u(t-1), u(t-2), ..., u(t-N_u)$. У загальному випадку довжина історії для виходів і елементів керування може не збігатися, тобто $N_y \neq N_u$.

На відміну від [303], у [304] запропоновано використання гаусової архітектури нелінійного шару мережі NARX замість сигмоїдальної архітектури NARX, оскільки в задачі ідентифікації параметрів робочого процесу ГТД вертольотів відповідь нейрона має бути максимальною для деякого конкретного вхідного значення. Видалення вихідних регресорів з нелінійного блоку підвищує надійність нейромережевої моделі ГТД вертольотів і дозволяє використовувати більше одного вихідного регресора в моделях. Зменшення кількості непотрібних вхідних регресорів і отримання конструктивно економних моделей покращує стійкість і зменшує чутливість до змін параметрів [303]. Окрім того, реалізація цих моделей в межах експертної системи моніторингу ГТД вертольотів [306– 308] значно доцільніша за рахунок меншої кількості оцінюваних параметрів [309]:

$$N_{Y} = (N_{HJI per} + 1) \cdot (N_{HE} + 1); \qquad (2.26)$$

де *N_{HЛper}* – кількість регресорів, що використовуються в нелінійному блоці, *N_{Лper}* – кількість регресорів, що використовуються в лінійному блоці, *N_{HE}* – кількість нейронів, що використовуються в нелінійному блоці.

Моделювання ГТД вертольотів гібридною мережею NARX дозволяє звести задачу ідентифікації до навчання мережі – коригування її вагових параметрів. У цьому випадку критерієм навчання (функціонал, що мінімізується) зазвичай вибирають функціонал квадратичної похибки, мінімізація якого здійснюється за допомогою розробленого модифікованого алгоритму Левенберга–Марквардта як методу нелінійної оптимізації [310]. Дослідження, проведене у [310], є обчислювальним експериментом, призначеним для розуміння характеристик конкретного класу досліджуваних нейромережевих моделей. У програмному середовищі Labview розроблено спеціальне програмне забезпечення, що реалізує модифікований метод Левенберга-Марквардта, а також забезпечує автоматизацію реєстрації результатів проведених експериментів (рис. Б.7, Б.8). У програмі реалізовані такі однопотокові та паралельні варіанти:

1) традиційного методу Левенберга-Марквардта з розрахунком *J* за допомогою формули центральної різницевої похідної;

2) методу Левенберга-Марквардта з розрахунком *J* методом Бройдена раз на дві епохи з двома вищеописаними евристичними підходами;

3) традиційного методу Левенберга-Марквардта з розрахунком *J* за допомогою аналітично виведених формул.

Обчислювальний експеримент за допомогою розробленого програмного забезпечення спрямований на оцінку часу виконання кожного методу з урахуванням запропонованих методів розрахунку матриці Якобі. Для навчання використовувалася гібридна мережа NARX (рис. 2.22) з 7 входами, 20 нейронами в нелінійному шарі, 5 нейронами в лінійному шарі та 1 нейроном у вихідному шарі. Для оцінки якості навчання згідно з [311] використовується миттєвий функціонал \mathbf{u}_{k+1} . Результати розрахунків представлені у табл. Б.26.

3 результатів обчислювального експерименту можна констатувати таке:

1. При збільшенні числа нейронів у прихованому шарі та обмеженні на кількість кроків збільшується значення E(w), потрібно більше кроків для корекції параметрів.

2. Методом Бройдена вдалося скоротити час обчислень приблизно у 10...12 разів порівняно з центральною похідною різницевою, проте *E*(*w*) збільшилася.

3. Прямі обчислення дозволили знизити час обчислень приблизно у 2.07...2.14 разів у порівнянні з центральною похідною різницевою. При невеликому розмірі навчальної вибірки прямі обчислення зазвичай дають мінімальне *E*(*w*).

4. Паралельні варіанти методів у середньому працюють приблизно 3...6 разів швидше, ніж послідовна реалізація.

5. *Е(w)* майже не змінюється при зміні кількості потоків, що свідчить про коректну

реалізацію паралельної обробки. Максимальне прискорення становить приблизно 61.38...120.71 разів.

Наступний етап обчислювального експерименту присвячений отриманню та аналізу похибки роботи навченої нейронної мережі у створеному програмному продукті за ідентифікованими параметрами. Отримано похибки ідентифікації таких параметрів авіаційного двигуна ТВЗ-117: ступінь підвищення загального тиску в компресорі (рис. 2.17, ліворуч вгорі), потужність на валу турбіни компресора (рис. 2.17, справа вгорі), робота турбіни компресора (рис. 2.17, ліворуч внизу), витрата палива в камері згоряння (рис. 2.17, праворуч внизу), де «жовта лінія» – помилка, отримана гібридною нейронною мережею NARX з класичним методом Левенберга-Марквардта [310], «червона лінія» – похибка, отримана гібридною нейронною мережею NARX модифікованим методом Левенберга-Марквардта [310], «зелена лінія» – лінія апроксимації.



Рисунок 2.17 – Результати обчислення помилки навчання нейронної мережі (авторський доробок [310])

Як видно з рис. 2.17, похибка навчання нейронної мережі, визначена ідентифікованим параметром – ступенем підвищення загального тиску в компресорі, залишається нижче 0,8 % як для навчальної, так і для тестової вибірок. У ході експериментальних досліджень було помічено, що так само похибка навчання нейронної мережі для решти 35 параметрів робочого процесу двигуна не перевищувала 0,8 % як на навчальній, так і на тестовій вибірках.

97

Аналіз результатів обробки середньої похибки навчання гібридної нейронної мережі NARX за модифікованим методом Левенберга–Марквардта показав зниження середнього значення похибки на 33 %, до рівня 0,025.

На заключному етапі обчислювального експерименту були розраховані та проаналізовані втрати гібридної нейронної мережі NARX (рис. 2.18), що є індикатором дисперсії між прогнозованими значеннями моделі та цільовою змінною під час навчання. У цій роботі застосовано такий вираз для обчислення функції втрат [310]:

$$L = \frac{1}{n_0} \cdot \sum_{i=1}^{n} \left(y_i - y_i \right)^2;$$
(2.27)

де *n* – кількість прикладів, *y_i* – фактичне значення цільової змінної, *y_i* – прогнозоване значення цільової змінної за допомогою нейромережевої моделі.



Рисунок 2.18 – Графік функції втрат під час навчання та тестування моделі на навчальній вибірці: 1 – навчання; 2 – валідація (авторський доробок [310])

Результати порівняльного аналізу точності реалізації нейромережевого методу ідентифікації параметрів робочого процесу ГТД вертольотів нейромережевими та класичними методами для кожного з параметрів моделі двигуна наведені в табл. Б.27. Для аналізу стійкості нейронних мереж до змін вхідних даних (табл. Б.27) було додано адитивний шум у вигляді білого шуму з нульовим математичним сподіванням $\sigma_i = 0,025$, тобто 2,5 %. Результати порівняльного аналізу точності реалізації методу ідентифікації параметрів робочого процесу ГТД вертольотів з використанням нейромережевих і класичних методів для кожного з параметрів моделі двигуна в умовах шуму наведено в табл. Б.28. Аналіз табл. Б.27 і Б.28 показує, що похибка ідентифікації з урахуванням заданих шумових умов залишається нижче певних порогів: для гібридної мережі NARX з модифікованим методом Левенберга-Марквардта становить 0,43 %, для гібридної мережі NARX – 0,71 %, для тришарового персептрона архітектури 7–53–36 – 1,09 % [310], а для універсальної математичної моделі ГТД вертольотів – 3,15 %. Під впливом білого шуму максимальна абсолютна похибка реалізації методу ідентифікації параметрів робочого процесу ГТД вертольотів методом найменших квадратів зросла з 1,96 до 3,15 %. Для тришарового персептрона з архітектурою 7–53–36 ця похибка зросла з 0,64 до 1,09 %, для гібридної мережі NARX – з 0,43 до 0,74 %, а для гібридної мережі NARX з модифікованим методом Левенберга-Марквардта – з 0,28 % до 0,43 %. Для визначення надійності нейромережевого методу ідентифікації параметрів робочого процесу ГТД вертольотів застосовано такі вирази [310]:

$$K_{nom} = \frac{T_{nom}}{T_0} \cdot 100\%;$$
 (2.28)

$$K_{\scriptscriptstyle ЯКість} = \left(1 - \frac{T_{\scriptscriptstyle nom}}{T_{\scriptscriptstyle 0}}\right) \cdot 100\%; \qquad (2.29)$$

де K_{nom} , K_{skicmb} – коефіцієнти помилкової та якісної ідентифікації відповідно; T_{nom} – сумарний час ділянок, що відповідають помилковій класифікації; T_0 – тривалість досліджуваної вибірки (в цій роботі $T_0 = 5$ с).

У табл. 2.4 наведено результати розрахунку коефіцієнтів помилкової та якісної ідентифікації ККД компресора, ступеня підвищення загального тиску в компресорі, потужності на валу турбіни компресора, роботи на валу турбіни компресора, витрати палива в камері згоряння.

Таблиця 2.4 – Результати розрахунку коес	ріцієнтів помилки	та якості	(авторський до-
робо	x [310])		

Параметр	Гібридна NARX мережа		Гібридна NARX мережа з модифікованим методом Ле-	
			венберга-Марквардта	
	K _{nom}	K _{nom}	K _{nom}	Кякість
ККД компресора	0,522	99,872	0,388	99,923
Ступінь підвищення загального тиску в компресорі	0,521	99,872	0,386	99,925
Потужність на валу турбіни компресора	0,523	99,871	0,389	99,921
Робота на валу турбіни компресора	0,523	99,871	0,389	99,921
Витрата палива в камері згоряння	0,526	99,872	0,390	99,922

Як видно з табл. 2.33, коефіцієнти помилкової ідентифікації не перевищують: для гібридної NARX-мережі – 0,528 %, гібридної NARX-мережі мережа з модифікованим методом Левенберга-Марквардта – 0,386 %, а мінімальні коефіцієнти якісної ідентифікації становлять: для гібридної NARX-мережі – 99,871 %, для гібридної NARX-мережі мережа з модифікованим методом Левенберга-Марквардта – 99,925 %.

2.4.2. Розробка нейромережевого методу ідентифікації багаторежимної моделі газотурбінних вертольотів за параметрами, що обчислюються за математичною моделлю

В рамках поставленої задачі ідентифікації багаторежимної моделі ГТД вертольотів за параметрами, що обчислюються за універсальною математичною моделлю ГТД вертольотів [204] розглядається приклад розв'язання цієї задачі з параметрами авіаційного двигуна ТВЗ-117, що використовується в складі силової установки вертольоту Мі-8МТВ, на основі даних про його експлуатацію, що записані стосовно стандартних атмосферних умов у табл. Б.29 (повна навчальна вибірка містить 256 рядків). Вхідним параметром у цій моделі є витрата палива $G_{T_{np}}$, а вихідними – будь-які параметри робочого процесу ГТД вертольотів. В якості прикладу у цій роботі використовується шість вихідних параметрів.

На етапі аналізу даних одним із ключових аспектів є оцінка репрезентативності вибірки, тобто ступінь повноти її відображення. Розв'язання цієї задачі виконується за допомогою застосування одного з методів кластерного або дискримінантного аналізу. Результати аналізу, представлені на рис. Б.9, а–в (а – вихідна (експериментальна) вибірка; б – навчальна вибірка; в – тестова вибірка), показують, що під час кластеризації виділено вісім класів. Після застосування процедури рандомізації були визначені навчальна і тестова вибірки у співвідношенні 2:1 (67 і 33 %).

Аналіз процесу кластеризації для навчальної (рис. Б.9, а) і тестової (рис. Б.9, б) вибірок показує, що вони, так само, як і вихідна вибірка (табл. Б.29), включають в себе вісім класів. Відстані між кластерами практично збігаються у кожній розглянутій вибірці. Отже, навчальні і тестові вибірки є репрезентативними.

Для розв'язання задачі ідентифікації багаторежимної моделі ГТД вертольотів в нейромережевому базисі подібно до досліджень професора Жернакова С.В. [229, 230, 289–293] обрано основні такі архітектури нейронних мереж: персептрон і РБФ-мережа (традиційна і поліморфна). Вибір цих архітектур обґрунтовується аналізом помилок, отриманих при застосуванні нейромережевих і класичних методів ідентифікації [265, 266]. На цьому етапі розв'язання поставленої задачі з використанням нейромережевих технологій вимагає вибору оптимальної структури для нейронної мережі.

У [295] визначено, що оптимальними структурами нейронних мереж є: для персептрона – структура 1–4–6, тобто один нейрон у вхідному шарі, чотири нейрони в прихованому шарі і шість нейронів у вихідному шарі; для РБФ-мережі – структура 1–12–6, тобто один нейрон у вхідному шарі, дванадцять нейронів в радіальному (прихованому) шарі і шість нейронів у вихідному шарі. Ці нейромережеві моделі ГТД вертольотів дозволяють обчислити шість вказаних вище параметрів двигуна як функції приведеної витрати палива $G_{T_{up}}$. Активаційною функцією для персептрона є сигмоїдна функція. РБФ-мережа є двошаровою мережею, де перший шар здійснює нелінійне перетворення вхідного параметра $G_{T_{up}}$ без застосування настроювальних ваг, а вихідний шар об'єднує отримані виходи першого шару шляхом обчислення їх лінійної зваженої комбінації.

У процесі порівняльного аналізу точності методів ідентифікації багаторежимної



Рисунок 2.19 – Порівняльний аналіз похибок нейромережевих і класичного методів ідентифікації параметрів авіаційного двигуна ТВЗ-117 на тестовій вибірці (авторський доробок [295])

моделі ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117), таких як нейромережеві (персептрон, РБФ-мережа і РБФ-мережа з модифікованим градієнтним алгоритмом навчання), і класичний метод (МНК) для окремого параметра - частоти обертання ротора турбокомпресора (*n*_{TK}) на тестовій вибірці (рис. 2.19, де 1 – МНК; 2 – персептрон; 3 – РБФ-мережа; 4 – поліморфна РБФ-мережа), виявлено, що похибка ідентифікації при використанні нейрона мережі

персептрон (крива 2) у 2,6 рази менше, ніж для поліноміальної регресійної моделі восьмого порядку, побудованої за допомогою МНК (крива 1). Для традиційної РБФмережі (крива 3) ця похибка менше в 1,5 рази, а для поліморфної РБФ-мережі (крива 4) – у 3,25 разів. При цьому персептрон демонструє похибку ідентифікації, яка не перевищує 0,38 %; нейронна мережа РБФ – 0,59 %; нейронна мережа РБФ з модифікованим градієнтним алгоритмом навчання – 0,23 %; МНК – 0,99 %.

У табл. Б.30 наведені результати порівняльного аналізу точності ідентифікації нейромережевих і класичних методів для кожного з виходів моделі авіаційного двигуна ТВЗ-117. Отримані дані свідчать, що значення похибки ідентифікації параметрів авіаційного двигуна ТВЗ-117 не перевищують відповідно (%): персептрона – 0,63; традиційної РБФ-мережі – 0,74; поліморфної РБФ-мережі – 0,47; МНК – 0,99. З метою оцінки стійкості нейронних мереж до змін вхідних даних до них вводилася адитивна перешкода у вигляді білого шуму з нульовим математичним очікуванням $\sigma_i = 0,025$, що відповідає 2,5 %. Результати порівняльного аналізу точності ідентифікації нейромережевих і класичних методів для кожної окремої компоненти авіаційного двигуна ТВЗ-117 за умови впливу шуму наведені в табл. Б.31.

Графічна інтерпретація (табл. Б.31) відображена на рис 2.20 (де 1 – МНК; 2 – персептрон; 3 – традиційна РБФ-мережа; 4 – поліморфна РБФ-мережа): а – для значень $n_{TK_{uv}}$, б – для значень $T^*_{\Gamma_{uv}}$.



Рисунок 2.20 – Порівняльний аналіз похибок нейромережевих і класичного методів ідентифікації параметрів авіаційного двигуна ТВЗ-117 в умовах дії шуму (авторський доробок [295])

З аналізу табл. Б.31 та рис. 2.20 випливає, що похибка ідентифікації в умовах дії зазначеного шуму не перевищує (%): при використанні персептрона – 0,84; традиційної РБФ-мережі – 0,85; поліморфної РБФ-мережі – 0,65; МНК – 2,14. В умовах дії білого шуму (σ = 0,025) похибка ідентифікації параметрів авіаційного двигуна ТВЗ-117 за методом найменших квадратів збільшилася з 0,99 до 2,14 %. Для нейромережевих методів (персептрон і РБФ-мережа) відзначається таке зростання похибки відповідно: для персептрону – з 0,63 до 0,84 %; для традиційної РБФ-мережі – з 0,74 до 0,86 %; для поліморфної РБФ-мережі – з 0,47 до 0,65 %. Отже, порівняльний аналіз нейромережевих і класичних методів ідентифікації в умовах шуму показує, що нейромережеві методи виявляють більшу стійкість до зовнішніх збурень.

2.4.3. Розробка нейромережевого методу ідентифікації зворотної багаторежимної моделі газотурбінних вертольотів за параметрами, що обчислюються за математичною моделлю

Відповідно до досліджень професора Жернакова С.В. [312] припускається, що ГТД вертольоту на сталих режимах роботи описується (2.22) і (2.23). На практиці виникає задача непрямих вимірювань: відповідно до спостережень за вектором вихідних параметрів робочого процесу ГТД вертольоту визначити значення його керуючих впливів (тобто компоненти вектору *U*). Наприклад, за виміряними значеннями параметрів n_{TK} , тощо, необхідно обчислити значення витрати палива в камері згоряння G_T . Аналітична постановка цієї задачі відповідно до [312, 313] полягає у визначенні оберненої нелінійної залежності f^{-1} у вигляді виразу:

$$U = f^{-1}(A, Y). (2.30)$$

Отже, відповідно до [312, 313], нейромережева модель ГТД вертольотів має гарантувати мінімізацію помилки навчання *E* згідно з процедурою, показаною на рис. 2.36, де $\varepsilon = (\varepsilon_1, \varepsilon_2, ..., \varepsilon_k)^T$ – вектор розбіжностей між фактичними і розрахунковими значеннями керуючих впливів, тобто $\varepsilon = U - U^*$, а $E = \sum_i \varepsilon_i^2$. Після завершення

процесу навчання нейронна мережа відтворює характеристики зворотної багаторежимної моделі ГТД вертольотів, що полягає у такому: за відомими значеннями параметрів двигуна, приведеними до стандартних атмосферних умов слід розробити багаторежимну нейромережеву модель для обчислення (непрямого вимірювання), наприклад, приведеної витрати палива (рис. 2.21).



Рисунок 2.21 – Схема розв'язку задачі ідентифікації зворотної багаторежимної моделі ГТД вертольотів (відповідно до досліджень професора Жернакова С.В. [312, 313])

Аналіз вихідних даних (навчальної вибірки) і їх попередня обробка здійснюється аналогічно підходу розв'язання прямої задачі ідентифікації багаторежимної моделі



ГТД вертольоту. Під час експеримелослінтальних лжень для розв'язання цієї задачі [312, 313] заосновні стосовано архітектури нейронних мереж, такі як персептрон, традиційна РБФ-мережа і поліморфна РБФ-мережа.

Рисунок 2.22 – Вибір оптимальних за складністю структур нейронних мереж для розв'язання зворотної задачі ідентифікації: 1 – персептрон; 2 – РБФ-мережа (авторський доробок [313])

У цьому плані експериментальні дослідження показали, що оптимальні за складністю нейронні мережі повинні мати 12 (рис. 2.22, крива 1) і 16 (рис. 2.22, крива 2) нейронів відповідно у прихованому шарі. Отже, для розв'язання зворотної задачі ідентифікації багаторежимної моделі ГТД вертольотів оптимальною структурою РБФмережі є 6–12–1, а персептрону – 6–16–1 із сигмоїдними функціями активації нейронів. Цей метод включає порівняльний аналіз точності нейромережевих (персептрон і РБФмережі) і класичного (МНК) методів ідентифікації зворотної багаторежимної моделі ГТД вертольотів (на прикладі двигуна ТВЗ-117) на тестовій вибірці (рис. 2.23, а) і в умовах адитивної складової перешкоди (білого шуму з нульовим математичним сподіванням M = 0 і $\sigma = 0,01$, рис. 2.23, б). Графіки на рис. 2.23, а, б, а також значення, наведені у табл. 2.36, є похибками обчислень витрати палива для нейромережевих моделей (персептрон і РБФ), а також для поліноміальної регресійної моделі восьмого порядку, отриманої за допомогою МНК (1– метод найменших квадратів; 2 – персептрон; 3 – традиційна РБФ-мережа; 4 – поліморфна РБФ-мережа).



Рисунок 2.23 – Результати дослідження нейромережевих і класичного методів ідентифікації зворотної багаторежимної моделі авіаційного двигуна ТВЗ-117

Аналіз отриманих результатів (табл. Б.32) свідчить, що поліморфна РБФ-мережа проявляє поліпшені характеристики у виконанні непрямих вимірювань витрати палива в широкому діапазоні роботи двигуна: за відсутності шуму – з похибкою не більше 0,151 %; за наявності шуму ($\sigma = 0,01$) – з похибкою не більше 0,555 %. Використання МНК в таких умовах призводить до значень похибки: за відсутності шуму – не більше 0,393 %; за наявності шуму – не більше 1,673 %.

Отже, у процесі розв'язання зворотної задачі ідентифікації багаторежимної моделі ГТД вертольотів нейронні мережі виявляються більш стійкими до впливу спотворень початкових даних, ніж традиційні методи, які в умовах шумових перешкод викликають значні похибки ідентифікації.

2.5. Розробка нейромережевого методу класифікації режимів роботи газотурбінних двигунів вертольотів

Для налагодження стратегії оптимального управління технічним станом ГТД вертольотів важливим етапом є класифікація та визначення класів їх станів. При цьому відповідно до досліджень професора Жернакова С.В. [314] динамічна поведінка ГТД вертольотів може бути описаною системою рівнянь у просторі станів:

$$\dot{X}(t) = F(X(t), U(t), V(t), A(t)); \qquad (2.31)$$

$$Y(t) = G(X(t), U(t), V(t)); \qquad (2.32)$$

де X(t) – вектор змінних стану двигуна; U(t) – вектор керуючих впливів; V(t) – вектор зовнішніх впливів, що обурюють; Y(t) – вектор спостережуваних (вихідних) координат; *F*, *G* – нелінійні вектор-функції. Тоді основними причинами зміни станів двигуна можна вважати зміну векторів U(t) і V(t), параметрів ГТД вертольоту A(t), а також зміна операторів *F* і *G* при його функціонуванні.

На рис. 2.24 показано орієнтований граф, що відображає етапи зміни режимів ГТД



Рисунок 2.24 – Модель процесу зміни класів станів ГТД вертольотів [314–317]

вертольотів, де H_1 – клас сталих режимів, для яких U(t) = const, A(t) = const, F(t) = const; H_2 – клас режимів, що супроводжуються лінійним трендом параметрів, для якого U(t) = const, A(t) = var, F(t) = var; H_3 – клас перехідних режимів роботи (станів), для яких U(t) = var, A(t) = const; F(t) = const; H_4 – клас невстановлених режимів роботи (розгін, дроселювання), для яких U(t) = var, A(t) = var, F(t) = var [314–317].

Поміж нормальних (ефективних) технічних станів також виділяються відмовні стани, що виявляються зміною класу операторів F і G у (2.31) і (2.32). Теоретично,

класифікація станів ГТД вертольотів можлива в просторі станів з використанням змінних стану як критеріїв класифікації. Однак доступні для моніторингу компоненти вектору Y(t) містять адитивні випадкові шуми вимірювань. Отже, виникає задача визначення набору параметрів для розробки правил класифікації, які були б нечутливими до випадкових шумів. Ще однією проблемою, що впливає на якість

розпізнавання, є точність визначення меж класами станів ГТД вертольотів унаслідок значної залежності меж від динамічних параметрів двигуна (і спектральних характеристик впливів і випадкових збурень) [314–317]. Основним підходом до класифікації режимів роботи ГТД вертольотів є байєсівський метод [318, 319]. При цьому здійснюється оцінка умовної ймовірності відповідно до

$$P(r_j/k) = \frac{P(r_j)P(k/r_j)}{\sum_{i=1}^{n} P(r_i)P(k/r_i)};$$
(2.33)

де $P(r_j/k)$ – ймовірність *j*-го діагнозу, тобто розглянутий динамічний режим належить до підмножин m_{rj} . Величина $P(r_j/k)$ є апостеріорної ймовірністю, тобто визначається після отримання інформації по комплексу ознак $k = (k_1, k_2, ..., k_n)$. Елемент $P(r_j/k)$ визначає ймовірність появи реалізованого комплексу ознак у підмножині m_{rj} .

До недоліків цього методу відносять [314]:

1. Потребу врахування суттєвих обсягів апріорної та апостеріорної інформації щодо потужності і спектральної щільності впливів, а також похибок вимірювань на всіх режимах роботи ГТД вертольотів.

2. Обмежену можливість класифікації лише на сталих режимах роботи ГТД вертольотів.

3. Низьку якість класифікації через похибки в оцінках масштабу розподілу, зумовлені недостовірною апріорною інформацією та обчислювальними похибками, а також близькістю центрів розпізнавання класів.

Професором Жернаковим С.В. визначено, що покращення якості класифікації режимів роботи ГТД вертольотів досягається за допомогою збільшення компактності аналізованих сигналів кожного класу, вибираючи певний вид нелінійного перетворення простору класифікованих параметрів. Це призводить до зміни відстані між класами і збільшення мір близькості класів в обраній метриці [314]. На теперішній час класифікацію режимів роботи ГТД зазвичай виконують вручну, залучаючи висококваліфікованого спеціаліста. Однак ця робота може бути тривалою та монотонною, що може призвести до помилок і витрат часу. Для подолання цих недоліків у [314] запропоновано використання алгоритму класифікації режимів роботи ГТД на основі нейронних мереж. Важливо відзначити, що нейромережевий класифікатор ґрунтується на відновленій осцилограмі термогазодинамічних показників, але має обмежену застосовність до авіаційних двигунів вертольотів через їх конструктивні особливості.

Тоді часовий ряд, утворений наборами даних за результатами вимірювання термогазодинамічних параметрів ГТД вертольотів $y_1(t), y_2(t), ..., y_N(t)$ на деякому інтервалі спостереження $t \in [t_1, t_2]$, подібно до досліджень професора Жернакова С.В. [314], дозволяє виділити характерні його ділянки, що відповідають певним класам $S_1, S_2, ..., S_k$ станів ГТД вертольотів $\bigcup_{\alpha=1}^{k} S_{\alpha} = S_0$, де S_0 – клас можливих режимів (справних станів).

Процедура розв'язання даної задачі за допомогою нейронної мережі показана на рис. 2.25, де F(t) – вектор бажаних вихідних реакцій нейронної мережі: $F(t) = \{F_1(t), F_2(t), ..., F_M(t)\}, \xi_1, ..., \xi_M$ – виходи нейронної мережі; $\varepsilon_1(t), ..., \varepsilon_M(t)$ –





значення вектору помилки на виході нейронної мережі.

Навчання нейронної мережі зводиться до того, що на вхід подаються «відрізки» часового ряду $y_1(t)$, ..., $y_N(t)$ на певному інтервалі спостереження $t \in [t_i, t_{i+1}]$, які нале-

жать заздалегідь відомим класам (режимам роботи) двигуна S_{α} , ($\alpha = 1, 2, ..., k$). Відповідно до кожного випадку, нейронна мережа генерує бажані реакції у вигляді двійкового представлення номера визнаного класу α . Наприклад, код (0, 0) на виході нейронної мережі відповідає класу сталих режимів ГТД вертольотів, код (0, 1) – класу перехідних режимів, а код (1, 0) – класу невстановлених режимів тощо. Помилка навчання нейронної мережі визначається згідно з виразом [314]:

$$E = \sum_{i=1}^{m} \varepsilon_i^2(t) \to \min.$$
 (2.34)

Мінімуму помилки (2.34) відповідає навчена нейронна мережа, що розв'язує
задачу розпізнавання (класифікації) режимів роботи ГТД вертольотів.



Рисунок 2.26 – Архітектура нейромережевого класифікатора [314]

Основними термогазодинамічними параметрами ГТД вертольотів, що реєструються на борту вертольоту, є n_{TK} і T_{Γ}^* . Нейромережевий класифікатор, запропонований професором Жернаковим С.В. [314], має вигляд, наведений на рис. 2.26, де Δ – тимчасова затримка, $\Delta t = 1$ с. Згідно з рис. 2.41 нейронна мережа повинна мати 2×*L* входів *L* для кожного з параметрів: n_{TK} і T_{Γ}^* . Зазначені *L* па-

раметрів є вимірювані параметри n_{TK} і T_{Γ}^* , а також затримані значення. В якості виходів нейронної мережі є сигнали ξ_1 і ξ_2 . Для навченої мережі виходи повинні приймати значення F_1 та F_2 (табл. Б.33).

У [320] створено метод аналізу часових рядів для класифікації режимів роботи ГТД вертольотів. Розроблений метод передбачає збір, попередню обробку даних та їх сегментацію на основі динамічних характеристик. Дані параметрів, такі як частота обертів ротора або температура газу, вимірюються сенсорами та фільтруються методом ковзного середнього для згладжування флуктуацій і виділення трендів. Нормалізація параметрів забезпечує порівнянність, а аномалії виключаються за заданими пороговими значеннями. Часові ряди декомпонуються на тренди, сезонні компоненти та випадкові похибки, що дозволяє виділяти циклічність у роботі двигуна. Сегментація здійснюється за критеріями стабільності, перехідних процесів та значної варіабельності параметрів. Для виявлення закономірностей використовуються автокореляційний аналіз, кластеризація за допомогою комбінованих метрик (Евклідова відстань та коефіцієнт кореляції Пірсона), а також спектральний аналіз. Класифікація сегментів часових рядів виконується за допомогою попередньо навченої нейронної мережі, що дозволяє автоматично розподіляти дані за заданими класами експлуатаційних режимів.

Для реалізації архітектури нейромережевого класифікатора (рис. 2.26) у [320]

використовується нейронна мережа, що складається з вхідного шару, двох прихованих шарів і вихідного шару (рис. 2.27). Вхідний шар містить три нейрони, відповідні параметрам n_{TK} , T_{Γ}^* , n_{CB} , доповнені лініями затримки для врахування часової залежності даних. Перший прихований шар складається з 64 нейронів, активованих функцією Smooth ReLU [321], яка для x > 0 є класичною ReLU, а для $x \le 0$ використовує сигмоїдальну функцію, що забезпечує плавний перехід до від'ємних значень, сприяючи швидшому навчанню. Другий прихований шар містить 32 нейрони з такою ж функцією активації. Вихідний шар включає два нейрони з функцією активації Softmax для формування розподілу ймовірностей трьох взаємовиключних класів вихідних комбінацій: (0,0), (1,0), (0,1). Така архітектура дозволяє ефективно враховувати часову залежність і виявляти приховані патерни у вхідних даних. Функція Smooth ReLU забезпечує нелінійність і плавність, необхідні для вловлювання складних залежностей, тоді як вихідний шар з Softmax забезпечує точну класифікацію робочих режимів ГТД вертольотів, досягаючи оптимального балансу між узагальненням і точністю.



Рисунок 2.27 – Пропонована структура нейронної мережі як нейромережевого класифікатора режимів роботи ГТД вертольотів (авторський доробок [242])

Згідно з [320], розроблений алгоритм навчання нейромережевого класифікатора режимів роботи ГТД вертольотів включає підготовку даних, використання механізму

уваги для обробки часових рядів та оптимізацію параметрів мережі з використанням алгоритму Adam. На етапі підготовки даних формується навчальна вибірка, де кожен вектор параметрів $X = (n_{TK}, T_{\Gamma}^*, n_{CB})$ нормалізується і перетворюється методом «timedelay embedding», що враховує затримки до τ . Механізм уваги додається між вхідним вектором і першим прихованим шаром для виділення значущих часових точок, визначаючи вагові коефіцієнти для кожного моменту часу. Контекстний вектор, отриманий як зважена сума часових точок, подається на вхід нейронної мережі, що дозволяє зосередитись на найважливіших моментах при навчанні.

Алгоритм розв'язання цієї задачі досліджено на прикладі даних, записаних на борту вертольоту Ми-8МТВ для двигуна ТВЗ-117 (рис. 2.28) у шестихвилинному інтервалі польоту вертольоту з дводвигуновою силовою установкою. Розпізнавальними режимами роботи двигуна є сталі режими (І), режим розгону (ІІ), режим дроселювання (ІІІ) [320].



Рисунок 2.28 – Оцифрована осцилограма термогазодинамічних процесів авіаційного двигуна ТВЗ-117 (авторський доробок [320])

Основною ознакою, за якою здійснюється виділення «еталонних» ділянок часового ряду при побудові навчальної вибірки нейронної мережі, є положення ручки управління двигуном (*RUD*). Надалі із загальної групи термогазодинамічних параметрів, наведених на оцифрованій осцилограмі, будемо розглядати ті з них, які відносяться до першого двигуна (N = 1): $n_{TK}^{(1)}$ – частота обертів ротора турбокомпресора (крива 1), %; $T_{\Gamma}^{(1)}$ – температура газів перед турбіною компресора (крива 5), %.

Ці дані у сукупності з часовою координатою t (хв) утворюють вхідний вектор $y(t) = \{n_{TK}^{(1)}, T_{\Gamma}^{(1)}\}$, де $t \in [7,268;13,374]$. У процесі роботи з осцилограмою (рис. 2.43) був виділений інтервал навчання $T_{naev} \in [7,268 \text{ xB}; 13,374 \text{ xB}]$, відповідний двом хвилинам, в межах якого існують такі режими: режим розгону: $t_1 = 7,268 \text{ xB}; t_2 = 7,318 \text{ xB};$ сталий (0,8 номіналу) режим: $t_2 = 7,318 \text{ xB}; t_3 = 8,268 \text{ xB};$ режим дроселювання: $t_3 = 8,268 \text{ xB}; t_4 = 8,308 \text{ xB}$. Дані знімалися кожну секунду, тому навчальна вибірка містила 120 часових відліків. При цьому на режими розгону і дроселювання припадало лише по п'ять відліків. Загальний інтервал спостережень склав шість хвилин (360 часових відліків). Для якісної класифікації, ширина часового вікна повинна бути не менше п'яти відліків, щоб розпізнати класи технічних станів.

Для розпізнавання режимів роботи (класів станів) ГТД вертольотів гібридною нейронною мережею необхідно зі значень часового ряду спостережень виділити інтервали, які в межах часового вікна $\Delta y_i(t)$ відповідають сталим режимом роботи двигуна. Це здійснюється шляхом обчислення середнього значення (змінного середнього), в межах часового вікна, на всьому інтервалі $t \in [t_1; t_2]$, оскільки $\Delta y_i(t)$ на сталому режимі роботи тотожно дорівнює нулю, а на інших режимах роботи двигуна відмінно від нуля.

При навчанні нейромережевого класифікатора (рис. Б.10) ширина вікна була прийнята рівною *L* = 12, що відповідає 3 × *L* = 36 входам нейронної мережі. Аналіз рис. 2.44 показує, що при вирішенні задачі класифікації (розпізнавання) режимів роботи ГТД вертольотів достатньо прийняти ширину часового вікна рівною 8...12.

Для розпізнавання режимів роботи (класів станів) ГТД вертольотів нейронною мережею необхідно зі значень часового ряду спостережень виділити відліки, які в межах часового вікна $\Delta y_i(t)$ відповідають сталим режимом роботи двигуна. Це здійснюється шляхом обчислення середнього значення (змінного середнього), у межах часового вікна, на всьому інтервалі $t \in [t_1; t_2]$, оскільки $\Delta y_i(t)$ на сталому режимі роботи тотожно дорівнює нулю, а на інших режимах роботи двигуна відмінно від нуля:

$$\Delta y_i(t) = y_i - \frac{1}{L} \cdot \sum_{i=0}^{L-1} y_i; \qquad (2.35)$$

де *L* – ширина «вікна». Оптимальний розмір часового вікна визначається експериментально з уточненням показників однорідності та репрезентативності навчальної і тестової вибірок. Після процесу навчання нейронної мережі на інтервалі навчання (67 % вибірки) здійснюється перевірка ефективності її роботи на тестовій вибірці, що становить 33 % обсягу всієї вибірки (рис. 2.29).



Рисунок 2.29 – Результати розпізнавання класів станів двигуна ТВЗ-117 («синя крива» – еталон; «помаранчева крива» – запропонований класифікатор нейронної мережі): а – 1-й вихід (*n*_{TK}); б – 2-й вихід (*T*^{*}_Г); в – 1-й вихід (*n*_{TK}) з урахуванням помилок; г – 2-й вихід (*T*^{*}_Г) з урахуванням помилок (авторський доробок [320])

З рис. 2.45 видно, що еталонні значення виходів нейронної мережі приймають значення 0 або 1, а фактичні сигнали на виході нейронної мережі (в силу інерційності процесу часового переміщення («вікна») можуть приймати безперервні значення в інтервалі [0; 1]. Тому подібно до [319] здійснюється округлення обчислених значень ζ_1

та ξ₂ до найближчого цілого числа:

$$\overline{\xi_i} = \begin{cases} 0, \text{ якщо } \xi_i \le 0, 5; \\ 1, \text{ якщо } \xi_i > 0, 5. \end{cases}$$
(2.36)

При цьому можуть мати місце помилки І і ІІ роду, тобто віднесення стану S_i до класу S_j . Для визначення достовірності класифікації визначаються коефіцієнти помилковою і якісної класифікації відповідно до (2.40) і (2.41) за тривалості тестової вибірки $T_0 = 4$ хв.

У табл. Б.33 і Б.34 наведені результати порівняльного аналізу помилок класифікації та якості класифікації режимів роботи двигуна для різних класів архітектур нейронних мереж.

Зазначається, що модель процесу зміни класів станів ГТД вертольотів (рис. 2.29) надала підстави провести низку досліджень, в ході яких створено дискретну мережу Маркова задля ідентифікації змін стану ГТД вертольотів у режимі льотної експлуатації [322–328]. Використовуючи матричний метод навчання динамічних рекурентних нейронних мереж, у [329, 330] отримано сигнальний графік рекурентної нейронної мережі, навченої ідентифікувати перехідний процес на виході другого нейрона, що сигналізує про нормальну роботу авіаційного двигуна ТВЗ-117, а також подібні графіки відповідних перехідних процесів на виходах інших нейронів.

Висновки до другого розділу

1. Запропоновано метод поетапного створення нейронної мережі для розв'язання прикладних задач моніторингу ГТД вертольотів, в якій обґрунтовані редукція нейронної мережі та заходи для підвищення робастності моделі, що свідчать про намагання досягти максимальної ефективності.

2. Розроблено метод формування однорідних і репрезентативних навчальних і тестових вибірок на основі бортових даних термогазодинамічних параметрів турбовальних ГТД вертольотів, що забезпечує створення ефективних нейромережевих моделей з високою точністю для моніторингу технічного стану зазначеного класу двигунів.

3. Вперше розроблено поліморфну архітектуру РБФ-мережі, яка завдяки динамічній структурі прихованого шару, застосуванню множення замість підсумовування радіальних елементів та адаптивній кількості багатовимірних радіально-базисних функцій, забезпечує покращену узагальнюючу здатність, підвищену стійкість до шуму та мінімізацію обчислювальної складності, демонструючи експериментально підтверджені результати: час навчання складає 1 мс, помилки навчання й тестування складають 0,38 і 0,73, що у 12,8 і 8,4 рази нижче, ніж у класичної РБФ-мережі, у 17,5 і 10,1 рази нижче, ніж у РБФ-мережі з окремим прихованим шаром для кожної змінної, та у 1,2 і 10,2 рази нижче, ніж у РБФ-персептрона, при цьому похибка апроксимації аналітичних залежностей не перевищує 0,32 %.

4. Вперше розроблено алгоритм навчання поліморфної РБФ-мережі на основі еволюційного підходу, який завдяки ініціалізації вагових коефіцієнтів із урахуванням структури задач, турнірному відбору для мутацій, додатковим критеріям у функції пристосованості та використанню еволюційної стратегії мутації забезпечує найнижчі помилки навчання (0,38 %) і тестування (0,73 %) для структури 2–36–1, що у 17,5 та 10,1 рази нижче за помилки навчання (6,64 %) і тестування (7,38 %) класичної РБФ-мережі, у 12,8 і 8,4 рази нижче за відповідні помилки (4,87 % і 6,11 %) РБФ-мережі з окремим прихованим шаром та у 1,2 і 10,2 рази нижче за помилки (0,45 % і 7,43 %) РБФ-персептрона, при цьому час навчання поліморфної РБФ-мережі становить 1 мс, що у 9 разів швидше за інші архітектури.

5. Експериментально підтверджено можливість практичного застосування вперше створеної поліморфної РБФ-мережі та її алгоритму навчання для багатокритеріальної оптимізації параметрів робочого процесу авіаційного двигуна ТВЗ-117, що дозволило отримати просторові залежності напруги розтягнення в лопатці робочого колеса останнього ступеня турбіни і питомої витрати палива, побудувати оптимальний Парето-фронт для трьох додаткових режимів роботи двигуна (зменшення питомої витрати палива при збільшенні ступеня підвищення повного тиску в компресорі на 5,0 %, мінімізація питомої витрати палива при збільшенні ступеня підвищення повного тиску в компресорі на 5,0 %, оптимізація питомої витрати палива при зниженні ступеня підвищення повного тиску в компресорі на 1,0 %, оптимізація ступеня підвищення тиску при підвищенні питомої витрати на 10,5 %), а також продемонструвати переваги цієї мережі над SMEA та MDESL, про що свідчать метрики IGD (1,168...1,795 проти 0,876...1,192 у SMEA і 2,987...4,017 у MDESL) та HV (5,026...5,622 проти 3,092...3,832 у SMEA і 1,377...1,922 у MDESL), забезпечуючи командирам екіпажів можливість коригування режимів роботи двигуна під час польоту для підвищення безпеки та ефективності експлуатації.

6. Науково обгрунтовано перехід від тришарового персептрона до гібридної нейронної мережі NARX із радіально-базисним шаром для ідентифікації багаторежимної моделі ГТД вертольотів за бортовими параметрами, що дозволило розвинути метод обчислення елементів матриці Гессе, скоротивши час обчислень на 1,82...1,96 разів порівняно з центральною різницевою похідною та на 11,5...14 разів за рахунок прямих обчислень, оптимізувати параметр регуляризації у методі Левенберга-Марквардта, знизити середню помилку навчання на 72 % (з 1,43 до 0,4), забезпечити стабільність функції втрат (не більше 2,5 %) протягом 500 епох навчання, а також зменшити максимальну абсолютну похибку ідентифікації вдвічі (з 0,74 % до 0,43 %), при цьому забезпечивши низький рівень похибки ідентифікації (0,71 % для гібридної NARX-мережі та 1,09 % для тришарового персептрона) та мінімальні коефіцієнти помилкової ідентифікації (0,528 % для гібридної NARX-мережі та 0,638 % для тришарового персептрона), що підтверджує високу робастність і ефективність моделей у реальних умовах

7. Аналіз результатів ідентифікації параметрів ГТД вертольоту на основі математичної моделі (на прикладі двигуна ТВЗ-117) продемонстрував переваги нейромережевих методів порівняно з класичними підходами. Установлено, що нейронні мережі забезпечують точніше визначення параметрів: похибка ідентифікації за допомогою персептрона виявилася у 1,6...3,16 разів меншою, ніж у моделі, побудованій МНК, а для поліморфної РБФмережі – у 8,14 разів меншою. Максимальна похибка ідентифікації параметрів для поліморфної РБФ-мережі не перевищила 0,7 % за відсутності шуму, тоді як для МНК цей показник склав 5,7 %. Умови дії шумів ($\sigma = 0,01$) також підтвердили робастність нейромережевих методів: похибка для персептрона, традиційної та поліморфної РБФ-мережі зросла до 3,8 %, 5,7 % та 1,4 % відповідно, тоді як для МНК вона досягла 13,93 %. Дослідження показали, що нейромережеві методи дозволяють виконувати непряме вимірювання параметрів проточної частини двигуна з високою точністю навіть за наявності шумів, забезпечуючи похибку не більше 1,4 %, що значно перевищує можливості класичних методів.

8. Розроблена нейромережевий метод класифікації режимів роботи ГТД вертольотів, що дозволяє командиру екіпажу приймати рішення з точністю до 0,945 (94,5 %), зменшуючи помилки першого типу на 2,09...2,14 рази та помилки другого типу на 2,05...2,21 рази порівняно з класифікатором на основі мереж ART-1 та BAM [316], при цьому навчання нейронної мережі забезпечило точність майже до 100 % і зниження втрат до 0,025 (2,5 %).

Основні результати досліджень, викладених у розділі, опубліковано у наукових працях [222–227, 235–239, 256–260, 263, 268, 294–302, 307, 308, 310, 313, 315–318, 320–330].

РОЗДІЛ З

НЕЙРОМЕРЕЖЕВІ МЕТОДИ РОЗВ'ЯЗАННЯ ПРИКЛАДНИХ ЗАДАЧ МОНІ-ТОРИНГУ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕРТОЛЬОТІВ

3.1 Розробка методу ідентифікації динамічної багаторежимної моделі газотурбінного двигуна вертольоту

Для ефективного розв'язання задачі ідентифікації динамічної багаторежимної моделі ГТД вертольоту необхідно проаналізувати існуючі закони управління та удосконалити їх задля забезпечення оптимальних режимів роботи [331–343], що неможливо без адекватних математичних моделей двигуна у формі диференціальних рівнянь. Опис моделей на теперішній час є неповним, оскільки не враховує різноманітні зв'язки та збурення у термодигазонамічних процесах, що перебігають у ГТД вертольотів. У цьому плані найбільш ефективним є застосування динамічних нейронних мереж задля апроксимації отриманих результатів досліджень термогазодинамічних процесів, наприклад, у двигуні ТВЗ-117 (вертоліт Ми-8МТВ) [338–343].

На теперішній час для ідентифікації динамічних об'єктів поширення набули динамічні рекурентні нейронні мережі, зокрема, нелінійна авторегресійна мережа (Nonlinear Autoregressive Network – NARX-мережа) і нейронна мережа Елмана – окремий випадок багатошарової рекурентної мережі (Layer-Recurrent Network – LRN-мережа) [339].

Під час навчання зазначених нейронних мереж вихідні дані реєструвалися у процесі льотних випробувань авіаційного двигуна ТВЗ-117 на борту вертольоту Мі-8МТВ за допомогою бортової системи контролю (запис даних відбувався в інтервалі 320 с реального польоту з періодом дискретизації 1 с [339, 344]). Динаміка параметрів авіаційного двигуна ТВЗ-117 відображає складність форми часових рядів (рис. 3.1), а сам вигляд кривих свідчить про необхідність урахування значень параметрів і накопичення інформації в пам'яті моделі.



Рисунок 3.1 – Часовий ряд динаміки параметрів двигуна ТВЗ-117 з використанням оцифрованих осцилограм: 1 – n_{TK} ; 2 – T_{Γ}^{*} ; 3 – n_{CB}

На рис. 3.1 видно збільшення значень параметрів у часовому проміжку від 21 до 62 с приблизно у 1,5...1,8 разів, що пояснюється перехідним режимом роботи двигуна. Зазначено, що близько 85 % часу двигун працює на сталих режимах, і лише приблизно 15 % – у перехідних режимах [345, 346]. Оскільки персептронні нейромережеві моделі охоплюють лише сталі режими, для розширення номенклатури параметрів технічного стану ГТД вертольотів розробляється динамічна багаторежимна модель з урахуванням особливостей роботи двигуна у перехідних режимах.

У [339] проведено моделювання динамічного розподілу параметрів робочого процесу авіаційного двигуна ТВЗ-117 із використанням NARX-мережі та мережі Елмана. Для NARX-мережі змінювали кількість ліній затримки (1–5) та нейронів у прихованому шарі (1–20) з алгоритмом Левенберга-Марквардта, отримавши мінімальне СКВ 52,4 для конфігурації з 15 нейронами та трьома лініями затримки. Однак модель демонструвала нестійкість при подачі нових даних, що вказує на її невідповідність задачі ідентифікації. Для мережі Елмана досліджено вплив кількості нейронів у прихованому шарі (1–20) з алгоритмом traingdx, і найменше СКВ (41,83) отримано для одношарової мережі з двома нейронами та подвійною затримкою сигналу зворотного зв'язку. Збільшення складності мережі погіршувало її чутливість до змін вхідних сигналів. Таким чином, мережа Елмана виявилася більш стійкою та здатною адекватно відображати динаміку параметрів ГТД вертольотів, що дозволяє рекомендувати її для використання з вказаними параметрами.

Для навчання мережі Елмана використовуються градієнтні методи, подібні до

методів для звичайних прямопередавальних мереж, з певними модифікаціями [347], що дозволяє коректно обчислювати градієнт функції похибки методом зворотного поширення в часі, перетворюючи рекурентну мережу на «звичайну». Процес обчислення градієнта складається з прямого проходу (обчислення стану шарів), зворотного проходу (визначення похибки шарів) та розрахунку змін ваг на основі даних попередніх етапів. Додавання динамічної стекової пам'яті до рекурентних нейронних мереж забезпечує адаптивне зберігання попередніх подій і створює гнучкий інструмент для розробки нелінійних моделей [347]. Модифікована мережа Елмана (рис. В.1) отримується шляхом додавання затримки до сигналів зворотного зв'язку прихованого шару, тобто включення шару динамічної стекової пам'яті. Використання динамічної стекової пам'яті (рис. В.2) забезпечує значні переваги порівняно з альтернативними механізмами пам'яті, такими як фіксовані затримки чи рекурентні механізми, зокрема ефективніше управління контекстною інформацією, адаптивність до змін структури вхідних даних і здатність обробляти довгі послідовності з часовими залежностями. Це підвищує точність прогнозування завдяки кращому збереженню інформації про минулі стани, зменшує обчислювальну складність і втрати критичної інформації, що особливо важливо для задач реального часу, таких як керування ГТД вертольотів.

На підставі вищезазначеного можна констатувати, що модифікована нейронна мережа Елмана описується без змін рекурентними рівняннями [344]:

$$v_{j}(n+1) = \sum_{i=1}^{p} w_{ji}^{(1)} u_{i}(n) + \sum_{i=1}^{N} w_{ji}^{c} x_{i}(n) + b_{j}^{(1)}; \qquad (3.1)$$

$$x_j(n+1) = F_1(v_j(n+1)); j = 1, 2, ..., N;$$
 (3.2)

$$y_{j}(n+1) = F_{2}\left(\sum_{i=1}^{N} w_{ji}^{(2)} x_{i}(n+1) + b_{j}^{(2)}\right); j = 1, 2, ..., M;$$
(3.3)

або у матричній формі:

$$\mathbf{X}(n+1) = \mathbf{F}_{1}\left(\mathbf{W}^{(1)}\mathbf{U}(n) + \mathbf{W}^{c}\mathbf{X}(n) + \mathbf{B}^{(1)}\right); \qquad (3.4)$$

$$\mathbf{Y}(n+1) = \mathbf{F}_{2}\left(\mathbf{W}^{(2)}\mathbf{X}(n+1) + \mathbf{B}^{(2)}\right); \qquad (3.5)$$

де U(n) – вектор зовнішніх вхідних сигналів у часі (*n*); *p* – число зовнішніх входів мережі; **X**(*n*) – вектор вихідних сигналів прихованого шару у момент часу (*n*); *N* – число сигналів у контекстному шарі; $\mathbf{W}^{(1)}$, \mathbf{W}^c , $\mathbf{W}^{(2)}$ – матриці синаптичних ваг зовнішніх вхідних сигналів, сигналів контекстного та вихідного шару відповідно; $\mathbf{B}^{(1)}$, $\mathbf{B}^{(2)}$ – вектори ваг зсувів у нейронах прихованого та вихідного шару відповідно; \mathbf{F}_1 , \mathbf{F}_2 – вектори функцій активації у прихованому та вихідному шарі відповідно; $\mathbf{Y}(n + 1)$ – вектор вихідних сигналів мережі у момент часу (n + 1); M – кількість виходів мережі. Виходи прихованого шару, позначені як v_1 , v_2 , ..., v_N , подаються на вхідні нейрони за допомогою вагових коефіцієнтів $\{w_{ij}\}^{-i}$, де i – індекс нейрона, що надсилає сигнал (i = 1, 2, ..., n); j – індекс вихідного сигналу нейрона прихованого шару (j = 1, 2, ..., k); t = 1 – індекс часової затримки (для мережі Елмана). При детальному розгляді архітектури нейронної мережі (рис. В.1) видно, що зворотним зв'язком від прихованого шару або від виходу мережі можна знехтувати шляхом включення до навчальної вибірки сигналів зворотного зв'язку.

У [344] розроблено математичне забезпечення динамічної стекової пам'яті (рис. В.2). Динамічна стекова пам'ять забезпечує ефективне управління даними під час виконання алгоритмів, особливо у випадках рекурсивних і ієрархічних процесів. Математична модель динамічної стекової пам'яті включає основні параметри: стек S(t), вказівник на вершину стеку H(t) і дані D(t), записані у вершину. Операції над пам'яттю формалізовані як *Push* (додавання елемента), *Pop* (видалення елемента) та *Peek* (перегляд елемента без видалення). Ініціалізація пам'яті починається з порожнього стеку ($S(0) = \emptyset$), а її адаптивне управління реалізовано шляхом поділу на сегменти з максимальним розміром *M*. Автоматичне розширення і стискання стеку відбувається залежно від заповнення сегментів: при перевищенні H(t) > M створюється новий сегмент, а при H(t) < M/2 сегменти об'єднуються. Запропонована сегментована структура дозволяє ефективніше використовувати пам'ять і знижує обчислювальну складність порівняно з традиційними моделями, які оперують суцільними масивами.

У [344] розроблено нелінійні динамічні моделі ГТД вертольотів на режимі запуску і прийомистості двигуна. Нелінійна динамічна модель ГТД вертольотів на режимі запуску двигуна представлена системою диференціальних рівнянь у нормальній формі Коші для швидкостей обертання роторів і алгебраїчних рівнянь для інших параметрів двигуна. Залежність коефіцієнтів моделі від часу та інших змінних режиму забезпечує її адекватність реальним процесам. Для ідентифікації параметрів використовується експериментальна інформація, оброблена методами фільтрації, апроксимації та оптимізації. Результатом є побудова функціональних залежностей коефіцієнтів від параметра режиму, що дозволяє використовувати модель для синтезу і налаштування АПУ ГТД вертольотів. Основу нелінійної динамічної моделі ГТД вертольотів на режимі прийомистості двигуна складають рівняння динаміки турбокомпресора та вільної турбіни, враховуючи газодинамічний зв'язок між їх роторами, а також вплив температури газів перед турбіною компресора. Для забезпечення безперервності похідних і адекватного моделювання нелінійності параметри двигуна представлені у вигляді функціональних залежностей від параметра режиму α. Визначення коефіцієнтів рівнянь моделі проводиться шляхом розв'язання задач оптимізації з використанням експериментальних даних, де для регуляризації застосовуються коефіцієнти відомих лінійних моделей [344].

У [344] розроблено алгоритм навчання модифікованої нейронної мережі Елмана з динамічною стековою пам'яттю, який включає кілька етапів: підготовку даних, ініціалізацію ваг, пряме поширення, зворотне поширення та оновлення ваг. На етапі підготовки даних використовуються вхідні сигнали та зворотні сигнали, що враховують часові затримки методом створення лагових ознак, які забезпечують обробку часових залежностей. Для підвищення точності та стабільності оптимізації застосовується n-го порядку фільтр Баттерворта [348], який згладжує сигнали. Початкові параметри алгоритму оптимізації Adam ініціалізуються, включаючи ваги та моменти градієнтів. У процесі прямого поширення розраховуються вихідні сигнали прихованого та вихідного шарів, після чого на етапі зворотного поширення обчислюється похибка та оновлюються ваги. Адаптивність алгоритму забезпечується коригуванням ваг за допомогою Adam, який враховує динаміку градієнтів, а також інтеграцією стекової пам'яті, що дозволяє зберігати часову інформацію.

На рис. 3.2 представлені графіки перехідних процесів параметрів n_{TK} , n_{CB} , T_{Γ}^* , змодельованих на прикладі двигуна ТВЗ-117, отриманих на основі виявленої нелінійної динамічної моделі в режимі запуску. На рис. 3.3 продемонстровано різницю між змодельованими та експериментальними діаграмами перехідних процесів. Результати ідентифікації параметрів нелінійної динамічної моделі ГТД вертольотів на режимі запуску показують, що похибка ідентифікації становить менше 0,5 %. При цьому коефіцієнти представлені у формі функціональних залежностей від параметра режиму, який визначає час

від моменту запалювання в камері згоряння до досягнення режиму холостого ходу.



Рисунок 3.2 – Графіки перехідних процесів параметрів ГТД вертольотів на режимі запуску двигуна (на прикладі двигуна ТВЗ-117): (авторський доробок [344]): а – n_{TK} ; б – T_{Γ}^* ; в – n_{CB}



Рисунок 3.3 – Графіки різниці перехідних процесів параметрів ГТД вертольотів на режимі запуску двигуна між модельованими і експериментальними даними (на прикладі двигуна ТВЗ-117): (авторський доробок [344]): а – *n*_{TK}; б – *T*^{*}_Γ; в – *n*_{CB}

Аналогічні дослідження проведені у [344] із застосуванням нелінійної динамічної моделі ГТД вертольотів на режимі прийомистості двигуна.

Як зазначено у [34, 73], у [344] позначено вектор стану нейронів прихованого шару як *V*, а вектор виходів мережі як *Y*. Вхідний вектор мережі Ельмана у момент часу *k* реалізує відображення:

 $U_1(k) = \{n_{TC}(k), V_1(k-1), V_2(k-1)\}, U_2(k) = \{n_{FT}(k), V_1(k-1), V_2(k-1)\}, U_3(k) = \{T_{\Gamma}^*(k), V_1(k-1), V_2(k-1)\}.$ (3.6)

На рис. 3.5 представлено поверхні розподілу $U_1(k)$, $U_2(k)$, $U_3(k)$, побудовані на основі значень n_{TK} , n_{CB} , T_{Γ}^* . З рис. 3.5 видно, що поверхні розподілу $U_1(k)$, $U_2(k)$, $U_3(k)$ є рівними, без випадкових збурень, що свідчить про стабільність і передбачуваність роботи мережі під час навчання та експлуатації. Відсутність різких коливань у поверхнях

розподілу вказує на якісний підбір параметрів мережі та її здатність ефективно обробляти вхідні дані без суттєвих аномалій або помилок.



Рисунок 3.5 – Поверхні розподілу: (авторський доробок [344]): $a - U_1(k)$; $6 - U_2(k)$; $B - U_3(k)$

Результати оцінки точності ідентифікації динамічної багаторежимної моделі ГТД вертольоту (на прикладі авіаційного двигуна ТВЗ-117) за допомогою нейронної мережі Елмана моделі наведено у табл. В.1.

У ході експериментальних досліджень визначення абсолютної помилки нейромережевого і класичного (МНК) методів здійснено їх порівняльний аналіз в умовах білого шуму (з нульовим математичним сподіванням M = 0 і значеннями $\sigma_T = 0,01$; 0,03; 0,05). Результати роботи цих методів наведені у табл. В.2.

Отримані результати свідчать про перевагу нейромережевих методів (зокрема, використання модифікованої нейронної мережі Елмана) перед класичними (МНК). У деяких випадках помилка динамічної ідентифікації за класичним методом практично вдвічі перевищує відповідні розрахунки з використанням модифікованої нейронної мережі Елмана, що вказує на високу стійкість нейронних мереж до зовнішніх збурень. Отже, за результатами аналітико-експериментальних досліджень можна констатувати таке:

1. Використання модифікованої нейронної мережі Елмана з динамічною стекпам'яттю зі структурою 3–2–2 і градієнтним методом найшвидшого спуску дозволяє розв'язати задачу ідентифікації динамічної багаторежимної моделі ГТД вертольоту з абсолютною похибкою не вище 0,5 %;

2. Точність динамічної ідентифікації параметрів ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) на основі модифікованої нейронної мережі Елмана з динамічною стек-пам'яттю в 1,5 разів вища, ніж застосування МНК;

3. Точність динамічної ідентифікації параметрів ГТД вертольотів в умовах шуму на

основі модифікованої нейронної мережі Елмана з динамічною стек-пам'яттю також у середньому вдвічі вища за МНК.

3.2 Розробка методу контролю технічного стану газотурбінного двигуна вертольоту

Відповідно до [349–356] задача контролю технічного стану ГТД вертольотів у режимі польоту на основі нейронних мереж розглядається таким чином: всі можливі стани ГТД вертольотів класифікуються як два класи – S_0 (справний стан двигуна) і \overline{S}_0 (несправний стан). Обидва класи поєднують споріднені стани, близькі між собою за певними інтегральними показниками. Перехід стану ГТД вертольотів $S_0 \leftrightarrow \overline{S}_0$ характеризується наявністю перехідного стану або так званого «невизначеного класу». Залежно від параметрів стану ГТД вертольотів за результатами обмеженої кількості вимірювань вектору вихідних параметрів двигуна $Y_i(t), t_i \in T$ (де t_i – дискретні моменти часу; T – інтервал моніторингу) приймається рішення про належність двигуна до одного із зазначених класів (система «працездатний \leftrightarrow невизначений \leftrightarrow непрацездатний»). Розв'язок даної задачі у загальному вигляді зводиться до визначення деякої роздільної функції (площини або гіперповерхні) у просторі контрольованих параметрів ГТД вертольотів.

Професором Жернаковим С.В. розроблено нейромережевий метод контролю технічного стану авіаційних турбореактивних двигунів, в якому поточний стан двигуна показаний як точка в просторі контрольованих параметрів $y_1, y_2, ..., y_n$. Для оцінки ступеня працездатності двигуна (відповідність його характеристик вимогам, що висуваються), необхідно обчислити відстань від даної точки до еталонної точки порівняльної оцінки еталонного (справного) двигуна. Якщо ця відстань дорівнює нулю, то технічний стан двигуна відповідає еталонному, а, відповідно, чим більше величина вказаної відстані, тим більше відмінність характеристик контрольованого і еталонного двигунів. Оцінка метричної відстані (метрик) здійснюється за Евклідовою метрикою і метрикою Чебишева [124]:

$$d = \sqrt{\sum_{i=1}^{n} (y_i - y_i^{eman})^2};$$
(3.7)

$$d = \max \left| y_i - y_i^{emax} \right|; \tag{3.8}$$

де *y_i* – виміряне значення *i*-го параметра двигуна; *y_i^{етал}* – еталонне значення цього параметру за показниками нейронної мережі.



Фізичний сенс метрики (3.7) – характеристика СКВ у просторі виходів між параметрами поточної й еталонної моделей двигуна, а метрика (3.8) – найбільше відхилення між цими виходами. Процес прийняття рішення про технічний стан двигуна за результатами контролю його параметрів, може здійснюватися на основі правил нечіткої логіки, де функції належності (рис. 3.6) призначаються

експертно, а рішення про справність двигуна *R* видається у вигляді коефіцієнтів впевненості. Вирішальне правило, на основі якого приймається рішення про справність двигуна, описується системою [124]:

$$R = \begin{cases} S_o, \text{ якщо } d = S(\text{Small}); \\ \overline{S_o}, \text{ якщо } d = L(\text{Large}). \end{cases}$$
(3.9)

Остаточне рішення про технічний стан двигуна приймається експертом з урахуванням отриманих значень коефіцієнтів впевненості: на рис. 3.7 величина *α*₁ означає коефіцієнт впевненості виконання першого правила у (3.9); *α*₂ – аналогічна величина для другого правила. Отже доведено, що вищевикладений метод може бути адаптований до ГТД вертольотів.

На підставі вищевикладеного створюються умови для вирішення задачі контролю технічного стану ГТД вертольотів у режимі льотної експлуатації із застосуванням нейромережевих алгоритмів без експертної оцінки (рис. В.3).

На першому етапі, шляхом систематизації даних, формується модель ГТД вертольоту, після чого створюється нейронна мережа для уникнення її неуніверсальності, здійснюється вибір архітектури мережі для кожної нової задачі та тестування в конкретних умовах. Для зручності подальшого використання та виведення графічної інтерпретації результатів проводиться редукція вихідних даних, що є необхідним для контролю роботи нейронної мережі за наявності додаткових етапів контролю. Найчастіше для розв'язання задач контролю технічного стану складних динамічних об'єктів застосовуються нейронні мережі прямого поширення, вхідні нейрони яких є значеннями атрибутів класифікованого об'єкта, а вихідні – мітками або числовими кодами класу. Для цієї задачі можна використовувати багатошарові персептрони, де елементи вектора ознак надходять на вхідні нейрони та розподіляються на всі нейрони першого прихованого шару, що змінює розмірність задачі, як показано в [351] за методом зворотного поширення помилки. Обчислювальну складність значно знижує застосування рекурентної нейронної мережі [351], що робить її оптимальним варіантом для поставленої задачі, оскільки вона забезпечує менший відсоток помилок порівняно з іншими методами (рис. В.4), а також має простішу реалізацію, ніж згорткові мережі.

Для розв'язання задачі контролю технічного стану ГТД вертольотів у польотних режимах пропонується використання рекурентної нейронної мережі архітектури LSTM зі змінною пам'яттю, що була застосована Кузнєцовою Т.А. для дослідження моделі турбореактивного двигуна JetCat P-60 [352].

Основною особливістю LSTM мереж (комірок) є набір невеликих повнозв'язаних нейронних мереж – гейтів або вузлів. Кожна комірка має один вихідний нейрон для прогнозування конкретного параметра. Кілька таких комірок утворюють мережу для прогнозування різних параметрів. Основною особливістю LSTM мереж є наявність тензора пам'яті – змінної, яку можна записувати чи очищати в процесі функціонування мережі. Робота LSTM мережі ґрунтується на принципі управління тензором пам'яті за допомогою вузлів запам'ятовування та забування: *Forget gate* (*sig*) – вузол забування з функцією сигмоїдальної активації; *Input gate* (*sig*) – вхідний вузол із сигмоїдною функцією активації; *Cand. cell state* (*tanh*) – вузол для обчислення тензора-кандидата на запис у пам'ять про тангенціальну функцію активації; *Output gate* (*sig*) – вихідний вузол із сигмоїдною функцією активації [352].

Для моделювання складних динамічних процесів з вираженим перерегулюванням в роботах Кузнєцової Т.А. [352] вузли *Forget gate* та *Input gate* об'єднані у вузол *Control*

gate – керуючий вузол із сигмоїдною функцією активації, що дозволило зменшити кількість вагових коефіцієнтів та матричних операцій, а також вузол *Cand. cell state* перейменовано *в Recording gate* – записуючий вузол із тангенціальною функцією активації, зберігаючи його функціональність. Ключовою зміною в архітектурі стало введення функціональної залежності вузла *Output gate* від тензора пам'яті, що дозволило незалежно від кількості виходів моделі регулювати розмір пам'яті (рис. 3.8). Отже, модифікована мережа LSTM відповідно до [352] містить три вузли – керуючий вузол (*Control gate*), записуючий вузол (*Recording gate*) і вихідний вузол (*Output gate*). Для обчислення тензора пам'яті використовуються два з них – керуючий та записуючий вузли:

$$c_{t} = n_{t} \circ c_{t-1} + (1 - n_{t}) \circ r_{t}; \qquad (3.10)$$

де c_t – тензор пам'яті на поточному кроці; c_{t-1} – тензор пам'яті на попередньому кроці; n_t – тензор на виході з керуючого вузла; r_t – тензор на виході із записуючого вузла.



Рисунок 3.8 – Структура LSTM мережі зі змінною пам'яттю [350, 352]

Керуючий вузол визначає, скільки інформації слід забути або наскільки важливо нову інформацію записати в пам'ять, й враховує вхідні значення, вихідні значення з попереднього кроку і значення, що зберігаються в пам'яті мережі. Записуючий вузол визначає нову інформацію, яка потенційно може бути збережена у внутрішню пам'ять мережі. Отже, значення в пам'яті може змінюватися, збільшуючись або зменшуючись залежно від поточних вхідних і вихідних значень на попередньому етапі. Коли результат обчислень керуючого вузла дорівнює нулю, відповідне значення тензора пам'яті анулюється. Коли значення тензора дорівнює одиниці, значення пам'яті залишається незмінним. Для проміжних значень відбувається запис виваженої суми записуючого вузла і тензора пам'яті. Головна відмінність цієї архітектури мережі полягає у використанні пам'яті мережі у вихідному вузлі. Це дозволяє використовувати розмірність тензора пам'яті як новий гіперпараметр мережі [352]:

$$n_{t} = \sigma \cdot (W_{cn} \cdot c_{t-1} + W_{hn} \cdot h_{t-1} + W_{xn} \cdot x_{t} + b_{n}); \qquad (3.11)$$

$$r_{t} = \tanh(W_{hr} \cdot h_{t-1} + W_{xr} \cdot x_{i} + b_{r}); \qquad (3.12)$$

$$h_{t} = \sigma \cdot (W_{ch} \cdot c_{t} + W_{hh} \cdot h_{t-1} + W_{xh} \cdot x_{t} + b_{h}); \qquad (3.13)$$

де W_{cn} , W_{hn} , W_{xn} , W_{hr} , W_{xr} , W_{ch} , W_{hh} , W_{xh} – вагові коефіцієнти, що пов'язують входи з вузлами; b_n , b_r , b_h – вектор зсувів керуючого, записуючого вихідного вузлів відповідно; h_{t-1} – тензор виходу мережі на попередньому кроці; x_t – тензор входу на поточному кроці; h_t – тензор виходу мережі на поточному кроці.

Для розв'язання задачі контролю технічного стану ГТД вертольотів на основі LSTM мережі зі змінною пам'яттю використано навчальну вибірку з достатньою кількістю векторів – 10000 векторів [352]. Навчальна вибірка складається зі значень основних термогазодинамічних параметрів ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) згідно з [350]. Кожному з цих параметрів присвоєно відповідний пріоритет, необхідний для функціонування нейронної мережі.

Тестовий варіант LSTM мережі зі змінною пам'яттю розроблено у середовищі Matlab: спочатку на вхід мережі послідовно подаються всі 10000 векторів навчального набору, за допомогою чого було здійснено її навчання відповідно алгоритму [350]. Щоразу, після навчання на 2000 наборів проводилось тест-навчання задля перевірки помилки на 100 довільних наборах (тестовий контроль помилки). На етапі остаточного контролю перевірено помилку на 1000 наборів (10 % від навчальної множини) – помилкова оцінка не перевищувала заданий поріг 1,2 %. Як алгоритм оптимізації LSTM мережі зі змінною пам'яттю застосовано алгоритм *Adam* – один із найефективніших алгоритмів оптимізації у навчанні рекурентних нейронних мереж. Цільовою функцією виступав показник *Accuracy* – метрика, що відповідає здатності нейронної мережі давати правильний результат для загальної кількості досліджень. Для оцінки якості навчання нейронної мережі можуть бути використані різні показники якості, зокрема такі показники, як точність (*Accuracy*), помилка (*Loss*), точність (*Precision*), повнота (*Recall*), *F*-міра.

Результати навчання LSTM мережі зі змінною пам'яттю за показниками

Accuracy та *Loss* наведено на рис. В.5 і В.6 відповідно. Як видно із рис. В.5 і В.6, показник *Accuracy* наближається до одиниці, а *Loss* – прагне до нуля, що свідчить про високу точність моделі і про мінімальну її помилку. У табл. В.3 наведені середні значення показників результатів навчання моделі, а також значення математичного очікування та дисперсії за показником *Accuracy*.



Рисунок 3.9 – Результати контролю технічного стану двигуна ТВЗ-117 (авторський доробок [350])

На рис. 3.9 наведено графік гіперповерхні у просторі контрольованих параметрів ГТД вертольотів у польотних режимах (на прикладі двигуна ТВЗ-117). У результаті своєї роботи навчена LSTM мережа зі змінною пам'яттю розбила всі подані на її входи значення ступеня підвищення повного тиску в компресорі на три області (рис. 3.14), що відповідають справному (синя область), несправному (червона область) та невизначеному станам, де складно виконати поділ значень па-

раметрів зважаючи на їх взаємне перекриття (зелена область). LSTM мережа зі змінною пам'яттю інтегрується в бортову систему контролю ГТД вертольотів, здатна в режимі реального часу співвідносити значення контрольованого параметра (ступеня підвищення повного тиску в компресорі) з однією з областей, і у разі його попадання в область несправного стану – видавати сигнал про несправність, що зароджується. Ця інформація (залежно від ступеня небезпеки) може видаватися командиру екіпажу вертольоту для своєчасного прийняття рішення щодо можливості здійснення польоту.

За результати кластеризації стану двигуна, наприклад, відповідно до методу професора Жернакова [124] отримано графік розподілу значень метрики Чебишева і Евклідової метрики (рис. 3.10). Згідно з отриманими результатами, досліджуваний двигун працездатний (тобто функціонує нормально) в інтервалі часу від 0 до 105 годин.



У момент часу 105 годин зафіксовано різкий стрибок метрики, після чого спостерігається стійка тенденція зростання метричної відстані, що вказує на зміну характеристик двигуна. Результати аналізу свідчать про наявність дефекту в першій і другій ступенях компресора, який спричиняє обрив двох компресорних лопа-

Рисунок 3.10 – Результати контролю технічного стану двигуна ТВЗ-117 (авторський доробок [349, 350])

ток. Це унеможливлює подальшу експлуатацію двигуна, що потребує негайного його зняття з використання. При цьому досягнуто точність 99,3 %.

Аналогічні дослідження були проведені із використанням інших архітектур нейронних мереж (багатошаровий персептрон, згорткова нейронна мережа, нейронна мережа Хопфілда, нейронна мережа Коско, нейронна мережа Джордана, нейронна мережа Елмана). Варто зазначити, використання зазначених архітектур нейронних мереж не дозволило адекватно класифікувати стан авіаційного двигуна ТВЗ-117, а саме, області справного, несправного та невизначеного станів не виділялися чітко. Результати порівняльного аналізу точності розв'язання задачі контролю технічного стану ГТД вертольотів у польотних режимах із застосуванням вищезазначених архітектур нейронних мереж наведено у табл. В.4.

Аналіз табл. В.4 показує, що застосування LSTM мережі зі змінною пам'яттю дозволяє з максимальною точністю (і найменшою похибкою) розв'язувати задачу контролю технічного стану ГТД вертольотів.

Отже, зазначається, що перевагою створеного методу є можливість працювати з обмеженими навчальними вибірками із застосуванням гнучких критеріїв для оцінки технічного стану ГТД вертольотів, що є ключовим у умовах неповної інформації.

3.3 Розробка методу діагностики дефектів в основних вузлах проточної частини газотурбінного двигуна вертольоту

Відповідно до [124, 354–363] приймається, що технічний стан ГТД вертольотів як динамічного об'єкта діагностики визначається значенням вектору параметрів *Y*, значення якого можуть змінюватися при виникненні аварійних або критичних ситуацій під час його роботи. Передбачається, що всі можливі його стани можна поділити на (r + 1) областей (класів) $S_0, S_1...S_r$. Знаходження вектору стану *X* в області визначається як подія, що відповідає справному стану двигуна. За будь-яких можливих відмов елементів (вузлів) у роботі двигуна (раптових, поступових і непередбачуваних) вектор *X* належить одній з областей $S_1...S_r$, пов'язаній з несправним станом двигуна: $X \in \overline{S_0} = US_\alpha$, $\alpha = 1...r$. Тоді задача діагностики технічного стану ГТД вертольотів у польотних режимах полягає у встановленні відповідності між координатами вектору моніторингу *Y* і простору станів S_α . Це створює умови для оцінки належності вектору стану *X* області S_0 або $S_1...S_r$ задля визначення приналежності класів станів станам конкретного двигуна. У зв'язку з вищезазначеним метою розв'язуваної задачі є дослідження алгоритмів побудови нейромережевого класифікатора для розпізнавання дефекту проточної частини двигуна з точністю до вузла, а також розробка відповідного методу для реалізації цих задач.

Для розробки методу діагностики технічного стану ГТД вертольотів у польотних режимах пропонується метод виявлення та ідентифікації несправностей (FDI) [354, 357]. У контексті побудови класичних експертних систем еталонна (середньостатистична) модель двигуна часто подається у вигляді математичної моделі як системи алгебраїчних і диференціальних рівнянь. Однак, вони, зазвичай, не враховують індивідуальні особливості конкретного двигуна. У випадку застосування нейронних мереж цей недолік може бути усунений. Отже, відповідно до [354, 357] реалізація FDI-методу в нейромережевому базисі (рис. 3.11) включає таке:

1. Збереження еталонних характеристик індивідуального (середньостатистичного) двигуна у цифровому вигляді за допомогою першої нейронної мережі НК-1.

2. Порівняння параметрів окремого двигуна з даними, отриманими за НК-1.

3. Аналіз «нев'язок» (відхилень) між виміряними параметрами конкретного двигуна і значеннями, розрахованими НК-1. 4. Прийняття рішення про технічний стан двигуна на основі аналізу вектору «нев'язок» за участю другої нейронної мережі НК-2.

5. На етапі навчання НК-2 можуть використовуватися характеристики індивідуального двигуна, зокрема, математична модель з імітованими дефектами.

НК-2 (рис. 3.11) – це бінарний нейрокласифікатор, на входи якого надходять дані про відхилення (нев'язки) Δy_i , а виходи утворюють бінарний вектор $R = \{R_1, R_2, ..., R_m\}$, компоненти якого відображають результати діагностики [354, 357, 359].



Рисунок 3.11 – Реалізація FDI-методу у нейромережевому базисі (бінарний нейрокласифікатор) [354, 357, 359]

Завданням класифікатора є визначення для кожної нової точки, яка не входить до навчальної вибірки, в умовах часткової або повної невизначеності, до якого класу належить ця точка. Тоді відповідно до [354, 357, 359] для розв'язання задачі діагностики технічного стану ГТД вертольотів у польотних режимах у нейромережевому базисі задається простір ознак *N*-вимірного характеру, кожну точку якого можна подати *N*-вимірним вектором $X = X_1, ..., X_N$. Наданий набір даних $\{X, B\} = (X_1, B_1), (X_2, B_2), ..., (X_N, B_N),$ де X_i – точка в просторі ознак, B_i – мітка класу приналежності точки. При цьому стан ГТД вертольотів X у кожний дискретний момент часу *t* описується *N*-вимірним вектором змінних $X^t = (X_1^t, X_2^t, ..., X_N^t)$, що відповідають *N* рівнянням $X^{t+1} = F(X^t, Q^t), k = 1, 2, ..., M,$ де $Q^t = (q_1^t, q_2^t, ..., q_m^t)$ – еталонний (бездефектний) вектор стану ГТД вертольоту. Зміни у робочому стані ГТД вертольоту в будь-який момент часу описуються рівнянням

 $Y^{t} = H \cdot X^{t}$, де $Y^{t} = (y_{1}^{t}, y_{2}^{t}, ..., y_{R}^{t})$ – вектор робочого стану реальних вихідних параметрів, H – матриця трансформації.

Отже, узагальнено можна визначити діагностичний вектор стану ГТД вертольоту, що мінімізує СВО між бажаним Y та реальними виходами Y_R^t [354, 357, 359]. Це передбачає включення значної кількості параметрів робочого процесу ГТД вертольотів до процедури діагностики для відображення поведінки вузлів проточної частини. Перехід ГТД вертольоту з одного стану в інший відзначається помітними змінами в керованих і діагностованих параметрах. Геометрична інтерпретація діагностики вузлів проточної



Рисунок 3.12 – Геометрична інтерпретація задачі діагностики ГТД вертольотів – створення гіперповерхонь (авторський доробок [359] на основі [354])

частини ГТД вертольотів полягає у такому [359]: на основі обмеженої кількості вимірювань термогазодинамічних показників ГТД вертольоту необхідно прийняти оптимальне рішення щодо його належності до одного або кількох класів, а саме: S_1 – область справних станів; S_2 – область критичних станів; S_3 – область несправних станів; P_1 , P_2 , P_3 – класи (області) невизначених станів. Звідси геометрично технічний стан

ГТД вертольотів подано *N*-вимірним

вектором (X_N) (рис. 3.12), де просторові координати є N вхідними параметрами двигуна $X_1, X_2, ..., X_N$ (табл. В.5), які або записуються на борту вертольоту, або обчислюються за допомогою універсальної математичної моделі ГТД вертольотів [359]. Положення вектору станів у просторі відповідає конкретному стану двигуна зі створенням роздільних гіперповерхонь – це межі між різними класами, визначеними правилом прийняття рішень залежно від їхньої конструкції.

Для розв'язання задачі діагностики ГТД вертольотів проаналізовано, що гібридні ансамблі нейронних мереж [359] можуть ефективно виступати як динамічні сховища експертних знань. Порівняно з традиційними нейронними мережами, гібридні ансамблі

нейронних мереж пропонують додаткові практичні переваги, зокрема: декомпозиція СДО на більш прості сутності чи підсистеми; підвищення адаптивності до мінливих зовнішніх умов, позиціонування їх у класі адаптивних і саморегульованих систем; оптимізація структури нейронного ансамблю для виконання конкретних діагностичних завдань; вища швидкість і точність порівняно з класичними повністю підключеними мережами; покращена апроксимація кусково-неперервних функцій гібридним ансамблем нейронних мереж [357]. Для адаптації розпізнавання дефектів гібридним ансамблем нейронних мереж у складі навчальної вибірки виділено п'ять узагальнених класів стану двигуна (табл. В.6): S_0 – справний (еталонний) стан, що відповідає вектору $R = [0; 0; 0]; S_1$ – дефект компресора, що відповідає вектору $R = [0; 1; 0]; S_2$ – дефект камери згоряння, що відповідає вектору $R = [1; 0; 0]; S_4$ – дефект вільної турбіни, що відповідає вектору $R = [1; 1; 0]; S_5$ – дефект вихідного пристрою, що відповідає вектору R = [1; 0; 1].

Особливістю нейромережевих класифікаторів є навчання їх характеристик на навчальній множині (навчання з учителем). Разом з тим, становить цікавість дослідження можливості побудови алгоритмів діагностики технічного стану ГТД вертольотів у режимі самонавчання. Професором Жернаковим С.В. запропонована реалізація таких алгоритмів у нейромережевому базисі на основі мереж Кохонена, які вважаються самонавчальними (самоорганізаційними) [357].

Для розв'язання даної задачі запропоновано нейромережевий класифікатор, що базується на ансамблі нейронних мереж і складається з РБФ мережі, персептрона, мережі Кохонена, гібридної нейронної мережі [359].

Вибір у якості розпізнавальної нейронної мережі архітектури РБФ відносно нейронної мережі персептрон є більш переважним, оскільки визначення вагових коефіцієнтів у РБФ мережі здійснюється швидше і точніше, ніж параметрів персептрона при застосуванні градієнтних методів для налаштування параметрів останньої, що призводить лише до досягнення локальних мінімумів.

Архітектура РБФ мережі є двошаровою мережею, в якій перший шар здійснює нелінійне перетворення без залучення налаштування параметрів. У даному випадку для 16 вхідних параметрів ГТД вертольоту (табл. 3.10) оптимальною з точки зору

декомпозиції буде наявність шести нейронних мереж архітектури РБФ. Кількість параметрів на вході (вектор стану) відповідно до вузла двигуна (2–4 залежно від вузла) та три параметри на виході визначаються відповідно до бінарної класифікації станів (табл. 3.5). Послідовність навчання нейронної мережі РБФ відповідає модифікованому градієнтному алгоритму.

Нейронна мережа архітектури персептрон у гібридному ансамблі виконує функції концентруючого поля, що поєднує виходи шести нейронних мереж архітектури РБФ по три виходи. У процесі експерименту з цією нейронною мережею (після процесу контрастування) мережа набула архітектури у вигляді шестишарового персептрона: перший вхідний шар нейронної мережі – 18 нейронів; другий невидимий шар – 15 нейронів; третій невидимий шар – 12 нейронів; четвертий невидимий шар – 9 нейронів; п'ятий невидимий шар – 6 нейронів, шостий вихідний шар – три нейрони. Нейронна мережа персептрон покращує якість розпізнавання дефектів шляхом уточнення її вагових коефіцієнтів. Опис роботи персептрона має таку схему: для вхідного шару $(k = 1) - U^1 = X$ (вхідний вектор); для першого прихованого шару $(k = 2) - U_j^2 = f \sum_{i=1}^{n_i} w_{ij}^1 \cdot U_i^1$; ...; для шостого вихідного шару $(k = 6) - Y_j = U_j^6 = f \sum_{i=1}^{n_i} w_{ij}^6 \cdot U_i^6$, внаслідок чого вибирається алгоритм зворотного поширення помилки (табл. В.7).

Для класифікації (розпізнавання) стану ГТД вертольоту з урахуванням часткової або повної невизначеності його параметрів у гібридному ансамблі застосовується нейронна мережа Кохонена для початкового сортування та кластеризації значень, що надходять. Це і забезпечує структуризацію вихідних даних для гібридної нейронної мережі [359].

Гібридна нейронна мережа дозволяє визначити ступінь приналежності сукупності значень показників на своїх входах певному, раніше заданому класу, що характеризує технічний стан ГТД вертольотів. Функціонування моделі передбачає: кластеризацію значень показників; обробку отриманих значень за допомогою гібридної нейронної мережі; фільтрацію отриманих значень і виділення цільового класу, що визначає поточний технічний стан ГТД вертольотів. Для фільтрації отриманих на виходах гібридної нейронної мережі значень показників технічного стану ГТД вертольотів і визначення

вихідного класу (*S*₀, ..., *S*₅), використовуються блоки, що реалізують ступінчасту функцію із заданим порогом активації [359].

Отже, маючи на вході розглянутої моделі певну сукупність значень показників, можна однозначно інтерпретувати її вихідні значення як оцінку поточного технічного стану ГТД вертольоту. Розроблений нейромережевий класифікатор наведено на рис. 3.13.



Рисунок 3.13 – Структура розробленого нейромережевого класифікатора (авторський доробок [359])

Основу навчання нейронної мережі Кохонена становить конкуренція між нейронами. У даному випадку мережа Кохонена має 16 входів за кількістю стовпців (табл. 3.5) і шість виходів $R_1...R_6$ за кількістю узагальнених класів станів (табл. 3.11, рис. 3.18). Вагові коефіцієнти синаптичних зв'язків кожного *i*-го нейрона вихідного шару нейронної мережі Кохонена утворюють вектор $w_i = (w_{i_1}; w_{i_2}; ...; w_{i_{10}})^T$ при i = 1, 2, ..., n. При активації нейронної мережі Кохонена вхідним вектором ΔY в конкурентній боротьбі перемагає той нейрон, ваги якого найменшою мірою відрізняються від відповідних компонентів вхідного вектору, тобто для нейрона-переможця w_p виконується умова [357]:

$$d(\Delta Y, w_p) = \min d(\Delta Y, w_i), \ 1 \le i \le n.$$
(3.14)

де $d(\Delta Y, w_i)$ – відстань (у сенсі обраної метрики) між векторами ΔY і $w = (w_1, w_2, ..., w_n)^T$; n – кількість виходів нейронної мережі вихідного шару (у даному випадку n = 6). Нейрон-переможець утворює навколо себе деяку топологічну площину $S_p(k)$ з певною енергетикою, а всі нейрони, що знаходяться в її межах, піддаються адаптації, у ході якої їх вектори вагових коефіцієнтів змінюються в напрямку вектору ΔY за правилом [357]: 137

$$w_{i}(k+1) = w_{i}(k) + \eta_{i}(k)(\Delta Y - w_{i}(k)); \qquad (3.15)$$

де $\eta_i(k)$ – коефіцієнт спілкування першого нейрона з площини $S_p(k)$ у k-й момент часу. Значення коефіцієнта навчання зменшується зі збільшенням відстані між *i*-м нейроном і переможцем, а вагові коефіцієнти нейронів, що знаходяться за межами площини $S_p(k)$, не змінюються.

Навчання нейронної мережі Кохонена на основі конкуренції нейронів формує таке впорядкування нейронів (підбір значень їх вагових коефіцієнтів), яке мінімізує значення очікуваного спотворення і оцінюється похибкою апроксимації вхідного вектору ΔY через значення вагових коефіцієнтів нейрона-переможця. При *L* вхідних векторах (ΔY)_{*j*}, (*j* = 1, 2,..., *L*) і евклідової метриці ця похибка виражається як:

$$E = \frac{1}{L} \sum_{j=1}^{L} \left\| \left(\Delta Y_i \right)_j - w_p(j) \right\|^2;$$
(3.16)

де $w_p(j)$ – вагові коефіцієнти нейрона-переможця при пред'явленні мережі вектору (ΔY)_{*i*}.

Результати процесу навчання нейронної мережі Кохонена (після 700...800 циклів навчання) подано у табл. В.8, з якої визначено, що нейронна мережа Кохонена самостійно шляхом кластерного аналізу надає повну інформацію про можливі технічні стани двигуна. Стовпець 2 (табл. В.8) визначає кількість діагностованих станів, віднесених нейронною мережею до відповідного класу (із загальної кількості 18 наданих їй станів).

Алгоритмом навчання гібридної нейронної мережі є модифікований алгоритм зворотного поширення помилки, за якого нев'язка мережі для нейронів вихідного шару визначається як і при зворотному поширенні помилки. Блок-схема розробленого у [359] алгоритму навчання гібридних нейронних мереж показана на рис. В.1, опис блоків – у табл. В.9.

Результати тестування невідомих станів ГТД вертольотів за допомогою розробленого нейромережевого класифікатора наведені у табл. 3.1. Якість роботи розробленого нейромережевого класифікатора визначалась на тестовій вибірці (третій і четвертий рядки табл. 3.1) в умовах без шуму (перший і третій рядки табл. 3.1), а також в умовах адитивної складової білого шуму ($\sigma = 0,01$; M = 0), для 1 і 3 % зміни ККД компресора (другий і четвертий рядки табл. 3.1). Останній рядок (табл. 3.1) відповідає подвійному дефекту, що складається в одночасній зміні ККД компресора і турбіни компресора.

Номер рядка	Значення виходів класифікатора						Стан
	R_1	R_2	R_3	R_4	R_5	R_6	Стан
1	0,609	0,084	0,009	0,011	0,009	0,007	Дефект компресора (–1 % <i>η</i> _К)
2 (із шумом)	0,717	0,143	0,204	0,135	0,252	0,004	
3	0,668	0,121	0,233	0,032	0,177	0,005	Дефект компресора (-3 % <i>η</i> _К)
4 (із шумом)	0,745	0,308	0,362	0,180	0,316	0,002	
5	0,732	0,711	0,009	0,018	0,016	0,001	Дефект компресора (-3 % <i>η_K</i>) і тур- біни компресора (-3 % <i>η_{TK}</i>)

Таблиця 3.1 – Результати тестування класифікатора, побудованого на основі розробленого нейромережевого класифікатора (авторський доробок [359])

Аналіз результатів тестування розробленого нейромережевого класифікатора показує, що нейроном-переможцем (для рядків 1...4) є нейрон, що має вихід R_1 , а це означає, що, відповідно до табл. 3.1 виявляється дефект у компресорі. Як і раніше, за числовим значенням на кожному з виходів нейронної мережі можна судити про інтенсивність дефекту. У п'ятому рядку (табл. 3.1) два нейрона-переможця, оскільки максимальні значення сигналів мають місце для виходів R_1 і R_2 . Відповідно до табл. 3.9, розроблений нейромережевий класифікатор виявляє при цьому зазначений вище подвійний дефект (зменшення ККД компресора і турбіни компресора).

Порівняльний аналіз нейромережевих (табл. 3.9) і класичного [357] методів класифікації технічного стану авіаційного двигуна вертольоту показує, що вони практично однакові за якістю роботи. Але, якщо для персептрона і метод найменших квадратів використовується процес навчання з учителем (заздалегідь відомі класи станів), то при діагностиці технічного стану авіаційного двигуна вертольоту за допомогою розробленого нейромережевого класифікатора розбиття діагностичного простору ознак на класи здійснюється автоматично, кількість кластерів у даному випадку заздалегідь невідома, що є перевагою.

Як уже зазначалося, завершальним етапом реалізації FDI-методу (рис. 3.19) є прийняття рішення про тип відмови в авіаційному двигуні вертольоту на основі аналізу числового вектору *R*. Графічна інтерпретація прийняття рішення для нейромережевого класифікатора і методу найменших квадратів показана на рис. 3.19, де вершини куба відповідають центрам кластерів (еталонних станів двигуна). Фактичний вектор стану двигуна *S* може приймати значення в будь-якій точці всередині даного куба $S = (R_1, R_2, R_3)^T$, $0 \le R_i \le 1$.



На рис. 3.14 позначено: S_0 – центр кластера (прецедент), який відповідає справному (еталонному стану двигуна); S_1 – центр кластера, який відповідає дефекту в компресорі; S_2 – центр кластера, який відповідає дефекту у камері згоряння; S_3 – центр кластера, який відповідає дефекту в турбіні компресора; S_4 – центр кластера, який від-

Рисунок 3.14 – Графічна інтерпретація процесу діагностики технічного стану ГТД вертольотів [357]

повідає дефекту у вільній турбіні; *S*₅ – центр кластера, який відповідає дефекту у вихідному пристрої.

Визначення технічного стану ГТД вертольотів аналогічно з [357] здійснюються за правилом «найближчого сусіда», на підставі якого двигун зараховується в той клас, якому належить його найближчий сусід (або більшість з його найближчих сусідів). Вирішальне правило, на підставі якого здійснюється прийняття рішення (постановка діагнозу), записується таким чином:

$$S \to S_p$$
, якщо $d(S, S_p) \to \min$, (3.17)

де *d* – відстань до центру найближчого (*p*-го) кластера (прецеденту), яка при цьому обчислюється, наприклад, з використанням евклідової метрики.

Ця процедура реалізована на прикладі задачі діагностики подвійного дефекту, пов'язаного зі зменшенням ККД компресора і турбіни компресора на 3 % (на прикладі авіаційного двигуна ТВЗ-117) [359]. Величина вектору на виході нейромережевого класифікатора у цьому випадку дорівнює $R = (0,732; 0,711; 0,009; 0,018; 0,016; 0,001)^T$ (табл. 3.9) Тоді, враховуючи еталонні стани $S_0...S_5$ ГТД вертольоту і, використавши (3.17), обчислено відстань d від відповідного прецеденту до центрів кластерів: $d(S, S_0) = 0,653; d(S, S_1) = 0,724; d(S, S_2) = 0,631; d(S, S_3) = 1,168; d(S, S_4) = 1,241; d(S, S_5) = 1,326.$

Аналіз отриманих значень $d(S, S_i)$ показує, що результатом розв'язку даної задачі буде: $S \in S_0 \cup S_1 \cup S_2$, тобто пропонований нейронною мережею прецедент приблизно рівновіддалений від таких станів: справний стан (*S*₀), дефект в компресорі (*S*₁) і дефект в турбіні компресора (*S*₂). Отже, діагноз мережі – «помірний» за інтенсивністю дефект у двох вузлах авіаційного двигуна вертольоту (компресорі і турбіні компресора). Проведений порівняльний аналіз показав можливість розв'язання задачі діагностики технічного стану ГТД вертольотів за допомогою різних архітектур нейронних мереж, а також методу найменших квадратів, що забезпечують високу достовірність розпізнавання дефектів, включаючи подвійні дефекти, у різних вузлах двигуна.

Ефективність розпізнавання дефектів оцінювалась за сумарною «розбіжністю» за параметрами стану елементів двигуна [359]:

$$\Delta \Sigma = \sum_{i=1}^{6} \delta x_i = |\delta x_1| + |\delta x_2| + \dots + |\delta x_6|;$$
(3.18)

де $\delta x_i = x_i^* - x_i$, δx_1 – відхилення робочого стану (розмір дефекту) вхідного пристрою; δx_2 – відхилення робочого стану (розмір дефекту) компресора; δx_3 – відхилення робочого стану (розмір дефекту) камери згоряння; δx_4 – відхилення робочого стану (розмір дефекту) турбіни компресора; δx_5 – відхилення робочого стану (розмір дефекту) вільної турбіни; δx_6 – відхилення робочого стану (розмір дефекту) вихідного пристрою.

На рис. 3.15 наведено результати ефективності нейромережевого класифікатора для розпізнавання дефектів ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117), де а: крива $1 - G_T$, крива $2 - T_K$, крива $3 - T_T$; б: крива $1 - T_K$, T_T ; крива $2 - G_T$, T_K ; крива $3 - G_T$, T_T ; в: крива $1 - G_T$, T_K , T_T ; г: крива $1 - G_T$, n_{TK} , n_{CB} , T_{TK} , T_{CB} ; д: крива $1 - T_{TK}$; крива $2 - G_T$, n_{TK} ; крива $2 - G_T$, n_{TK} ; крива $2 - G_T$; крива $3 - n_{CB}$; крива $4 - T_{CB}$; крива $5 - n_{TK}$; е: крива $1 - G_T$, n_{TK} , n_{CB} , T_{TK} ; крива $2 - G_T$, n_{TK} , T_{CB} ; крива $3 - G_T$, n_{TK} , T_{CB} ; сигvе $5 - n_{TK}$, n_{CB} , T_{TK} , T_{CB} .

Встановлено (рис. 3.15), що із збільшенням глибини вузлових дефектів δx_i в інтервалі навчання 0...10 % ефективність розпізнавання спочатку зростає (зменшується значення $\Delta \Sigma$), досягаючи максимуму (мінімального значення $\Delta \Sigma$), а потім зменшується. Ця особливість залежності $\Delta \Sigma = f(\delta x_i)$ може бути використана для практичних цілей, наприклад, границі тренувального інтервалу слід вибирати з умови отримання найбільшої ефективності розпізнавання несправного стану двигуна (для блок компресора двигуна це може бути граничне значення зниженої ефективності компресора, при якому потрібна промивка двигуна тощо).



Рисунок 3.15 – Результати ефективності нейромережевого класифікатора для розпізнавання дефектів (авторський доробок [359])

Результати порівняльного аналізу точності та похибки діагностики дефектів агрегатів ГТД вертольотів (на прикладі дефектів компресора та турбіни компресора) наведені в табл. В.10.

На сьогодні відомо декілька методів параметричної діагностики робочого стану ГТД, які можна розділити на методи A, B, C, D та E [359]: А – метод діагностичних матриць; В – метод, що ґрунтується на розв'язуванні системи нормальних рівнянь; С – метод, заснований на нелінійній оптимізації критерію, що характеризує стан двигуна; D – метод коригування за допомогою квадратичної цільової функції; Е – метод коригування за допомогою квадратичної цільової функції; Е – метод коригування за допомогою квадратичної цільової функції. Результати порівняння ефективності нейромережевого підходу з методами A, B, C, D і Е показують (рис. 3.16), що перевага розробленого нейромережевого класифікатора над іншими методами зростає в міру зменшення інформації про контрольовані параметри двигуна. При цьому: а – діагностика за параметром T_{Γ} ; в – діагностика за параметром G_{T} ; г –

діагностика за параметром G_T і T_{Γ} ; д – діагностика за параметром G_T і T_K ; е – діагностика за параметром T_K і T_{Γ} .



Рисунок 3.16 – Порівняльна оцінка ефективності методів діагностики стану з використанням розробленого нейромережевого класифікатора та методів A, B, C, D та E (авторський доробок [359])

Оскільки ефективність розглянутих методів діагностики технічного стану ГТД вертольотів неоднакова в різних ситуаціях, очевидно, що комбінований метод, реалізований за допомогою нейромережевого класифікатора, є оптимальним.

3.4 Розробка методу прогнозування динаміки зміни термогазодинамічних параметрів газотурбінних двигунів вертольотів

Нейромережеве прогнозування відноситься до методів штучного інтелекту, здатних вирішити багатоцільові завдання. Переваги алгоритмів нейромережевого прогнозування технічного стану складних динамічних об'єктів з використанням багатошарових нейронних мереж базуються на хороших апроксимуючих здібностях, також нейронні мережі можна налаштовувати градієнтними методами, незважаючи на велику кількість вагових коефіцієнтів. Нейронні мережі з кількома шарами потужніші, ніж із одним шаром, лише за наявності нелінійності. Дані характеристики визначає перспективність застосування нейронних мереж для прогнозування технічного стану складних динамічних об'єктів. Задача прогнозування у нейромережевому базисі зводиться до побудови нейромережевої моделі (предиктора), що дозволяє знайти значення вектору *Y* в момент часу t + 1 за попередніми *N* значеннями часового ряду Y(t - N + 1), Y(t - N + 2), ..., Y(t), тобто Y(t+1) = f(Y(t), Y(t-1), ..., Y(t - N + 1)), де $Y(\cdot)$ – деяка нелінійна векторна функція, яку потрібно оцінити за допомогою нейронної мережі; *Y* – вектор контрольованих параметрів; t – дискретний час. Точність прогнозу, реалізованого з допомогою нейронної мережі, оцінюється величиною $\|\varepsilon_{t+1}\| = \|Y_{t+1} - Y_{t+1}\|$, де Y_{t+1} – прогнозоване значення, обчислене нейронною мережею моменту часу t + 1; Y_{t+1} – реальне значення вектору *Y* у цьому моменті часу; ε_{t+1} – помилка прогнозування [364–370].

На теперішній час відома низка методів прогнозування, таких як: евристичні методи, математичні методи часової екстраполяції, математичні методи просторової екстраполяції, методи моделювання процесів розвитку, логічні та структурні методи [364– 370]. Однак, для їх застосування необхідна наявність великих обсягів апріорної інформації про об'єкт, що досліджується, значення законів розподілу їх параметрів, математичних моделей, що описують процеси зміни режимів роботи двигуна, в рамках яких можна здійснювати вибір критеріїв і прогнозуючих функцій для розв'язання задачі прогнозування технічного стану складних динамічних об'єктів [364–370]. При індивідуальному прогнозуванні апріорна інформація має бути індивідуальною для кожного об'єкта. До недоліків перерахованих вище методів слід зарахувати: малу робастність за умов шумів; нездатність видавати багатопараметричний прогноз з урахуванням емерджентності явищ; неможливість оперативної обробки інформації на ЕОМ; складність обробки даних, представлених у різнотипних шкалах тощо [364–370].

Розв'язання задачі прогнозування технічного стану ГТД вертольотів у нейромережевому базисі базується на апріорній інформації, що пред'являється нейронній мережі у вигляді готових рішень (задачників), на основі яких здійснюється процес навчання (донавчання). Це дозволяє використовувати такі переваги нейронних мереж, як: здатність здійснювати багатопараметричний прогноз; нечутливість до нестачі апріорної та апостеріорної інформації щодо динаміки прогнозованих процесів; можливість обробки даних, представлених у різнотипних шкалах; здатність до узагальнення та донавчання; робастність по відношенню до зовнішніх збурень. При оцінюванні якості роботи нейронної мережі на її вхід подаються дані тестової вибірки, на основі яких вона обчислює вектор відхилень (різниця між виходом нейронної мережі та бажаними характеристиками).

Відомо два підходи до розв'язання задачі прогнозування технічного стану СДО, що грунтуються на [364–370]:

– використанні рекурентної (динамічної) нейронної мережі, що реалізує залежність виду Y(t+1) = f(Y(t), Y(t-1), ..., Y(t-N+1));

– статичній нейронній мережі, що реалізує часову залежність Y = f(t).

Методи прогнозування технічного стану авіаційних турбореактивних двигунів із застосуванням нейронних мереж детально описані у дисертаційній роботі професора Жернакова С.В. [124], при цьому ці методи адаптовані до ГТД вертольотів. Однак, даний підхід ґрунтується на застосуванні статичної нейронної мережі, що реалізує тимчасову залежність Y = f(t) і побудові екстраполюючих функцій y(t) як функції $y_i(t) = f(t)$. Тому для прогнозування технічного стану ГТД вертольотів у польотних режимах, тобто в режимі реального часу, цей підхід потребує суттєвої модифікації, зокрема, застосування рекурентної (динамічної) нейронної мережі.

У зв'язку з вищевикладеним, розроблено метод, що ґрунтується на використанні рекурентної (динамічної) нейронної мережі, реалізація якого здійснюється таким чином:

задається часовий інтервал (інтервал моніторингу), який є навчальною вибіркою
 для нейронної мережі (*t* – вхід нейронної мережі; параметри двигуна *y*₁, *y*₂, ..., *y_n* – виходи
 нейронної мережі);

– задається крок прогнозу *Т*_{прогн} з урахуванням вимог до прогнозу (короткостроковий, середньостроковий, довгостроковий прогноз);

– після процесу навчання нейронної мережі на інтервалі моніторингу (T_{MOH}) обчислюються прогнозовані значення $y_i(t + T_{nport})$ для цього на вхід нейронної мережі подається значення часу $t + T_{nport}$;

– процес прогнозування повторюється в режимі реального часу.

При створенні прогнозів за допомогою нейронних мереж застосовуються локально регульовані лінійні авторегресійні прогнози, коефіцієнти яких визначаються методом найменших квадратів:
$$x_{t+1}^{f} = \alpha_0 x_t + \alpha_1 x_{t-1} + \dots + \alpha_{m-1} x_{t-(m-1)} + \alpha_m.$$
(3.19)

Лінійна регресія x_{t_r+1} для $x_{t_r}^m = (x_{t_r}, x_{t_r-1}, ..., x_{t_r-(m-1)}), r = 1...k$ встановлюється мето-

дом найменших квадратів, $\alpha_t - \epsilon$ значеннями α_t , що мінімізують суму $\sum_{r=1}^k \left(x_{t_r+1} - \alpha_0 x_{t_r} - \alpha_1 x_{t_r-1} - \alpha_{m-1} x_{t_r-(m-1)} - \alpha_m \right)^2$. Щоб встановити SNN до останньої *m*-хронології $\left(x_t^m, y_t^m \right)$, можна подивитися на найближчу точку *k*, яка максимізує функцію $\rho(x_n^m, x_t^m) + \rho(y_n^m, y_t^m)$, i = m, m + 1, t. Отже, отримано набір *k* одночасної *m*-хронології в обох рядах:

Прогнози для *x*_{*t*+1} і *y*_{*t*+1} можна отримати за допомогою предиктора лінійної авторегресії з різними коефіцієнтами за методом найменших квадратів:

$$x_{t+1}^{t} = \alpha_0 x_t + \alpha_1 x_{t-1} + \dots + \alpha_{m-1} x_{t-(m-1)} + \alpha_m;$$
(3.21)

$$y_{t+1}^{f} = \beta_{0} y_{t} + \beta_{1} y_{t-1} + \dots + \beta_{m-1} y_{t-(m-1)} + \beta_{m}.$$
(3.22)

Коефіцієнти α_t і β_t є значеннями α_t і β_t відповідно і мінімізує суми:

$$\sum_{r=1}^{k} \left(x_{t_{r}+1} - \alpha_{0} x_{t_{r}} - \alpha_{1} x_{t_{r}-1} - \alpha_{m-1} x_{t_{r}-(m-1)} - \alpha_{m} \right)^{2};$$
(3.23)

$$\sum_{r=1}^{k} \left(y_{t_{r}+1} - \beta_0 y_{t_{r}} - \beta_1 y_{t_{r}-1} - \beta_{m-1} y_{t_{r}-(m-1)} - \beta_m \right)^2.$$
(3.24)

При виборі архітектури мережі зазвичай випробовується кілька конфігурацій із різною кількістю елементів. Виходячи з того, що задача прогнозування є окремим випадком задачі регресії, слід, що вона може бути вирішена такими типами нейронних мереж: багатошаровим персептроном (MLP), радіально-базисною мережею (RBF), узагальненорегресійною мережею (GRNN), мережею Вольтер, мережею Елмана [364–370]. При розв'язанні задачі прогнозування технічного стану ГТД вертольотів у польотних

режимах (в режимі реального часу) в якості нейронної мережі була обрана узагальненорегресійна мережа, що реалізує методи ядерної апроксимації. У задачах регресії вихід мережі може розглядатися як очікуване значення моделі у цій точці простору входів. Це очікуване значення пов'язане із щільністю ймовірності спільного розподілу вхідних та вихідних даних. У точці розташування кожного навчального спостереження міститься гаусова ядерна функція. Вважається, що кожне спостереження свідчить про деяку впевненість у тому, що поверхня відгуку в цій точці має певну висоту, і ця впевненість зменшується при відході убік від точки. GRNN мережа копіює в себе всі навчальні спостереження і використовує їх для оцінки відгуку в довільній точці. Остаточна вихідна оцінка мережі виходить як виважене середнє виходів за всіма навчальними спостереженнями, де величини терезів відображають відстань від цих спостережень до тієї точки, в якій проводиться оцінювання (і, таким чином, найближчі точки вносять більший внесок в оцінку). Перевагою мережі GRNN вважатимуться визначеність структури: мережа вміщує у собі все навчальні дані [365]. Структура нейронної мережі GRNN представлена на рис. В.2. GRNN-мережа має два приховані шари: шар радіальних елементів та шар елементів, що формують виважену суму для відповідного елемента вихідного шару. У вихідному шарі визначається виважене середнє шляхом поділу виваженої суми на суму ваг. В якості радіальної функції застосовується функція Гауса. Вхідний шар передає сигнали до першого проміжного шару нейронів, які є радіально симетричними. Вони несуть у собі інформацію про даних навчальних випадків або їх кластерах і передають її в другий проміжний шар. У ньому формуються зважені суми всіх елементів вихідного шару і сума ваг, обчислювана спеціальним елементом [365]. Позначивши вихід і-го нейрона RBF-шару як v_i , вихідний сигнал *l*-го нейрона другого проміжного шару обчислюється відповідно до виразу:

$$u_l = \sum_{i=1}^k v_i;$$
 (3.25)

де k – число нейронів в RBF-шарі.

Позначивши ваговий коефіцієнт *i*-го нейрона RBF-шару як ω_i , отримаємо вираз для суми ваг:

$$v_0 = \sum_{i=1}^k \omega_i.$$
 (3.26)

Вихідний шар ділить зважені суми на суму вагів і видає остаточний прогноз. Позначивши його за *y*_l, отримаємо:

$$y_l = \frac{u_l}{v_0}.$$
(3.27)

Схема принципу функціонування першого проміжного шару структура представлена на рис. В.3 [365]. На вхід радіальних елементів із вхідного шару подається вектор x. Базисні функції RBF-шару задаються матрицею Q, але в практичному плані зручніше використовувати для опису елементів матрицю кореляції C, що виходить з матриці Q таким чином:

$$C = Q^T Q. \tag{3.28}$$

Центр *i*-го нейрона радіального шару позначено як *c_i*. Остаточний результат обробки вхідних сигналів *S_i* обчислюється відповідно до виразів:

$$S_{j}^{(t)} = -\frac{1}{2} \sum_{t=1}^{n} \left(x_{t} - c_{i}^{(t)} \right)^{2}; \qquad (3.29)$$

$$S_t = \sum_{j=1}^n S_j^{(t)};$$
(3.30)

$$v_i = \sum_{t=1}^k e^{-\frac{S_t \omega_t}{2\sigma_t^2}}.$$
 (3.31)

Потім вектор вихідних сигналів передається на вхід другого проміжного шару мережі. Навчання мережі необхідно виконувати окремо для кожного часового ряду, оскільки спроба прогнозування ряду, на якому мережа не була навчена, призведе до помилкового результату. В якості алгоритму навчання використовувався модифікований алгоритм зворотного поширення помилки з автоматичною корекцією довжини кроку навчання (*ParTan*) [365].

В якості вхідних даних застосовані термогазодинамічні параметри авіаційного двигуна ТВЗ-117, що реєструються на борту вертольоту, приведені до абсолютних параметрів: n_{TK} і T_{Γ}^* (табл. В.11). Проведено дослідження залежності якості прогнозування від параметрів алгоритму навчання та структури нейронної мережі: кількість нейронів у 1 прихованому шарі – 8, кількість нейронів у 2 прихованому шарі – 6, дальність прогнозу – 5, алгоритм навчання – *ParTan*, параметри алгоритму – оптимальні, розбиття відліків низки на множини – оптимальне. На рис. 3.17 наведено графік помилки навчання нейронної мережі.

Результати досліджень показали, що якість прогнозування залежить, насамперед, від розбиття відліків ряду на три множини – навчальна, тестова та контрольна. Найкраща якість прогнозу досягається за співвідношенням обсягів вибірок 60:20:20. Очевидно, що точність прогнозу падатиме в міру збільшення дальності.



Рисунок 3.17 – Графік помилки навчання нейронної мережі: *a* – показник *Accuracy*; *б* – показник *Loss* (1 – train, 2 – test, 3 – control) (авторський доробок [365])

Відповідно до табл. В.12, В,13 оптимальними значеннями параметрів алгоритму є коефіцієнт швидкості навчання $\eta = 0,7$, коефіцієнт моменту навчання $\mu = 0,9$, кількість ітерацій до запам'ятовування N = 20, величина зміни коефіцієнта швидкості навчання $\alpha = 0.1$. Число нейронів у прихованих шарах мережі визначається для кожного часового ряду індивідуально.



Рисунок 3.18 – Результати прогнозування термогазодинамічних параметрів авіаційного двигуна ТВЗ-117 (1 – реальне значення; 2 – прогнозування із застосуванням нейронної мережі), *t* = 94,65 години – момент прогнозу: *a* – *T*_Г (температура газів перед турбіною компресора); *б* – *n*_{TK} (частота обертання ротора турбокомпресора)

При оцінюванні ефективності розробленого нейромережевого методу прогнозування технічного стану ГТД вертольотів відповідно до [366] здійснюється порівняльний аналіз із низкою класичних методів: експоненціального згладжування, ковзного середнього, методу найменших квадратів. Прогнозування згідно з методом ковзного середнього здійснюється згідно з виразом:

$$y_{t+1} = \frac{1}{N} \sum_{b=0}^{N} y_{t-b+1};$$
(3.32)

де N – число попередніх періодів, що входять у ковзне середнє; y_t – фактичне значення у час; y_{t+1} – прогнозоване значення у час t + 1.

Прогнозування згідно з методом експоненційного згладжування здійснюється згідно з виразом:

$$y_{t+1} = y_t + \alpha (A_t - y_t) + \alpha A_t + (1 - \alpha) y_t;$$
(3.33)

де y_{t+1} – передбачене значення параметра на основі попереднього значення y_t , скоригованого з урахуванням похибки прогнозування $A_t - y_t$ та вагового коефіцієнта α (0 < α < 1).

На рис. 3.19 наведено результати порівняльного аналізу нейромережевого та класичних методів прогнозування технічного стану ГТД вертольотів (на прикладі двигуна



Рисунок 3.19 – Результати прогнозування температури газів перед турбіною компресора (авторський доробок [365])

ТВЗ-117) для температури газів перед турбіною компресора, як найбільш значущого параметра, де позначено: 1 – реальне значення температури газів перед турбіною компресора; 2 – значення температури газів перед турбіною компресора, обчислене з використанням нейронної мережі; 3 – значення температури газів перед турбіною компресора, обчислене на основі методу ковзного середнього; 4 – значення температури газів перед турбіною

компресора, обчислене з використанням методу експонентного згладжування; 5 – значення температури газів перед турбіною компресора, обчислене за допомогою методу найменших квадратів. У процесі розв'язання задачі прогнозування крок Δt відповідав: у задачі короткострокового прогнозування $\Delta t = 0,4$ години; у задачі середньострокового прогнозування $\Delta t = 3,35$ години. На рис. 3.26 прийнято, що момент прогнозу дорівнює t = 94,65; інтервал часу $t \in [94,65; 95,05]$ відповідає короткостроковому прогнозуванню; $t \in [94,65; 96,40]$ – середньострокове прогнозування; $t \in [94,65; 98,0]$ – довгострокове прогнозування.

Результати порівняльного аналізу роботи класичних та нейромережевих методів прогнозування технічного стану ГТД вертольотів наведено у табл. В.14 та на рис. 3.20 де суцільна лінія відповідає помилкам прогнозу за відсутності шуму, а штрих-пунктирна – помилкам прогнозу за наявності адитивної перешкоди (шуму), помилка прогнозу $\delta_{inpoch} = \max_{i} |\delta_{inpoch}|$ температури газів перед турбіною компресора T_{Γ}^{*} відповідає використанню: 1, 2 – методу ковзного середнього; 3, 4 – методу експоненційного згладжування; 5, 6 – методу найменших квадратів; 7, 8 – нейромережевого методу.



Рисунок 3.20 – Залежність зміни помилки прогнозу від інтервалу прогнозу (авторський доробок [365])

У табл. В.14 використовуються такі позначення: КП – короткостроковий прогноз; СП – середньостроковий прогноз; ДП – довгостроковий прогноз; МКС – метод ковзного середнього; МЕЗ – метод експонентного згладжування; МНК – метод найменших квадратів. У табл. В.14 наведено результати прогнозу для двох випадків:

- «чисті» виміри, отримані за відсутності додаткових випадкових перешкод;

– вимірювання за наявності адитивної випадкової перешкоди у вигляді білого шуму ($\sigma = 0,01; M = 0$).

Аналіз результатів, наведених у табл. В.14 та на рис. 3.20 свідчить про високу якість прогнозування за допомогою нейромережевого методу. Так, в умовах відсутності адитивної перешкоди точність короткострокового, середньострокового та довгострокового прогнозу температури газів за допомогою нейронних мереж вища порівняно з методом найменших квадратів відповідно у 4,27; 4,78 та 6,0 разів. Аналогічна похибка прогнозування на основі методу ковзного середнього для короткострокового, середньострокового, середньострокового та довгострокового прогнозу температури газів за допомогою нейронних мереж вища порівняно з методом найменших квадратів відповідно у 4,27; 4,78 та 6,0 разів. Аналогічна похибка прогнозування на основі методу ковзного середнього для короткострокового, середньострокового та довгострокового прогнозу температури газів вища порівняно з нейромережним методом відповідно у 1,67; 3,80 та 3,66 разів; а для методу експоненційного згладжування на аналогічних ділянках прогнозу температури газів похибка прогнозування

також вища порівняно з нейромережним методом відповідно у 2,66; 4,16 та 3,89 разів. У разі наявності перешкоди точність короткострокового, середньострокового і довгострокового прогнозу температури газів за допомогою нейромережевого методу порівняно з методом найменших квадратів також вища відповідно у 4,56; 4,17 та 5,45 разів. Похибка методу ковзного середнього в цих умовах на аналогічних інтервалах прогнозу температури газу істотно вища у порівнянні з нейромережевим методом відповідно у 2,97; 2,36 та 3,18 разів; а для методу експоненційного згладжування в цих умовах похибка також вища порівняно з нейромережним методом відповідно у 3,62; 2,92 та 3,67 разів.

Розв'язання даної задачі прогнозування температури газів перед турбіною компресора авіаційного двигуна ТВЗ-117 на основі нейронних мереж показало, що у період з 94,65 по 98,0 годин помітна стійка тенденція до деградації даного параметра, що свідчить про появу несправності у роботі ГТД вертольоту. Результати прогнозування показують, що з t = 95 годин необхідно вертоліт негайно посадити на землю у зв'язку з ризиком поломки двигуна. Своєчасне прийняття рішення дозволить не допустити серйозних руйнувань вузла компресора двигуна, які в цьому випадку є результатом помпажу лопаток першого ступеня компресора.

Розроблений нейромережевий метод прогнозування може ефективно застосовуватися для прогнозування широкого класу характеристик ГТД вертольотів, і, зокрема, прогнозування такого важливого параметра, як залишковий ресурс двигуна.

Розроблений нейромережевий метод прогнозування є базою для створення методу ідентифікації можливих несправностей (дефектів) ГТД вертольотів у польотних режимах за умов малої кількості відмов (навчальна вибірка з мінориторним класом, що характеризує дефекти у вузлах авіаційних двигунів вертольотів). Задача сформульована таким чином: нехай задано масив даних термогазодинамічних показників $X(t) = \{x_{t_1}, x_{t_2}, ..., x_{t_n}\}$, що відповідають лише нормальному режиму функціонування двигуна (тобто в той час, коли не було відмов та інших аномалій). Необхідно розробити модель $f(X(t), \theta)$, де θ – параметри моделі, що на основі фрагмента з регулярними значеннями $\{x_{t_1}, x_{t_2}, ..., x_{t_k}\}$ визначає, чи є фрагменти $\{x_{t_{k+1}}, x_{t_{k+2}}, ..., x_{t_{k+1}}\}$ аномальними із прийнятною точністю для

ідентифікації можливих несправностей (дефектів) двигуна [371–373]. Розроблений метод полягає у використанні ретроспективних даних термогазодинамічних показників двигуна для побудови моделі прогнозування часових рядів. При цьому навчання моделей здійснюється на даних, що відповідають лише нормальному режиму функціонування двигуна (тобто в той час коли не було поломок та інших аномалій). Отже, модель вчиться прогнозувати, яким повинен бути сигнал при нормальному режимі роботи. У тому випадку, якщо у певний момент часу фактичне значення термогазодинамічного показника відрізняється від прогнозованого «нормального» значення, фіксується аномальна поведінка та формується сигнал про потенційний дефект (рис. В.4).

На відміну від [371], пропонований нейромережевий метод ідентифікації потенційних дефектів складних динамічних об'єктів базується не на основі нейронної мережі GRNN, як у [365], а на основі моделі Transformer [374], яка здатна адаптуватися до різних довжин вхідних та вихідних послідовностей без необхідності попереднього налаштування. При цьому модель Transformer дозволяє враховувати залежність між елементами послідовності на великих часових інтервалах, що важливо для прогнозування дефектів у складних динамічних об'єктах, таких як ГТД вертольотів.

Для нормальної поведінки системи збираються дані вихідних показників об'єкта, що досліджується, які повинні бути представлені у вигляді часового ряду, що містить послідовність фактичних значень. При цьому замість Seq-to-Seq моделі на основі загальної регресійної нейронної мережі нейронної мережі GRNN пропонується використовувати модель, засновану на глибокому навчанні та архітектурі Transformer, яка добре підходить для роботи з послідовностями даних, дозволяючи враховувати довгострокові залежності та працювати з різними довжинами вхідних і вихідних послідовностей. Пропонована модель на основі Transformer має таку архітектуру:

1. Кодувальник (Encoder) – перетворює вхідну послідовність даних у внутрішнє уявлення, враховуючи контекст та залежності між елементами послідовності. Для кожного елемента вхідної послідовності X модель створює його векторне уявлення x_i, які потім поєднуються в матрицю X_{enc}:

$$X_{enc} = \operatorname{Encoder}(X). \tag{3.34}$$

2. Декодувальник (Decoder) – генерує вихідну послідовність даних з

урахуванням внутрішнього уявлення, враховуючи як вхідні дані, і попередні елементи вихідної послідовності. На кожному кроці генерації вихідної послідовності *Y* декодер використовує вектори контексту *C* з кодувальника, а також попередні елементи вихідної послідовності *Y* для передбачення наступного елемента:

$$Y_t = \text{Decoder}(Y_{t-1}, C). \tag{3.35}$$

3. Позиційне кодування (Positional Encoding) – додає вектори, які мають позиції елементів у послідовності, щоб модель могла враховувати порядок даних. Для цього використовуються функції синуса та косинуса з різними частотами [374]:

$$PE_{pos,2i} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{MODerb}}}}\right), \quad PE_{pos,2i+1} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{MODerb}}}}\right), \quad (3.36)$$

де *pos* – позиція у послідовності, *i* – індекс елемента у векторі позиційного кодування, *d*_{модель} – розмірність моделі.

4. Механізм уваги (Attention Mechanism) дозволяє моделі фокусуватись на різних частинах вхідної послідовності при генерації вихідної послідовності [375, 376]. Одним із поширених методів є механізм уваги за скалярним твором (Scaled Dot-Product Attention) [377, 378]:

Attention
$$(Q, K, V) = V \cdot \operatorname{softmax}\left(\frac{Q \cdot K^{T}}{\sqrt{d_{k}}}\right);$$
 (3.37)

де Q, K, V – запити, ключі та значення, d_k – розмірність ключів. Запити Q зазвичай генеруються на основі прихованого стану декодера або останнього згенерованого елемента вихідної послідовності, також можуть бути створені шляхом лінійного перетворення відповідних векторів. Ключі K генеруються із прихованого стану кодувальника або послідовності вхідних даних, аналогічно до запитів. Значення V є фактичними даними, на які модель повинна орієнтуватися при генерації вихідної послідовності. Розмірність ключів d_k є гіперпараметром, який підбирається досвідченим шляхом у процесі налаштування моделі, при цьому зазвичай вибирається відповідно до розмірності прихованого стану моделі та складності задачі.

Після отримання прогнозних значень з використанням моделі Transformer для ідентифікації потенційних дефектів досліджуваного об'єкта можна використовувати

такий підхід: якщо різниця між фактичними та прогнозними значеннями перевищує певний поріг, це може вказувати на наявність дефекту; додатково можна розглядати статистичні показники, такі як середнє квадратичне відхилення, щоб зважити на ступінь відхилення прогнозних значень від фактичних.

Для визначення потенційних дефектів проточної частини ГТД вертольотів застосовуються такі вирази:

$$A(X, X', W, \tau, \rho) = \begin{cases} 1, \text{ якщо } A > \rho; \\ 0, \text{ якщо } A \le \rho'; \end{cases} Z = \frac{1}{L_w} \sum_{i=1}^{L_w} e_i; \ e_i = \frac{1}{n} \sum_{j=1}^n \left| r_j^{(i)} - \hat{r}_j^{(i)} \right|; \ e_i = \begin{cases} 1, \text{ якщо } e_i > \tau; \\ 0, \text{ якщо } e_i \le \tau; \end{cases} (3.38)$$

де X – послідовність фактичних значень довжиною L_w ; X' – послідовність прогнозних значень ознак довжиною момент часу; $r_j^{(i)}$ – фактичне значення *j*-го термогазодинамічного показника в *i*-й момент часу; $\hat{r}_j^{(i)}$ – прогнозне значення *j*-го термогазодинамічного показника в *i*-й момент часу.

Для моделі на основі Transformer доцільно застосовувати функцію втрат, яка відображає різницю між фактичними та передбаченими значеннями послідовності [379, 380]. Враховуючи, що модель генерує послідовність, зазвичай використовуються функції втрат, що оцінюють ймовірність збігу між згенерованою послідовністю та фактичною цільовою послідовністю. Одним із стандартних виборів для завдання генерації послідовностей є перехресна ентропія (категоріальна крос-ентропія) [381, 382]. Ця функція втрат широко застосовується у завданнях класифікації та генерації послідовностей. Функція втрат перехресної ентропії між фактичними та передбаченими розподілами ймовірностей описується виразом:

$$I = -\sum_{t=1}^{T} y_t \cdot \log(y_t); \qquad (3.39)$$

де *T* – довжина послідовності, *y*_t – фактичний розподіл ймовірностей елемента послідовності на кроці *t*, *y*_t – передбачений розподіл ймовірностей для елемента послідовності на кроці *t*.

Функція втрат (3.46) оцінює різницю між фактичними та передбаченими розподілами ймовірностей для кожного елемента послідовності та штрафує модель за невірні прогнози. Також варто зазначити, що у запропонованому методі середньоквадратична помилка може бути використана для оцінки точності числових прогнозів:

$$MSE = \frac{1}{T} \cdot \sum_{t=1}^{T} \left(y_t - y_t \right)^2;$$
(3.40)

На теперішній час моделі на основі Transformer успішно реалізуються у вигляді графових нейронних мереж, здатність яких до навчання на великих обсягах даних та ефективна робота з послідовностями будь-якої довжини роблять їх незамінними інструментами у сучасних дослідженнях та розробках у галузі штучного інтелекту [383–386]. Графові нейронні мережі (GNN) є потужний клас нейронних мереж, спеціалізованих на аналізі даних, представлених у вигляді графів. На відміну від нейронних мереж GRNN, GNN мають унікальні переваги, такі як здатність враховувати структуру даних, адаптивність до різних графових структур, ефективність у моделюванні складних залежностей та здатність до графового навчання. Тож у запропонованому методі застосовується графова нейронна мережу (рис. 3.21) на відміну від [371], де застосовувалася нейронна мережу GRNN.



Рисунок 3.21 – Загальний вигляд графової нейронної мережі

На початковому етапі навчання GNN на основі архітектури Transformer передбачається, що вхідні дані є графами, де вузли можуть містити ознаки, а ребра можуть мати ваги або іншу інформацію. У цьому графи представляються як матриці суміжності чи списків суміжності. Для навчання моделі також потрібен поділ даних на навчальний, валідаційний та тестовий набори.

На наступному етапі архітектура Transformer адаптується до роботи з графовими даними відповідно до (3.34)–(3.36). Це включає використання механізмів уваги (3.37)

для обліку інформації про сусідні вузли і ребра в графі, що включає створення вхідних і вихідних векторних уявлень для вузлів і ребер, а також використання багатошарових перцептронів для обчислення агрегованих ознак.

На наступному етапі обчислюється функція втрат згідно з (3.39) та середньоквадратична помилка згідно з (3.40). Для мінімізації функції втрат під час навчання далі здійснюється вибір оптимізатора, в якості якого доцільно застосувати Adam, який має адаптивну швидкість навчання, забезпечує стабільне навчання за рахунок використання моментів градієнта і зазвичай демонструє хорошу продуктивність на практиці в задачах класифікації. Для кожної епохи навчання здійснюється прохід по навчальній вибірці. Кожен елемент навчального набору подається на вхід моделі, потім обчислюється функція втрат (3.39) для даного елемента і градієнти функції втрат за параметрами моделі обчислюються як:

$$\nabla_{\theta} J(\theta) = \frac{\partial J(\theta)}{\partial \theta}.$$
(3.41)

Використовуючи обчислені градієнти, параметри моделі оновлюються за допомогою формули оновлення, що базуються на оптимізаторі Adam:

$$m = \beta_1 \cdot m + (1 - \beta_1) \cdot \nabla_{\theta} J(\theta); \qquad (3.42)$$

$$v = \beta_2 \cdot m + (1 - \beta_2) \cdot (\nabla_{\theta} J(\theta))^2; \qquad (3.43)$$

$$\theta = \theta - \alpha_t \cdot \frac{m}{\sqrt{\nu} + \varepsilon}; \tag{3.44}$$

де $\beta_1 = 0.9...0.999$ і $\beta_2 = 0.9...0.999$ – коефіцієнти експоненційного згладжуваня для оцінок першого та другого моментів градієнта відповідно, *m* і *v* – оцінки першого та другого моментів градієнта, ϵ – мале число для чисельної стабільності, α_t – адаптивна швидкість навчання (training rate), пропонована у цій роботі, обчислювана відповідно до виразу:

$$\alpha_t = \alpha \cdot \sqrt{\frac{1 - \beta_2^t}{1 - \beta_1^t}}; \tag{3.45}$$

де *α* – задана швидкість навчання.

Після кожної епохи навчання модель оцінюється на валідаційній вибірці із використанням метрик продуктивності для цієї задачі із застосуванням таких метрик продуктивності:

$$Precision = \frac{TP}{TP + FP}; \ Recall = \frac{TP}{TP + FN}; \ F1 - score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}; \quad (3.46)$$

де *Precision* – точність, *Recall* – повнота, *TP* (True Positives) – кількість правильно ідентифікованих дефектів, *FP* (False Positives) – кількість неправильно ідентифікованих дефектів, *FN* (False Negatives) – кількість дефектів, які модель не змогла ідентифікувати.

Якщо задача ідентифікації потенційних дефектів має кілька класів дефектів, пропонується обчислювати точність кожного класу дефектів, щоб оцінити продуктивність моделі кожному класі незалежно із застосуванням метрики *PerClassAccuracy* – відсотка правильно ідентифікованих дефектів кожного класу:

$$PerClassAccuracy = \frac{TP_i}{TP_i + FN_i};$$
(3.47)

де TP_i (True Positives) – кількість правильно ідентифікованих дефектів *i*-го класу, FN_i (False Negatives) – кількість невірно ідентифікованих дефектів *i*-го класу.

Навчання моделі зупиняється при досягненні критерію зупинки, наприклад, максимальна кількість епох, при якому якщо поточна епоха навчання дорівнює максимальному числу епох, навчання моделі завершується. Іншим критерієм зупинки є відсутність поліпшення на валідаційній вибірці протягом деякої кількості епох. Для цього критерію зазвичай використовується механізм ранньої зупинки (early stopping), який дозволяє припинити навчання, якщо продуктивність моделі на валідаційній вибірці не покращується протягом деякої кількості епох P. Формально це може бути записано таким чином: приймається val_{L_i} – значення функції втрат на валідаційній вибірці після *i*-ї епохи навчання. Тоді для *i*-ї епохи навчання перевіряється, чи покращилася продуктивність моделі на валідаційній вибірці:

$$Impr = val_{L_{i-1}} - val_{L_i}.$$
(3.48)

Якщо відбулося покращення (*Impr* > 0), лічильник епох обнулюється без поліпшення. Якщо покращення не відбулося, лічильник збільшується на 1. Якщо лічильник досягає заздалегідь заданого значення *P*, то навчання моделі зупиняється.

Після завершення навчання моделі оцінюється її продуктивність на тестовому наборі даних, щоб оцінити її здатність до узагальнення нових даних.

У [374] запропоновано застосовувати нову функцію активації нейронів Smooth

ReLU, яка грунтується на функції ReLU. Основна ідея модифікації функції ReLU полягає в тому, щоб зробити функцію активації більш гладкою та безперервною, щоб покращити збіжність та стійкість навчання. Функція активації Smooth ReLU описується виразом:

$$f(x) = \begin{cases} x, \text{ якщо } x > 0; \\ \frac{1}{1 + e^{-\gamma \cdot x}}, \text{ якщо } x \le 0; \end{cases}$$
(3.49)

де γ – параметр, який визначає «ступінь гладкості» функції. При x > 0 функція поводиться як звичайна ReLU. При $x \le 0$ вона використовує функцію сигмоїди, щоб плавно переходити від 0 до негативних значень. Це дозволяє уникнути різких «сходів» у градієнті та допоможе прискорити навчання нейронних мереж.

У роботі математично обґрунтовується доцільність застосування запропонованої функції активації нейронів Smooth ReLU (3.49) порівняно з традиційною ReLU $f(x) = \max(0, x)$, яка застосовується у графових нейронних мережах. Вихідними даними завдання є функція втрат *J* (3.39), яку необхідно мінімізувати, тобто *J* \rightarrow min. Для дослідження функції активації нейронів дуже важливо аналізувати їх похідні. Похідна функції активації дозволяє проаналізувати швидкість зміни функції активації нейронів залежно від змін вхідних даних. Це, у свою чергу, допомагає оптимізувати процес оновлення ваг нейронів під час навчання нейронних мереж.

Похідна традиційної функції активації нейронів ReLU (рис. 3.22, червона крива) має вигляд:

$$f'(x) = \begin{cases} 0, \text{ якщо } x > 0; \\ 1, \text{ якщо } x \le 0. \end{cases}$$
(3.50)

Похідна пропонованої функції активації нейронів Smooth ReLU (рис. 3.22, чорна крива) має вигляд:

$$f'(x) = \begin{cases} 1, \text{ якщо } x > 0; \\ \frac{\gamma \cdot e^{-\gamma \cdot x}}{\left(1 + e^{-\gamma \cdot x}\right)^2}, \text{ якщо } x \le 0. \end{cases}$$
(3.51)



Рисунок 3.22 – Графік похідної традиційної функції ReLU (a) і запропонованої функції Smooth ReLU (б) (авторський доробок [374]).

Як видно з (3.50), (3.51), і з рис. 3.22 проблема зі звичайною ReLU полягає в тому, що похідна дорівнює 0 для всіх негативних значень *x*, що може призвести до проблеми «мертвих нейронів» в нейронній мережі, коли нейрони перестають оновлюватися через нульовий градієнт. Перевага Smooth ReLU полягає в тому, що вона завжди має ненульовий градієнт для всіх значень x, включаючи негативні значення. Це дозволяє уникнути проблеми «мертвих нейронів» та сприяє більш стабільному навчанню, особливо у глибоких нейронних мережах. Отже, математично обґрунтовано застосування Smooth ReLU, оскільки вона забезпечує гладкий та безперервний градієнт на всій області визначення, що може сприяти покращенню збіжності та навчання моделі.

У ході навчання графової нейронної мережі (рис. 3.22) запропонованим алгоритмом отримано залежності точності (рис. 3.23, а), повноти (рис. 3.23, б) та втрат (рис. 3.23, в) нейронної мережі від кількості ітерацій (у роботі застосовано 1000 ітерацій), на яких «синя крива» означає навчання на тренувальній вибірці, «помаранчева крива» означає валідацію на контрольній вибірці. З рис. 3.23, а видно, що граничне значення точності досягає практично 1. 3 рис. 3.23, б видно, що повнота є практично постійною та дорівнює 1. 3 рис. 3.23, в видно, що значення втрат не перевищує 0.025, що свідчить про високу ефективність навчання моделі на наявних даних та її здатність до точного узагальнення нових даних. Такі результати роблять модель потенційно придатною для розв'язання задачі ідентифікації потенційних дефектів ГТД вертольотів.



Рисунок 3.23 – Графіки залежності точності (а), повноти (б) і втрат (в)

На рис. 3.24 показано результати ідентифікації потенційних дефектів на основі довгострокового прогнозування параметра температури газів перед турбіною компресора T_{Γ}^* у вузлах авіаційного двигуна ТВЗ-117 [371]. На графіку вихідного параметра T_{Γ}^* , який відповідає моменту часу t = 94,65 години, проводиться прогнозування. При t = 96.2години спостерігається зниження параметра T_{Γ}^* на 4 %, а при t = 99,3 години – ще 3%, що у сумі становить зниження 7 %. У моменти часу t = 96.2 години та t = 99,3 години на рис. 3.25 і 3.26 показані відповідні сплески, що свідчать про можливу несправність камери згоряння двигуна – потенційну появу тріщин (прогарів). Таким чином, нормальна робота двигуна може гарантуватися протягом 8 годин. Результати даних досліджень повністю підтверджують раніше проведені ідентичні дослідження [371].

Червона крива на рис. 3.26 означає виявлений ймовірний дефект – можливу появу тріщин (прогарів) в камері згоряння. Отримані дані щодо довгострокового прогнозу параметра температури газу перед турбіною компресора ГТД вертольотів дозволяють вживати ефективних заходів щодо виявлення та попередження потенційних дефектів камери згоряння двигуна, що в свою чергу сприяє підвищенню безпеки та надійності.

Аналогічно [371], в результаті проведеного порівняльного експерименту отримано результати (табл. В.15) розробленого та відомих методів: Simple Autoencoder, Autoencoder із застосуванням нейронної мережі LSTM, розробленого в [371] методу із застосуванням нейронної мережі GRNN та розробленого методу із застосуванням графової нейронної мережі.



Рисунок 3.24 – Результати виявлення можливих дефектів камери згоряння



Рисунок 3.25 – Результати виявлення можливих дефектів камери згоряння

авіаційного двигуна ТВЗ-117 (авторський доробок [374])



Рисунок 3.26 – Результати виявлення можливих дефектів камери згоряння авіаційного двигуна ТВЗ-117 (авторський доробок [374])

З табл. В.15 видно, що результати запропонованого методу з використанням графової нейронної мережі перевершують майже всі представлені точності метрики. Альтернативні методи (Simple AutoEncoder [387], LSTM AutoEncoder [388] та аналогічний метод із застосуванням нейронної мережі GRNN, розроблений у [371]) також демонструють погіршення показників на тих самих сигналах. З табл. 3.20 також

видно, що результати за всіма метриками Precision, Recall, F1-scope при використанні графової нейронної мережі є кращими порівняно з Simple AutoEncoder, LSTM AutoEncoder та аналогічним методом із застосуванням нейронної мережі GRNN [371]. Ці результати підтверджують ефективність та високу точність запропонованого методу з використанням графової нейронної мережі, при цьому досягається висока точність по всіх аналізованих перетвореннях. Отже, результати запропонованого методу перевершують майже всі представлені метрики точності порівняно з альтернативними методами: Simple AutoEncoder, LSTM AutoEncoder та аналогічним методом із застосуванням нейронної мережі GRNN [371].

На заключному етапі порівняльного експерименту здійснювалося оцінювання ефективності запропонованого методу, яке полягає у проведенні порівняльного аналізу точності класичних та нейромережевих методів ідентифікації потенційних дефектів, результати якого наведено у табл. В.16, в якій відображено результати розрахунку ймовірності помилок 1 і 2 роду при ідентифікації дефектів компресора (параметр n_{TK}), камери згоряння (параметр T_{Γ}) та турбіни компресора (параметр n_{CB}). При цьому помилки першого та другого роду обчислювалися як:

$$FPR = \frac{FP}{FP + TN}; \quad FNR = \frac{FN}{FN + TP}; \quad (3.52)$$

де False Positives (*FP*) – кількість спостережень, які неправильно класифіковані як позитивні, False Negatives (*FN*) – кількість спостережень, які неправильно класифіковані як негативні, True Positives (*TP*) – кількість спостережень, які правильно класифіковані як позитивні, True Negatives (*TN*) – кількість спостережень, які правильно класифіковані як негативні.

Помилка першого роду означає, що нульова гіпотеза відкидається, коли вона насправді вірна, а помилка другого роду означає прийняття нульової гіпотези, коли вона насправді є невірною. У контексті ідентифікації потенційних дефектів нульова гіпотеза визначається як: «Немає потенційних дефектів в ГТД вертольотів». Це означає, що у припущенні нульової гіпотези немає аномалій, помилок чи дефектів, які потрібно ідентифікувати чи виправити.

З табл. В.16 визначено, що застосування графової нейронної мережі знижує помилки першого та другого роду порівняно із застосуванням Simple AutoEncoder у 3.49...7.58 разів, LSTM AutoEncoder – у 2.88...4.36 разів, нейронної мережі GRNN [371] – у 1.81...1.93 разів. Тому можна дійти невтішного висновку, що застосування графової нейронної мережі у методі ідентифікації потенційних дефектів знижує помилки першого і другого роду майже 2 разу порівняно із застосуванням нейронної мережі GRNN [371].

3.5 Розробка методу налагодження дозатора палива газотурбінного двигуна вертольоту

Аналіз аварій вертольотів за типом двигуна показав, що аварії вертольотів із поршневими двигунами відбувалися частіше на ранніх етапах експлуатації вертольотів, але в міру того, як ГТД стали більш популярними, тенденція суттєво змінилася близько десяти років тому. Останні дані свідчать, що кількість аварійних і катастрофічних ситуацій вертольотів з ГТД зросла порівняно з кількістю аварій і катастроф вертольотів з поршневими двигунами. Як наслідок, необхідні подальші дослідження для підвищення безпеки польотів вертольотів з ГТД, однією із локальних задач якої є задача налагодження (регулювання) параметрів ГТД вертольотів [389, 390].

Професором Жернаковим С.В. встановлено [391–393], що параметри відрегульованого, нормально функціонуючого ГТД у просторі контрольованих параметрів, наприклад, на площині термогазодинамічних параметрів (рис. В.5) X_1^* і X_2^* , відповідають заданому номінальному режиму роботи двигуна: $X_1^* = X_{1nom}^*$, $X_2^* = X_{2nom}^*$. Прийнято, що характеристики парку справних двигунів для тих же параметрів, що вимірюються, дають деякий розкид щодо зазначеної номінальної точки, утворюючи еліпс (у багатовимірному просторі – еліпсоїд) розсіювання (рис. 3.35). Вихід робочої точки межі цього еліпса відповідає аномальним змінам параметрів індивідуального двигуна. Тоді метою налагодження параметрів авіаційного двигуна є повернення «точки, що випала» в еліпс (еліпсоїд) шляхом плавного регулювання елементів конструкції двигуна. Відповідно до досліджень професора Жернакова С.В. [391–393], регульованим елементом конструкції авіаційних двигунів є площа критичного перерізу соплового апарату двигуна F_{con} . Даний параметр є тільки в турбореактивних та турбовентиляторних двигунах і відсутній у турбовальних двигунах (авіаційних двигунах із вільною турбіною), що застосовуються у складі силових установок вертольотів.

Розв'язання даної задачі у нейромережевому базисі, відповідно до досліджень професора Жернакова С.В., представлене у вигляді такої послідовності кроків [391–393]:

– формування навчальної вибірки за результатами випробувань парку двигунів;

- визначення меж зміни параметра, що варіюється;

побудова нейромережевої моделі середньостатистичного двигуна, вхідними параметрами якої є величина діаметра реактивного сопла, а виходами – термогазодинамічні параметри двигуна;

побудова регулювальної кривої;

 обчислення необхідної поправки діаметра реактивного сопла індивідуального двигуна;

 уточнення значень термогазодинамічних параметрів відрегульованого двигуна для скоригованого значення діаметра реактивного сопла.

У [389] була зроблена спроба застосувати розв'язання задачі налагодження параметрів авіаційних двигунів у нейромережевому базисі при експлуатації авіаційного двигуна ТВЗ-117, що належить класу авіаційних двигунів зі вільною турбіною та застосовується у складі силової установки вертольоту Ми-8МТВ.

Математична модель налагодження параметрів ГТД вертольоту ґрунтується на алгоритмі роботи пристрою управління, що призводить до усунення неузгодженості є, розраховують для кожного регулюючого елемента (РЕ) двигуна. Найбільш універсальним визнано підхід, що ґрунтується на застосуванні функцій А. М. Ляпунова [390]:

$$V_1 = F(\varepsilon, \dot{\varepsilon}, u_n, \alpha_1); \ V_2 = F(\varepsilon, \dot{\varepsilon}, u_p, \alpha_2); \dots \ V_i = F(\varepsilon, \dot{\varepsilon}, u_i, \alpha_i);$$
(3.53)

де α_i – параметр, що характеризує положення РЕ. У цьому визначається похідна за часом кожної функції А.М. Ляпунова і накладається неї умова непозитивності $\frac{dV_i}{dt} \le 0$

. Потім, з умов стійкості процесу настройки, визначається алгоритм настройки у вигляді $\dot{\alpha}_i = F(\varepsilon, \dot{\varepsilon}, u_n, u_p)$. Таким чином здійснюється налагодження регулятора ГТД вертольотів за заданими параметрами u_n і u_p .

З використанням прямого методу А.М. Ляпунова за умовами стійкості здійснюється компенсація взаємного впливу становища РЕ на вихідні параметри паливного

регулятора. Оскільки алгоритм налаштування кожного РЕ буде схожим, то у разі одночасного налаштування узгоджених характеристик всіх РЕ весь процес налагодження паливного регулятора буде схожим, стійким. Основним недоліком запропонованого методу є можлива неузгодженість характеристик різних РЕ. Розглянемо процес налагодження неузгоджених параметрів ГТД вертольотів на прикладі дозатора палива (рис. В.6).

Використовуючи підхід, який базується на використанні функцій Ляпунова, у [390] отримано рівняння налаштування:

$$\dot{A}^{M} = \varepsilon_{1} \cdot \left| K \cdot \Psi(\alpha) \right|^{T} \text{ abo } A^{M} = \int \varepsilon_{1} \cdot \left| K \cdot \Psi(\alpha) \right|^{T} dt; \qquad (3.54)$$

$$\dot{B}^{M} = \varepsilon_{1} \cdot \left| L \cdot \Phi(I) \right|^{T} \text{ also } A^{M} = \int \varepsilon_{1} \cdot \left| L \cdot \Phi(I) \right|^{T} dt; \qquad (3.55)$$

$$\dot{C}^{M} = \varepsilon_{2} \cdot \left| M \cdot Q(G_{T}) \right|^{T} \text{ abo } C^{M} = \int \varepsilon_{2} \cdot \left| M \cdot Q(G_{T}) \right|^{T} dt; \qquad (3.56)$$

$$\dot{D}^{M} = \varepsilon_{2} \cdot \left| N \cdot U(\alpha) \right|^{T} \text{abo } C^{M} = \int \varepsilon_{2} \cdot \left| N \cdot U(\alpha) \right|^{T} dt.$$
(3.57)

де A^M , B^M , C^M , D^M – коефіцієнти, що перебудовуються, рівні після закінчення процесу ідентифікації коефіцієнтам рівнянь, що описують дозатор палива, $\Psi(\alpha)$, $\Phi(I)$, $Q(G_T)$; $U(\alpha)$ – нелінійні функції, ε_1 , ε_2 – залишкові сигнали, K, L, M, N – позитивно визначені діагональні матриці заданих сталих коефіцієнтів [390].

Визначені значення коефіцієнтів A^M , B^M , C^M , D^M , що описують реальну модель, порівнюються зі значеннями A^E , B^E , C^E , D^E еталонної моделі. Для налагодження дозатора





палива використовуються сигнали відмінностей між ідентифікованим і еталонним коефіцієнтами $\delta A = A^M$ $-A^E$, $\delta B = B^M - B^E$, $\delta C = C^M - C^E$, δD $= D^M - D^E$. Величина переміщення виконавчих механізмів визначається чутливістю дозатора палива до переміщення елемента керування двигуном.

У [394] розв'язана задача налагодження параметрів дозатора палива ГТД вертольотів за допомогою нейронної мережі прямого поширення, для якої розроблено алгоритм навчання на основі адаптивних компонентів. Відповідно до [394] нейронна мережа прямого поширення зберігає інформаційний портрет середньостатистичного двигуна на одному з режимів його роботи і за подачі її вхід значення n_{TK} обчислює значення наведеного параметра G_T із застосуванням універсальної математичної моделі налагодження параметрів ГТД вертольоту. Базуючись на [389–393], в якості архітектури нейронної мережі приймається тришарова мережа прямого поширення з використанням адаптивних елементів (рис. 3.27). Створено алгоритм навчання нейронних мереж прямого поширення, що грунтується на алгоритмі зворотного розповсюдження помилки, який за рахунок застосування адаптивних елементів, таких, як адаптивна швидкість навчання, адаптивна ініціалізація ваг нейронної мережі, адаптивна регуляризація, адаптивна функція активації нейронів, адаптивна зміна архітектури нейронної мережі, адаптивна зміна розміру міні-пакету. Для розв'язання задачі налаштування параметрів ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) в якості навчальної вибірки використовуємо значення частоти обертання ротора турбокомпресора на злітному режимі, наведеної до абсолютних значень, наведені у табл. В.17, а параметри середньостатистичного парку дви-



Рисунок 3.28 – Графік залежності $C_{num} = f(n_{TK})$ та результат апроксимації (авторський доробок [394])

гуна такі: $\bar{n}_{TK} = 0,994, \ \bar{C}_e = 0,977.$

У задачі налагодження параметрів ГТД вертольотів вхідним сигналом згідно [391] представлена залежність питомої витрати палива *С*_{пит} від частоти обертання ротора турбокомпресора *п*_{TK} для авіаційного двигуна ТВЗ-117 (що представляє елемент дросель-

ної характеристики двигуна). На рис. 3.28 представлені вхідні дані, позначені точками, які для наочності апроксимовані ламаними лініями. У ході навчання нейронної мережі прямого поширення запропонованим алгоритмом [394] отримано залежності точності (рис. 3.29, а) та втрат (рис. 3.29, б) нейронної мережі від кількості ітерацій (у роботі застосовано

100 ітерацій), на яких «синя крива» означає навчання на тренувальній вибірці, «помаранчева крива» означає валідацію на контрольній вибірці. З рис. 3.39, а видно, що граничне значення точності досягає 1, а з рис. 3.39, б видно, що максимальне значення втрат вбирається у 0,025. Це вказує на високий ступінь ефективності навчання моделі на наданих даних та здатність моделі узагальнювати нові дані з високою точністю, що робить її потенційно придатною для вирішення завдання налагодження параметрів ГТД вертольотів.



Рисунок 3.29 – Графік зміни функції точності (а) і втрат (б) нейронної мережі при 100 ітерацій

Результатами проведеного обчислювального експерименту є як частинні дослідження розробленого алгоритму навчання нейронної мережі [394], так і результуючий графік площі розподілу даних двох класів та граничні лінії за рівнями 0.1, 0.5, 0.9, на якій відображені допустимі та неприпустимі значення n_{TK} згідно зі значеннями C_{num} , яку необхідно порівняти з відповідними результатами, отриманими у [391]. Адекватність результуючого графіка площі розподілу даних двох класів, відновленого нейронною мережею, безпосередньо залежить від процесу навчання. Відповідно до [391] виділено ряд параметрів, що впливають на якість навчання: коефіцієнт швидкості навчання (приймається 10^{-4}); кількість нейронів у прихованому шарі (приймається 10); кількість пройдених епох навчання (приймається 100 епох навчання). Як критерій оцінки якості навчання застосовано підсумкове сумарне середньоквадратичне відхилення за епоху, яке визначається згідно з виразом:

$$E_{enox} = \frac{1}{N} \cdot \sum_{i=1}^{N} \frac{1}{2} \cdot \left(y_k - y_k\right)^2.$$
 (3.58)

Результати проведених досліджень наведено у табл. Б.18–Б.20 та на рис. 3.30, де: рис. 3.30, а – графік, що визначає вплив швидкості навчання на підсумкове середньоквадратичне відхилення; рис. 3.30, б – графік, що визначає вплив кількості прихованих нейронів на підсумкове середньоквадратичне відхилення; рис. 3.30, в – графік, визначальний вплив кількості пройдених епох на підсумкове середньоквадратичне відхилення.



прихованому шарі (б), кількості епох навчання (в) на результуючу похибку (авторський доробок [394])

З отриманих результатів випливає, що мінімальні підсумкові сумарні середньоквадратичні відхилення за епоху отримані при оптимальному значенні коефіцієнта навчання є 10⁻⁴ при 10 нейронах у прихованому шарі. Варто зазначити, що у [391] оптимальною кількістю нейронів у прихованому шарі З. Збільшення кількості нейронів у прихованому шарі з 3 до 10 призводить до помітного поліпшення узагальнюючої здатності моделі та зниження ризику перенавчання. Збільшення числа нейронів до 10 дозволяє моделі гнучкіше адаптуватися до складних взаємозв'язків у даних, що сприяє підвищенню точності передбачень на нових даних, що раніше не зустрічалися. Це пов'язано з тим, що більша кількість нейронів дозволяє моделі вивчати складніші функції та структури даних, що особливо важливо у випадку з високорозмірними та складними даними. Отже, збільшення кількості нейронів до 10 у прихованому шарі є перспективним кроком для покращення якості роботи нейронної мережі.

Також варто зазначити, що, починаючи зі 100 епох навчання, мінімальне підсумкове сумарне середньоквадратичне відхилення є мінімальним і постійним – 3,358, що вказує на те, що модель досягла оптимальної точності на даному наборі даних та подальше навчання не призводить до суттєвого покращення результатів. Це може свідчити про те, що модель навчилася пророкувати цільову змінну з високою точністю і додаткові епохи навчання не приносять значного приросту як передбачення. Отже, постійне значення мінімального сумарного середньоквадратичного відхилення після 100 епох свідчить про збіжність моделі та готовність її до використання для розв'язання задачі налагодження параметрів ГТД вертольотів.

На наступному етапі обчислювального експерименту проводиться дослідження регулювальної кривої $C_{num} = f(\bar{n}_{TK})$, яка, відповідно до [391], подана як:

$$C_{num}(\bar{n}_{TK}) = 0,0016 \cdot n_{TK}^4 - 0,0195 \cdot n_{TK}^3 + 0,0864 \cdot n_{TK}^2 - 0,1774 \cdot n_{TK} + 0,4083.$$
(3.59)

де $\overline{n_{TK}} = \frac{n_{TK}}{n_{TK \max}}$ – відносне значення величини частоти обертання ротора турбокомпресора.

На рис. 3.31 наведено графік залежності цільової функції $C_{num}(\bar{n}_{TK}) \rightarrow \min$ від значення n_{TK} , де «синя крива» показує вихідну залежність, отриману у [391], «помаранчева» – залежність, отримана в даній роботі з використанням L2-регуляризації [394]. У цьому випадку цільова функція матиме оновлений вигляд:

$$C_{num}\left(\bar{n}_{TK}\right)_{L2} = C_{num}\left(\bar{n}_{TK}\right) + \left(L + \frac{\lambda}{2 \cdot N} \cdot \sum_{i=1}^{L} \left\|W^{(i)}\right\|^{2}\right);$$
(3.60)

або

$$C_{num} \left(\bar{n}_{TK} \right)_{L2} = 0,0016 \cdot n_{TK}^4 - 0,0195 \cdot n_{TK}^3 + 0,0864 \cdot n_{TK}^2 - 0,1774 \cdot n_{TK} + 0,4083 + \left(L + \frac{\lambda}{2 \cdot N} \times \left(W^{(1)} + W^{(2)} + W^{(3)} + W^{(4)} + W^{(5)} \right)^2 \right);$$
(3.61)



Рисунок 3.31 – Графік залежності цільової функції від значень *n*_{TK} (авторський доробок [391])

де $W^{(1)}$, $W^{(2)}$, $W^{(3)}$, $W^{(4)}$, $W^{(5)}$ є ваговими коефіцієнтами моделі, що відповідають кожному з п'яти членів у вихідній функції $C_{num}(\bar{n}_{TK})$ (3.59).

Як видно з рис. 3.31, додавання L2-регуляризації до цільової функції дозволило підняти криву коригування $C_{marr}(\bar{n}_{TK})$ на величину регуляризації вгору, наблизивши її до 1, додавши до початкової функція, яка збільшує його значення. Це дозволяє моделі більш ефективно враховувати складність даних і зменшувати ризик переобладнання за рахунок штрафу за великі значення вагових коефіцієнтів. Піднята крива забезпечує більш стабільну та надійну оптимізацію моделі, що може призвести до покращеної здатності до узагальнення та точності прогнозування нових даних. У цьому випадку мінімум цільової функції 0,40 досягається при значенні $n_{TK} = 0,992$. Так, поправка середнього значення n_{TK} на $n_{TK}^{sopucoeane} = 0,994 –$ $0,991 = 0,003, а значення <math>n_{TK}^{sopucoeane} = 0,006$, отримане у [391]. Отже, додавання L2-регуляції дозволило точніше (в 2 рази порівняно з [391]) регулювати значення n_{TK} і наблизити його до середнього значення по парку двигунів $\overline{n}_{TK} = 0,994$. Для демонстрації застосування нейронної мережі прямого поширення з використанням адаптивних елементів для вирішення задачі налагодження параметрів ГТД вертольотів [391] досліджено сценарій двовимірної класифікації, який полягає в тому, що з використанням квадратурного демодулятора спостерігається один з двох випадкових вузькосмугових процесів. При цьому функція щільності ймовірності кожного з цих процесів описується таким виразом:

$$p(I,Q) = \frac{1}{\sqrt{2\pi\sigma_I\sigma_Q}} \cdot e^{-\left[\frac{(I-m_I)^2}{2\sigma_I^2} + \frac{(Q-m_Q)^2}{2\sigma_Q^2}\right]};$$
(3.62)

де σ_{I} , σ_{Q} – дисперсії, m_{I} , m_{Q} – математичні очікування складових випадкових процесів, I – відповідає значенням n_{TK} ; Q – відповідає значенням C_{num} .

Отримані результати дозволили отримати уточнену площу розподілу даних двох класів (I і Q) з граничними значеннями n_{TK} відповідно до ліній за рівнями 0,1, 0,5, 0,9 (рис. 3.42). Рис. 3.42 дозволяє визначити області, у яких найбільш імовірно перебування кожного класу. Уточнені граничні значення n_{TK} на лініях за рівнями 0,1, 0,5, 0,9 дозволяють точніше визначити оптимальні значення n_{TK} для досягнення необхідних рівнів C_{num} . Як видно із рис. 3.32, до області неприпустимих значень n_{TK} і C_{num} (червона область) входять їх значення, розташовані на межі цієї області. Це свідчить про неприпустимість регулювання параметра n_{TK} щоб одержати гранично допустимого значення C_{num} . Рівень 0,1 означає нижній рівень допустимих значень C_{num} , рівень 0,5 – оптимальних значень C_{num} , рівень 0,9 – максимально допустимих значень C_{num} . Неприпустимість регулювання

параметра n_{TK} для отримання гранично допустимого значення C_{num} в режимі польоту гелікоптера пояснюється тим, що у цьому контексті існує певний зв'язок між n_{TK} і C_{num} , що визначається оптимальними умовами роботи двигуна. При регулюванні n_{TK} з метою досягнення гранично допустимого значення питомої витрати палива C_{num} , що знаходиться



Рисунок 3.32 – Дані двох класів (синя зона – дозволені значення *n*_{TK} і *C*_{num}; червона область – неприпустимі значення *n*_{TK} і *C*_{num}) і граничні лінії на рівнях 0,1, 0,5, 0,9 (авторський доробок [394])

на межі червоної області на рис. 3.42, система може вийти за межі допустимих параметрів функціонування двигуна. Це може призвести до небажаних наслідків, таких як перегрівання двигуна, втрата стабільності польоту або навіть аварії. Для забезпечення безпеки і нормальної роботи вертольоту в умовах льотної експлуатації важливо дотримуватися оптимальних параметрів

роботи двигуна, у тому числі, пов'язаних з n_{TK} , щоб уникнути виходу за межі допустимої області значень C_{num} . Отже, рис. 3.42 надає важливу інформацію регулювання параметрів роботи системи, оскільки дозволяє визначити оптимальні значення n_{TK} для досягнення бажаних показників C_{num} .

Проведено порівняльний аналіз розв'язання задачі налагодження параметрів ГТД вертольотів на основі нейронної мережі прямого поширення з адаптивними елементами із застосуванням запропонованого в роботі алгоритму її навчання, так і з алгоритмом Delta-Bar-Delta, застосованим у [391]. Обчислено помилки першого та другого роду (табл. В.21) отримання граничних значень *n*_{TK} для досягнення необхідних рівнів *C*_{num}.

З табл. В.21 визначено, що застосування нейронної мережі прямого поширення з адаптивними елементами, навчену на основі запропонованого алгоритму [394], дозволив знизити помилки першого та другого роду в 1.65...1.71 раз порівняно із застосуванням алгоритму Delta-Bar-Delta для її навчання [391]. На заключному етапі порівняльного аналізу обчислено коефіцієнти помилки і коефіцієнти якості (табл. В.22) нейронної

мережі прямого поширення з адаптивними елементами як для запропонованого алгоритму її навчання, так і для алгоритму Delta-Bar-Delta [391].

З табл. В.22 визначено, що застосування нейронної мережі прямого поширення з адаптивними елементами, навчену на основі запропонованого [394] алгоритму, дозволив знизити коефіцієнт похибки в 1,89 і раз і незначно (в 1,01 раз) підвищити коефіцієнт якості визначення граничних значень частоти обертання ротора турбокомпресора *n*_{TK} порівняно алгоритму Delta-Bar-Delta [394].

3.6 Розробка методу тренд-аналізу параметрів газотурбінного двигуна вертольоту

Важливою задачею у процесі аналізу експериментальних даних, які відображають розпізнавання «вигляду» ГТД вертольоту є визначення розладнання у виміряних параметрах часового ряду, тобто аналіз статистичних характеристик результатів реєстрації контрольованих параметрів з метою визначення їх стаціонарності. Основна задача тренд-аналізу – виявлення закономірностей в послідовності даних. Серед найбільш поширених «класичних» методів аналізу тренду виділяють: параметричні, непараметричні і змішані методи [395–397]. З параметричних методів найбільш докладно розглянемо інтегральний критерій, який полягає в такій послідовності операцій:

попередньо здійснюється обробка числового ряду (даних вимірювань) {*Y*₁, ..., *Y_N*}
 з метою перетворення його до вигляду, зручного для подальшої оцінки;

 – аналізується логіка і фізика процесу, що робить істотний вплив як на вибір виду апроксимуючої функції, так і на визначення меж зміни її параметрів.

Попередня обробка вихідного числового ряду на інтервалі часу $T_{\in}[t_1,...,t_N]$ спрямована на зниження впливу випадкової складової $\varepsilon(t)$ у початковому числовому ряді $\{Y_1, ..., Y_N\}$ (тобто наближення її до тренду) на подання міститься в числовому ряду інформації в такому вигляді, щоб істотно зменшити труднощі аналітичного опису тренду [397].

Основні методи розв'язку цих задач – процедури згладжування і вирівнювання статистичного ряду. При цьому процедура згладжування направлена на мінімізацію випадкових відхилень точок від деякої гладкої кривої передбачуваного тренду процесу. Згладжування здійснюється за допомогою многочленів, що наближають по методу найменших квадратів групи виміряних в експерименті точок. Навіть у простому лінійному варіанті процедура згладжування дуже ефективна у процесі виявлення тренду при накладенні на емпіричний числовий ряд випадкових перешкод і похибок вимірювань. Якщо згладжування направлено на первинну обробку числового ряду для виключення випадкових коливань і виявлення тренду, то вирівнювання на меті сприяння більш зручного представлення вихідного ряду при збереженні його значень. У найпростішому випадку ця процедура може бути здійснена апроксимацією по вихідному ряду оброблених експериментальних точок. Вибір критерію оптимальності заходів відхилення точок емпіричного ряду від апроксимуючої функції здійснюється за формулою (метод МНК) [397]:

$$\sum_{j=1}^{N} \left(Y_j - \eta \left(t_j, \alpha_1, \dots, \alpha_N \right) \right)^2 \to \min;$$
(3.63)

де Y_j – точки емпіричного ряду (виміряні значення); η – апроксимуюча функція; t_j – часова складова; $\alpha_1 \dots \alpha_N$ – апроксимовані точки.

Одним з інтегральних критеріїв оцінки тренду були розглянуті такі функціонали:

$$\delta = \frac{Y_j - Y_n(j)}{Y_n(j)}; \qquad (3.64)$$

де Y_j – дані експерименту, $j = \overline{1, N}$; $Y_n(j)$ – дані, обчислені за моделлю; N – кількість точок, виміряних в експерименті; δ – оцінка тренду.

Застосування цього критерію (3.64) у процесі оцінки експериментальних даних показано на рис. 3.43, *a*. На рис. 3.43, *б* виділено чотири характерні ділянки: I – з 0 по 80 год; II – з 80 по 94 год; III – з 94 по 115 год; IV – з 115 по 126,5 год експлуатації двигуна. Тренд відсутня на I і III ділянках, а проявляється на II і IV. На рис. 3.43, *a* можна також спостерігати чотири характерних ділянки: I – з 0 по 80 год; II – з 80 по 106 год; III – з 106 по 115 год; IV – з 115 по 126,5 год експлуатації двигуна. Очевидно, що тренд відсутній лише на першій ділянці напрацювання, а на інших трьох помітна тенденція до зміни температури газу перед турбіною компресора, тобто присутність тренду. При цьому, якщо тільки на другій ділянці температура повільно підвищується, то на третьому і четвертому її зміна має яскраво виражений характер.

Іншим інтегральним критерієм оцінки тренду є функціонал виду [397]:

$$\delta = \sum_{j=1}^{N} \left(\frac{Y_j - Y_n(j)}{Y_n(j)} \right)^2.$$
(3.65)

Застосування критерію (3.65) у процесі аналізу частоти обертання ротора високого тиску показано на рис. 3.33, δ , де також помітні чотири характерних ділянки: І – з 0 до 20 год; II – з 20 по 94 год; III – з 94 по 116 год; IV – з 116 по 126,5 год експлуатації систем управління вертольотом (СУВ). Перша ділянка напрацювання характеризується як область підробітки; друга – область нормального періоду експлуатації; третя і четверта – області інтенсивного зносу і старіння.



Рисунок 3.33 – Тренд-аналіз: *а* – температури газу перед турбіною компресора; *б* – частоти обертання ротора турбокомпресора (авторський доробок [393])

У процесі дослідження тренду класичними методами зроблено висновок про те, що «класичні» інтегральні критерії вельми ефективні при експрес-аналізі, мають точність, наочність і здатні з високим ступенем достовірності визначити момент початку прояви тренду. Прийнято, що x(t) (t = 1, 2, ..., N) – послідовність дискретних спостережень параметрів СУВ $x(t) = f(t) + \zeta(t)$ на тлі перешкоди $\zeta(t)$ з нульовим середнім і дисперсією σ^2 . В якості моделі часових залежностей (трендів) використано множину поліномів [394]:

$$f_{j}(t) = \sum_{s=0}^{j=1} c_{sj} t^{s}; \ (j = 1, 2, ..., n)$$
(3.66)

з невідомими коефіцієнтами c_{sj} ; де j – індекс типу моделі.

При поточному оцінюванні модель (3.66) приведена до вигляду:

$$f_{j}(t + \Delta t) = \sum_{s=0}^{j=1} f_{j}^{(s)}(t) \cdot \frac{\Delta t^{s}}{s!}; \ (j = 1, 2, ..., n);$$
(3.64)

176

де Δt – час, що відраховується від поточного моменту часу t; $f_i^{(s)} - s$ -а похідна функції $f_j(t)$.

Визначається значення функції $f_i(t)$ по ковзній вибірці спостережень x(t - N + 1) x(t)-N+2),..., x(t) сталого обсягу N, що дозволяє відслідковувати зміну коефіцієнтів c_{sj} моделі (3.64). Регулярні дані відповідають наявності певної закономірності. Порушення цієї закономірності відбувається при зміні коефіцієнтів c_{sj} у (3.64). Задача полягає в побудові нейромережевої моделі, що дозволяє на підставі результатів обробки спостережень (вимірювань параметрів СУВ) x(t) встановити факти порушення закономірностей трендів і моменти часу появи цих порушень (трендів). Проведена порівняльна оцінка ефективності тренд-аналізу нейромережевого і класичних критеріїв. Порівняльне дослідження критеріїв здійснювалось на основі імітаційного моделювання, що дозволило здійснити перевірку в широкому діапазоні зміни похибок вимірювань і інтенсивності прояви тренду. Значення контрольованого параметра дорівнює сумі детермінованою основи і випадкової нормально розподіленої перешкоди з дисперсією ξ . Детермінована складова постійна на інтервалі $[0, t_0]$, а потім змінюється лінійно з темпом $a = tg(\alpha) (1/c)$ (де *α* – інтенсивність тренду). У ході моделювання значення *а* варіювалося в діапазоні [0,01; 1]; а значення ξ в діапазоні [0,001; 1]. При моделюванні для настройки математичної моделі ГТД вертольоту використовувалася вибіркова дисперсія, розрахована на інтервалі стаціонарності $[0, t_0]$. Починаючи з моменту t_0 , обчислювалися значення критеріїв і перевірялося наявність тренду. Ефективність критеріїв оцінювалася часом спрацьовування критеріїв від початку тренду τ_0 до моменту часу, відповідного виявлення тренду τ_{3an} [394].

При попередній обробці вважається, що функції f(t) і $\xi(t)$ не корельовані. Потрібно, щоб вектор $Out^{x}(t)$ вихідних величин фільтра $Out_{l}^{x}(t)$, $l = \overline{1, N}$, що є реакцією на зовнішній вплив, наближався до бажаної функції від корисного сигналу:

$$Out^{x}(t) \approx Ff(t); \qquad (3.65)$$

де $F = (F_l)$ – деякий векторний оператор, що описує відображення множини корисних сигналів у вихідні сигнали фільтра. Мірою наближення *Out^x(t)* до *Ff(t)* у загальному випадку можна вибрати функціонал: 177

$$J = J\left\{\varphi\left(Ff\left(t\right) - Out^{x}\left(t\right)\right)\right\};$$
(3.66)

де $\varphi(\bullet)$ – деяка міра векторної функції.

У найпростішому випадку (рис. 3.43) вхідний сигнал подається на множину послідовно з'єднаних функціональних елементів, що володіють затримкою Z⁻¹ (в синапсах). Їх вхідні величини подаються у вигляді сигналів $In^{x}(t - kZ^{-1}), k = 1, N$ з вагами W_{jk} , формуючи вектор оцінок корисних сигналів $(x_{j}(t))$, на основі якого за допомогою мережі, що реалізує матрицю операторів (F_{lj}) , формується вектор вихідних сигналів $(Out_{l}^{x}(t))$:

$$Out_l^x(t) = F_{lj}\left(\sum_k W_{jk} In^x(t-kZ^{-1})\right).$$
(3.67)

Задачею фільтрації є відтворення корисного сигналу на тлі шумів і виконання необхідного перетворення. Для розв'язання даної задачі необхідно мінімізувати середньоквадратичне відхилення оцінки корисного сигналу $x_j(t)$ від очікуваного j – корисного сигналу $f_j(t)$, що характеризує відповідний корисний результат нейромережевого фільтра, тобто знайти [394]:

$$\min_{W_{jk}} M\left\{\sum_{j} \left(f_{j}\left(t\right) - \sum_{k} W_{jk} In^{x}\left(t - kZ^{-1}\right)\right)^{2}\right\};$$
(3.68)

де М – математичне сподівання.

Згідно з цим критерієм можуть бути реалізовані класичні алгоритми адаптації фільтра з використанням апріорної інформації про корисний сигнал і шумі. Для розв'язання поставленої задачі професором Жернаковим С.В. [394] запропоновано використовувати в якості динамічної (рекурентної) нейронної мережі, що реалізує НЧфільтр, може бути обраний персептрон; для ВЧ-фільтра – нейронна мережа РБФ (радіально-базисної функції). Алгоритм навчання ансамблевої нейронної мережі – комплексний *back propagation*.

Ключовим недоліком класичних алгоритмів адаптації фільтрів є обмежена здатність враховувати динамічні зміни вхідних сигналів і шуму, що знижує їх ефективність в реальних умовах. У зв'язку з цим, доцільно розробляти нейронну мережу Джордана з динамічною стековою пам'яттю, яка дозволяє більш ефективно обробляти часові залежності і адаптуватися до змін у сигналі, що робить її оптимальним вибором для розв'язання цієї задачі [393] (рис. В.7).

Зворотний зв'язок реалізується через подачу на вхідний шар не тільки вихідних даних, а й сигналів виходу мережі із затримкою на один або кілька тактів, що дозволяє врахувати передісторію процесів, що спостерігаються, і накопичити інформацію для вироблення правильної стратегії управління. Модифікована нейронна мережа Джордана отримана шляхом додавання затримки сигналів зворотного зв'язку прихованого шару кілька тактів, тобто, додавання до шару динамічної стекової пам'яті. Опис модифікації рекурентної нейронної мережі шляхом додавання до неї динамічної стек-пам'яті описано у [393], а також подано у п. 3.1 цієї роботи (на прикладі нейронної мережі Елмана).

Модифікація нейронної мережі Джордана шляхом додавання до неї динамічної стек-пам'яті здійснюється аналогічно до нейронної мережі Елмана. Модифікована нейронна мережа Джордана описується системою рекурентних рівнянь:

$$v_{j}(n+1) = \sum_{i=1}^{p} w_{ji}^{(1)} u_{i}(n) + \sum_{i=1}^{N} w_{ji}^{c} y_{i}(n) + \alpha y_{i}(n-1) + b_{j}^{(1)}; \qquad (3.69)$$

$$x_{j}(n+1) = F_{1}(v_{j}(n+1)); j = 1, 2, ..., N;$$
 (3.70)

$$y_{j}(n+1) = F_{2}\left(\sum_{i=1}^{N} w_{ji}^{(2)} x_{i}(n+1) + b_{j}^{(2)}\right); j = 1, 2, ..., M;$$
(3.71)

або у матричній формі:

$$\mathbf{X}(n+1) = \mathbf{F}_{1}\left(\mathbf{W}^{(1)}\mathbf{U}(n) + \mathbf{W}^{c}\left(\mathbf{Y}(n) - \alpha\mathbf{Y}(n-1)\right) + \mathbf{B}^{(1)}\right); \qquad (3.72)$$

$$Y(n+1) = \mathbf{F}_{2}\left(\mathbf{W}^{(2)}\mathbf{X}(n+1) + \mathbf{B}^{(2)}\right); \qquad (3.73)$$

де $\mathbf{U}(n)$ – вектор зовнішніх вхідних сигналів у час n; p – число зовнішніх входів мережі; $\mathbf{X}(n + 1)$ – вектор вихідних сигналів прихованого шару у момент часу (n + 1); N – число сигналів у контекстному шарі; $\mathbf{W}^{(1)}$, \mathbf{W}^c , $\mathbf{W}^{(2)}$ – матриці синаптичних ваг зовнішніх вхідних сигналів, сигналів контекстного та вихідного шару відповідно; $\mathbf{B}^{(1)}$, $\mathbf{B}^{(2)}$ – вектори ваг зсувів у нейронах прихованого та вихідного шару відповідно; \mathbf{F}_1 , \mathbf{F}_2 – вектори функцій активації у прихованому та вихідному шарі відповідно; $\mathbf{Y}(n + 1)$ – вектор вихідних сигналів мережі у момент часу (n + 1); M – кількість виходів мережі.

Процес трансформації навчальної вибірки для розв'язання задачі тренд-аналізу

часового ряду параметра температури газу перед турбіною компресора (рис. 3.43, *a*) за допомогою модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю наведено у табл. В.23.

Навчання модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю методом зворотного поширення помилки можна звести до навчання багатошарового персептрона, трансформуючи навчальну вибірку у діапазоні від 1,375 год до 2,0 год) методом ковзного вікна (табл. В.24). На рис. 3.34 наведено графік зміни функції середньоквадратичної похибки відповідно до кількості епох навчання.



Рисунок 3.34 – Графік зміни функції середньоквадратичної похибки модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю під час навчання (авторський доробок [393])

Вирішальне правило для модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю, що реалізує НЧ і ВЧ фільтри, має такий вигляд [394]:

$$\alpha = \frac{\sum_{j=1}^{N} f(f_{j+1}(t) - f_{j}(t))^{2}}{t} \ge C; \qquad (3.74)$$

де чисельник виразу (3.74) означає накопичення суми відхилень контрольованих параметрів (C – поріг спрацьовування (чутливість) нейронної мережі; при C = 0 (нормальний режим роботи), при $\alpha \ge C$ (тренд)).

Проведено аналіз наявності тренду (рис. 3.33, *a*) на ділянках І і ІІ за допомогою апарату нейронних мереж. Процес навчання модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю розпізнаванню тренду наведено на рис. 3.35, аналіз тренду на першій та визначення тренду нейронної мережі на другій характерній ділянках – на рис. 3.36, 3.37. Одна клітина при цьому відповідає півгодини експлуатації вертольоту. Видно, що поява тренду помічена нейронною мережею після шостої клітини. Для ускладнення процесу розпізнавання тренду і максимального наближення до реальної ситуації на вхідний сигнал, ідентифікований нейронною мережею, «накладається» перешкода [393].



Рисунок 3.35 – Процес навчання модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю розпізнаванню тренду: а – сигнал на вході фільтра; б –



Рисунок 3.36 – Процес тестування рекурентної нейронної мережі (тренд відсутній): а – сигнал на вході фільтра; б – сигнал на виході фільтра (авторський доробок [394])


Рисунок 3.37 – Визначення тренду за допомогою нейромережевої бази знань: а – сигнал на вході фільтра; б – сигнал на виході фільтра (авторський доробок [394])

Результати чисельного моделювання (табл. В.25) свідчать про можливість розв'язку задач інтелектуального моніторингу технічного стану ГТД вертольотів, що дозволяють поряд з класичними критеріями виявлення тренду параметрів застосовувати якісно нові нейромережеві критерії, що розширюють і доповнюють класичні критерії, що підвищують достовірність інформації при моніторингу технічного стану і на етапах прийняття рішень.

У процесі математичного моделювання на модифікованій нейронній мережі Джордана з динамічною стековою пам'яттю, що реалізує рекурентні фільтри, порівняно з класичними критеріями виявлення тренду параметрів, наприклад, авіаційного двигуна ТВЗ-117, отримано результати, наведені на рис. В.8.

Аналогічні дослідження були проведені з використанням інших архітектур нейронних рекурентних мереж в якості, що реалізують НЧ і ФЧ фільтри (табл. В.26).

Із табл. В.26 визначено, що модифікована нейронна мережа Джордана з динамічною стековою пам'яттю є доцільна у використанні в якості реалізації НЧ і ФЧ фільтрів з метою розв'язання задачі тренд-аналізу параметрів ГТД вертольотів у польотних режимах, тобто, у режимі реального часу. Перелічені вище переваги модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю над нейронними мережами інших архітектур дають можливість їх подальшого застосування при розв'язанні задачі тренд-аналізу параметрів ГТД вертольотів.

Висновки по третьому розділу

1. Удосконалено нейромережевий метод ідентифікації динамічної багаторежимної моделі ГТД вертольотів, який за рахунок використання рекурентної мережі Елмана з динамічною стековою пам'яттю дозволив досягти абсолютної похибки ідентифікації не більше 0,25 %, при цьому для рівнів шуму $\sigma = \{0,01, 0,03, 0,05\}$ похибка складає 0,36 %, 0,42 % і 0,5 %, що є значно кращим результатом порівняно з традиційною архітектурою мережі Елмана (0,54 %, 0,57 %, 0,61 %) та МНК (1,75 %, 2,69 %, 3,68 %), а загальна точність ідентифікації динамічної моделі двигуна досягає 99,88 %.

2. Набув подальшого розвитку нейромережевий метод контролю технічного стану ГТД вертольотів, який за рахунок використання модифікованої LSTM-мережі зі змінною пам'яттю дозволило класифікувати технічний стан двигуна ТВЗ-117 з абсолютною похибкою 0,64...0,65 %, що значно менше порівняно з тришаровим персептроном архітектури 2–12–4 (похибка 2,08...2,14 %), та здійснити контроль за допомогою гіперповерхні у просторі контрольованих параметрів замість використання метричних відстаней.

3. Створено нейромережевий метод діагностики дефектів в основних вузлах проточної частини ГТД вертольотів за допомогою ансамблю нейронних мереж, що дозволяє здійснювати кластеризацію станів (справний стан, дефекти в компресорі, камері згоряння та турбіні компресора) та автоматичну класифікацію без експертних інструкцій, а також на прикладі задачі діагностики подвійного дефекту компресора і турбіни компресора з ККД, зменшеним на 3 %, використовувати евклідову метрику для оцінки інтенсивності та множинності дефектів на основі найближчого сусіда, що дозволяє точніше визначити характер і розташування дефекту.

4. Набув подальшого розвитку нейромережевий метод прогнозування динаміки зміни термогазодинамічних параметрів ГТД вертольотів, який за рахунок використання GRNN-мережі дозволив виявляти моменти розладнання часового ряду та вчасно приймати рішення щодо зміни режиму експлуатації, забезпечивши помилку коротко-, середньо-, довгострокового прогнозу, не перевищуючи 0,465 %, а в умовах білого шуму (σ = 0,01) – 0,726 %, що значно перевищує результати при використанні МКС (1,556 % в нормальних умовах, 1,969 % в шумових), МЕЗ (1,653 % в нормальних, 2,273 % в шумових), МНК (2,552 % в нормальних, 3,378 % в шумових).

5. На основі нейромережевого методу прогнозування динаміки зміни термогазодинамічних параметрів ГТД вертольотів було вперше створено нейромережевий метод виявлення потенційних дефектів, що дозволив обчислювати як потенційний час виникнення дефекту, так і потенційний час нормальної роботи (на прикладі прогнозування температури газів перед турбіною компресора для визначення дефекту камери згоряння з можливістю виникнення тріщин, гарантується нормальна робота на 8 годин), при цьому використання моделі Transformer на основі графової нейронної мережі дозволило знизити помилки першого та другого роду у 3.49...7.58 разів порівняно з Simple AutoEncoder, у 2.88...4.36 разів порівняно з LSTM AutoEncoder, у 1.81...1.93 разів порівняно з нейронною мережею GRNN, а удосконалення функції активації ReLU до Smooth ReLU покращило збіжність та стійкість навчання, усунувши проблему «мертвих нейронів» і забезпечивши ненульовий градієнт для всіх значень вхідних даних.

6. Удосконалено нейромережевий метод налагодження параметрів дозатора палива ГТД вертольотів, який за рахунок використання еталонної математичної моделі дозатора палива та нейронної мережі прямого поширення з адаптивними елементами дозволив визначити оптимальні значення термогазодинамічних параметрів, при цьому застосування L2-регуляризації дозволило досягти в 2 рази точнішого регулювання частоти обертання ротора турбокомпресора, знизивши помилки першого і другого роду в 1.65...1.71 рази порівняно з Delta-Bar-Delta, а коефіцієнт похибки знижено в 1,89 рази, при цьому незначно підвищено коефіцієнт якості визначення граничних значень частоти обертів ротора турбокомпресора в 1,01 разів

7. Удосконалено нейромережевий метод тренд-аналізу параметрів ГТД вертольотів, який за рахунок використання модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю забезпечив розпізнавання тренду з точністю 95…100 % при 4…5 вимірюваннях, при цьому максимальне СКВ за відсутності тренду склало 0,025, за присутності тренду – 0,056, а точність розпізнавання тренду досягла 99,9 % за відсутності тренду і 99,5 % за присутності тренду, в той час, як при використанні ансамблю нейронних мереж «персептрон + РБФ-мережа» максимальне СКВ за відсутності тренду склало 0,087, за присутності тренду – 0,117, а точність розпізнавання тренду була 93,2 % за відсутності тренду і 91,6 % за присутності тренду.

Основні результати досліджень, викладені у розділі, опубліковано у наукових працях [338–344, 349–353, 358–366, 371–374, 389, 390, 394–396].

РОЗДІЛ 4

МОДИФІКОВАНА БОРТОВА ЗАКРИТА НЕЙРОМЕРЕЖЕВА АВТОМАТИЗОВАНА ПІДСИСТЕМА УПРАВЛІННЯ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕРТОЛЬОТІВ

4.1 Передумови розроби бортової автоматизованої підсистеми управління газотурбінних двигунів вертольотів

Процес забезпечення стабільності параметрів роботи ГТД вертольотів шляхом підтримання необхідної (сталої) частоти обертання ротора турбокомпресора і дозування подачі палива в камеру згоряння завжди був непростою задачею. Особливу складність становлять режими запуску і перехідні режими роботи двигуна з урахуванням зовнішніх чинників (вплив атмосферних умов і режимів польоту повітряного судна). Зважаючи на це, для регулювання двигуна використовуються електронні АПУ [398-400]. Необхідні для польоту вертольоту значення термогазодинамічних параметрів двигуна, надійна і стійка робота силової установки у всьому діапазоні зміни умов експлуатації забезпечуються при відповідному регулюванні двигуна, що здійснюється АПУ. Вона встановлює і підтримує певні зв'язки між параметрами двигуна. Це регулювання, що формуються з урахуванням вимог до питомої витрати палива й інших термогазодинамічних параметрів, обмежень за міцністю, необхідної точності підтримки параметрів та інших чинників [401]. На теперішній час до АПУ ГТД, що реалізують задані закони управління, висуваються досить жорсткі вимоги як щодо допустимих відхилень параметрів на сталих режимах роботи, так і стосовно динамічних похибок при перехідних процесах [402]. Не є виключенням і АПУ ГТД вертольотів. До АПУ ГТД пред'являються, як правило, такі вимоги: висока точність підтримання заданих параметрів; мінімальна складність технічного виконання; можливість переходу з одного режиму в інший (при здійсненні маневру) без зниження якості управління. Для виконання всіх вищеперелічених вимог необхідно розробити новий підхід до вибору структури АПУ, синтезу алгоритмів управління та їх технічної реалізації. Дане твердження грунтується на аналізі результатів натурних випробувань та на проведених раніше теоретичних дослідженнях [403-405]. Зважаючи на вищевикладене, метою розробки системи автоматичного управління ГТД вертольотів полягає в покращенні ефективності, безпеки та надійності їх роботи (табл. Г.1).

У [404, 405] прийнято, що динамічні властивості ГТД як багатовимірних об'єктів управління описуються такими диференціальними рівняннями «вхід–вихід»:

$$\varphi = \left(\mathbf{Y}^{(n)}, \mathbf{Y}^{(n-1)}, \dots, \mathbf{Y}; \mathbf{U}^{(n)}, \mathbf{U}^{(n-1)}, \dots, \mathbf{U}\right);$$
(4.1)

де $\mathbf{U} = (u_1(t), u_2(t), ..., u_N(t))^T$, $Y = (y_1(t), y_2(t), ..., y_N(t))^T$ – відповідно вектори входів (керуючих впливів) і виходів (керованих змінних); m і n – максимальні порядки похідних $u_k^{(i)}, y_e^{(j)}$ для вхідних і вихідних змінних $u_k(t)$ і $y_e(t), (m \le n); N$ – число каналів управління двигуна, тобто розмірність АПУ; $\varphi(\cdot)$ – нелінійна вектор-функція.

Прийнято, що для ГТД вертольотів виконується умова спостереження та управління. У [404, 405] розроблена структурна схема багатовимірної АПУ ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) із включенням у систему N інтеграторів (I) – по одному в кожному з N каналів системи управління (рис. 4.1), що реалізується у вигляді багаторежимного нейромережевого регулятору з використанням динамічної рекурентної нейронної мережі на базі персептрона (рис. Г.1).



Рисунок 4.1 – Структурна схема багатовимірної АПУ ГТД вертольотів (авторський доробок [404, 405])

Відповідно до [404, 405] нейромережевий регулятор має N входів і N виходів, включаючи в себе $N + \sum_{i=1}^{N} (p_i + q_i)$ нейронів у вхідному шарі, σ нейронів у загальному прихованому шарі і N нейронів у вихідному шарі, зв'язки між якими здійснюються за допомогою налаштовувальних (учнів) ваг $W_{\alpha\beta}$, W_{β} ($\alpha = 1, 2, ..., N + \sum_{i=1}^{N} (p_i + q_i); \beta = 1, 2, ..., N_{\sigma}$). Кількість нейронів у прихованому шарі σ має задовольняти обмеження $\sigma \ge N$ (в іншому випадку не можна забезпечити незалежне формування керуючих впливів $u_1, u_2, ..., u_N$ при зміні входів нейронної мережі $v_1, v_2, ..., v_N$). Загальна кількість невідомих параметрів

нейромережевого регулятора, тобто число ваг нейронної мережі, що налаштовуються, при цьому складає:

$$K_{\Pi} = \sigma \left(2N + \sum_{i=1}^{N} \left(p_i + q_i \right) \right). \tag{4.2}$$

Для забезпечення стійкості на заданій множині $M_1, ..., M_R$ режимів роботи АПУ ГТД вертольотів необхідно виконання наступного співвідношення між величинами p_i , q_i, σ, n, R і N:

$$\sigma\left(2N+\sum_{i=1}^{N}p_{i}\right)+\left(\sigma-R\right)\sum_{i=1}^{N}q_{i}\geq R(N+n);$$
(4.3)

з якого можна визначити невідомі цілочислові значення p_i , q_i і σ , що визначають структуру нейромережевого регулятора.

Складність нейромережевого регулятора визначається кількістю нейромережевих параметрів, що настроюються (K_{Π}). Рішенням задачі структурного синтезу на основі критерію мінімальної складності повинен вважатися нейромережевий регулятор, який описується набором чисел $\langle p_1, ..., p_N; q_1, ..., q_N; \sigma \rangle$, що мінімізують значення цільової функції (4.2) при виконанні обмеження (4.3).

Для ГТД вертольотів вектор входів (керуючих впливів) має вигляд:

$$\mathbf{U} = (G_T)^T, \tag{4.4}$$

де G_T – витрата палива, а вектор стану і вектор виходів (керованих змінних) двигуна записуються відповідно як $\mathbf{X} = (n_1, n_2)^T$ і $\mathbf{Y} = (n_{TK}, T_{\Gamma}^*)$.

Відповідно до [404, 405] структурна схема базової АПУ приведена на рис. 4.2, де \mathcal{I}_n і \mathcal{I}_T – датчики частоти обертання ротора турбокомпресора n_{TK} і температури газів перед турбіною компресора T_{Γ}^* ; $BM_{G_{\Gamma}}$ – виконавчий механізм, що забезпечує формування дій по координаті \overline{G}_T ; $\mathbf{G} = \left(\overline{n_{TK}^0}, \overline{T_{\Gamma}^*}^0\right)^T$ – вектор уставок (заданих впливів); $\overline{n_{TK}^0}$ і $\overline{T_{\Gamma}^*}^0$ – необхідні (задані) значення частоти обертання ротора турбокомпресора і температури газів перед турбіною компресора.



Рисунок 4.2 – Структурна схема синтезованої АПУ ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) (авторський доробок [404, 405])

4.2 Базова модифікація бортової автоматизованої підсистеми управління газотурбінних двигунів вертольотів

Відповідно до концепції, розробленої у [406], виконавчий механізм (ВМ) і ГТД розглядалися як єдине ціле: незмінна частина системи. Даний підхід добре зарекомендував себе при синтезі алгоритмів управління ГТД для цивільних літальних апаратів або транспортної авіації. Для таких об'єктів управління динамічні процеси у паливній системі перебігають набагато швидше, ніж у двигуні, тому їх вплив на ГТД нехтувався. Але у ГТД перехідні процеси в агрегаті палива та двигуна перебігають практично одночасно. Дане твердження неодноразово підтверджено результатами натурних випробувань. На підставі вищесказаного відповідно до [406] виділено в окремі ланки безпосередньо ГТД та ВМ – агрегат дозування палива (АДП). Результатом є модифікація структурної схеми АПУ, що приведена на рис. 4.1 (рис. 4.3).



Рисунок 4.3 – Структурна схема модифікованої багатовимірної АПУ ГТД вертольотів з розділеним об'єктом управління на АДТ та ГТД (авторський доробок [406])

При проведенні найпростішого дослідження роботи АПУ ГТД вертольотів, що полягає в різних комбінаціях параметрів передавальних функцій для ГТД і АДП, було виявлено [406], що якість керування (точність, перерегулювання, запаси стабільності) різко змінюється при переході з режиму в режим. Отже, задача аналізу якості керування та синтезу алгоритмів керування об'єктами цього класу стає дуже актуальною при розробці бортової багатовимірної АПУ ГТД вертольотів.

Досліджено АПУ ГТД вертольотів та проаналізовано якість контролю з урахуванням динаміки АДП та ГТД. Структурна схема АПУ ГТД вертольотів (рис. 4.4) складається з елемента порівняння (ЕП), регулятора, АДП та ГТД. Початкове значення n_{TK} і T_{Γ}^* та отримані значення ряду цих параметрів надходять на вхід ЕП, де формується неузгодженість вхідних параметрів і формується системна похибка – ξ . Похибка надходить на вхід контролера, на виході формується сигнал u, який надходить на вхід АДП, на виході формується сигнал витрати палива G_T , який надходить на вхід ГТД і, відповідно, формується сигнал **Y**, який надходить на вхід ЕП. Враховуючи, що в розробленій схемі АПУ ГТД вертольотів об'єкт керування було розділено, доцільним є введення нелінійних моделей окремо для АДП та ГТД та моделювати роботу системи з урахуванням динаміки її елементів. Для дослідження описаної АПУ ГТД вертольотів також запропоновано введення математичних моделей АДП та ГТД з метою підвищення якості керування всією системою в цілому.

На рис. 4.4 представлена розроблена схема АПУ ГТД вертольотів. У логічному блоці (ЛБ) вхідні сигнали аналізуються таким чином: на основі експериментальних даних і висновків будується база знань. По відношенню до нього формуються функції приналежності для вхідних параметрів ЛБ, а також вихідних сигналів [406]. Сформувавши необхідну зміну, ЛБ посилає відповідні сигнали на вхід елемента порівняння, формуючи керуючий сигнал, який надходить на вхід АДП та його моделі. ЛБ отримує два сигнали: невідповідність моделей АДП та ГТД моделям АДП та ГТД – помилка моделі (ξ_{mod}) і невідповідність АДП моделі АДП – помилка АДП ($\xi_{AДП}$). Як показує практика, похибка ГТД невелика і в ході дослідження не враховується.



Рисунок 4.4 – Пропонована базова АПУ ГТД вертольотів, включаючи регулятор, АДП, ГТД, модель АДП, модель ГТД та ЛБ (авторський доробок [406])



Рисунок 4.5 – Структурна схема окремого каналу АПУ: ПУ – пристрій управління; ВП – вимірювальний пристрій [158] Значний внесок у синтез логіко-динамічних АПУ ГТД на основі узгодження та адаптації каналів керування зробив професор Петунін В.І. [157–163]. Відповідно до [158] структурна схема окремого каналу АПУ ГТД має вигляд, представлений на рис. 4.5, при цьому передавальна функція замкнутої АПУ визначається виразом:

$$\Phi(p) = \frac{W_{\Pi V}(p) \cdot H_{\Gamma T \mathcal{A}}(p)}{1 + W_{\Pi V}(p) \cdot H_{\Gamma T \mathcal{A}}(p) \cdot W_{B \Pi}(p)}.$$
(4.5)

Згідно з [158] передавальна функція вимірювального пристрою повинна дорівнювати одиниці ($W_{B\Pi}(p) = 1$), при цьому передавальна функція замкнутої системи прирівняна до передавальної функції шуканої системи $\Phi^*(p)$, тобто $\Phi(p) = \Phi^*(p)$, тоді

 $\Phi^*(p) = \frac{W_{\Pi Y}(p) \cdot H_{\Gamma T \mathcal{A}}(p)}{1 + W_{\Pi Y}(p) \cdot H_{\Gamma T \mathcal{A}}(p) \cdot W_{B \Pi}(p)}.$ Після перетворень отримано вираз для пере-

давальної функції пристрою управління [159]:

190

$$W_{\Pi Y} = \frac{1}{H_{\Gamma T \Pi}(p)} \cdot \frac{\Phi^*(p)}{1 - \Phi^*(p)}; \qquad (4.6)$$

де $\frac{1}{H_{_{\Gamma T\!\!\!\!\!\!\mathcal{I}\!\!\!\!\mathcal{I}}}(p)}$ – обернена передавальна функція ГТД вертольоту як об'єкта управління;

 $rac{\Phi^{*}(p)}{1-\Phi^{*}(p)}$ – бажана передавальна функція відкритого контуру.

Згідно з [158] для одного каналу передавальна функція ГТД вертольоту $H_{\Gamma T \mathcal{I}}(p) = k_{\Gamma T \mathcal{I}} \cdot \frac{A(p)}{B(p)}$, тоді $\frac{1}{H_{\Gamma T \mathcal{I}}(p)} = \frac{1}{k_{\Gamma T \mathcal{I}}} \cdot \frac{B(p)}{A(p)}$, а бажана передавальна функція ві-

дкритого контуру:

$$W^{*}(p) = \frac{\Phi^{*}(p)}{1 - \Phi^{*}(p)} = \frac{k}{p \cdot C(p)};$$
(4.7)

де $\frac{k}{p}$ визначає астатизм системи, а $\frac{1}{C(p)}$ – її інерційність, тоді передавальна функція

пристрою управління набула вигляду:

$$W_{\Pi V} = \frac{1}{k_{\Gamma T \Pi}} \cdot \frac{B(p)}{A(p)} \cdot \frac{k}{p \cdot C(p)}.$$
(4.8)

В АПУ складних динамічних об'єктів професор Петунін В.І. довів доцільність застосування загального ізодромного регулятора [158] з передавальною функцією:

$$W_{I_{3P}}(p) = \frac{k_{I_{3P}} \cdot (T_{I_{3P}} \cdot p + 1)}{p \cdot C(p)}; \qquad (4.9)$$



Рисунок 4.6 – Структурна схема бажаної АПУ ГТД вертольотів [158]: *W*^{*}(*p*) – перевальна функція розімкнутої бажаної системи

$$W_{\Pi Y} = \frac{1}{k_{\Gamma T \mathcal{A}_{i}}} \cdot \frac{B(p)}{A_{i}(p)} \cdot \frac{k}{k_{I_{3}P}} \cdot \frac{k}{(T_{I_{3}P} \cdot p + 1)}.$$
 (4.10)

Відповідно до досліджень професора Петуніна В.І. [158] структурна схема бажаної АПУ ГТД вертольотів для одного каналу представлена на рис. 4.6, при цьому передавальна функція замкнутої бажаної системи може представлена у вигляді:

$$\Phi^{*}(p) = \frac{W^{*}(p)}{1 + W^{*}(p)}.$$
(4.11)

3 урахуванням (4.7) якщо
$$W^*(p) = \frac{k}{p \cdot C(p)}$$
, то

$$\Phi^*(p) = \frac{k}{p \cdot C(p) + k}.$$
(4.12)

Інерційність виконавчих пристроїв повинна враховуватись у C(p), у разі потреби вона коригується. Передавальна функція замкнутої системи $\Phi^*(p)$ повинна наближуватись до стандартної функції передачі з урахуванням вимог до якості перехідних процесів. Професором Петуніним В.І. [158] досліджено такі окремі випадки:

1. При
$$W^*(p) = \frac{k}{p} \Phi^*(p) = \frac{k}{p+k} = \frac{1}{T \cdot p + 1}$$
 перехідний процес є експоненціаль-

ним монотонним з часом регулювання $t_{per} = 3 \cdot T = \frac{3}{k}$.

2. При
$$W^*(p) = \frac{k}{p \cdot (\tau \cdot p + 1)}$$
 $\Phi^*(p) = \frac{k}{\tau \cdot p^2 + p + k} = \frac{\omega^2}{p^2 + 2 \cdot \xi \cdot \omega \cdot p + \omega^2}$, де

 $\xi = \frac{1}{2 \cdot \sqrt{k \cdot \tau}}, \ \omega^2 = \frac{k}{\tau},$ перехідний процес є монотонним за умови $\xi \ge 1$ ($k \cdot \tau \le 0,25$), а

перехідний процес із перерегулюванням $\sigma_m < 5$ % за умови $\xi = 0,707$ ($k \cdot \tau \le 0,5$).

3. При
$$W^*(p) = \frac{k}{p \cdot (\tau_2^2 \cdot p^2 + \tau_1 \cdot p + 1)}$$
 $\Phi^*(p) = \frac{k}{\tau_2^2 \cdot p^3 + \tau_1 \cdot p^2 + p + k} =$

$$=\frac{\omega^3}{p^3+A_1\cdot\omega\cdot p^2+A_2\cdot\omega^2\cdot p+\omega^3}, \text{ де } A_1\cdot\omega=\frac{\tau_1}{\tau_2^2}, A_2\cdot\omega^2=\frac{1}{\tau_2^2}, \omega^3=\frac{k}{\tau_2^2}, \text{ перехідний про-$$

цес є монотонним за умови $A_1 = A_2 = 3$, перехідний процес із перерегулюванням $\sigma_m < 5$ % за умови $A_1 = A_2 = 2,15$.

Для контуру дозування палива в камеру згоряння відповідно до [158, 406, 407] передавальна функція каналу частоти обертання ротора турбокомпресора ГТД вертольоту представлена у вигляді:

191

$$H_{nG_T}(p) = k_n \cdot \frac{A_n(p)}{B(p)}; \qquad (4.13)$$

192

де порядок полінома $A_n(p)$ на одиницю менший від порядку B(p) (табл. 4.1).

Таблиця 4.2 – Відповідність порядку полінома від кількості валів ГТД вертольотів [406]

Число валів ГТД вертольотів	Порядок полінома	
1	0	1
2	1	2

Передавальна функція одновального ГТД (наприклад, ГТД-350) за частотою обертання ротора турбокомпресора отримана відповідно до [158] у вигляді:

$$H_{nG_{T}}(p) = \frac{0.4}{0.5 \cdot p + 1}.$$
(4.14)

Згідно з [158] передавальна функція пристрою управління для каналу частоти обертання ротора турбокомпресора представляється у вигляді:

$$W_{\Pi V_n}(p) = \frac{1}{k_n} \cdot \frac{B(p)}{A_n(p)} \cdot \frac{k}{p \cdot C(p)}.$$
(4.15)

Якщо передавальна функція бажаної системи $W^*(p) = \frac{3}{p \cdot (0.02 \cdot p + 1)}$ та передавальна

функція загального ізодромного регулятора $W_{I_{3}P}(p) = \frac{3 \cdot (0,56 \cdot p + 1)}{p \cdot (0,02 \cdot p + 1)}$ [160], то передавальна

функція регулятора по каналу частоти обертання ротора турбокомпресора становить:

$$W_n(p) = W_1(p) = \frac{1}{0,4} = 2,5.$$
 (4.16)

Для надзвичайного режиму роботи передавальна функція двовального ГТД (наприклад, ТВЗ-117) за частотою обертання ротора турбокомпресора отримана відповідно до [161]:

$$H_{n_{TK}G_{T}}(p) = 0.875 \cdot \frac{0.212 \cdot p + 1}{0.133 \cdot p^{2} + 0.94 \cdot p + 1} = 0.875 \cdot \frac{0.212 \cdot p + 1}{(0.766 \cdot p + 1) \cdot (0.174 \cdot p + 1)}.$$
 (4.17)

Тоді передавальна функція пристрою управління для каналу частоти обертання ротора турбокомпресора складає:

$$W_{\Pi V n_{TK}}(p) = \frac{1}{k_{n_{TK}}} \cdot \frac{B(p)}{A_{n_{TK}}(p)} \cdot \frac{k}{p \cdot C(p)}.$$
(4.18)

Якщо передавальна функція бажаної системи $W^*(p) = \frac{3}{p \cdot (0,02 \cdot p + 1)}$ та передавальна

льна функція регулятора по каналу частоти обертання ротора турбокомпресора становить:

$$W_{n_{TK}}(p) = W_{1}(p) = \frac{1}{0,766} \cdot \frac{0,175 \cdot p + 1}{0,210 \cdot p + 1} = 1,306 \cdot \frac{0,175 \cdot p + 1}{0,210 \cdot p + 1}.$$
(4.19)

Для контуру дозування палива в камеру згоряння відповідно до [158] передавальна функція каналу температури газів перед турбіною компресора передавальна функція ГТД вертольоту представлена у вигляді:

$$H_{T_{\Gamma}^{*}G_{T}}(p) = k_{T_{\Gamma}^{*}} \cdot \frac{A_{T_{\Gamma}^{*}G_{T}}(p)}{B(p)};$$
(4.20)

де $A_{T_{\Gamma}^*G_{T}}(p)$ і B(p) – поліноми одного порядку (табл. 4.2).

Таблиця 4.2 – Відповідність порядку полінома від кількості валів ГТД вертольотів [158]

Число валів ГТД вертольотів	Порядок полінома	
1	1	1
2	2	2

Для надзвичайного режиму роботи передавальна функція одновального ГТД вертольоту (наприклад, ГТД-350) за температурою газів перед турбіною компресора отримана відповідно до [161]:

$$H_{T_{r}^{*}G_{T}}(p) = 0,35 \cdot \frac{0,829 \cdot p}{0,56 \cdot p + 1}.$$
(4.21)

Тоді передавальна функція пристрою управління для каналу температури газів перед турбіною компресора має вигляд:

$$H_{\Pi V T_{\Gamma}^{*}}(p) = \frac{1}{k_{T_{\Gamma}^{*}}} \cdot \frac{B(p)}{A_{T_{\Gamma}^{*} G_{\Gamma}}(p)} \cdot \frac{k}{p \cdot C(p)}.$$
(4.22)

Якщо передавальна функція бажаної системи $W^*(p) = \frac{3}{p \cdot (0,02 \cdot p + 1)}$ та передавальна

функція загального ізодромного регулятора $W_{I3P}(p) = \frac{3 \cdot (0,56 \cdot p + 1)}{p \cdot (0,02 \cdot p + 1)}$ [160], то передавальна

функція регулятора по каналу температури газів перед турбіною компресора становить:

$$W_{T_{\Gamma}^{*}}(p) = W_{2}(p) = \frac{1}{0,35} \cdot \frac{1}{0,829 \cdot p + 1} = \frac{2,857}{0,829 \cdot p + 1}.$$
(4.23)

Для надзвичайного режиму роботи передавальна функція двовального ГТД (наприклад, ТВЗ-117) каналу температури газів перед турбіною компресора отримана відповідно до [162]:

$$H_{T_{\Gamma}^*G_{\Gamma}}(p) = 0,333 \cdot \frac{0,064 \cdot p^2 + 0,667 \cdot p + 1}{0,133 \cdot p^2 + 0,94 \cdot p + 1} = 0,333 \cdot \frac{0,064 \cdot p^2 + 0,667 \cdot p + 1}{(0,766 \cdot p + 1) \cdot (0,174 \cdot p + 1)}.$$
 (4.24)

Тоді передавальна функція пристрою управління для каналу температури газів перед турбіною компресора має вигляд:

$$H_{I_{3PT_{T}^{*}}}(p) = \frac{1}{k_{T_{T}^{*}}} \cdot \frac{B(p)}{A_{T_{T}^{*}G_{T}}(p)} \cdot \frac{k}{p \cdot C(p)}.$$
(4.25)

Якщо передавальна функція бажаної системи $W^*(p) = \frac{3}{p \cdot (0,02 \cdot p + 1)}$ та передавальна

функція загального ізодромного регулятора $W_{I3P}(p) = \frac{3 \cdot (0.56 \cdot p + 1)}{p \cdot (0.02 \cdot p + 1)}$ [160], то передавальна

функція регулятора по каналу температури газів перед турбіною компресора становить:

$$W_{T_{\Gamma}^{*}}(p) = W_{2}(p) = \frac{1}{0,333} \cdot \frac{0,174 \cdot p + 1}{0,064 \cdot p^{2} + 0,667 \cdot p + 1} = 3 \cdot \frac{0,174 \cdot p + 1}{0,064 \cdot p^{2} + 0,667 \cdot p + 1}.$$
 (4.26)

Принципи побудови малоінерційних вимірювачів температури газів ГТД досліджено у [162]. Відповідно до [158] прийнято, що $W_{K1}(p)$ і $W_{K2}(p)$ – передавальні функції коригувальних ланок, результати синтезу яких наведено у [162], що мають вигляд:

$$W_{K1}(p) = \frac{W_1(p) - 1}{W_2(p)}; \ W_{K2}(p) = \frac{1 - W_2(p)}{W_2(p)}.$$
(4.27)

Тоді вирази для передавальних функцій для цих зв'язків мають вигляд:

1. Для одновальних ГТД вертольотів (наприклад, ГТД-350):

$$W_{K1}(p) = 0,428 \cdot (0,829 \cdot p + 1) = 0,355 \cdot p + 0,428;$$

$$W_{K2}(p) = 0,35 \cdot (0,829 \cdot p - 1,857) = 0,29 \cdot p - 0,65.$$
(4.28)

2. Для двовальних ГТД вертольотів (наприклад, ТВ3-117):

$$W_{K1}(p) = \frac{-0,0018 \cdot p + 0,0517}{0,206 \cdot p + 1} \cdot \frac{0,064 \cdot p^2 + 0,667 \cdot p + 1}{0,174 \cdot p + 1};$$

$$W_{K2}(p) = 0,333 \cdot \frac{0,064 \cdot p^2 + 0,145 \cdot p - 2}{0,174 \cdot p + 1}.$$
(4.29)

Відповідно до [158] коригувальний елемент $W_1(p)$ каналу управління є постійно увімкненим, а коригувальний елемент $W_2(p)$ реалізується при включенні каналу обмеження шляхом паралельного підключення до $W_1(p)$ диференціальної динамічної ланки з передавальною функцією за вихідним логічним сигналом селектора *L*:

$$W_{\Delta}(p) = W_1(p) - W_2(p).$$
 (4.30)

1. Для одновальних ГТД вертольотів (наприклад, ГТД-350):

$$W_{\Delta}(p) = \frac{1,842 \cdot p - 0,653}{0,829 \cdot p + 1}.$$
(4.31)

2. Для двовальних ГТД вертольотів (наприклад, ТВЗ-117):

$$W_{\Delta}(p) = \frac{0.174 \cdot p + 1}{0.206 \cdot p + 1} \cdot \frac{0.0739 \cdot p^2 + 0.152 \cdot p - 1.845}{0.064 \cdot p^2 + 0.667 \cdot p + 1}.$$
(4.32)

4.3 Нейромережева реалізація базової бортової автоматизованої підсистеми управління газотурбінних двигунів вертольотів

Відповідно до [403–408] бортова АПУ ГТД вертольотів реалізована у вигляді саморегульованої нейронної мережі зі зв'язаними координатами (рис. Г.2). Відповідно до [408] вектор помилки управління $\mathbf{e} = [e_1, e_2, ..., e_n]^T$ після елементів порівняння подається на вхід нейронної мережі та блоку корекції ваги, де вагові коефіцієнти нейронної мережі коригуються відповідно до сигналу e(t) на кожному дискретному часі t. Вихідний вектор сигналів $\mathbf{u} = [u_1, u_2, ..., u_n]^T$ з нейронної мережі виступає в якості сигналу управління, який надходить на вхід ГТД вертольоту. Для управління ГТД вертольотів використана багатошарова нейронна мережа (рис. 4.7) з одним проміжним шаром, N_1 нейронів у внутрішньому шарі (шар 1), N_0 нейронів у вхідному шарі та N_2 нейронів у вихідному шарі, де $N_2 = N_0 = n$. Вхідний рівень (рівень 0) складається з вузлів – приймачів сигналів e_i ($i = \overline{1, n}$), вихідний рівень – з нейронів – джерел сигналів u_i ($i = \overline{1, n}$). На вхід нейронної мережі у дискретний момент часу t (t = 0, 1, 2, ...) надходять сигнали e_i , що перетворюються мережею в керуючі сигнали u_i . Дискретний час t пов'язаний із безперервним часом Θ так: $\Theta = \delta \cdot t$, де δ – крок квантування. Кожен *i*-й нейрон *l*-го шару ($l = \overline{1,2}$) перетворює вхідний вектор у вихідне скалярне значення [406].



Рисунок 4.7 – Структура саморегульованої нейронної мережі зі зв'язаними координатами (авторський доробок [406] на основі [408])

Відповідно до [408] на першому етапі розраховується суперпозиція вхідних сигналів нейрона:

$$z_i^l = \sum_{j=1}^{N_{l-1}} w_{ij}^l \cdot o_j^{l-1} - \mathcal{G}_i^l;$$
(4.33)

де w_{ij}^{l} – ваговий коефіцієнт, який є регульованим параметром і характеризує зв'язок *j*-го нейрона (l-1) шару з *i*-м нейроном *l*-го шару; \mathcal{G}_{i}^{l} – кількість зміни.

3 урахуванням припущень $w_{i0}^l = -\mathcal{G}_i^l$ і $o_0^{l-1} = 1$

$$z_i^l = \sum_{j=1}^{N_{l-1}} w_{ij}^l \cdot o_j^{l-1}.$$
(4.34)

Перетворення значень *z* на початкове значення нейрона здійснюється згідно з виразом [408]:

$$o_i^l = f\left(z_i^l\right). \tag{4.35}$$

Нелінійне перетворення (4.35) визначається функцією активації (застосована сигмоїдна функція активації нейрона [408]):

$$f(z) = \frac{1}{1 - e^{-z}}.$$
(4.36)

Важливою властивістю цієї функції є простота визначення похідної цієї функції, тобто

$$f'(z) = f(z) \cdot (1 - f(z)).$$
 (4.37)

У [406, 408] математичний опис нейронної мережі записано за допомогою системи рівнянь:

$$\begin{cases} u_{j}(t) = o_{j}^{2}; \ j = \overline{1, n}; \\ o_{i}^{l} = f(z_{i}^{l}); \ i = \overline{1, N_{l}}; \ l = \overline{1, 2}; \\ z_{i}^{l} = \sum_{j=1}^{N_{l-1}} w_{ij}^{l} \cdot o_{j}^{l-1}; \ i = \overline{1, N_{l}}; \ l = \overline{1, 2}; \\ o_{j}^{0} = e_{j}(t); \ j = \overline{1, n}; \\ o_{0}^{0} = o_{0}^{1} = 1. \end{cases}$$

$$(4.38)$$

Під час роботи саморегульованої нейронної мережі зі зв'язаними координатами вагові коефіцієнти нейронної мережі змінюються таким чином, що значення $E = \|\mathbf{e}\| \to 0$, а значення $E = \frac{1}{2} \cdot \sum_{i=1}^{n} \alpha_i \cdot e_i^2$, де α_i – коефіцієнти, що визначають вагу кожного САУ, а сумарна похибка *E*, приймається за норму вектору **E**. Корекція вагових коефіцієнтів нейронної мережі (навчання нейронної мережі) здійснюється в блоці корекції ваг методом зворотного поширення похибки [408]. Основні розрахункові коефіцієнти в цьому випадку мають вигляд, представлений згідно з [408]:

$$w_{ij}^{l}(t) = w_{ij}^{l}(t-1) - \gamma \cdot \delta \cdot \frac{\partial E}{\partial w_{ij}^{l}}.$$
(4.39)

Для вагових коефіцієнтів нейрона вихідного шару (шару 2) значення $\frac{\partial E}{\partial w_{ij}^{(2)}}$ визна-

чаються згідно з виразом [408]:

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = \sum_{k=1}^{n} \left(\alpha_k \cdot e_k \cdot \frac{\partial y_k}{\partial u_i} \right) \cdot f\left(z_i^{(2)} \right) \cdot o_j^{(1)}; \quad k = \overline{1,n}; \quad i = \overline{1,n}; \quad j = \overline{1,N_i}; \quad (4.40)$$

де e_k – похибка управління для k-ї початкової змінної; α_k – ваговий коефіцієнт для k-ї вихідної змінної; $\frac{\partial y_k}{\partial u_i}$ – похідна k-ї вихідної змінної ГТД вертольоту по i-й вхідній дії; $f\left(z_i^{(2)}\right)$ – похідна функції активації для i-го нейрона другого (початкового) шару; $o_j^{(1)}$ – початкове значення j-го нейрона першого шару.

Для внутрішнього шару (шар 1) значення $\frac{\partial E}{\partial w_{ij}^{(1)}}$ визначаються скалярним добутком:

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \left(\overline{\boldsymbol{\alpha}} \times \mathbf{e}, \mathbf{Y}_u \times \mathbf{U}_{w_{ij}^{(1)}}\right); \ i = \overline{1, N_1}; \ j = \overline{0, n};$$
(4.41)

де \mathbf{a} – матриця вагових коефіцієнтів змінних коригувань; е – вектор похибки налаштування; \mathbf{Y}_u – матриця похідних змінних регулювання щодо вхідних керуючих дій; $\mathbf{U}_{w_{ij}^{(1)}}$ – вектор похідних вихідних сигналів нейронної мережі за вагою нейрона першого рівня $w_{ij}^{(1)}$; $\mathbf{a} \times \mathbf{e}$ – векторний добуток матриці \mathbf{a} на вектор е; $\mathbf{Y}_u \times \mathbf{U}_{w_{ij}^{(1)}}$ – векторний добуток матриці \mathbf{Y}_u на вектор $\mathbf{U}_{w_{ij}^{(1)}}$, при цьому [408]

$$\bar{\boldsymbol{\alpha}} = \begin{pmatrix} \alpha_1 & 0 & \dots & 0 \\ 0 & \alpha_2 & \dots & 0 \\ M & M & \dots & M \\ 0 & 0 & \dots & \alpha_n \end{pmatrix}; \ \boldsymbol{e} = \begin{pmatrix} e_1 \\ e_2 \\ M \\ e_n \end{pmatrix}; \ \boldsymbol{Y}_n = \begin{pmatrix} \frac{\partial y_1}{\partial u_1} & \frac{\partial y_1}{\partial u_2} & \dots & \frac{\partial y_1}{\partial u_n} \\ \frac{\partial y_2}{\partial u_1} & \frac{\partial y_2}{\partial u_2} & \dots & \frac{\partial y_2}{\partial u_n} \\ M & M & \dots & M \\ \frac{\partial y_n}{\partial u_1} & \frac{\partial y_n}{\partial u_2} & \dots & \frac{\partial y_n}{\partial u_n} \end{pmatrix}; \ \boldsymbol{U}_{w_{ij}^{(1)}} = \begin{pmatrix} \frac{\partial u_1}{\partial w_{ij}^{(2)}} \\ \frac{\partial u_2}{\partial w_{ij}^{(2)}} \\ M \\ \frac{\partial u_n}{\partial w_{ij}^{(2)}} \end{pmatrix}.$$

Для бортової реалізації представленого алгоритму навчання матриця \mathbf{Y}_u буде являти собою матрицю, що складається з набору нулів і одиниць, причому одиниці будуть дорівнювати елементу, що відповідає основним (прямим) каналам управління. Для ГТД вертольоту з *n* входами та виходами матриця \mathbf{Y}_u виглядає таким чином: 199

$$\mathbf{Y}_{n} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ M & M & \dots & M \\ 0 & 0 & \dots & 1 \end{pmatrix}.$$
 (4.42)

Елементи $\frac{\partial u_k}{\partial w_{ij}^{(1)}}$ вектору $\mathbf{U}_{w_{ij}^{(1)}}$ визначаються згідно з виразом [408]:

$$\frac{\partial u_k}{\partial w_{ij}^{(1)}} = f'\left(z_k^{(2)}\right) \cdot w_{ki}^{(2)} \cdot f'\left(z_i^{(1)}\right) \cdot o_j^{(0)}; \ k = \overline{1, n}; \ i = \overline{1, N_1}; \ j = \overline{0, n}.$$
(4.43)

Перед запуском саморегульованої нейронної мережі зі зв'язаними координатами встановлюються параметри системи: у блоці вагової корекції – параметр налаштування вагових коефіцієнтів γ , у блоці нейронної мережі – кількість нейронів у внутрішньому шарі N_1 та вагові коефіцієнти нейронів $w_{ij}^{(l)}$ першого і другого шарів, які підбираються випадковим датчиком [–1, 1] за рівномірним законом розподілу [408].

В якості об'єкта дослідження у [408] використано АПУ двигуна ТВЗ-117, що входить до складу силової установки вертольоту Ми-8МТВ з двома входами (n_{TK} , T_{T}^{*}), одним виходом (G_{T}) і наявністю значних перехресних зв'язків (рис. 4.8). Для оцінювання якості навчання нейронної мережі використовуються метрики *Accuracy*, *Precision*, *Recall*, *F*-міра. *Accuracy* інтерпретована як частка параметрів, які нейронна мережа назвала позитивними і при цьому є дійсно позитивними, а *Recall* показує, яку частку параметрів позитивного класу всіх об'єктів позитивного класу знайшов алгоритм навчання [406]. Результати навчання нейронної мережі за показниками *Accuracy* і *Loss* наведено на рис. 4.9. Як видно з рис. 4.9 показник *Accuracy* наближається до одиниці, а показник *Loss* – до нуля, що свідчить про високу точність моделі та її мінімальну похибку.



Рисунок 4.8 – Структурна схема об'єкта управління (авіаційного двигуна ТВЗ-117)



Рисунок 4.9 – Результати навчання нейронної мережі (1 – train; 2 – test): а – показник *Accuracy*; b – показник *Loss* (авторський доробок [406])

На рис. 4.10 наведено графіки перехідних процесів в АПУ під час тестування заданого впливу без попереднього саморегулювання за моделлю (криві 1, 2) та з попереднім саморегулюванням (криві 3, 4). Нерідко на початковому етапі саморегулювання (при першому включенні нейронної мережі в контур управління) відзначаються значні відхилення контрольованих параметрів від заданих (рис. 4.10, крива 1) [406, 408].



Рисунок 4.10 – Графік впливу попереднього саморегулювання за моделлю на якість процесу управління (авторський доробок [406] на основі [408])

Це зумовлено тим, що при активації нейронної мережі вагові коефіцієнти нейронної мережі ініціалізуються випадковим чином. У такому випадку існує можливість

формування позитивних зворотних зв'язків, що можуть призводити до надто великих відхилень контрольованих параметрів на початковому етапі саморегулювання. Ця ситуація може викликати аварійні ситуації під час польоту вертольоту.

Наявність апріорної інформації про ГТД вертольотів, їх динамічні та статичні характеристики може значно зменшити розбіжності між керованими значеннями під час саморегулювання. Це досягається завдяки попередньому регулюванню системи за допомогою апроксимованої моделі ГТД вертольоту на початковому етапі. Після цього система переключається на взаємодію з реальним об'єктом управління (ГТД вертольоту), який описується нелінійними зв'язками першого порядку із запізненням. Параметри ГТД вертольоту оцінюються приблизно, і похибка в їх визначенні в межах \pm 100 % слабко впливає на результати саморегулювання з основною чутливістю до підсилення. Параметри розробленої нейромережевої АПУ ГТД вертольотів включають кількість нейронів у внутрішньому шарі (N_1) та параметрі N_1 і γ на якість регулювання. Підвищення значень N_1 і γ призводить до зростання швидкості системи, але також збільшує перерегулювання і динамічну похибку, знижує ступінь згасання перехідних процесів. При значному збільшенні регульованих параметрів може виникнути незгасаючі коливання та нестабільність у процесі управління [406, 408].



Рисунок 4.11 – Діаграми впливу: а – кількості нейронів N₁ у проміжному шарі на якість процесу регуляції; b – вагового поправочного коефіцієнта на якість процесу контролю (авторський доробок [406] на основі [408])

Нейромережева АПУ ГТД вертольотів досить добре відпрацьовує як зовнішні збурювальні впливи (рис. 4.12, а), так і задаючі впливи (рис. 4.12, б), а також протифазні задаючі дії (рис. 4.12, в).



Рисунок 4.12 – Діаграми процесу: а – прямокутні збурення; б – один керуючий вплив; в – два задаючі впливи, що виходять за фазу; г – впливи налаштувань при зміні коефіцієнтів підсилення каналів об'єкта управління (авіаційного двигуна ТВЗ-117) (авторський доробок [406] на основі [408])

У нейромережевій АПУ ГТД вертольотів, як і в традиційних системах, важливим фактором для якості регулювання є взаємовплив перехресних каналів. Зменшення впливу цих поперечних зв'язків, виражене у зменшенні коефіцієнта зв'язку $\frac{K_{12}K_{21}}{K_{11}K_{22}}$, суттєво покращує якість регулювання. Важливою особливістю нейромережевої АПУ ГТД вертольотів є її здатність ефективно адаптуватися до змін у властивостях ГТД вертольотів. Під час імітаційних досліджень вивчався вплив зміни властивостей об'єкта управління (авіаційного двигуна ТВ3-117) на якість регулювання в системі. На рис. 4.14, г показано перехідний процес в системі при зміні двох налаштувальних параметрів у вигляді прямокутних хвиль. Під час цього процесу коефіцієнти підсилення по каналах авіаційного двигуна ТВ3-117 змінювалися: K_{11} і K_{22} лінійно зменшувалися з 2,0 до 1,0 і з 1,5 до 1,0 відповідно, а K_{12} і K_{21} лінійно збільшувалися з 0,3 до 0,5 і від 0,4 до 0,6 відповідно. Як видно з рис. 4.14, г, висока якість регулювання зберігалася при значних варіаціях (30...100 %) коефіцієнтів підсилення каналів авіаційного двигуна ТВ3-117, підтверджуючи здатність нейромережевої АПУ ГТД вертольотів адаптуватися до змін цих параметрів. У [404] проведено моделювання перехідних процесів на сталих режимах роботи (для номінального та надзвичайного режимів) за допомогою багаторежимного нейромережевого контролера на базі персептрона. Було проведено аналогічне дослідження [404] з використанням розробленої нейромережевої АПУ ГТД вертольотів на базі саморегульованої нейронної мережі зі зв'язаними координатами. Вхідні дані, аналогічні [404], наведено в табл. Г.2.

На рис. Г.З наведено результати моделювання нейромережевої АПУ ГТД вертольотів на базі саморегульованої нейронної мережі, з яких випливає, що використання розробленої АПУ підвищує точність моделювання перехідних процесів в АПУ ГТД вертольотів, графіки якого близькі до стандартних.

4.4 Забезпечення відмовостійкості бортової автоматизованої підсистеми управління газотурбінних двигунів вертольотів з нейромережевим контролером

Сучасні ГТД вертольотів, що працюють в умовах параметричних умов і конструктивної невизначеності, вимагають удосконалення підходів до забезпечення відмовостійкості АПУ. Алгоритми прийняття рішень на основі нечіткої логіки можуть бути покладені в основу розробки відмовостійкої АПУ. Наявність бази правил типу «ЯКЩО-ТО» дозволяє використовувати експертні знання для вирішення даної проблеми. Нечітку систему управління, діагностики, прогнозування та реконфігурації АПУ можна представити як супервізор, керуючі сигнали якого використовуються для зміни структури основного контролера нейронної мережі. Цей контролер повинен містити певну функціональну надмірність (наприклад, додаткові керуючі програми або дублюючі спрощені алгоритми HM_i (i = 1, ..., m). Алгоритм контролю і навчання є системою правил:

якщо
$$E = S$$
 і $\Delta E = S$ і ... $u = S$, то виберіть HM_1 ;
якщо $E = M$ і $\Delta E = M$ і ... $u = M$, то виберіть HM_2 ;
(4.44)

якщо E = L і $\Delta E = L$ і ... u = L, тоді виберіть HM_i ;

де E, ΔE , u – входи та виходи контролера; S, M, L – значення лінгвістичної змінної, що відповідають наборам «Малий», «Середній», «Великий». Відповідно для кожного параметра будується функція належності. Далі за допомогою механізму логічного висновку розраховується значення вихідних параметрів блоку керування та навчання, які є керуючими сигналами, що з'єднують необхідний на даний момент нейромережевий регулятор *HM_i* з виконавчими механізмами.

Відмінною рисою вищезазначеного підходу від існуючого, вперше запропонованого професором Васильєвим В.І. [409], є використання функції Гауса для опису лінгвістичної змінної, а не функції трикутного типу. Це пояснюється тим, що крива Гауса має більш вузький розподіл, а приналежність параметра близька до заданого значення, ніж трикутна функція.

Як ефективний спосіб забезпечення відмовостійкості використано активний підхід, що ґрунтується на реконфігурації контролера нейронної мережі за допомогою селектора (рис. Г.4) у разі виникнення аварійних ситуацій у роботі АПУ. Таким чином, селектор каналів ГТД вертольотів, що ґрунтується на дослідженнях професора Петуніна В.І. [158], реалізовується у вигляді нейромережевого блоку регуляторів.

Відповідно до розробленої структурної схеми бортової АПУ ГТД вертольотів (рис. 4.3) [404], а також узагальненої (найпоширеніший варіант включення нейронної мережі в АПУ), на рис. 4.13 зображено схему замкнутого контуру бортової АПУ ГТД вертольотів, в якому диспетчерська нейронна мережа використовується для налаштування параметрів лінійного ПІД-регулятора залежно від робочого стану двигуна та зовнішніх умов. Порівняно з класичним (табличним) методом апроксимації коефіцієнтів, нейромережевий апроксиматор забезпечує більш гнучку адаптацію (навчання) до змін зовнішніх умов і параметрів ГТД вертольотів [406, 410].



Рисунок 4.13 – Узагальнена схема ввімкнення нейромережевого регулятора в бортову АПУ ГТД вертольотів (авторський доробок [410] на основі [406])

Професором Васильєвим В.І. встановлено [409], що нейронна мережа виконує функції нелінійного багаторежимного регулятора, забезпечуючи формування необхідних керуючих впливів на виконавчі механізми об'єкта дослідження (у цьому випадку, ГТД вертольотів) на основі процедури навчання. Структурна надмірність, вбудована в нейронну мережу, передбачає підвищений шум і відмовостійкість порівняно з класичними алгоритмами.

Відповідно до досліджень професора Васильєва В.І. [409] застосовано підхід до дослідження стійкості АПУ ГТД вертольотів з нейромережевим регулятором, що грунтується на використанні теореми про малий коефіцієнт посилення. Відповідно до методики, розробленої професором Васильєвим В.І. [409], передбачається, що на базових (сталих) режимах роботи ГТД вертольотів (з урахуванням динаміки виконавчого механізму) описується передавальними функціями виду:

$$W_{\Gamma T \mathcal{A}}^{(r)}(s) = \frac{N_{TK}(s)}{T_{\Gamma}^{*}(s)} = \frac{a(s)}{b(s)} = \frac{a_{0}^{(r)}s^{m} + \dots + a_{m}^{(r)}}{b_{0}^{(r)}s^{n} + \dots + b_{n}^{(r)}};$$
(4.45)

де $N_{TK}(s)$ і $T_{\Gamma}^{*}(s)$ – зображення Лапласа для змінних n_{TK} і T_{Γ}^{*} ; r – номер режиму роботи ГТД вертольотів, r = 1...M, m < n. Коефіцієнти $a_{0}^{(r)}...a_{m}^{(r)}$ і $b_{0}^{(r)}...b_{n}^{(r)}$ передавальної функції залежать від конкретного режиму роботи двигуна.

На рис. 4.14 представлена типова еквівалентна блок-схема нелінійного нейромережевого регулятора замкнутої бортової АПУ ГТД вертольотів, отримана еквівалентними перетвореннями бортової АПУ, де $y = (e, V)^T$, x – вектори вихідних координат



Рисунок 4.14 – Еквівалентна структурна схема нелінійного нейромережевого регулятора замкнутої бортової АПУ ГТД вертольотів [409] лінійної частини (ЛЧ) і виходу нелінійного елемента (НЕ) розмірами 2×1 і $m \times 1$ відповідно; u – скалярний вихід НЕ; $u = \Phi(x)$ – характеристика «вхід-вихід» нейронної мережі; $f_1 = f_1(t)$ і $f_2 = f_2(t)$ – зовнішні впливи на систему, обмежені за величиною $W_{\pi 4}(s) = W_{\pi \pi 4}^{(r)}(s) \cdot (1, s^{-1})^T$

– матриця передавальної функції ЛЧ розміром 2×1 [409].

Згідно з теоремою про малий коефіцієнт підсилення [409], процеси керування в даній системі є стійкими, якщо можна знайти такий лінійний закон керування зі зворотним зв'язком $u = C_x$ і додатне число *r*, для якого виконуються такі умови [409]:

1) граничний коефіцієнт підсилення нелінійного відображення $\Phi(x) - C_x$ повинен бути меншим за нахил конуса *r*:

$$\sup_{x\neq 0} \frac{\left\|\Phi(x) - C_{x}\right\|}{\left\|x\right\|} \le r;$$
(4.46)

2) замкнена лінійна система, отримана заміною $\Phi(x)$ на C_x , що описується матрицею передавальних функцій $H(s) = \frac{W_{JY}(s)}{I + CW_{JY}(s)}$, є стійкою;

3) добуток коефіцієнта підсилення лінійної системи H, заданий її частотною характеристикою матриці $H(j\omega)$, і нахилу конуса r має бути менше одиниці:

$$\sup_{\omega} \overline{\sigma} \left\{ H(j\omega) \right\} \cdot r < 1; \tag{4.47}$$

Для ГТД вертольотів (на прикладі авіаційного двигуна ТВЗ-117) коефіцієнти передавальної функції для різних режимів роботи двигуна наведені в табл. Г.З.

В якості нейромережевого регулятора професором Васильєвим В.І. доведено доцільність використання багатошарової нейронної мережі архітектури персептрон з трьома нейронами у прихованому шарі та одним нейроном у вихідному шарі (рис. Г.5), загальна кількість ваг синаптичних зв'язків (конфігурованих параметрів контролера нейронної мережі) – 9; тип функції активації нейрона – сигмоїдна тангенціальна [409]. Для

нейромережевого регулятора застосовано характеристику «вхід-вихід» нейронної мережі $u = \Phi(e, V)$ із лінеаризуючою характеристикою $u = C\mathbf{x}$ у вигляді u = 0,5e + 0,5V, тобто C = (0,5; 0,5) [409]. Для цього способу апроксимації оператора $\Phi(x)$ отримано для діапазонів і значення коефіцієнта r = 0,392. Обчислення власних значень матриці

$$H(s) = \frac{W_{\mathcal{J}\mathcal{Y}}(s)}{I + CW_{\mathcal{J}\mathcal{Y}}(s)} = \frac{s \cdot W_{\mathcal{F}\mathcal{T}\mathcal{J}}^{(r)}(s)}{s + 0.5(s+1) \cdot W_{\mathcal{F}\mathcal{T}\mathcal{J}}^{(r)}(s)} \cdot (1; s^{-1})^{T}$$
(4.48)

здійснено за правилом [409]:

$$\sup_{\omega \ge 0} \overline{\sigma} \left\{ H(j\omega) \right\} = \max_{\omega \ge 0} \sqrt{H^*(j\omega) \cdot H(j\omega)} = \max_{\omega \ge 0} \sqrt{\frac{\left(\omega^2 + 1\right) \cdot \left|W_{LP}^{(r)}(j\omega)\right|^2}{\left|0.5 \cdot (1 + j\omega) \cdot W_{LP}^{(r)}(j\omega) + j\omega\right|^2}} = 2,471; \quad (4.49)$$

де $H^*(j\omega)$ – матриця передавальної функції, спряжена до $H(j\omega)$.

Отже, добуток граничних значень підсилення ЛЧ і НЕ в цьому випадку дорівнює:

$$\sup_{\omega \ge 0} \overline{\sigma} \{ H(j\omega) \} \cdot r = 0,392 \cdot 2,471 = 0,969 < 1;$$

тобто виконуються умови теореми про малий коефіцієнт підсилення. Отже, усі вимушені процеси в досліджуваній АПУ ГТД вертольотів, що відповідають обмеженій установчій дії (уставці) та іншим зовнішнім збуренням, що діють під час роботи ГТД вертольотів, є в цілому асимптотично стійкими, що є необхідною умовою для працездатності ГТД вертольотів.

При виборі алгоритму реалізації запропонованої схеми навчання слід розглянути методи послідовного навчання нейронної мережі з високою швидкістю збіжності, до яких в першу чергу відносяться методи градієнтного спуску першого та другого порядку. В якості алгоритму навчання нейромережевого регулятора прийнято алгоритм зворотного поширення помилок (метод моментів) з регуляризацією [410] завдяки простоті його реалізації та низьким обчислювальним витратам. При цьому пропонується використовувати змінний параметр швидкості навчання для кожного шару нейронної мережі як функцію помилки нейронів відповідного шару. Алгоритм діаграми являє собою набір дій, наведених у табл. Г.4.

З точки зору адаптивного й оптимального управління ключову роль відіграє мінімізований функціонал [411], запропонований академіком Красовським А.А. Комп'ютерним моделюванням різних варіантів АПУ відбірним каскадом встановлено, що середньоквадратичне відхилення n_{TK} (або n_{CB}) і T_{Γ}^* , яка не перевищує 1 % від заданого значення, забезпечує стабільну роботу двигуна. Тому в САУ ГТД вертольотів метою управління є стабілізація n_{TK} (або n_{CB}) і T_{Γ}^* . Це означає, що мінімізований функціонал може діяти як цільовий функціонал, поданий у вигляді [411]:

$$J_{Y^0} = \sum_{i=1}^{k+he} \varepsilon_i^2 + \sum_{i=1}^{k+hu} (u_i - u_k)^2; \qquad (4.50)$$

де $k = 1, 2, ..., \infty$; ε_i – похибка регулювання обертів ротора турбокомпресора n_{TK} (або частоти обертів ротора вільної турбіни n_{CB}) і температури газів перед турбіною компресора T_{Γ}^* ; u_i – керуюча дія; he – інтервал оптимізації за похибкою управління; hu – інтервал оптимізації управління. Відповідно до [411] мінімізований функціонал (4.50) розділено на чотири частини:

$$J_{n_{TK}} = \sqrt{\frac{\sum_{i=k}^{k+he^{-1}} \varepsilon_i^2}{he^{-1}}} \le \Delta n_{TK}; \ \Delta n_{TK} = 1 \ \%;$$
(4.51)

$$J_{n_{CB}} = \sqrt{\frac{\sum_{i=k}^{k+he^{-1}} \varepsilon_i^2}{he^{-1}}} \le \Delta n_{CB}; \ \Delta n_{CB} = 1 \ \%;$$
(4.52)

$$J_{T_{\Gamma}^{*}} = \sqrt{\frac{\sum_{i=k}^{k+he-1} \varepsilon_{i}^{2}}{he-1}} \le \Delta T_{\Gamma}^{*}; \ \Delta T_{\Gamma}^{*} = 1\%;$$
(4.53)

$$J_{u} = \sqrt{\frac{\sum_{i=k}^{k+he^{-1}} (u_{i} - u_{k})^{2}}{hu - 1}} \le \Delta u; \ \Delta u \le 1 \ \%;$$
(4.54)

де Δn_{TK} , Δn_{CB} , ΔT_{Γ}^* – допустиме стандартне відхилення обертів ротора турбокомпресора n_{TK} (або частоти обертів ротора вільної турбіни n_{CB}) і температури газів перед турбіною компресора T_{Γ}^* ; Δu – допустима середньоквадратична зміна керуючої дії на інтервалі оптимізації управління. Значення Δu було визначено експериментально для досягнення цілей (4.54) для прийнятної продуктивності системи.

Досліджено процес управління контуром швидкості обертів ротора турбокомпресора *n*_{TK}. У різних робочих точках обертів ротора турбокомпресора *n*_{TK} проведено параметричний синтез нейромережевого контролера за такими методами: оптимального модуля, Куна, Копеловича, Копеловича–Шаркова, аперіодичної стійкості, динамічної компенсації [412–416]. У кожній робочій точці з отриманих параметрів нейромережевого регулятора були обрані параметри, що забезпечують найкращі прямі показники якості управління (час, динамічний коефіцієнт регулювання) та грубості. Отже, отримано сіткові функції $k_i^p(n_{TK})$, $T_i^i(n_{TK})$, $T_i^d(n_{TK})$. Для підвищення точності контролю проведено ампліфікацію $k_i^p(n_{TK}) = 8,5 \cdot k_i^p(n_{TK})$. Використовуючи ці сіткові функції, отримано навчальні дані для нейронної мережі розміром n = 256 [410].

Експериментально встановлено, що похибка апроксимації табличних заданих залежностей за допомогою нейронних мереж [417], приведена до діапазону їх зміни, не перевищувала 0,025 %. Із зображеного на рис. 4.15 і 4.16 перехідного процесу випливає, що АПУ ГТД вертольотів з нейромережевим регулятором забезпечує найкращу якість управління: динамічний коефіцієнт регулювання в шість разів менший, час управління в два рази менший порівняно з системою на основі ПІД-регулятора з постійні налаштування. На рис. 4.22 наведено часову діаграму сигналу n_{TK} з безперервними завадами з нейромережевою адаптацією та без неї.



Рисунок 4.15 – Графіки перехідних процесів у АПУ ГТД вертольотів (канал частоти обертання ротора турбокомпресора *n*_{TK}): а – вхідний сигнал; б – реальні перехідні процеси (1 – з нейромережевим регулятором; 2 – без нейромережевого регулятора) (авторський доробок [410])

209



Рисунок 4.16 – Графіки перехідних процесів у АПУ ГТД вертольотів (канал частоти обертання ротора турбокомпресора *n*_{*TK*}): а – сектор I на рис. 4.20, б; сектор II на рис. 4.15, б (1 – з нейромережевим регулятором; 2 – без нейромережевого регулятора) (авторський доробок [410])

В результаті порівняльного аналізу точності нейромережевого регулятора (персептрон (рис. Г.5), RBF, модульна нейронна мережа) і класичних методів: метод найменших квадратів (LSM) і груповий метод обліку аргументів (ГМОА) ідентифікації регулятора АПУ за трьома параметрів двигуна (n_{TK} , n_{CB} , T_{T}^{*}) встановлено, що максимальна помилка ідентифікації при використанні нейронної мережі персептрон в 2,14 рази менша, ніж для моделі поліноміальної регресії 12-го порядку, побудованої з використанням LSM, і в 1,85 рази менша, ніж для ГМОА, і менша для модульної нейронної мережі і для RBF відповідно в 1,29 і 1,25 рази. При цьому персептрон забезпечує похибку ідентифікації не більше 0,441 %; модульна нейронна мережа – 0,732 %; нейронна мережа RBF – 0,755 %; ГМОА – 0,817 %; LSM – 0,942 %.

Для аналізу стійкості нейронних мереж до змін вхідних даних (табл. Г.5) до них було додано адитивний шум по відношенню до поточного значення кожного з параметрів у вигляді білого шуму з нульовим математичним сподіванням і $\sigma_i = \pm 0,01$ (табл. Г.6).

Результати аналізу точності ідентифікації нейромережевого регулятора АПУ ГТД вертольотів за трьома параметрами двигуна в умовах шуму показали такі результати: нейронна мережа персептрон (рис. 4.19) – 0,695 %; модульна нейронна мережа – 1,215 %; мережа RBF – 1,324 %; ГМОА – 1,957 %; МНК – 5,866 %.

4.5 Модифікація бортової автоматизованої підсистеми управління газотур-

бінних двигунів вертольотів шляхом введення каналу управління частотою обертів ротора вільної турбіни

Розроблена бортова нейромережева АПУ ГТД вертольотів ґрунтується на використанні селективного управління, тобто, на селекторів каналів управління. Перевага селективного управління, що сприяло його широкому застосуванню у виробничій сфері, полягає в автономному налаштуванні кожного регулюючого контуру [406, 410]. Цей метод істотно спрощує процес розробки АПУ при обмежених параметрах, що робить його більш гнучким та ефективним у практичному застосуванні. Поряд із перевагами селективного управління у табл. Г.7 виділено низку його недоліків, урахування яких тягне за собою модифікацію розробленої бортової нейромережевої АПУ ГТД вертольотів.

Метод адаптивного управління складними динамічними об'єктами (на прикладі наземної газотурбінної установки) розроблено Бахірєвим І.А. [418]. Метою модифікації розробленої нейромережевої АПУ ГТД вертольотів є модифікація і адаптація методу адаптивного управління до АПУ ГТД вертольотів. Модифікація розробленої нейромережевої АПУ ГТД вертольотів відповідно до досліджень Бахірєва І.А. [418] полягає у доповненні модифікованими порівняно з [406] програмними модулями, що реалізують методи адаптивного управління: модуль сигнальної адаптації з підмодулями лінійної та налаштовувальної моделями [418]; модуль параметричної адаптації з підмодулями лінійної та налаштовувальної моделями [418] (табл. Г.8). Відповідно до [418] у табл. Г.9 подано блок-схеми роботи модулів з сигнальною та параметричною адаптацією, у табл. Г.10 – узагальнену інформацію щодо модифікації бортової нейромережевої АПУ ГТД вертольотів.

При використанні сигнальної гілки з функцією знаку *sign* [418, 419] виникають частотні коливання високої частоти, викликані ковзним режимом. Ці коливання є неприпустимими через конструкцію дозатора газу. Для усунення цього недоліку рівняння си-

гнальної гілки було перетворено на sigma'
$$\left(\frac{x}{k}\right) = \frac{1 - \operatorname{sigma}^2\left(\frac{x}{k}\right)}{2k}$$
. [418, 419]. У цій моди-
фікації функцію знаку *sign* було замінено гладкою сигма-функцією, що призвело до ус-
унення високочастотних коливань. Отже, ключовою особливістю застосованого методу

адаптивного управління є введення додаткової сигнальної дії, яка в кожний момент часу відповідає виваженій сумі сигналів неузгодженості. Високочастотні коливання, що виявляються під час використання сигнальної гілки з функцією знаку, представлені рис. 4.17, а, тоді як відсутність таких коливань демонструється рис. 4.17, б.



Рисунок 4.17 – Діаграми дослідження високочастотних коливань [419]

У разі використання лінійної еталонної моделі з сигнальним налаштуванням sigma' $\left(\frac{x}{k}\right) = \frac{1 - \operatorname{sigma}^2\left(\frac{x}{k}\right)}{2k}$. виникає статична помилка. Це пов'язано з тим, що витрата палива та частота обертання турбокомпресора змінюються нелінійно, що призводить до ненульового значення сигнальної гілки статичного режиму. Таким чином, еталонна мо-

дель має бути доповнена статичними характеристиками.

Результати моделювання нейромережевої системи з модулем сигнальної адаптації з підмодулем еталонної моделі наведено на рис. 4.18, де 1 – еталонна модель, 2 – система з сигнальною адаптацією, 3 – система зі штатним регулятором.

Завдяки використанню сигнального налаштування час перехідного процесу суттєво скоротився та підвищилася стійкість системи. Поліпшення показників якості протягом перехідних процесів наведено у табл. Г.11 і Г.12.



Рисунок 4.18 – Графік зміни: а – частоти обертання вільної турбіни; б – частоти обертання турбокомпресора; в – інтегратора регулятора дозатора; г – інтегратора регулятора вільної турбіни (авторський доробок [419])

Відповідно до [418, 419] наступним кроком є дослідження адаптивних регуляторів FGE ГТД вертольотів на складних поелементних моделях. Перевірка роботи адаптивного регулятора з сигнальною гілкою та еталонною моделлю [419] проводиться в штатному регуляторі двигуна, який включає різні схеми обмеження і управління. Схема стабілізації обертів вільної турбіни є адаптивною. На першому етапі навантаження встановлювалося миттєвою зміною активної потужності двигуна, далі проводилися перевірки на різноманітність робочих ситуацій двигуна. Порівняння штатного регулятора та штатного регулятора з сигнальною адаптацією наведено на рис. 4.19, де 1 – штатний регулятор з сигнальною адаптацією, 2 – штатний регулятор.



Рисунок 4.19 – Графік зміни: а – частоти обертання вільної турбіни; б – частоти обертання турбокомпресора; в – витрати палива (авторський доробок [419])

З рис. 4.19 випливає, що зміна навантаження впливає поліпшення параметрів перехідних процесів n_{CB} в роботі двигуна. Це пов'язано з налаштуванням еталонної моделі, при цьому реакція еталонної моделі стає ідеалізованою починаючи з 45 секунди, що призводить до значного збільшення неузгодженості з поелементною моделлю двигуна. У результаті адаптивний контур формує неприйнятну витрату палива, тому управління переходить до іншого контуру управління. Це підтверджує, що завдяки схемі селектування адаптивна АПУ не становить небезпеки. У табл. Г.13 і Г.14 представлено поліпшення параметрів якості.

Порівняльний аналіз точності класичного та нейромережевого методів управління ГТД вертольотів (на прикладі двигуна ТВЗ-117) наведено в табл. Г.15, де наведено ймовірності помилок 1-го та 2-го роду при визначенні оптимального параметри *n*_{TK} і *n*_{CB}.

Реалізація адаптивного методу управління з модулем сигнальної адаптації та підмодулем еталонної моделі, що грунтується на використанні нейронної мережі архітектури персептрон, забезпечує зменшення похибок першого та другого роду порівняно з класичними методами (метод допускового контролю) – у 2,93 ... 3,22 і 4,67 ... 7,33 разів відповідно.

Досліджено процес сигнальної адаптації за допомогою налаштовувальної моделі [420] без динамічної компенсації для нелінійної моделі ГТД вертольоту (на прикладі авіаційного двигуна ТВЗ-117) (первинна перевірка). На початковому етапі вектори стану лінійної налаштовувальної моделі і нелінійної моделі авіаційного двигуна ТВЗ-117 збігаються. Перехідний процес у цей початковий момент обумовлений неузгодженістю початкових умов та зміною потужності навантаження, що є складним режимом, аналогічним зміні навантаження в перехідному процесі.

Відповідно до рис. 4.20 і 4.21 виявлено суттєве поліпшення параметрів якості перехідних процесів при використанні налаштованої моделі авіаційного двигуна TB3-117 на основі нейронної мережі NEWFF порівняно з моделлю, що використовує стандартний регулятор. Це пояснюється тим, що динамічна компенсація не була використана, оскільки порядок моделей збігається, і налаштовувальна модель демонструє кращі показники якості, ніж реальний двигун, навіть при зміні параметрів протягом перехідного процесу. Результати максимального поліпшення параметрів якості в перехідних процесах наведено в табл. Г.16 і Г.17.



Рисунок 4.20 – Діаграма зміни: а – частоти обертання ротора вільного турбіни; б – частоти обертання ротора турбокомпресора (авторський доробок [420])

215



Рисунок 4.21 – Діаграма зміни інтегратора регулятора: а – дозатор; б – вільна турбіна (авторський доробок [420])

Проведено експеримент вторинної перевірки сигнальної адаптації з моделлю [420] для поелементної динамічної моделі ГТД вертольоту (на прикладі авіаційного двигуна TB3-117). У початковий момент часу налаштовувальна модель відповідає номінальному режиму роботи двигуна (наприклад, І крейсерському режиму), так як поелементна модель істотно складніше налаштовувальної моделі, в процесі ідентифікації виникають великі параметричні обурення, тому застосовується динамічна компенсація моделі, що налаштовується. На рис. 4.22 і 4.23 представлені перехідні процеси, де: 1 – система зі штатним регулятором, 2 – налаштовувальна модель (із застосуванням нейронної мережі NEWFF). Результати максимального поліпшення параметрів якості в перехідних процесах наведено в табл. Г.18 і Г.19.



Рисунок 4.22 – Діаграма зміни: а – частоти обертання ротора вільного турбіни; б – частоти обертання ротора турбокомпресора (авторський доробок [420])


Рисунок 4.23 – Діаграма зміни інтегратора регулятора: а – дозатор; б – вільна турбіна (авторський доробок [420])

При порівняльному аналізі точності нейромережевої (багатошарової нейронної мережі NEWFF) і класичної (метод найменших квадратів) реалізації випадку 2 (табл. Г.10) [418] встановлено, що максимальна абсолютна похибка ідентифікації при використанні багатошарової нейронної мережі NEWFF у 2,94 рази менше, ніж для моделі поліноміальної регресії восьмого порядку, побудованої методом найменших квадратів. При цьому багатошарова нейронна мережа NEWFF забезпечує похибку ідентифікації, що не перевищує 0,78 %. Результати порівняльного аналізу точності реалізації випадку 2 (табл. 4.11) [420] нейромережевими та класичними методами для кожного з параметрів моделі двигуна ТВЗ-117 наведені в табл. Г.20.

Для аналізу стійкості нейронної мережі NEWFF до змін вхідних даних було додано адитивний шум по відношенню до поточного значення кожного з параметрів у вигляді білого шуму з нульовим математичним сподіванням і $\sigma_i = 0,025$, тобто 2,5 % по відношенню до максимального значення. Результати порівняльного аналізу точності реалізації випадку 2 (табл. Г.10) [418] нейромережевими та класичними методами для кожного з параметрів моделі двигуна ТВЗ-117 в середовищі з білим шумом наведені в табл. Г.21.

Аналіз табл. Г.21 показує, що похибка ідентифікації за умов білого шуму не перевищує: при використанні багатошарової нейронної мережі NEWFF – 1,32 %, методу наймен ших квадратів – 3,67 %. Для дослідження випадку 3 (табл. Г.10) [418] обрано тришарову нейронну мережу прямого поширення (рис. 4.24), в якій N_i – нейрони прихованого шару (i = 1...n), $w_{11}, w_{12}, ..., w_{1n}, w_{2,n+1}, w_{3,n+1}, ..., w_{n+3,n+1}$ – вагові коефіцієнти, що

утворюють матрицю вагових коефіцієнтів **W**. Задача параметричної адаптації АПУ набула розв'язання за допомогою алгоритму навчання нейронної мережі, сформованого на



основі методу Нелдера-Міда, дослідженого у роботах Ігумнова І.В. [422, 423]. Для оцінки роботи Ігумновим І.В. запропоновано використовувати інтегральний критерій виду [422]:

Рисунок 4.24 – Архітектура нейронної мережі прямого поширення [421]

$$I(\mathbf{W}) = \int_{0}^{\infty} F(H(t, \mathbf{W})), \varepsilon(t, \mathbf{W}) dt; \qquad (4.74)$$

де x(t, W) – вихідна координата системи; $\varepsilon(t, W)$ – помилка системи; F – деяка опукла функція. Оператор об'єкта регулювання (ГТД вертольотів) $G_p(p)$, що враховує передатну функцію, що компенсує регулятор частоти обертання вільної турбіни, подано у вигляді [422]:

$$G_{p}(p) = \frac{1}{k_{p}} \cdot \frac{k_{i} + p}{k_{i} + k_{f} \cdot p} \cdot \frac{1}{(T_{\mu 1} \cdot p + 1) \cdot (T_{\mu 2} \cdot p + 1)} \cdot e^{-\tau_{\mu} \cdot p}; \qquad (4.75)$$

де $T_{\mu 1}$, $T_{\mu 2}$ – малі некомпенсовані постійні часу об'єкта; τ_{μ} – малий некомпенсований час запізнення.

Згідно з [422] критерій адаптації представляється у вигляді:

$$I(\mathbf{W}) = \int_{0}^{L} \varepsilon^{2}(t, \mathbf{W}) dt; \qquad (4.76)$$

де *L* – інтервал інтегрування.

У табл. Г.22 представлений алгоритм навчання нейронної мережі, розроблений на основі методу Нелдера-Міда [422].

Отже, якщо виконується критерій закінчення пошуку, точка з найменшим значенням критерію *I* розглядається як розв'язок для даного симплексу. Нейронна мережа прямого поширення складається з двох нейронів у прихованому шарі, і ця кількість обрана на підставі попередніх досліджень [422], які показали прийнятну якість регулювання за такою архітектурою нейронної мережі. Коефіцієнт відбиття $\alpha = 1$, коефіцієнт розтягування $\gamma = 2$, коефіцієнт стиснення $\beta = 0,5$, коефіцієнт усічення d = 2 [422] є параметрами алгоритму навчання нейронної мережі, які характеризують основні операції методу Нелдера-Міда [422].

Досліджено процес параметричної адаптації з налаштовувальною моделлю без динамічної компенсації для нелінійної моделі авіаційного двигуна ТВ3-117 (первинна перевірка) [421, 424–428]. У початковий момент часу вектори стану лінійної регульованої моделі та нелінійної моделі авіаційного двигуна ТВ3-117 співпадають. Перехідний процес в початковий момент часу викликаний розходженням початкових умов та зміною потужності навантаження, що представляє собою складний режим роботи, схожий на зміну навантаження під час перехідного процесу. На рис. 4.25 представлені перехідні процеси, де: 1 – налаштовувальна модель (з використанням нейронної мережі прямого поширення); 2 – система із стандартним регулятором. На рис. 4.26 відображена зміна значень коефіцієнтів регулятора частоти обертання ротора вільної турбіни.



Рисунок 4.25 – Діаграми зміни: а – частоти обертання ротора вільної турбіни; б – частоти обертання ротора турбокомпресора; в – інтегратора регулятора дозатора; г – інтегратора регулятора вільної турбіни (авторський доробок [421])



Рисунок 4.26 – Діаграми зміни значень коефіцієнтів регулятора частоти обертання ротора вільної турбіни: а – діаграми зміни інтегрального коефіцієнта; б – діаграми зміни пропорційного коефіцієнта; в – діаграми зміни коефіцієнта форсування (авторський доробок [421])

За допомогою параметричної адаптації покращуються такі показники якості, як максимальне відхилення. Результати покращення показників якості під час перехідних процесів наведені в табл. Г.23 і Г.24.

Досліджено процес параметричної адаптації з налаштовувальною моделлю [421] для нелінійної (поелементної) моделі ГТД вертольотів (на прикладі авіаційного двигуна TB3-117). Перше порівняльне дослідження включає порівняння налаштовувальної та поелементної моделей. Коефіцієнти регулятора поелементної моделі залишаються незмінними. Невідповідність початкових умов викликає перехідний процес протягом перших 15 секунд. На рис. 4.27 представлені результати експерименту, де: 1 – поелементна модель; 2 – налаштовувальна модель [421].

Поелементна модель авіаційного двигуна ТВЗ-117 значно складніша в порівнянні з налаштовувальною моделлю [421], тому точність ідентифікації замовної моделі гірша, ніж у випадках, які розглядалися раніше. Також це може бути пов'язано з тим, що розрахункові значення моменту інерції вільної турбіни та еквівалентної сталої часу лініаризованої моделі турбокомпресора були отримані з недостатньою кількістю експериментів, тому є недостатньо точними.



Рисунок 4.27 – Діаграми зміни: а – частоти обертання ротора вільної турбіни; б – частоти обертання ротора турбокомпресора; в – інтегратора регулятора дозатора; г – інтегратора регулятора вільної турбіни (авторський доробок [421])

На другому етапі відбувається налаштування коефіцієнтів регулятора відповідно до поточної налаштованої моделі [421]. На рис. 4.28 представлені діаграми перехідних процесів, де: 1 – поелементна модель; 2 – індивідуальна модель.

На рис. 4.29 показано зміну значень коефіцієнтів регулятора частоти обертання ротора вільного турбіни. Це важливий аспект, який доповнює аналіз перехідних процесів, демонструючи вплив налаштувань регулятора на динаміку системи. Ці дані сприяють більш глибокому розумінню ефективності використання налаштованої моделі авіаційного двигуна TB3-117 на основі нейронної мережі прямого поширення у реальних умовах роботи.



Рисунок 4.28 – Діаграми зміни: а – частоти обертання ротора вільної турбіни; б – частоти обертання ротора турбокомпресора; в – інтегратора регулятора дозатора; г – інтегратора регулятора вільної турбіни (авторський доробок [421])



Рисунок 4.29 – Діаграми зміни значень коефіцієнтів регулятора частоти обертання ротора вільної турбіни: а – діаграми зміни інтегрального коефіцієнта; б – діаграми зміни пропорційного коефіцієнта; в – діаграми зміни коефіцієнта форсування (авторський доробок [421])

З рис. 4.29 очевидно, що значення коефіцієнтів k_p , k_i та k_f майже дорівнюють 1, що свідчить про правильний вибір їх значень. За умови $k_p = k_i = k_f = 1$ максимальне покращення якості адаптації перехідних процесів досягається, забезпечуючи при цьому приблизно 30 % покращення розробленої АПУ ГТД вертольотів порівняно із стандартними.

Поліпшення якісних показників перехідних процесів відбувається незважаючи на те, що відповідність між скоригованою моделлю та об'єктом (авіаційним двигуном TB3-117) не така висока, як у попередніх випадках. Максимальне покращення показників якості під час перехідних процесів наведено в табл. Г.25 і Г.26. Порівняльний аналіз точності класичного та нейромережевого методів управління ГТД вертольотів (на прикладі двигуна TB3-117) наведено в табл. Г.27, де наведено ймовірності помилок 1-го та 2-го роду при визначенні оптимального параметри n_{TK} і n_{CB} .

Реалізація адаптивного методу управління з модулем параметричної адаптації та підмодулем налаштовувальної моделі, що грунтується на використанні нейронної мережі прямого поширення, забезпечує зменшення похибок першого та другого роду порівняно з класичними методами (метод допускового контролю) – у 3,07...3,59 і 3,78...5,65 разів відповідно.

4.6 Синтез модифікованої закритої бортової автоматизованої підсистеми управління газотурбінних двигунів вертольотів

На рис. Г.6 наведена синтезована модифікована закрита бортова АПУ ГТД вертольотів, особливостями якої є:

1. Відокремлення елементів ГТД і АДП.

2. Наявність блоку нейромережевих регуляторів на вході АПУ з метою забезпечення відмовостійкості.

3. Наявність каналу управління частотою обертів ротора вільної турбіни.

4. Наявність під'єднаних модулів адаптивного управління.

5. Ключ 1 виконує функцію ввімкнення або вимкнення підключених модулів адаптивного управління, ключ 2 – перемикання моделей сигнальної або параметричної адаптації, ключ 3 – перемикання підмодулів еталонної або налаштовувальної моделей.

6. Алгоритми адаптивного управління ГТД вертольотів на основі еталонної моделі та налаштовувальної моделі реалізовані у вигляді модуля адаптивного управління та використовуються у складі розробленої закритої бортової АПУ ГТД вертольотів, що дає змогу проводити комп'ютерне управління, випробування АПУ в режимі реального часу, прогнозувати робочий стан двигуна, що, в кінцевому підсумку, впливає на поточний процес управління.

Таким чином, відповідно до [428] розроблена закрита бортова АПУ ГТД вертольотів має узагальнену структурну схему, представлену на рис. 4.30, де $k_{11}...k_{33}$ – коефіцієнти нейромережевого регулятора. На рис. 4.31 представлено структурну схему інтегрованої АПУ польотом вертольоту і розробленої закритої бортової АПУ ГТД вертольотів, де блоки M_1 і M_2 (мультиплексори) [424] відображають наявність великої кількості виконавчих механізмів і датчиків параметрів вертольоту і його ГТД.



Рисунок 4.30 – Узагальнена структурна схема розробленої закритої бортової АПУ ГТД вертольотів (авторський доробок)



Рисунок 4.31 – Узагальнена структурна схема інтегрованої АПУ ГТД вертольотів та польоту вертольоту (авторський доробок)

Висновки до четвертого розділу

1. Удосконалено систему автоматичного керування двигунами літальних апаратів вертольотів, у якій поділ моделі об'єкта управління на виконавчий механізм і ГТД дозволив враховувати динаміку виконавчої частини системи та двигуна, а також використовувати невідповідність між частинами структурної схеми для підвищення надійності та стійкості системи в різних режимах.

2. Розвинуто метод побудови математичної моделі АПУ ГТД вертольотів, який базується на селекторі каналів управління за термогазодинамічними параметрами двигуна, шляхом модифікації передатних функцій, що дозволило адаптувати систему до змін часових сталих і затримок; навіть їх збільшення вдвічі чи втричі не має істотного впливу на якість регулювання.

3. Набули подальшого розвитку самоналаштовувані нейромережеві системи керування багатозв'язаними динамічними об'єктами, адаптація яких у вигляді модифікованого нейромережевого контролера для двигунів вертольотів (через впровадження інтегратора у структуру системи) дозволила наблизити графік реального перехідного процесу двигуна до ідеального, підвищуючи надійність і стійкість системи в різних режимах. Інтелектуальний підхід дав змогу створити логічний блок, який значно поліпшив вихідні параметри системи та забезпечив наближення до ідеальних характеристик із достатнім ступенем точності.

4. Набув подальшого розвитку алгоритм аналізу стійкості нейромережевої системи керування на основі теореми низького підсилення, що через застосування переналаштовуваного нейромережевого контролера перед селектором каналів керування двигуном і використання гауссової форми лінгвістичних змінних у системі правил навчання гарантує абсолютну стійкість АПУ ГТД вертольотів за довільного діапазону збурень.

5. Набув подальшого розвитку метод адаптивного керування з еталонною моделлю та налаштуванням сигналу, що автоматизує процес управління ГТД вертольотів у польотних режимах. Розвинуто нейромережевий метод моніторингу технічного стану двигунів, який через застосування гібридного нейро-ПІД керування з емулятором і контролером зменшує помилки першого і другого роду при визначенні оптимальних параметрів двигуна. Доведено, що використання блоків регуляторів сигналу з еталонною моделлю в АПУ ГТД вертольотів підвищує якість розпізнавання перехідних процесів у середньому на 60 % порівняно із штатними контролерами.

6. Набув подальшого розвитку метод адаптивного управління сигналом з безпошуковим алгоритмом ідентифікації, реалізованим на основі нейронних мереж, що покращило АПУ ГТД вертольотів. Доведено, що нейронні мережі забезпечують точнішу реалізацію цього алгоритму порівняно з класичними методами: помилка ідентифікації за допомогою багатошарової нейронної мережі NEWFF у 2,94 рази менша за помилку регресійної моделі, отриманої методом найменших квадратів. Помилка ідентифікації за NEWFF не перевищує 0,78 %, тоді як для класичного методу вона становить близько 2,39 %. Порівняння методів показує, що нейронні мережі більш стійкі до зовнішніх перешкод: при рівні шуму $\sigma_i = 0.025$ помилка зростає з 0,78 до 1,32 % для NEWFF і з 2,39 до 3,67 % для методу найменших квадратів.

7. Набув подальшого розвитку метод адаптивного управління з налаштовуваною моделлю та параметричним налаштуванням, що дозволяє автоматизувати процес управління ГТД вертольотів у режимі льотної експлуатації. Покращено метод моніторингу технічного стану ГТД вертольотів через використання нейроконтролера на основі нейронної мережі архітектури персептрон з двома нейронами в прихованому шарі, що знизило помилки першого та другого роду при визначенні оптимальних параметрів двигуна. Доведено, що використання параметричного налаштування з налаштовуваною моделлю в АПУ ГТД підвищує якість розпізнавання перехідних процесів на 30 % порівняно із штатними контролерами.

Основні результати досліджень, викладені у розділі, опубліковано у наукових працях [398-400, 403-407, 410, 414, 417, 419-421].

РОЗДІЛ 5

АЛЬТЕРНАТИВНІ ПІДХОДИ ДО МОНІТОРИНГУ І УПРАВЛІННЯ ЕКСПЛУА-ТАЦІЄЮ ГАЗОТУРБІННИХ ДВИГУНІВ ВЕРТОЛЬОТІВ З ВИКОРИСТАННЯМ АПАРАТУ НЕЧІТКОЇ ЛОГІКИ ТА НЕЙРО-НЕЧІТКИХ МЕРЕЖ

5.1. Передумови застосування апарату нечіткої логіки та нейро-нечітких мереж

Відомо, що ефективність управління параметрами ГТД вертольотів значною мірою залежить від якості налаштування електронних алгоритмів [429]. У АПУ ГТД часто використовуються лінійні регулятори різних типів, такі як, П-, ПД-, ПІ- та ПІД- [430–435]. Їхня популярність обумовлена простотою математичного опису, доступністю в реалізації та достатньою ефективністю. Проте практика показує, що в рамках лінійної теорії не завжди вдається налаштувати ПІД-регулятор таким чином, щоб забезпечити необхідну якість перехідних процесів у нелінійній системі. При керуванні ГТД вертольотів, такі лінійні регулятори не завжди здатні забезпечити необхідну якість керування параметрами, стабільність системи та її стійкість за змін умов експлуатації та виникнення відмов [432]. У таких випадках є сенс використовувати альтернативні нелінійні регулятори. Наприклад, нечіткий логічний регулятор (НЛР) є одним з таких варіантів, що має властивість робастності [433]. Завдяки відсутності потреби суворого математичного опису об'єкта, НЛР здобули широку популярність серед розробників електронних систем. Нечіткий закон управління, що отримується в результаті синтезу, є нелінійним і ефективно функціонує в системах з високим ступенем складності, нелінійними ефектами, такими як зона нечутливості і гістерезис, а також при відхиленнях параметрів незмінної частини системи від їх номінальних значень і при втраті інформації при відмовах. Отже, в задачах моніторингу і управління експлуатацією ГТД вертольотів передбачається використання апарату нечіткої логіки та нейро-нечітких мереж з таких передумов (табл. Д.1).

Розв'язання задач моніторингу і управління експлуатацією ГТД вертольотів на основі FDI-методу [124] відрізняється від класичних методів. Останні використовують жорсткі допуски для контрольованих і діагностованих параметрів та обмеження для варіювання коефіцієнтів. У свою чергу, FDI-метод використовує правила нечіткої логіки, що базуються на адаптації розрахункової математичної моделі реального двигуна до конкретних умов експлуатації та експертних знань [436, 437]. Елементи нечіткої логіки застосовуються спільно з класичними методами, такими, як метод діагностичних матриць [436] та варіювання коефіцієнтів [437] параметрів стану двигуна. Задача семантичної візуалізації та реконфігурації математичної моделі розв'язується в середовищі нечіткої експертної системи. Математична модель ГТД вертольоту, що враховує розсіювання параметрів компресорних характеристик, налаштована на конкретний двигун.

Відповідно до [436, 437] узагальнена лінійна функція, що розділяє одну з підмножин технічного стану ГТД вертольотів від сукупності всіх інших підмножин його технічного стану, має вигляд [436–440]:

$$L_{j} = \sum_{n=1}^{N} d_{n_{j}} f\left(F_{l}, F_{l_{n}}\right);$$
(5.1)

де $d_{n_j} = \begin{cases} 1, якщо F_{l_n} \in y'_j \\ -1, якщо F_{l_n} \notin y'_j \end{cases}, f(F_l, F_{l_n}) = e^{-(|F_l - F_{l_n}|)^2}, y'_j \in y' - peдуцирована множина техні-$

чних станів двигуна, отримана з початкової множини У шляхом відбору його елементів (еталонних векторів F_{l_i}) за правилом вектору F_{l_i} з множини Y встановлюється однозначний йому вектор F_{l_n} множини у' $F_{l_i} \equiv F_{l_n}$ тільки в тому випадку, коли відмінна від нуля величина τ_i , що розраховується за рекурентним співвідношенням [436–440]:

$$\tau_{i} = \frac{1}{2} b_{i} \left\{ 1 - b_{i} \operatorname{sgn} \left(a \left(F_{l_{i-1}} \right) \right) \right\};$$
(5.2)

де $a(F_{l_{i-1}}) = a(F_{l_{i-2}}) + \tau_{i-1}e^{-(|F_l - F_{l_{i-1}}|)^2}, \qquad aF_{l_1} = e^{-(|F_l - F_{l_1}|)^2}, \qquad b_i = \begin{cases} 1, \text{якщо } F_{l_i} \in y'_j \\ -1, \text{якщо } F_l \notin y'_i \end{cases},$

 $\operatorname{sgn}(aF_{l_{i-1}}) = \begin{cases} 1, \, \operatorname{skilo} a(F_{l_{i-1}}) > 0\\ -1, \, \operatorname{skilo} a(F_{l_{i-1}}) \le 0 \end{cases}.$

У дослідженнях професора Жернакова С.В. [436, 437] вирішальне правило розпізнавання *і*-го технічного стану подається у вигляді:

– якщо $L_j > 0$, то вектор виміряних параметрів F_l відповідає *j*-му технічному стану двигуна;

– якщо $L_j < 0$, то вектор виміряних параметрів F_l не відповідає *j*-му технічному

стану двигуна;

-якщо $L_i = 0$, то технічний стан двигуна не визначено.

Критерії ефективності ідентифікації середньостатистичної математичної моделі ГТД вертольотів відповідно до [436–440] подаються у вигляді:

$$\delta_{p} = \frac{1}{m_{z}} \sum_{Ij}^{m_{z}} \left(P_{I_{j}} - P_{M_{I}} \right)^{2};$$
(5.3)

$$\delta_{x} = \frac{1}{n_{z}} \sum_{lj}^{n_{z}} \left(x_{g_{j}} - x_{M_{lj}} \right)^{2};$$
(5.4)

де P_{I_j} , P_{M_I} – відповідно виміряні при випробуваннях і розраховані за адекватною математичною моделлю значення параметрів проточної частини ГТД вертольоту; x_{g_j} , $x_{M_{ij}}$ – дійсні і розраховані за математичною моделлю значення характеристик вузлів двигуна (варійовані параметри моделі); $I = \overline{1, m}$, де m – число вимірюваних при випробуваннях параметрів ГТД вертольоту; $i = \overline{1, n}$, де n – число змінних параметрів математичної моделі; $j = \overline{1, z}$, де z – число повторних вимірів параметрів ГТД вертольоту.

Критерій δ_p вказує на точність визначення параметрів ГТД вертольотів за допомогою статистичної моделі, порівняно з аналогічними параметрами, які отримані під час експлуатації вертольоту, а критерій δ_x відображає точність визначення значень характеристик окремих вузлів ГТД вертольотів.

Відповідно до досліджень Жернакова С.В. [436, 437] розв'язання задачі включає пряму задачу (рис. Д.1), що використовує статистику характерних дефектів та обернену задачу (рис. Д.2), де результуючий вектор відхилень дозволяє приймати рішення про фактичний технічний стан двигуна. Метод забезпечує адаптацію до умов експлуатації та враховує експертні знання для точного визначення технічного стану двигуна. Для виявлення несправних модулів проточної частини ГТД вертольотів використано метод діагностичних матриць, вперше застосований Жернаковим С.В. для розробки експертних систем контролю і діагностики турбореактивних двигунів С-Priz і TILShell 3.0 в умовах стендових випробувань [436, 437]. Цей метод встановлює зв'язки між відхиленнями термогазодинамічних параметрів робочого циклу і відхиленнями конструктивних

параметрів стану вузлів двигуна. Моделі представлені у векторній формі $\overline{\delta_x} = A^{-1}B\overline{\delta_y}$, де вектор $\overline{\delta_x}$ представляє параметри стану двигуна, вектор $\overline{\delta_y}$ – діагностичні ознаки, а матриці *B* і *A* встановлюють кількісний взаємозв'язок параметрів на різних режимах роботи двигуна. Діагностична матриця конкретного двигуна на певному режимі містить чисельні значення коефіцієнтів, що дозволяють визначати відхилення невимірюваних параметрів стану вузлів за відхиленнями виміряних параметрів.

5.2. Розробка нейро-нечіткої експертної системи моніторингу газотурбінних двигунів вертольотів

Згідно з математичною моделлю ГТД вертольотів [204], основними вхідними параметрами є параметри, що реєструються на борту вертольоту, такі, як n_{TK} , T_{Γ}^* , n_{CB} та інші термогазодинамічні параметри, обчислені за аналітичними виразами.

Вихідними діагностичними параметрами ГТД вертольотів є: ступінь підвищення загального тиску в компресорі, ККД компресора η_{K} , механічний ККД компресора η_{MK} , коефіцієнт відновлення загального тиску газу в камері згоряння σ_{Γ} , площа поперечного перерізу камери згоряння F_{KC} , ККД турбіни компресора η_{TK} , робота турбіни компресора A_{TK} , ступінь зниження загального тиску газу в турбіні компресора, коефіцієнт зниження загального тиску газу в турбіні компресора, коефіцієнт зниження загального тиску газу в турбіні компресора, коефіцієнт зниження загального тиску у вільній турбіні, енергетичний ККД вільної турбіни $\eta_{\Sigma CB}$, коефіцієнт загального зниження тиску у вільній турбіні та вихідному пристрої, загальний коефіцієнт відновлення тиску газу у вихідному пристрої σ_{C} .

Шляхом аналізу статистичних даних щодо типових дефектів у вузлах двигуна, а також застосування імітації (введення дефектів) на математичній моделі двигуна, на основі досліджень Жернакова С.В. [436, 437] створено діагностичну матрицю у вигляді (табл. Д.2):

$$DEF\gamma_i = M_p; (5.5)$$

де γ_i – перший стовпець матриці, що містить імітовані дефекти; i = 1, ..., N – кількість дефектів; \overline{M}_p – вектор параметрів, отриманий в процесі розрахунків за компонентною математичною моделлю (реакція на прояв дефекту); p = 1, ..., K – кількість вимірюваних параметрів.

У табл. Д.2 Δy_i – значення параметрів двигуна, відповідні відхилень від їх еталонних даних; «Стан» – стовпець даних, що описують певну ситуацію. Наприклад, запис π_{κ}^* (5 %) означає зменшення ступеня підвищення тиску в компресорі на 5 % від еталонного значення.

Перший рядок цієї матриці є еталонним станом двигуна, що складається з нульових елементів. Усі наступні рядки відображають відхилення від еталонного стану внаслідок прояву дефекту. Вивчено 12 різних дефектів на надзвичайному режимі роботи ГТД вертольоту (на прикладі авіаційного двигуна ТВЗ-117). Кожен дефект було імітовано на математичній моделі зі зміною внутрішнього параметра двигуна в межах від 1 до 5 %.

Відповідно до досліджень Жернакова С.В. [436, 437] створено шляхом перетворення діагностичної матриці (5.5) створено обернену діагностичну матрицю:

$$M_p = DEF\gamma_i; (5.6)$$

Діагностичну матрицю (5.6), використовуючи методику Жернакова С.В., адаптовано до експертної бази знань у вигляді продукцій, де верхній рядок матриці визначає атрибути експертної бази знань, а наступні рядки представляють значення цих атрибутів. Проведений аналіз матриці показав, що введення дефекту в конкретний вузол двигуна призводить до суттєвих змін декількох параметрів в рядку. Шляхом оцінювання зміни кожного параметра створено табл. Д.З, що відображає зміну поведінки кожного параметра та мінімізує кількість виокремлених штатних датчиків (виділяються найбільш істотні). Знак «мінус» вказує на тенденцію до зменшення значення вимірюваного параметра, а «плюс» – до його збільшення. Рядки, позначені символом «⊗», вказують на суттєве відхилення вимірюваних параметрів. Інформація, представлена у рядку, служить основою для створення єдиної бази експертних знань для класу авіаційних двигунів з вільною турбіною, що використовуються в складі силових установок вертольотів.

Ця база формується на основі табл. Д.3 та функцій належності відповідних лінгвістичних змінних (рис. Д.1) (функції приладдя для інших лінгвістичних змінних наведено в додатку). Таким чином, на логічному рівні база експертних знань (база правил) виглядає, як показано в табл. Д.4.

У цьому стані експертна система «навчена» тільки на розпізнавання фактичного

231

технічного стану ГТД вертольотів за умови, що вектор відхилень вихідних параметрів ГТД вертольотів містить нев'язки, відповідні 5 % зміни параметрів вузлів. У табл. Д.4 наведено фрагмент бази експертних знань, відповідний процесу прийняття рішення про технічний стан того чи іншого вузла двигуна. Задля розширення діагностичних показників табл. Д.4 може поповнюватися іншими нечіткими експертними правилами. У табл. Д.4 наведені параметри відхилень (нев'язок) і відповідні їм лінгвістичні змінні: LN (Large Negative) – дуже мале; MN (Middle Negative) – невелике; Z (Zero) – близько нуля; MP (Middle Positive) – середнє; LP (Large Positive) – дуже велика.

Варто відзначити, що у даній експертній системі використовується система нечіткого виводу Сугено на відміну від [436, 437, 441–443], де використовується система нечіткого виводу Мамдані.

Аналогічно дослідженням Жернакова С.В. [436, 437], тестування працездатності нейро-нечіткої експертної системи проведено за правилами, що не входять до навчальної множини (див. табл. Д.4). Ці правила базуються на двох попередніх рядах, які використовують відхилення параметрів стану двигуна на 1 % і 3 % відповідно. У ході порівняльного аналізу виміряних та обчислених параметрів двигуна ТВ3-117 отримано вектор нев'язок, представлений восьмим і дев'ятим рядками зверху у табл. Д.2. Під час аналізу функцій приналежності лінгвістичних змінних, що входять у цей вектор, експертна система може обчислити значення таких функцій належності:

1. Для другого рядка (1 % відхилення ступеня підвищення тиску в турбокомпресорі) можна знайти:

$$\mu_{Z}\left(\Delta T_{2}^{(k)}\right) = 0,945; \ \mu_{MN}\left(\Delta T_{2}^{(k)}\right) = 0,04; \ \mu_{Z}\left(\Delta P_{4}^{(k)}\right) = 0,85; \ \mu_{MN}\left(\Delta P_{4}^{(k)}\right) = 0,08;$$
$$\mu_{Z}\left(\Delta F_{C}^{(k)}\right) = 0,79; \ \mu_{MN}\left(\Delta F_{C}^{(k)}\right) = 0,07.$$

Використовуючи базу нечітких правил експертної системи, а також операцію перетину нечітких множин, отримуємо:

$$\min\left(\mu_{Z}\left(\Delta T_{2}^{(k)}\right) \& \mu_{Z}\left(\Delta P_{4}^{(k)}\right) \& \mu_{Z}\left(\Delta F_{C}^{(k)}\right)\right) \to 0,79.$$

Це означає, що ймовірність прийняття рішення (коефіцієнт впевненості) щодо справності турбокомпресора становить 0,79. За аналогією, можна записати: 233

$$\min\left(\mu_{MN}\left(\Delta T_{2}^{(k)}\right) \& \mu_{MN}\left(\Delta P_{4}^{(k)}\right) \& \mu_{MN}\left(\Delta F_{C}^{(k)}\right)\right) \to 0,04.$$

Отже, ймовірність прийняття рішення щодо несправності турбокомпресора становить 0,04.

2. Для третього рядка, що відповідає 3 % зниження ступеня підвищення тиску в турбокомпресорі, маємо:

$$\mu_{Z}\left(\Delta T_{2}^{(k)}\right) = 0,85; \ \mu_{Z}\left(\Delta P_{4}^{(k)}\right) = 0,66; \ \mu_{MN}\left(\Delta P_{4}^{(k)}\right) = 0,22; \ \mu_{Z}\left(\Delta F_{C}^{(k)}\right) = 0,52;$$
$$\mu_{MN}\left(\Delta F_{C}^{(k)}\right) = 0,26.$$

Використовуючи базу нечітких правил експертної системи, а також операцію перерізу нечітких множин, отримуємо:

$$\min\left(\mu_Z\left(\Delta T_2^{(k)}\right) \& \mu_Z\left(\Delta P_4^{(k)}\right) \& \mu_Z\left(\Delta F_C^{(k)}\right)\right) \to 0,52.$$

Це означає, що ймовірність прийняття рішення (коефіцієнт впевненості) щодо справності турбокомпресора становить 0,52. За аналогією, можна записати:

$$\min\left(\mu_{MN}\left(\Delta P_{4}^{(k)}\right) \& \mu_{MN}\left(\Delta F_{C}^{(k)}\right)\right) \to 0,22.$$

Таким чином, ймовірність прийняття рішення про несправності турбокомпресора становить 0,22.

Дані величини говорять про те, що є висока ймовірність наявності дефекту в турбокомпресорі, що може відповідати конструктивному дефекту, зумовленого зниженням зазору в турбокомпресорі в порівнянні з заданим по ТУ, що, в свою чергу, знизило ступінь підвищення тиску в турбокомпресорі на 3%. Результати аналізу експертної системи збігаються з результатами досліджень, проведених в ході стендових випробувань знятого з експлуатації двигуна.

Модифікована логіка процесу прийняття рішень показана на рис. 5.1. Вектор відхилень (рядок діагностичної матриці) (табл. Д.2) обробляється базою експертних знань, що утворює систему правил (продукцій), що дозволяють обчислити рівні активності правил. Відповідно до їх значеннями і шкалою значимості результатів прийняття рішень по кожному з правил.

Так для першого рядка (табл. Д.2) і (табл. Д.3) маємо рівень активності правила α₁,

для якого відповідно до справного стану двигуна (*a*) максимальне значення ступеня впевненості дорівнює 1 і воно характеризує придатний двигун, а мінімальне значення (нуль) відповідає несправному двигуну. Проміжні значення ступеня впевненості при постановці діагнозу можуть означати, наприклад, що двигун «майже не придатний» ($\alpha_1 = 0,25$) або «майже придатний» ($\alpha_1 = 0,75$).

Інші рядки табл. Д.2, Д.3 відповідають рівню активності правила α_4 і діагнозу «дефект у вузлу двигуна». Максимальне значення $\alpha_1 = 1$ у даному випадку характеризує «істотний дефект», тобто відповідне зменшення на 5 % того чи іншого показника, а мінімальне значення $\alpha_4 = 0$ означає, що даний дефект відсутній. Проміжні значення α_4 можуть означати, наприклад, що «дефект у вузлу двигуна» відповідає зменшенню того чи іншого показника на 1 % ($\alpha_4 = 0.25$) або на 3 % ($\alpha_4 = 0.75$).



Рисунок 5.1 – Модель застосування вирішального правила для нечіткої експертної системи (авторський доробок на основі [436, 437])

Даний приклад наочно демонструє, що діагностична нечітка експертна система легко виявляє наявність відмов в ГТД вертольотів. Найбільш складною задачею, розв'язуваною діагностичною експертної системою, є виявлення і локалізація передвідмовного стану розвитку прихованих дефектів в проточній частині двигуна із

застосуванням методик побудови вирішальних правил в базах знань діагностичної нечіткої експертної системи, моніторингу технічного стану ГТД вертольотів і їх підсистем на базі нечіткої експертної системи [444–446].

Оскільки в умовах льотної експлуатації повітряного судна (вертольоту) не є можливою реалізація даної експертної системи засобами Matlab, пропонується здійснювати її практичну реалізацію з використанням нечіткої нейронної мережі Ванга-Менделя (рис. Д.2), що базується на системі нечіткого виведення Такагі-Сугено-Канга.

Нечітка нейронна мережа Ванга-Менделя складається з чотирьох шарів. Перший шар виконує фаззифікацію вхідних змінних $x_j(j = 1, 2, ..., N)$, визначаючи для кожного *i*го правила виведення значення коефіцієнта належності $\mu_A^{(i)}(x_j)$ відповідно до застосовуваної функції фаззифікації. Це параметричний шар із параметрами ($c_j^{(i)}, \sigma_j^{(i)}, b_j^{(i)}$), що підлягають адаптації у процесі навчання. Другий шар виконує агрегування значень активації умови, визначаючи результуюче значення коефіцієнта належності $w_i = \mu_A^{(i)}(x)$ вектору *x*. Цей шар непараметричний. Третій (лінійний) шар здійснює агрегування *M* правил виведення (перший нейрон) та генерацію нормалізуючого сигналу (другий нейрон). Це параметричний шар, у якому адаптації підлягають лінійні ваги v_i для i = 1, 2, ..., M, інтерпретовані як центр c_k функції належності слідства *k*-го нечіткого правила виведення. Четвертий шар складається з одного вихідного нейрона та виконує нормалізацію, формуючи вихідний сигнал y(x). Це непараметричний прошарок. Таким чином, нейронна мережа реалізує функцію апроксимації виду:

$$y(x) = \frac{1}{\sum_{k=1}^{M} \left[\prod_{j=l}^{N} \mu_{A}^{(k)}(x_{j})\right]} \cdot \sum_{k=1}^{M} \nu_{k} \left[\prod_{j=1}^{N} \mu_{A}^{(k)}(x_{j})\right].$$
(5.7)

На початку навчання нечіткої нейронної мережі Ванга-Менделя підлягають адаптації параметри поділяються на дві групи: лінійних параметрів *p*_{ij} третього шару та параметрів нелінійної функції належності першого шару. Уточнення параметрів проводиться у два етапи.

На першому етапі при фіксації певних значень параметрів функції належності шляхом розв'язання системи лінійних рівнянь розраховуються лінійні параметри (у першому циклі – це значення, отримані результаті ініціалізації). При відомих значеннях функції належності залежність (5.7) подаються у лінійній формі:

$$y(x) = \sum_{i=1}^{M} w'_i \left(p_{i0} + \sum_{j=1}^{N} p_{ij} x_j \right);$$
(5.8)

де
$$w'_i = \frac{\prod_{j=1}^N \mu_A^{(i)}(x_j)}{\sum_{i=1}^M \left[\prod_{j=1}^N \mu_A^{(i)}(x_j)\right]} = \text{const для } i = 1, 2, ..., M.$$

При *р* навчальних вибірок (x(t), d(t)) (t = 1, 2, ..., p) і заміні вихідного сигналу мережі очікуваним значенням d(t) отримано систему з лінійних рівнянь виду:

$$\begin{bmatrix} w_{11}' & w_{11}'x_{1}^{(1)} & \dots & w_{11}'x_{N}^{(1)} & \dots & w_{1M}' & w_{1M}'x_{1}^{(1)} & \dots & w_{1M}'x_{N}^{(1)} \\ w_{21}' & w_{21}'x_{1}^{(2)} & \dots & w_{21}'x_{N}^{(2)} & \dots & w_{2M}' & w_{2M}'x_{1}^{(2)} & \dots & w_{2M}'x_{N}^{(2)} \\ \dots & & & & \dots & & \\ w_{p1}' & w_{p1}'x_{1}^{(p)} & \dots & w_{p1}'x_{N}^{(p)} & \dots & w_{pM}' & w_{pM}'x_{1}^{(p)} & \dots & w_{pM}'x_{N}^{(p)} \end{bmatrix} \cdot \begin{bmatrix} p_{10} \\ \dots \\ p_{1N} \\ \dots \\ p_{M0} \\ \dots \\ p_{M0} \\ \dots \\ p_{MN} \end{bmatrix} = \begin{bmatrix} d^{(1)} \\ d^{(2)} \\ \dots \\ d^{(p)} \end{bmatrix}; \quad (5.9)$$

де w'_{ti} позначає рівень активації (вага) умови *i*-го правила за умови пред'явлення *t*-го вхідного вектору *x*. Цей вираз подано у скороченій матричній формі:

$$\mathbf{A} \cdot \mathbf{p} = \mathbf{d}. \tag{5.10}$$

Розмірність матриці **A** складає $p \times (N + 1) \cdot M$, при цьому кількість рядків значно більша за кількість стовпців $(N + 1) \cdot M$. За допомогою псевдоінверсії матриці **A** рішення можна отримати за один крок:

$$\mathbf{p} = \mathbf{A}^+ \cdot \mathbf{d}. \tag{5.11}$$

де A^+ – псевдоінверсія матриці A, що полягає у проведенні декомпозиції SVD з подальшим скороченням її розмірності. На другому етапі після фіксації значень лінійних параметрів p_{ij} розраховуються фактичні вихідні сигнали y(t) мережі для t = 1, 2, ..., p, для чого використовується лінійна залежність

$$\mathbf{y} = \begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(p)} \end{bmatrix} = \mathbf{A} \cdot \mathbf{p}$$
(5.12)

і за ними – вектор помилки $\varepsilon = y - d$. Сигнали помилок направляються через підключену мережу до входу мережі (зворотне поширення) аж до першого шару, де можуть бути розраховані компоненти градієнта цільової функції щодо конкретних параметрів ($c_j^{(i)}$, $\sigma_j^{(i)}$, $b_j^{(i)}$). Після формування вектору градієнта параметри уточнюються з використанням одного з методів градієнтів навчання, наприклад, методу якнайшвидшого спуску. При застосуванні методу якнайшвидшого спуску відповідні вирази адаптації набувають вигляду:

$$c_{j}^{(i)}(t+1) = c_{j}^{(i)}(t) - \eta_{c} \frac{\partial E(t)}{\partial c_{j}^{(i)}}; \qquad (5.13)$$

$$\sigma_{j}^{(i)}(t+1) = \sigma_{j}^{(i)}(t) - \eta_{\sigma} \frac{\partial E(t)}{\partial \sigma_{j}^{(i)}}; \qquad (5.14)$$

$$b_{j}^{(i)}(t+1) = b_{j}^{(i)}(t) - \eta_{b} \frac{\partial E(t)}{\partial b_{j}^{(i)}}; \qquad (5.15)$$

де *n* – номер наступної ітерації.

Після уточнення нелінійних параметрів знову запускається адаптація лінійних параметрів функції Такагі-Сугено-Канга (перший етап) і нелінійних параметрів (другий етап). Цей цикл повторюється до стабілізації всіх параметрів процесу. Вирази (5.13) – (5.15) вимагають розрахунку градієнта цільової функції щодо параметрів приналежності. Остаточний вид цих виразів залежить як від визначення функції похибки на виході мережі, так і від форми функції приналежності. При використанні узагальненої функції

Гауса $\mu_A(x) = \frac{1}{1 + \left(\frac{x - c}{\sigma}\right)^{2b}}$, відповідні вирази градієнта цільової функції

 $E = \frac{1}{2} \sum_{i=1}^{p} \left(y(x^{(l)}) - d^{(l)} \right)^2$ для однієї пари навчальних даних (*x*, *d*) набувають значення:

$$\frac{\partial E}{\partial c_j^{(i)}} = \left(y(x) - d\right) \sum_{i=1}^{M} \left[p_{i0} + \sum_{j=1}^{N} p_{ij} x_j\right] \frac{\partial w_i'}{\partial c_j^{(i)}};$$
(5.16)

$$\frac{\partial E}{\partial \sigma_j^{(i)}} = \left(y(x) - d\right) \sum_{i=1}^{M} \left[p_{i0} + \sum_{j=1}^{N} p_{ij} x_j\right] \frac{\partial w'_i}{\partial \sigma_j^{(i)}};$$
(5.17)

$$\frac{\partial E}{\partial b_j^{(i)}} = \left(y(x) - d\right) \sum_{i=1}^{M} \left[p_{i0} + \sum_{j=1}^{N} p_{ij} x_j\right] \frac{\partial w_i'}{\partial b_j^{(i)}}.$$
(5.18)

Похідні $\frac{\partial w'_i}{\partial c_j^{(i)}}, \frac{\partial w'_i}{\partial \sigma_j^{(i)}}, \frac{\partial w'_i}{\partial b_j^{(i)}},$ визначені на основі залежностей w'_i і $\mu_A(x)$, подані

у вигляді

$$\frac{\partial w_{k}'}{\partial c_{j}^{(i)}} = \frac{\delta_{kl} m(x_{j}) - l(x_{j})}{\left[m(x_{j})\right]^{2}} \prod_{s=1,s\neq j}^{N} \left[\mu_{A}^{(i)}(x_{s})\right]^{2} \frac{\left[\frac{2b_{j}^{(i)}}{\sigma_{j}^{(i)}}\left(\frac{x_{j} - c_{j}^{(i)}}{\sigma_{j}^{(i)}}\right)^{2b_{j}^{(i)}}\right]^{2}}{\left[1 + \left(\frac{x_{j} - c_{j}^{(i)}}{\sigma_{j}^{(i)}}\right)^{2b_{j}^{(i)}}\right]^{2}};$$
(5.19)
$$\frac{\partial w_{k}'}{\partial \sigma_{j}^{(i)}} = \frac{\delta_{kl} m(x_{j}) - l(x_{j})}{\left[m(x_{j})\right]^{2}} \prod_{s=1,s\neq j}^{N} \left[\mu_{A}^{(i)}(x_{s})\right] \frac{\left[\frac{2b_{j}^{(i)}}{\sigma_{j}^{(i)}}\left(\frac{x_{j} - c_{j}^{(i)}}{\sigma_{j}^{(i)}}\right)^{2b_{j}^{(i)}}\right]^{2}}{\left[1 + \left(\frac{x_{j} - c_{j}^{(i)}}{\sigma_{j}^{(i)}}\right)^{2b_{j}^{(i)}}\right]^{2}};$$
(5.20)
$$\frac{\partial w_{k}'}{\partial b_{j}^{(i)}} = \frac{\delta_{kl} m(x_{j}) - l(x_{j})}{\left[m(x_{j})\right]^{2}} \prod_{s=1,s\neq j}^{N} \left[\mu_{A}^{(i)}(x_{s})\right] \frac{\left[-2\left(\frac{x_{j} - c_{j}^{(i)}}{\sigma_{j}^{(i)}}\right)^{2b_{j}^{(i)}}\right]^{2}}{\left[1 + \left(\frac{x_{j} - c_{j}^{(i)}}{\sigma_{j}^{(i)}}\right)^{2b_{j}^{(i)}}\right]^{2}};$$
(5.21)

для k = 1, 2, ..., M, де δ_{ki} – дельта Кронскера, $l(x_j) = \prod_{j=1}^N \mu_A^{(i)}(x_s), m(x_j) = \sum_{i=1}^M \left[\prod_{j=1}^N \mu_A^{(i)}(x_s)\right].$

При практичній реалізації гібридного методу навчання нечітких мереж

238

домінуючим фактором їх адаптації вважається перший етап, на якому ваги *p_{ij}* підбираються з використанням псевдоінверсії за один крок. Для врівноваження його впливу другий етап (підбір нелінійних параметрів градієнтним методом) багаторазово повторюється у кожному циклі.

Як приклад, у Matlab розроблена тестова версія нечіткої нейронної мережі Ванга-Менделя, що ілюструє зміну ступеня підвищення тиску в компресорі на 1 %, тобто $Y_1 = \pi_K^*$ (див. табл. Д.4) при постійній температурі навколишнього середовища, тобто $T_H = \text{const. Biдповідні вхідні змінні (в абсолютних одиницях) наведені в табл. Д.5.$

На рис. 5.2, а показано структуру згенерованої системи нечіткого логічного висновку, а на рис. 5.2, б – сформована система нечіткого логічного висновку.



Рисунок 5.2 – Нечітка нейронна мережа Ванга-Менделя: а – структура згенерованої системи нечіткого логічного висновку; б – створений редактор системи нечіткого логічного висновку (авторський доробок [446])

На рис. 5.3, а зображено графік залежності похибок навчання від кількості циклів навчання (за результатами навчання середня похибка становить лише приблизно 0,007 на 100 циклів), рис. 5.3, б – результати визначення ступеня підвищення тиску.



Рисунок 5.3 – Нечітка нейронна мережа Ванга-Менделя: а – графік залежності похибок навчання від кількості циклів навчання; б – результати визначення ступеня підвищення тиску в компресорі в графічному редакторі ANFIS (авторський доробок [446])

На рис. 5.4 наведено тестовий приклад поверхні класів технічного стану авіаційного двигуна ТВЗ-117, реалізований у програмному середовищі Matlab (Fuzzy-Logic Toolbox) на основі нечіткого правила «ЯКЩО ($\Delta T_C = Z$) $\wedge (\Delta P_G = MP) \wedge (\Delta P_{CT} = Z)$, ТО $Y_1 = \pi_K^*$ » with $T_H = \text{const.}$



Рисунок 5.4 – Класи поверхонь технічних станів авіаційного двигуна ТВЗ-117, реалізовані в Fuzzy-Logic Toolbox (авторський доробок [446])

Отже, точність моніторингу технічного стану ГТД вертольотів, залежить від

кількості правил і відсутності протиріч між ними. Застосування системи моніторингу на основі нечітких експертних систем дає змогу в режимі реального часу з високою точністю діагностувати технічний стан ГТД вертольотів (наприклад, ТВЗ-117), прогнозувати та запобігати виникнення аварійних режимів, тим самим, збільшуючи термін служби двигуна.

Розроблена нечітка експертна система містить єдину для класу авіаційних двигунів з вільною турбіною (ГТД вертольотів) базу експертних знань із можливим її розширенням задля діагностики інших дефектів двигуна на відміну від досліджень Жернакова С.В., в яких автор пропонує використовувати декілька експертних систем («C-PRIZ», «TILLShell 3.0»), для яких формуються окремі бази експертних знань, що обмежує їх можливості діагностики основних дефектів в основних вузлах авіаційного двигуна. Крім того, експертні системи «C-PRIZ», «TILLShell 3.0» [436, 437] реалізовані лише для класу авіаційних турбореактивних двигунів в умовах стендових випробувань, що унеможливлює їх використання для класу авіаційних двигунів з вільною турбіною (зокрема, авіаційного двигуна TB3-117) в умовах льотної експлуатації вертольоту.

5.3. Синтез алгоритмів нейро-нечіткого управління газотурбінних двигунів вертольотів з урахуванням забезпечення необхідної якості

Критерії якості роботи автоматичних регуляторів (AP) та їх компонентів варіюються залежно від функціонального призначення і режиму роботи системи, тоді як математичні моделі ГТД вертольотів залишаються складними для аналізу та синтезу регуляторів. Для забезпечення необхідної якості AP застосовуються методи інтелектуального аналізу даних, включаючи розпізнавання, оцінку технічного стану, інтелектуальне та нелінійне управління, а також теорію систем штучного інтелекту. Особливості взаємозалежностей між параметрами підсистем та їх вплив на показники, як-от перерегулювання чи час регулювання, ускладнюють побудову відповідних математичних моделей. Для вирішення цих завдань ефективним підходом є використання гібридних нечітких нейронних мереж (ГННМ), які поєднують переваги нечітких систем виведення та нейронних мереж. ГННМ забезпечують простоту інтерпретації через правила нечітких продукцій і зручність проектування завдяки методам нейронних мереж. Синтез алгоритмів нейро-нечіткого управління для забезпечення необхідної якості роботи АР здійснюється із застосуванням методів вибору параметрів системи на основі аналізу багатокритеріальних залежностей. При побудові ГННМ, що здійснює прийняття рішень щодо вибору параметрів системи для досягнення заданих показників перерегулювання, застосовується алгоритм, описаний у [240, 447]. Структура аналізованої системи нечіткого висновку представлена рис. Д.3, а розташування координуючої частини структурної схеми багатопараметричної АПУ ГТД вертольотів – на рис. Д.4.

Використання навченої ГННМ дозволяє налаштовувати параметри АПУ ГТД вертольотів з урахуванням важливих показників якості. Це забезпечує можливість корекції роботи системи в умовах зміненої експлуатації. В ГННМ логічні висновки формуються за допомогою нечіткої логіки, а відповідні функції належності налаштовуються за допомогою алгоритму навчання нейронної мережі з використанням зворотного поширення помилки [447, 448]. Іншими словами, опис ГТД вертольотів виконується за допомогою методів нечіткої логіки, а налаштування цієї моделі здійснюється за допомогою методів штучної нейронної мережі. Це забезпечує отримання більш точного відповідності досліджуваної моделі ГТД вертольотів. Основною підсистемою є система нечіткого логічного висновку з вихідною змінною дискретного типу (рис. Д.5).

Оскільки нечіткий логічний висновок – це апроксимація «входи – вихід» на основі лінгвістичних тверджень «ЯКЩО–ТО» та логічних операцій над нечіткими множинами [447], тобто є нейро-нечітким логічним висновком з дискретним виходом, то вектор вхідних сигналів $X = \{x_1, x_2, ..., x_n\}$ визначає набір термогазодинамічних параметрів двигуна, а значення вихідної змінної $y - d_j$ представляють клас вихідної змінної, пов'язані з еталонним зразком у базі нечітких знань. Основною умовою для АПУ ГТД вертольотів є наявність повного набору еталонних зразків вхідних сигналів у базі нечітких знань. Структура системи нечіткого висновку АПУ ГТД вертольотів включає загальні модулі для апарату нечіткої логіки. Для побудови нечіткої бази знань використано алгоритм нульового порядку Такагі-Сугено-Канга (TSK) [240, 447], де вихідна змінна є лінійною комбінацією значень вхідних параметрів:

Правило № 1: Якщо $x_1 = x_1^{emaлон_1}$ і $x_2 = x_2^{emaлoh_1}$ і ... і $x_n = x_n^{emaлoh_1}$, то $y = y_1$; Правило № 2: Якщо $x_1 = x_1^{emaлoh_2}$ і $x_2 = x_2^{emaлoh_2}$ і ... і $x_n = x_n^{emaлoh_2}$, то $y = y_2$; (5.22) Правило № *m*: Якщо $x_1 = x_1^{emaлoh_m}$ i $x_2 = x_2^{emaлoh_m}$ i ... i $x_n = x_n^{emaлoh_m}$, то $y = y_m$.

Для *j*-го правила в алгоритмі TSK значення визначається як *i*-та вихідна змінна, і це виражається виразом [240, 447]:

$$y = y_{j} + \sum_{i=1}^{n} a_{i}^{j} \cdot x_{i}^{emanoH_{j}}.$$
 (5.23)

Використання алгоритму нульового порядку TSK [240, 447] спрощує процедуру вибору параметрів системи нечіткого логічного висновку. Це звільняє від необхідності обчислення коефіцієнтів у виразі (5.23). Машина нечіткого логічного висновку (рис. 5.11), що розв'язує задачу класифікації, реалізована як відношення вхідних параметрів до значення еталонної вибірки з бази знань, і ця нечітка база знань визначена як [447]:

$$\left(\bigcap_{i=1}^{n} x_{i} = x_{i}^{emanoh_{j}}\right) \to y = y_{j};$$
(5.24)

де ∩ – операція; *t* – норма (логічне «І»).

Далі відповідно до [447] визначено ступінь належності класифікованого термогазодинамічного параметра еталонному зразку:

$$\mu_j(x) = \bigcap_i^n \mu_{ji}(x_i); \qquad (5.25)$$

де $\mu_{ji}(x_i)$ – ступінь належності *i*-го параметра класифікованого об'єкта до *j*-го параметра еталонного об'єкта.

В якості розв'язання задачі управління ГТД вертольотів відповідно до [447] обрано рішення з максимальним ступенем функції належності [240]:

$$y^{*} = \arg_{y_{1}, y_{2}, \dots, y_{k}} \max\left(\mu_{1}\left(x^{*}\right), \mu_{2}\left(x^{*}\right), \dots, \mu_{k}\left(x^{*}\right)\right).$$
(5.26)

Система нечіткого висновку поєднана з нейронною мережею, що призвело до отримання ГННМ типу ANFIS [240, 447]. Регульованими параметрами є параметри функцій належності – $\mu_{ji}(x_i)$ (блок-схема ГННМ наведена на рис. 5.5). Згідно з рис. 5.5 визначено, що ГННМ типу ANFIS складається з п'яти шарів:

1. Перший шар включає входи досліджуваного ГТД вертольоту.

2. Другий шар є набором нечітких термінів, що використовуються в базі нечітких

знань щодо ГТД вертольотів.



Рисунок 5.5 – Структурна схема ГННМ типу ANFIS (авторський доробок [240] на основі [447])

 Третій шар складасться з нечітких ліній зв'язку в базі знань (нечіткі правила).

4. Четвертий шар визначає класи вихідної змінної *d_j*.

 5. П'ятий шар відповідає за рівень дефаззифікації,

тобто за перетворення нечіткого виводу в чітке число.

Кількість одиниць (нейронів) у кожному шарі ГННМ визначається таким чином [240]:

1. У першому шарі вона залежить від кількості входів ГТД вертольоту.

2. У другому шарі вона визначається кількістю нечітких термінів вхідних змінних нечіткої бази знань.

3. У третьому шарі вона залежить від кількості лінійних з'єднань в нечіткій базі знань.

4. У четвертому шарі кількість нейронів визначається кількістю класів вихідної змінної *d_i*.

Функції блоків (аналогів нейронів у звичайній нейронній мережі) блок-схеми ГННМ відображені у [240].

Дана модель є нечіткою базою знань щодо ГТД вертольотів і складається з «грубої» конфігурації моделі, побудованої експертом, а також має механізм «тонкої» настройки – навчання ГННМ за допомогою методу, аналогічного алгоритму зворотного поширення помилки [240]. При прямому проходженні сигналів через мережу виникають вирази для визначення ступеня віднесеності значень вхідних сигналів до лінгвістичних термів нечіткої бази знань, що описує ГТД вертольоту [240, 447]:



Рисунок 5.13 – Графіки дзвоноподібної функції належності залежно від значень параметрів [447]

$$\mu^{jp}(x_i) = \frac{1}{\left(1 + \frac{x_i - b_i^{jp}}{c_i^{jp}}\right)^2}; \quad (5.27)$$

де *b* і *c* – параметри дзвоноподібної функції віднесеності, що має форму, зображену на рис. 5.6.

Аналітичний вираз дзвоноподібної функції належності згідно з [240, 447] має вигляд:

$$\mu^{T}(x) = \frac{1}{1 + \left(\frac{x - b}{c}\right)^{2}}.$$
(5.28)

Ступінь належності вихідного сигналу до відповідних класів вихідної змінної визначається за виразом [240, 447]:

$$\mu^{dj}(y) = \max\left\{w_{jp}\left(\min\mu^{jp}(x_i)\right)\right\}.$$
(5.2)

Значення моделі, що відповідає операції математичних очікувань в теорії випадкових процесів, обчислює вихідну змінну у за допомогою процедури дефазифікації за таким виразом:

$$y = \frac{y_0 \mu^{d_1}(y) + y_1 \mu^{d_2}(y) + \dots + y_{m-1} \mu^{d_m}(y)}{\mu^{d_1}(y) + \mu^{d_2}(y) + \dots + \mu^{d_m}(y)}.$$
(5.30)

Тоді значення похибки ГННМ визначається за виразом [240, 447]:

$$E_{t} = \frac{\left(y_{tm} - y_{t}\right)^{2}}{2}; \qquad (5.31)$$

де *y*_{tm} – вихідне значення моделі ГННМ на *i*-му кроці навчання; *y*_t – експериментальне вихідне значення термогазодинамічного параметра двигуна.

За аналогією з алгоритмом зворотного поширення помилок для нейронних мереж у нейро-нечіткій мережі, процедури зворотного відстеження виконуються в ГННМ у кожному сегменті для оцінки помилки. Визначення швидкості зміни помилки мережі при зміні значення вихідної змінної:

$$\frac{\partial E_t}{\partial y} = \varepsilon_1 = y_{tm} - y_t. \tag{5.32}$$

На останньому етапі алгоритму навчання нечіткої нейронної мережі параметри ГННМ змінюються подібно до методу зворотного поширення помилок для нейронних мереж [240, 447]:

$$w_{jp}(t+1) = w_{jp}(t) - \eta \frac{\partial E_t}{\partial w_{jp}(t)}; \qquad (5.33)$$

$$c_i^{jp}(t+1) = c_i^{jp}(t) - \eta \frac{\partial E_t}{\partial c_i^{jp}}; \qquad (5.34)$$

$$b_i^{jp}(t+1) = b_i^{jp}(t) - \eta \frac{\partial E_t}{\partial b_i^{jp}}.$$
(5.35)

Під час моніторингу ГТД вертольотів у режимі польоту необхідно представити його термогазодинамічні параметри, використовуючи вхідні параметри нечіткої бази знань – $x_1, x_2, ..., x_n$, та можливі класи вихідних змінних (еталонні значення) – $y_1, y_2, ..., y_m$. Використання ГННМ передбачає, що вхідними змінними (лінгвістичними термінами) є $n_{TK}, n_{CB}, T_{\Gamma}^*$. Після проведення експериментів з розробки структури ГННМ була отримана діаграма ГННМ, що відображена на рис. 5.7, де:



Рисунок 5.7 – Структура ГННМ типу ANFIS (авторський доробок [240], на основі [447])

1. Шар 1 – вхідні змінні, параметри яких чітко визначають значення термогазодинамічних параметрів ГТД вертольотів (*n*_{*TK*}, *n*_{*CB*}, *T*^{*}_{*Г*}).

 Шар 2 – три терми для кожного вхідного параметра системи моніторингу.

3. Шар 3 – три правила нечіткої бази знань.

4. Шар 4 – три класи вихідних змінних.

5. Шар 5 – результат дефазифікації.

База нечітких знань визначається

трьома правилами:

Правило № 1: якщо n_{TK} приблизно 0,905 і T_{Γ}^* приблизно 0,900 і n_{CB} приблизно 0,900, то $y = y_1$;

Правило № 2: якщо n_{TK} приблизно 0,950 і T_{Γ}^* приблизно 0,995 і n_{CB} приблизно 0,900, то $y = y_2$; Правило № 3: якщо n_{TK} приблизно 0,900 і T_{Γ}^* приблизно 0,900 і n_{CB} приблизно 0,995, то $y = y_3$; де клас вихідної змінної у представлений такими значеннями: y_1 – перевизначення параметра n_{TK} ; y_2 – перевизначення параметра T_{Γ}^* ; y_3 – перевизначення параметра n_{CB} .

Лінгвістичні терміни, відібрані експертним методом у нечіткій базі знань, найповніше передають суть термогазодинамічних параметрів ГТД вертольотів, що реєструються на борту вертольотів. З одного боку, значення складових, таких як n_{TK} , n_{CB} , T_{Γ}^* , у будь-який момент часу є конкретними числами. Проте, з іншого боку, ці значення можуть змінюватися випадковим чином (необмежено) через помилки, умови польоту, робочий стан двигуна тощо. Суть лінгвістичного терміну «приблизно» на найбільш повний спосіб відображає дзвоноподібні функції належності, які також були відібрані експертним методом серед найпоширеніших функцій належності: трикутної, трапецієподібної та дзвоноподібної. Дзвоноподібні функції належності для нечіткої бази знань, визначеної зазначеними правилами, були обрані для цієї задачі використання ГННМ і представлені на рис. 5.8.



Рисунок 5.8 – Діаграма дзвоноподібної функції приналежності до навчання ГННМ (авторський доробок [240] на основі [447])

Для точного розв'язання задачі синтезу моделі реконфігурованої модифікованої закритої бортової АПУ ГТД вертольотів (рис. 5.9) застосовано методи навчання ГННМ (5.33) - (5.35), аналогічні тим, що використовуються в нейронних мережах, за аналогією із [447]. Після проведення навчання розробленої ГННМ відповідно до (5.33) - (5.35) отримано об'єктну модель, параметри *b* і *c* функцій належності, а також ваги нечітких правил *w* якої, представлені в табл. Д.6.

Після процесу навчання ГННМ на рис. 5.16 та в табл. 5.7 представлені діаграми фу-

нкцій належності та параметрів дзвоноподібних функцій належності, де с вказує на



Рисунок 5.9 – Розроблена модель реконфігурованої модифікованої закритої бортової АПУ ГТД вертольотів (авторський доробок [240] на основі [447])



Рисунок 5.10 – Діаграми результуючої дзвоноподібної функції приналежності після навчання ГННМ (авторський доробок [240] на основі [447])

коефіцієнт згортання дзвоноподібних функцій приналежності, b – максимальні координати цих дзвоноподібних функцій приналежності. Згідно з [447], в процесі навчання мережі ГННМ були отримані нові значення параметрів дзвоноподібних функцій належності (табл. Д.б, рис. 5.10), а також ваги правил нечіткої бази знань

(табл. Д.4), що відповідає етапу «тонкого» налаштування нечіткої моделі реконфігурованої модифікованої закритої бортової АПУ ГТД вертольотів.

Для досягнення стійкої роботи реконфігурованої модифікованої закритої бортової АПУ ГТД вертольотів є виконання заданих показників якості перехідних процесів [240]. Залежність величин, що розглядаються, від параметрів синтезованої системи відповідно до [240] подано у вигляді системи рівнянь:

$$\begin{cases}
q_1(\{k_1\},\{\tau_1\},\{T_1\}) = f_1(\{k_1\},\{\tau_1\},\{T_1\}); \\
q_2(\{k_2\},\{\tau_2\},\{T_2\}) = f_2(\{k_2\},\{\tau_2\},\{T_2\}); \\
\dots \\
q_i(\{k_i\},\{\tau_i\},\{T_i\}) = f_i(\{k_i\},\{\tau_i\},\{T_i\});
\end{cases}$$
(5.36)

де $q_1, ..., q_i$ – показники якості перехідних процесів, що розглядаються; $\{k_i\}, \{\tau_i\}, \{T_i\}$ – змінні набори параметрів системи (коефіцієнти підсилення, постійні часу тощо); $f_1(\bullet), ..., f_i(\bullet)$ – функції, що виражають залежність показників якості системи від параметрів синтезованих регуляторів.

Відповідно до [447] для визначення перерегулювання та час регулювання підсистем як основних показників якості систем система рівнянь (5.36) має вигляд:

$$\begin{cases} t_{per1} = f_1(\{k_1\}, \{\tau_1\}, \{T_1\}); \\ \sigma_1 = g_1(\{k_1\}, \{\tau_1\}, \{T_1\}); \\ \dots \\ t_{per_i} = f_i(\{k_i\}, \{\tau_i\}, \{T_i\}); \\ \sigma_i = g_i(\{k_i\}, \{\tau_i\}, \{T_i\}); \end{cases}$$
(5.37)

де $\sigma_1, ..., \sigma_i$ – перерегулювання, $t_{per1}, ..., t_{per_i}$ – час управління перехідними процесами підсистем.

Для розв'язання задачі забезпечення заданих показників якості в одному з режимів роботи ГТД вертольотів (наприклад, у номінальному режимі – І крейсерському режимі) вимоги до показників перехідних процесів задаються у такому вигляді: { t_{pez} } = {1,5; 1,5}, { σ_{pez} } = {0,1; 0,1}.

У результаті моделювання динаміки зміни термогазодинамічних параметрів ГТД вертольотів за навчальною вибіркою (n_{TK} , n_{CB} , T_{Γ}^*) в залежності від модельного часу отримано результати, представлені на рис. 5.11, де а – зміна параметра n_{TK} , б – зміна параметра T_{Γ}^* , в – зміна параметра n_{CB} , при цьому крива 1 відповідає експериментальним значенням термогазодинамічних параметрів ГТД вертольотів, зареєстрованих на борту вертольоту, крива 2 відповідає моделі (скориговані з використанням реконфігурованої модифікованої закритої бортової АПУ ГТД вертольотів) значення термогазодинамічних параметрів ГТД вертольотів) значення термогазодинамічних



Рисунок 5.11 – Результати моделювання динаміки зміни термогазодинамічних параметрів ГТД вертольотів (авторський доробок [240])



Значення зміни залишків після контролю $\varepsilon(t) = x_1(t) + x_2(t) + x_3(t) - y(t)$ не перевищує допустимого відхилення термогазодинамічних параметрів ГТД вертольотів, що становить 0,004. Динаміка зміни значень термогазодинамічних параметрів ГТД вертольотів після контролю $\varepsilon(t)$, наведена на рис. 5.12, свідчить про стійкість керування, тобто про тенденцію наближення показника $\varepsilon(t)$ до нуля [240].

На рис. 5.13 наведено результати

розрахунку параметра витрати палива G_T для точного (модифікована закрита бортова АПУ ГТД вертольотів [240]), нечіткого та нейро-нечіткого управління (реконфігурована модифікована закрита бортова АПУ ГТД вертольотів) відповідно для заданих значень термогазодинамічних параметрів АПУ ГТД вертольотів згідно зі ступінчастою зміною необхідної витрати палива G_T . На рис. 5.13 позначені: 1 – еталонне значення витрати палива G_T (ступінчата дія), 2 – реальне значення витрати палива G_T . Для порівняння якості точного, нечіткого та нейро-нечіткого управління було накладено графіки перехідних процесів для цих режимів, що наведено на рис. 5.14.



Рисунок 5.13 – Результати визначення витрати палива: а – точне управління; б – нечітке управління; в – нейро-нечітке управління (авторський доробок [240])



Рисунок 5.14 – Графіки перехідного процесу точного, нечіткого та нейро-нечіткого управління: 1 – еталонне значення, 2 – точне управління, 3 – нечітке управління, 4 – нейро-нечітке управління (авторська розробка) (авторський доробок [240])

Як видно з наведених графіків перехідних процесів, якість управління (тривалість перехідного процесу та максимальне відхилення регульованої величини) для розглянутих типів управління (чіткого, нечіткого та нейро-нечіткого) є приблизно однаковою. Як видно з рис. 5.13 і 5.14, реконфігурована модифікована закрита бортова АПУ ГТД вертольотів має задані показники якості t_{per} , σ_{per} , тобто перерегулювання та час контролю задовольняють вимогам.

Результати порівняльного аналізу розв'язання задачі управління ГТД вертольотів (на прикладі визначення витрати палива) з використанням різних архітектур нейронних мереж представлені в табл. Д.7, а результати визначення похибок 1-го та 2-го роду за основними термогазодинамічними параметрами ГТД вертольотів – в табл. Д.8.

Порівняльний аналіз отриманих результатів (табл. Д.7 і Д.8) підтверджує, що розроблена реконфігурована модифікована закрита бортова АПУ ГТД вертольотів забезпечує мінімальну похибку при розв'язанні задачі управління ГТД вертольотів в процесі експлуатації. Зазначається, що розроблена реконфігурована модифікована закрита бортова АПУ ГТД вертольотів дістала подальшого розвитку у [449]. Розроблена у [449] АПУ ГТД вертольотів включає комплекс, що складається з досліджуваного об'єкта, регулятора, емулятора, компенсатора та блока спостерігача. Кожен компонент цього комплексу використовує шестишарову гібридну нейро-нечітку мережу типу AFNN, яка базується на нечіткому виведенні за методом Сугено та функціях належності дзвоноподібної форми для нечітких змінних.

На основі дослідження перехідних процесів є критичним для забезпечення оптимальної роботи та високої ефективності ГТД вертольотів у різних умовах експлуатації критичним є моделювання витрати палива ГТД вертольотів за математичним і програмним забезпеченням. Необхідність моделювання витрати палива ГТД вертольотів за математичною моделлю на основі дослідження перехідних процесів визначається декількома ключовими аспектами, наведеними в табл. Д.9.

5.4. Розробка методу нейро-нечіткого моніторингу витрати палива газотурбінних двигунів вертольотів

Моніторинг витрати палива ГТД вертольотів на основі дослідження перехідних процесів є необхідним і важливим інструментом їх розвитку, оптимізації та підвищення продуктивності. У [450–452] ця задача розв'язана за допомогою адаптивної нейро-нечіткої системи типу ANFIS, що використовує систему нечіткого виведення Сугено в
структурі п'ятирівневої нейронної мережі з прямим поширенням сигналу (рис. Д.6). Початковий рівень цієї мережі охоплює лінгвістичні терміни, пов'язані з вхідними змінними, як поточними значеннями термогазодинамічних параметрів ГТД вертольотів, так і їх затримані значення. Варто зазначити, що за своєю структурою розроблена у [450– 452] адаптивна нейро-нечітка система типу ANFIS є аналогом реконфігурованої модифікованої закритої бортової АПУ ГТД вертольотів.

Для оцінювання ефективності використання нейро-нечітких методів, моделей і алгоритмів у сфері інтелектуального моделювання витратою палива ГТД вертольотів використана навчальна вибірка (табл. Д.10), що містила дані, пов'язані із витратою повітря в камері згоряння, питомою потужністю двигуна, а також відношенням витрати палива та повітря у камері згоряння [204]. Ці дані були розраховані (в абсолютних одиницях) за допомогою нейромережевої моделі ГТД вертольотів відповідно до [204].

Для розв'язання поставленої задачі моніторингу витрати палива ГТД вертольотів нейро-нечітка мережа типу ANFIS (реконфігурована модифікована закрита бортова АПУ ГТД вертольотів) навчена за допомогою алгоритму зворотного поширення помилки (рис. 5.15, а). Після 2200 епох навчання похибка навчання становила $\delta = 5,86 \cdot 10^{-4}$. За результатами навчання гібридним методом з паралельними обчисленнями [452] (рис. 5.15, б) похибка навчання через 20 епох склала $\delta = 1,29 \cdot 10^{-4}$, тобто в 4,53 рази менше, ніж при навчанні за алгоритмом зворотного поширення.



Рисунок 5.15 – Результати навчання нейро-нечіткої мережі: а – допомогою алгоритму зворотного поширення помилок; б – гібридним методом (авторський доробок [451, 452])

На рис. 5.22 показано, що гібридний метод потребує в 105 разів менше епох для навчання мережі порівняно з алгоритмом зворотного поширення помилки. Для розв'язання задачі нейро-нечіткого моделювання витрати палива ГТД вертольотів важливе значення має вибір функції належності.

При розв'язанні задачі нейро-нечіткого моделювання витратою палива ГТД вертольотів найменшу похибку навчання дає двостороння функція Гауса (рис. Д.7 [451]), з δ = 1,29 · 10⁻⁴ і N = 20 епох. Це порівняно з симетричною функцією приналежності Гауса, використання якої призводить до похибки δ = 3,67 · 10⁻⁴ з N = 20 епохами, і трапецієподібною функцією приналежності, яка дає найбільшу похибку навчання δ = 1,86 · 10⁻² з N= 45 епохами.

У табл. Д.11 представлені результати оцінювання впливу кількості функцій належності на показники ефективності розв'язуваної задачі [451]. Дослідження впливу кількості затриманих входів на показники ефективності моделювання [451] показало (табл. Д.12), що оптимальні результати досягаються при 2...3 затриманих входах.

Для практичної реалізації розв'язання задачі нейро-нечіткого моделювання витрати палива ГТД вертольотів створено програмний засіб (рис. Д.8) для генерації за заданими значеннями матриці бази знань для нечіткого регулятора [451]. Для завантаження бази знань, яка необхідна для роботи нейро-нечіткої системи (рис. Д.8) використано команду fuzzy2=readfis('fuzzy2777'). Ця програма працює таким чином:

- викликається збережена матриця елементів;

– визначаються найбільші за модулем значення кожного з входів і виходів;

– діапазон значень (від –max до +max) кожного входу та виходу розбитий на терміни з кроком, який задає користувач;

 відповідно до приналежності значень змінних (з результуючої матриці) на кожному кроці формуються правила «вхід–вихід» до того чи іншого терму;

– правила комбінуються, якщо вихід не змінює своїх значень при зміні входів;

- однакові правила також комбінуються;

– після виконання цього методу формується база правил.

У [451] прийнято, що *X*₁ – витрата повітря в камері згоряння; *X*₂ – питома потужність двигуна; *X*₃ – відношення витрат палива і повітря в камері згоряння. На рис. 5.16

показано криві відгуку блоку FIS для генерації змінних X_1 , X_2 , X_3 . Зведена діаграма вихідних даних і результатів нейро-нечіткого моніторингу витрати палива ГТД вертольотів, а також його похибки наведені на рис. 5.16. На рис. 5.17 наведено діаграми розкиду вихідних параметрів: витрати палива на навчальній вибірці в інтервалі від 0 до 5 секунд, витрати палива на тестовій вибірці в інтервалі від 0 до 5 секунд; результуюча похибка навчання нейро-нечіткої системи в інтервалі від 0 до 5 секунд відповідно.



Рисунок 5.16 – Результати: а – результат перевірки моделі на навчальній (1) і тесто-



Рисунок 5.17 – Діаграма розсіювання: а – даних на навчальній вибірці; б – даних на тестовій вибірці; в – даних нейро-нечіткої моделі (авторський доробок [451])

Також в рамках розв'язання задачі нейро-нечіткого моделювання витрати палива ГТД вертольотів отримано дані щодо цього параметру на різних режимах роботи авіаційного двигуна ТВЗ-117 при H = 0, V = 0. Вихідні дані для розрахунку взято з [453], де також наведено паспортні дані двигуна, з якими порівнювалися результати розрахунку. Результати розрахунку та паспортні дані зведені в табл. Д.13 та представлені на рис. Д.9 (крива 1 – розрахункові дані, крива 2 – паспортні дані, крива 3 – розрахункові дані, отримані в [453]).

Адекватність нейро-нечіткої моделі визначається її точністю та узгодженістю з експериментальними даними [453]. З точки зору узгодженості можна стверджувати, що створена нейро-нечітка модель витрати палива не суперечить паспортним даним, оскільки характер розрахункової залежності та залежності, побудованої за паспортними даними, збігаються. З точки зору точності можна відзначити наявність систематичної похибки, причини якої будуть досліджені далі.

Оцінено точність алгоритму нейро-нечіткого моніторингу витрати палива ГТД вертольотів у порівнянні з іншими методами машинного навчання, включаючи Random Forest, ExtraTree та Multilayer Perceptron Classifier (MLP) (табл. Д.14).

Загальна продуктивність нейро-нечіткої системи ANFIS продемонструвала гідні результати щодо можливості узагальнення порівняно з MLP. Однак алгоритм ExtraTree продемонстрував перевагу з точки зору F1-міри, враховуючи його ансамблеву природу. Результати деталізації похибок 1-го і 2-го роду щодо витрати палива ГТД вертольотів наведені в табл. Д.15.

Порівняльний аналіз отриманих результатів (табл. Д.15) стверджує, що розроблена нейро-нечітка мережа для розв'язання задачі моніторингу витрати палива ГТД вертольотів дозволяє досягти мінімальної похибки під час польоту вертольоту.

Результати порівняння отриманих результатів витрати палива двигуна ТВЗ-117 з паспортними даними, а також з дослідженнями, проведеними у [453] (табл. Д.13) представлені в табл. Д.16.

З табл. Д.16 визначено, що розроблена нейро-нечітка система найбільш точно визначає витрату палива авіаційного двигуна ТВЗ-117 на різних режимах його роботи. Отже, застосування нейро-нечітких мереж для моделювання витрати палива ГТД вертольотів у контексті дослідження перехідних процесів виявилося успішним, що підтверджує їхню ефективність та потенціал у покращенні динаміки та оптимізації функціонування ГТД вертольотів. 5.5. Розробка методу нейро-нечіткого моделювання динамічного коефіцієнта корисної дії газотурбінних двигунів вертольотів

Розробка методу нейро-нечіткого моделювання динамічного коефіцієнта корисної дії (ККД) газотурбінних двигунів (ГТД) вертольотів є актуальним завданням сучасної авіаційної техніки. Цей метод відіграє ключову роль у вирішенні завдань оптимізації роботи двигунів, що сприяє підвищенню ефективності, зменшенню витрат палива та покращенню загальної продуктивності вертольотів. Незважаючи на значні досягнення у сфері нейромережевих методів моніторингу ГТД, аналіз наукової літератури [219–231] свідчить про відсутність моделей і методів, які забезпечують моніторинг динаміки зміни ККД компресора двигуна. Використання нейронних мереж є ефективним засобом вирішення цього завдання, проте вибір оптимальної архітектури нейронної мережі, яка відповідала б вимогам до точності моніторингу та контролю ККД компресора, є окремою науковою проблемою, що залежить від специфіки поставленої задачі. Розв'язання цієї задачі включає аналіз вхідних даних та їх попередню обробку, визначено значення G_{Bnn} і п_{тКпр}, визначення ККД, і класифікація стану двигуна відповідно до значень ККД. Ці кроки тісно пов'язані та можуть бути функціонально розділені, що вимагає розробки відповідних методів та інструментів на базі різних моделей нейронних мереж. Схематично цей ланцюг виглядає як: задача — функції — методи (засоби) — реалізація.

При розв'язанні цієї задачі проведено низку експериментів, що показали перспективи вибору ансамблю нейронних мереж (РБФ – Персептрон – Нейро-нечіткий класифікатор), які є ефективними особливо в задачах великої розмірності [454]. Загальна декомпозиція нейромережевої моделі на окремі складові з повною параметричною «прив'язкою» показує, що вибір найефективнішої архітектури нейромережевого ансамблю матиме такий вигляд, представлений на рис. 5.18, де нейронні мережі HM_1 і HM_2 – це РБФ мережі, які відповідають за аналіз та попередню обробку вхідних даних та обчислення значень G_{Bnp} і n_{TKnp} ; HM_3 – це багатошаровий персептрон, відповідальний визначення значень η_C ; HM_4 – це нейро-нечіткий класифікатор (ANFIS), який відповідає за класифікацію (кластеризацію) стану двигуна згідно з значеннями η_C .



Рисунок 5.18 – Нейромережева модель моніторингу динаміки зміни ККД компресора ГТД вертольотів (авторський доробок [454])

Відповідно до [204], ККД компресора ГТД вертольотів є функціональною залежні-

стю виду $\eta_{K} = \eta_{K} \left(G_{Bnp}, n_{TKnp} \right)$, де $n_{TKnp} = n_{TK} \cdot \sqrt{\frac{288}{T_{H}^{*}}}$ – приведена частота обертів ротора

турбокомпресора; $G_{Bnp} = \frac{G_B \cdot 760}{P_H^*} \cdot \sqrt{\frac{288}{T_H^*}}$ – приведена витрата повітря через компресор;

$$T_{H}^{*} = T_{H} \left(1 + \frac{k-1}{2} M^{2} \right)$$
 і $P_{H}^{*} = P_{H} \sigma_{ex} \left(1 + \frac{k-1}{2} M^{2} \right)^{\frac{k}{k-1}}$ – загальмовані значення цих параме-

трів на даній висоті польоту; k – показник адіабати; M – число Маха польоту; σ_{ex} – коефіцієнт відновлення повного тиску у вхідному пристрої.

Вибір архітектури РБФ в якості нейронної мережі, що розпізнає, по відношенню до нейронної мережі персептрона більш кращий, оскільки визначення вагових коефіцієнтів в мережі РБФ здійснюється швидше і точніше, ніж параметрів персептрона за рахунок того, що використання градієнтних методів для налаштування параметрів останніх призводить лише до досягненню локального мінімуму. Архітектура мережі RBF є двошаровою мережею, в якій перший шар виконує задане нелінійне перетворення без використання параметрів так, що простір входів відображається в новий простір. У цьому випадку для 7 вхідних параметрів ГТД вертольотів (табл. Д.17) оптимальною з точки зору

декомпозиції параметрів є використання двох нейронних мереж архітектури RBF за кількістю параметрів на вході (вектор стану) відповідно до параметрів механізму (4–6 залежно від виразу для обчислення значень G_{Bnp} і n_{TKnp}) і одного вихідного параметра (значення G_{Bnp} і n_{TKnp}). В якості алгоритму навчання для нейронної мережі RBF використано модифікований градієнт навчання мереж RBF, описаний у [269].

Нейронна мережа архітектури персептрон у гібридному ансамблі виконує функції концентруючого поля, що поєднує виходи РБФ мереж – 2 виходи (значення G_{Bnp} і n_{TKnp}). У процесі експерименту з даної нейронної мережі (після процесу контрастування) мережа мала таку архітектуру: тришаровий персептрон, у якому перший вхідний шар має 2 нейрони, другий прихований шар – 4 нейрони, третій вихідний шар – 1 нейрони (значення η_K). За рахунок уточнення вагових коефіцієнтів відбувається точне обчислення значень η_K . В якості активаційної функції нейронів для тришарового персептрона широкого поширення набула сигмоїдна функція активації нейрона виду, яка застосована у



Рисунок 5.19 – Графік залежності помилки навчання від складності персептрону (авторський доробок [454])

[454]. З метою визначення оптимальної кількості нейронів у прихованому шарі побудовано експериментальну залежність E = f(N), наведену на рис. 5.19, де E – помилка навчання нейронної мережі; N – кількість нейронів у прихованому шарі (передбачається, що кількість нейронів у вхідному шарі – 2, у вихідно му шарі – 1). Як видно із рис. 5.29, при 4 нейронів у прихованому шарі досягається найменша помилка навчання нейронної мережі, тобто оптимальною структурою ней-

ронної мережі є 2–4–1 [454]. У табл. Д.18 наведено порівняльний аналіз результатів навчання розробленого тришарового персептрона, на підставі якого як алгоритм навчання обраний алгоритм зворотного поширення помилки, який забезпечує високу швидкість збіжності та точність процесу навчання.

Процедура визначення технічного стану ГТД вертольотів шляхом класифікації значень динамічного ККД компресора (η_K) ґрунтується на використанні нечітких гібридних мереж ANFIS (рис. 5.30). ANFIS є п'ятишаровою нейронною мережею прямого поширення, що використовує алгоритм нечіткого виведення Sugeno.

Вхідні параметри мережі ANFIS представлені індикативно-аналітичними показниками, що описують значення η_K , а виходи визначають поточний стан двигуна. Нейронечіткий класифікатор використовується для формування трьох класів і складається з



трьох шарів. Перший шар отримує розраховані значення динамічного ККД *η_K*. Другий шар визначає ступінь приналежності до нечітких множин («низький», «середній», «високий») за допомогою двосторонньої функції Гауса. Третій шар реалізує нечіткі логічні операції «І» та «АБО» на основі визначених антецедентів. Четвертий шар агрегує результати виконання нечітких

Рисунок 5.20 – Структура нейро-нечіткого класифікатора (авторський доробок [454])

продукційних правил, а п'ятий шар порівнює отримані значення функцій належності з певними групами. Значення η_K визначається належністю до конкретної групи, де функція належності має найбільше значення, як показано на рис. 5.20.

Проведено нечіткий кластерний аналіз обчислених значень динамічного ККД компресора η_K , що дозволяє віднести однакові значення η_K до різних груп із відповідними ступенями належності. Алгоритм нечіткого кластерного аналізу використовується для групування нечітких даних і формування груп, прототипи яких визначаються точками в просторі даних.

Відповідно до [204] у [454] прийнято, що значення η_K , які групуються, представлені *n*-вимірними векторами $\eta_{K_k} = \left[\eta_{K_k}, \eta_{K_k}, \eta_{K_k}\right]^T$, $\eta_{K_k} \in R_n$, k = 1...M, які містять числові значення, що характеризують ГТД вертольотів. Набір *M* векторів утворює $n \times M$ матрицю **H**_C. Для заданого набору з *n* вхідних векторів η_{K_k} і *c* різних кластерів з центром v_i передбачається, що будь-який η_{K_k} належить будь-якому c_i з членством $\mu_{ik} \in [0,1]$, де *i* – номер кластера, *k* – номер вхідного вектору. Основна ідея цього алгоритму полягає в мінімізації визначеного критерію [454]:

$$I(H_{C},U,V) = \sum_{i=1}^{c} \sum_{k=1}^{M} (\mu_{ik})^{m} \cdot \|\eta_{K_{k}} - v_{i}\|_{A}^{2};$$
(5.38)

причому $U = [\mu_{il}] \in \mathbb{Z}_2$ є матрицею декомпозиції множини **H**_C; матриця $V = [v_1, ..., v_c]$ є центрами кластерів, що мають бути визначені в результаті виконання алгоритму; $\mu_k \in \mathbb{R}_n$, i = 1...c – коефіцієнт, що характеризує ступінь нечіткості утворених груп д аних. Віддаленість вектору η_{K_k} від центру групи v_i визначається через стандартну Евклідову норму:

$$D_{ik}^{2} \cdot A = \left\| \eta_{K_{k}} - v_{i} \right\|_{A}^{2} = \left(\eta_{K_{k}} - v_{i} \right)^{T} \cdot A \cdot \left(\eta_{K_{k}} - v_{i} \right).$$
(5.39)



Рисунок 5.21 – Результати кластерного аналізу значень ефективності (критичної та нормальної) у середовищі МАТLAB (авторський доробок [454]) Для виконання алгоритму на деякій кількості даних \mathbf{H}_{C} необхідно вибрати кількість груп *c*, ступінь нечіткості *m*, параметр ε в критерії зупинки алгоритму, а також випадковим чином ініціювати матрицю $U(0) \in \mathbb{Z}_{2}$ і вектор прототипів групи V(0).

На рис. 5.21 показано результати кластерного аналізу розрахованих значень η_K (критичного та нормального) цим методом у середовищі MATLAB, з яких видно, що дані згруповані у два кластери.

На рис. 5.22 показано результати моделювання нечіткого логічного виведення в середовищі MatLab за допомогою пакета Fuzzy Logic Toolbox. У табл. Д.19 наведено опис вхідної логічної змінної $\eta_{K,k}$ та вихідної – значення зміни ККД компресора двигуна.



Рисунок 5.22 – Результати: а – результати навчання нейро-нечіткого класифікатора гібридним методом; б – візуалізація поверхні нечіткого виведення моделі зміни ККД (авторський доробок [454])

На рис. 5.23, а зображено графік вибірки навчальних даних, на яких моделюється постійне значення ККД компресора двигуна, що є нормальним для здійснення (продовження) польоту гелікоптера. На рис. 5.33, б зображено графік вибірки навчальних даних, на яких моделюється падіння ККД компресора двигуна на 1...3 %, після чого значення ККД компресора двигуна носить постійний характер, що не є критичним для здійснення (продовження) польоту вертольоту. На рис. 5.33, в зображено графік вибірки навчальних даних, на яких моделюється падіння ких моделюється постійний характер, що не є критичним для здійснення (продовження) польоту вертольоту. На рис. 5.33, в зображено графік вибірки навчальних даних, на яких моделюється поступове падіння ККД компресора двигуна на 10 %, що є критичним для здійснення (продовження) польоту вертольоту.



Рисунок 5.23 – Графік класифікації зміни динамічного ККД компресора ГТД вертольотів (авторський доробок [454])

Результати тестування нейромережевого ансамблю наведено в табл. Д.20 [454]. Ефективність нейромережевого ансамблю в ідентифікації тесту оцінюється відсотковим співвідношенням між кількістю правильних результатів тесту та загальною кількістю тестових даних. Чим вищий відсоток, тим вище ефективність нейронних мереж у цьому тесті. Дане дослідження характеризує ефективність ансамблю нейронних мереж, тобто ефективність класифікації. СКВ характеризує точність результатів експериментів з ансамблем нейронних мереж. Чим менша ця похибка, тим вища точність ансамблю нейронних мереж на цьому тесті, тобто дослідження характеризує точність класифікації.

Порівняльний аналіз точності класичного та нейро-нечіткого методів класифікації відмов наведено в табл. Д.21, де наведено ймовірності помилок 1-го та 2-го роду при класифікації (кластеризації) робочого стану ГТД вертольотів за значеннями динамічного ККД компресора. Дані, наведені в табл. 5.23, свідчать про те, що інтелектуальні методи вирішують задачу ефективніше та результативніше. Для аналізу стійкості нейронних мереж до змін вхідних даних (табл. Д.21) було додано адитивний шум по відношенню до поточного значення кожного з параметрів у вигляді білого шуму з нульовим математичним сподіванням і $\sigma_i = \pm 0,01$ (табл. Д.22).

Отже, проведений порівняльний аналіз показує, що нейронні мережі є стійкими до зовнішніх збурень, при цьому помилки 1-го і 2-го роду суттєво не збільшуються.

5.6. Розробка нейро-нечіткого регулятора частоти обертів несучого гвинта вертольотів

Розробка регулятора частоти обертів несучого гвинта вертольоту є критичним етапом у вдосконаленні АПУ ГТД вертольотів. Гібридні нейро-нечіткі мережі, що застосовуються для реконфігурації АПУ ГТД вертольотів та моделювання витрати палива та динамічного коефіцієнта корисної дії двигунів, можуть ефективно використовуватися і для оптимізації регулятора частоти обертів несучого гвинта. Це дозволить покращити ефективність як вертольоту в цілому, так і окремо його двигуна, забезпечуючи точність та стабільність роботи при різних умовах експлуатації. Переваги такого дослідження включають зменшення споживання палива, підвищення надійності та безпеки польоту, а також збільшення маневреності вертольотів. Слизавета Чичерова здійснила низку досліджень зі створення методів регулювання для підвищення стійкості АПУ ГТД вертольотів та усунення коливань. Серед використаних регуляторів застосовано лінійний ПД регулятор із зменшеним пропорційним коефіцієнтом підсилення, квадратичний регулятор, регулятор із змінним коефіцієнтом підсилення, нечіткий логічний регулятор пропорційного типу із пропорційним коефіцієнтом підсилення та коригуючою диференціальною ланкою [455, 456]. Це дозволило досягти аперіодичного характеру перехідного процесу та досягти статистичної точності \pm 0,2 % при швидкодії до 6 секунд. Проте, застосування цих типів регуляторів супроводжується коливанням значень закидання в діапазоні від 1 до 22 %. З метою уникнення цих коливань, підвищення статистичної точності та розроблення методу управління обертами несучого гвинта вертольоту запропоновано використання нейро-нечіткого підходу [457–459].

Регулювання частоти обертів несучого гвинта вертольотів досягається регулюванням параметрів n_{CB} і G_T . Величина параметра G_T формується відповідно до n_{TK} і його похідної n_{TK_req} . Різні контури формують похідну n_{TK_req} залежно від режиму роботи двигуна, наприклад, на режимі малого газу n_{TK_req} визначається контуром n_{TK} , а у польотному режимі – контуром n_{CB} . Оскільки у польотному режимі вертоліт може проводити значну частину часу, динамічна якість управління та його ресурс значно залежать від вибору структури та параметрів електронного регулятора. Математична модель ГТД вертольоту (у цьому дослідженні розглядаються відхилення змінних стану) згідно з [455–460] має такий вигляд:

$$\tau_{1} \frac{dn_{TC}}{dt} + n_{TC} = k_{11}G_{T};$$

$$\tau_{2} \frac{dn_{FT}}{dt} + n_{FT} = k_{21}G_{T} + k_{22}n_{TC};$$
(5.40)

де G_T – витрата палива, τ_1 і τ_2 – постійні часу, k_{11} , k_{21} , k_{22} – коефіцієнти підсилення.

Модель ГТД вертольотів згідно з [455–460] подається у вигляді послідовного з'єднання динамічних ланок з передавальними функціями виду:

$$W_{TK} = \frac{n_{TK}}{G_T} = \frac{k_{11}}{\tau_1 p + 1};$$

$$W_{CB} = \frac{n_{CB}}{n_{TK}} = \left(1 + \frac{k_{21}}{k_{22} W_{TC}}\right) \cdot \left(\frac{k_{22}}{\tau_2 p + 1}\right).$$
(5.41)

Математична модель дозатора палива з безпосереднім приводом від електромеханічного перетворювача згідно з [455–460] після лінеаризації сухого тертя подається у вигляді:

$$J\frac{d^{2}\alpha}{dt^{2}} + k_{em}\frac{d\alpha}{dt} = k_{\kappa m} \cdot i;$$

$$G_{T} = \alpha \cdot k_{G_{T}};$$
(5.42)

де J – момент інерції ротора, α – кут повороту ротора, k_{sm} , k_{κ_M} , k_{G_T} – коефіцієнти в'язкого тертя крутного моменту і витрати палива, i – струм управління.

Отже, передавальна функція дозатора палива подається у такому вигляді [455]:

$$W_{\mathcal{A}\Pi} = \frac{k_i \cdot k_{G_T}}{p \cdot \left(J \cdot p + k_v\right)}.$$
(5.43)

Для внутрішнього контуру регулювання витрати палива у [457] запропоновано застосовувати пропорційно-диференціальний закон регулювання у вигляді:

$$W_{\Pi \mu} = \frac{i}{G_{T_{-} sadahe} - G_{T}} = k_{\Pi} + k_{\mu} \cdot p; \qquad (5.44)$$

де $G_{T_{_{_{_{_{_{_{_{_{_{3adaне}}}}}}}}}$ – задане значення витрати палива, k_{Π} та $k_{\mathcal{J}}$ – коефіцієнти посилення пропорційної та диференціальної складових.

У [457] задля урахування запізнення цифрового блоку управління запропоновано введення ланки чистого запізнення зі значенням 1,5 *·T*:

$$W_{_{3amp}} = e^{-1.5 \cdot p \cdot T};$$
 (5.45)

де *T* – період дискретизації за часом. У результаті застосовується вираз для передавальної функції замкнутого внутрішнього контуру регулювання витрати палива:

$$W_{G_T} = \frac{W_0}{1 + W_0}; (5.46)$$

де $W_0 = W_{_{samp}} \cdot W_{_{\Pi\!\Pi\!\Pi}} \cdot W_{_{\Pi\!\Pi\!\Pi}}$.

Законом регулювання *n*_{CB} слугує пропорційно-інтегральний закон регулювання з передавальною функцією [455, 456]:

$$W_{\Pi I} = \frac{i}{n_{CB_{-}req} - n_{CB}} = k_{\Pi 1} + \frac{k_i}{p};$$
(5.47)

де n_{CB_reg} – задане значення параметра n_{CB} , $k_{\Pi 1}$ і k_i – коефіцієнти підсилення пропорційної та інтегральної складових.

Для виключення послідовного включення двох інтегральних складових додаткового внутрішнього контуру регулювання *n*_{*TK*} у [455, 456] запропоновано застосовувати пропорційний закон регулювання:

$$W_{\Pi} = \frac{G_{T_set}}{n_{TK_set} - n_{TK}} = k_{\Pi 2};$$
(5.48)

де n_{TK_set} – задане значення параметра n_{TK} , $k_{\Pi 2}$ – коефіцієнт підсилення.

У [455, 456] значення коефіцієнта підсилення запропоновано обирати за умови забезпечення необхідної точності реалізації закону $\frac{dn_{TC}}{dt} = f(U)$ на всіх режимах роботи двигуна. Передавальна функція розімкнутого контуру регулювання n_{CB} при незалежній роботі регулятора подається у такому вигляді:

$$W_1 = W_{\Pi I} \cdot W_{\Pi} \cdot W_{G_T} \cdot W_{TK} \cdot W_{CB}.$$
(5.49)

Класичний ПІД-регулятор має низку недоліків, зокрема, фазове запізнення і велику чутливість до перешкод у вимірювальному каналі, що погіршує якість регулювання [455, 456]. Для усунення цих недоліків застосовуються різні підходи, такі як введення фазопередавального фільтра [461, 462] та корекція властивостей ПІД-регулятора [455]. Згідно з [458], до структури класичного ПІД-регулятора додаються псевдолінійна ланка з амплітудним приглушенням (рис. 5.24, а) та псевдолінійна ланка з фазовим випередженням (рис. 5.24, б).



Рисунок 5.24 – Блок-схеми псевдолінійних ланок з амплітудним приглушенням (a) і з фазовим випередженням (б) [458]

Амплітудно-фазова частотна характеристика псевдолінійної ланки з приглушенням амплітуди, отримана шляхом гармонічної лінеаризації, подається у вигляді [458]:

$$W = a + jb; \tag{5.50}$$

де
$$a = \frac{8}{\pi^2 \cdot \sqrt{1 + T^2 \omega^2}} \cdot \left(1 + \frac{1}{3} \cdot \cos(2\theta)\right); b = \frac{8 \cdot \sin(2\theta)}{3\pi^2 \cdot \sqrt{1 + T^2 \omega^2}}; \ \theta = -\operatorname{arctg}(\omega T); \omega$$
 – кутова частота.

Коефіцієнти гармонічної лінеаризації псевдолінійної ланки з фазовим випередженням подаються у вигляді [458]:

$$a = \frac{1}{\pi} \cdot \left(\pi - 2\alpha + \sin 2\alpha\right); \ b = \frac{1 - \cos 2\alpha}{\pi};$$

$$(5.51)$$

$$\text{de } \alpha = \arctan \frac{\omega T_1 \cdot \left(1 - \frac{T_2}{T_1}\right)}{1 + \omega^2 T_1 T_2}.$$

Враховуючи вищевикладене, пропонується модифікована типова схема контуру підтримки *n*_{CB} (рис. 5.25).



Рисунок 5.25 – Модифікована структурна схема контуру підтримки частоти обертів вільної турбіни ГТД вертольотів з лінійним електронним регулятором (авторський доробок [457–460])

На вході контуру подається розбіжність між поточним та заданим значеннями параметра n_{CB} , а також похідна поточного значення параметра n'_{CB} . Вихідним сигналом є значення необхідної похідної частоти обертання ротора турбокомпресора. Аналітичний вираз, що описує контур підтримки параметра n_{CB} подається у вигляді [455, 456]:

$$n'_{TK_req} = \Delta n_{CB} \cdot k_G + n_{CB} \cdot k_{\mathcal{I}}.$$
(5.52)

Коефіцієнти підсилення пропорційної k_{Π} та диференціальної k_{\Im} ланок визначаються з рівнянь [460]:

$$k_{\Pi} = k(\Delta n_{CB}) \cdot k_{cmam_{\Pi}} \cdot G_{T_{cmam}}(n_{TK}) \cdot a_{13}(n_{TK});$$

$$k_{\Pi} = k_{cmam_{\Pi}} \cdot \tau_{CB}(n_{TK});$$
(5.53)

де $G_{T_cmam}(n_{TK})$ – характеристика статичної витрати палива, $a_{13}(n_{TK})$ – коефіцієнт лінійної динамічної моделі ГТД вертольотів за витратою палива, $\tau_{CB}(n_{TK})$ – постійна часу ротора вільної турбіни.

У [455, 456] коефіцієнт $k(\Delta n_{CB})$ задається такою системою рівнянь:

$$k(\Delta n_{CB}) = \begin{cases} |\Delta n_{CB}|, \text{ якщо } \Delta n_{CB} \leq 1; \\ 1 + \frac{\Delta n_{CB} - 1}{2}, \text{ якщо } 1 < \Delta n_{CB} \leq 3; \\ \frac{2 \cdot (\Delta n_{CB} + 4)}{7}, \text{ якщо } \Delta n_{CB} > 3; \end{cases}$$
(5.54)

Статичний коефіцієнт пропорційної ланки $k_{cmam_{II}} = 0,35$, а диференціальної ланки $k_{cmam_{II}} = 0,05$ [455, 456].

Відповідно до поставленої задачі – підтримки частоти обертів несучого гвинта, у [457, 458] запропоновано застосувати нейромережеве налаштування коефіцієнтів k_{Π} , k_{I} і $k_{Д}$, що дозволить, зрештою, здійснювати динамічну підтримку частоти обертання несучого гвинта.

Відповідно до [463] приймається, що у загальному вигляді контур підтримки частоти обертів вільної турбіни ГТД вертольотів з лінійним електронним регулятором описується таким рівнянням:

$$\dot{X} = A(t)X + B(t)u + f(t); \qquad (5.55)$$

де $x = (x_1...x_n)^T$ – вектор стану системи під дією управління $u = (u_1, u_2, u_3)^T$, компоненти якого є постійними величинами при обмеженнях $|u_i| < 1$, i = 1, 2, 3. Елементи матриць A(t), B(t) і вектору f(t) приймаються речовинними, безперервними функціями при $t \in [0,T]$, їх

розмірності – $(n \times n)$, $(n \times 3)$ та $(n \times 1)$ відповідно. Матриця B(t) визначається заздалегідь

заданим речовинним і безперервним при $t \in [0,T]$ вектором $b(t) = \begin{pmatrix} b_1(t) \\ ... \\ b_n(t) \end{pmatrix}$ у вигляді:

$$B(t) = \left(b(t), \int_{0}^{t} b(\tau) d\tau, \dot{b}(t)\right).$$
(5.56)

Для знаходження рівняння, що визначає коефіцієнти k_{Π} і k_{\exists} для досягнення оптимальної якості або відповідності заданим вимогам в системі управління, робиться припущення, що k_{Π} = const і k_{\exists} = const. При цьому припускається, що вектор-функція b(t) відповідає нерівності $a_1 e^{-\lambda t} \le ||b(t)|| \le a_2 e^{-\lambda t}$ для деяких позитивних значень λ , де $a_1 < a_2$. За допомогою вибору управління метою є досягнення експоненціальної стійкості вихідної системи. При цьому [463]

$$b(t) = B_1(t); \int_0^t b(\tau) d\tau = B_2(t); \dot{b}(t) = B_3(t); \qquad (5.57)$$

де вектори $B_1(t)$, $B_2(t)$, $B_3(t)$ є складовими матриці B(t).

У [463] подається припущення, що коефіцієнти управління u є постійними. Однак для подальших аналізів вводиться нове управління $\overline{u}(t)$, що є функцією часу

$$u = \overline{u}(t)x. \tag{5.58}$$

Задля забезпечення відповідності управління $\overline{u}(t)$ програмному руху $x(t,\overline{u}(t))$ та

сталості добутку $\bar{u}(t)x(t,\bar{u}(t))$, (5.55) відповідно до [463] подається у такому вигляді:

$$\dot{x} = \left(A(t) + \sum_{i=1}^{3} B_i(t)\overline{u_i}(t)\right)x + f(t).$$
(5.59)

Приймається Z(t, u) – матриця фундаментальної системи рішень, що відповідає однорідній системі (5.59) при $f(t) \equiv 0$. Тоді для Z(t, u) буде виконуватися

$$\dot{Z}(t,\overline{u}) = \left(A(t) + \sum_{i=1}^{3} B_i(t)\overline{u_i}(t)\right) Z(t,\overline{u});$$
(5.60)

при цьому $Z^{-1}(t, u)$ – обернена матриця Z(t, u).

Звідси випливає, що загальне рішення у формі Коші системи (5.60) за початкових даних *x*₀ = *x*(0) подається у вигляді [463]:

$$x(t,\overline{u}) = Z(t,\overline{u})x_0 + Z(t,\overline{u})\int_0^t Z^{-1}(\tau,\overline{u})f(\tau)d\tau.$$
(5.61)

Оскільки вибір управління обмежений умовами експлуатації ГТД вертольотів у режимі польоту, то враховуються ці обмеження і встановлюються умови припустимості для значень коефіцієнтів:

$$\int_{0}^{T} \sum_{i=1}^{3} \overline{u_{i}}^{-2}(t) dt \le \varphi;$$
(5.62)

де φ – позитивна стала, T – довжина інтервалу часу, у якому діятиме програмний закон управління як зафіксованих коефіцієнтів u(t). Відповідно до [463] введено функціонал виду:

$$J(\overline{u}) = \overline{u}(t) = x^2(t,\overline{u}).$$
(5.63)

Розв'язання задачі Коші (5.61) $x(t, \overline{u})$ визначається функціональним законом коефіцієнтів $\overline{u}(t)$ на інтервалі часу [0, *T*]. Припускається [463], що існує оптимальне управління [464, 465] у вигляді $\overline{u}^{(0)} = \left(\overline{u}_1^{(0)}(t), \overline{u}_2^{(0)}(t), \overline{u}_3^{(0)}(t)\right)^T$, що мінімізує значення функціоналу (5.63), при цьому одночасно виконуються умови:

$$\int_{0}^{T} \sum_{i=1}^{3} \left(\overline{u}_{i}^{(0)}(t) \right)^{2} dt = \varphi.$$
(5.64)

Тоді будь-яке інше управління в деякій локальній близькості до оптимального відповідає виразу:

$$\vec{u} = \vec{u}^{(0)} + \varepsilon \nu = \left(\vec{u}_1^{(0)}(t) + \varepsilon \nu_1(t), \vec{u}_2^{(0)}(t) + \varepsilon \nu_2(t), \vec{u}_3^{(0)}(t) + \varepsilon \nu_3(t)\right)^T;$$
(5.65)

Для (5.65) також повинна виконуватися умова допустимості, але при цьому обов'язково буде виконуватися нерівність:

$$J\left(\overset{-(0)}{u}\right) = J\left(\overset{-(0)}{u} + \varepsilon \nu\right)$$
(5.66)

для всіх досить малих значень ε . Тоді, з урахуванням індивідуального вибору, вибирається вектор-функція v(t), яка задовольняє вимогу:

$$\int_{0}^{T} \sum_{i=1}^{3} v_i(t) \overline{u}_i^{(0)}(t) dt \neq 0$$
(5.67)

і, таким чином, за умови допустимості для неоптимального управління $\bar{u} = \bar{u}^{(0)} + \varepsilon v$ та урахування квадрата під знаком інтеграла у цій умові sign $\varepsilon = -\text{sign} \int_{0}^{T} \sum_{i=1}^{3} v_i(t) u_i^{(0)}(t) dt$. З не-

обхідності мінімізації функціоналу при значенні параметра $\varepsilon = 0$ обов'язково виконуються такі нерівності:

$$\frac{dJ}{d\varepsilon} \ge 0 \text{ при } \varepsilon > 0 \text{ або } \int_{0}^{T} \sum_{i=1}^{3} v_i(t) \overline{u}_i^{(0)}(t) dt < 0;$$

$$\frac{dJ}{d\varepsilon} \le 0 \text{ при } \varepsilon < 0 \text{ або } \int_{0}^{T} \sum_{i=1}^{3} v_i(t) \overline{u}_i^{(0)}(t) dt > 0;$$
(5.68)

Згідно з [463] структура похідної функціоналу Ј(и) має вигляд

$$\frac{dJ\left(\overline{u}^{(0)} + \varepsilon \nu\right)}{d\varepsilon} = \int_{0}^{T} \sum_{i=1}^{3} \psi_{i}\left(\overline{u}^{(0)}\right) \nu_{i}(t) dt; \qquad (5.69)$$

де $\psi_i(\overline{u}^{(0)})$ – залежні від раціонального управління й від правих елементів системи (5.59) функції.

При
$$\overline{u}_{1}^{(0)}(t) \equiv 0$$
 управління подається у вигляді $v_{2}(t) = v_{3}(t) = 0$ і $v_{1}(t) = \alpha \cdot \overline{u}_{1}^{(0)}(t) + \omega(t)$, де константа $\alpha = \frac{\int_{0}^{T} v_{1}(t) \overline{u}_{1}^{(0)}(t) dt}{\int_{0}^{T} (\overline{u}_{1}^{(0)}(t))^{2} dt}$, то, здійснюючи пряму підста-

новку у (5.67), отримуємо, що $\int_{0}^{T} u_{1}^{-(0)}(t) \omega(t) dt$, тобто функція $\omega(t)$ є ортогональною. Для

будь-якого управління при будь-якому β визначається, що будь-яка з нерівностей (5.68) буде порушуватися, враховуючи обраний вигляд структури у вигляді (5.69), при достатньо великому за модулем значенні параметра β . Отже,

$$\int_{0}^{T} \sum_{i=1}^{3} \psi_{i}(t) v_{i}(t) dt = \int_{0}^{T} \psi_{1}(t) v_{1}(t) dt = \beta \int_{0}^{T} \psi_{1}(t) \omega(t) dt + \alpha \int_{0}^{T} \psi_{1}(t) \overline{u}_{1}^{-(0)}(t) dt < 0.$$
(5.70)

Нерівність (5.70) буде виконуватися може лише за однієї умови:

$$\int_{0}^{T} \psi_{1}(t) \omega(t) dt = 0.$$
 (5.71)

Отримані вирази свідчать, що функція $\psi_1(t)$ є ортогональною до будь-якої функції, ортогональної до $\overline{u}_1^{(0)}(t)$, тобто $\psi_1 = \alpha_1 \cdot \overline{u}_1^{(0)}(t)$. Аналогічно $\psi_i = \alpha_i \cdot \overline{u}_i^{(0)}(t)$, при деяких фіксованих значеннях α_i , i = 1, 2, 3. З отриманих рівнянь відповідно до [463] оптимальне управління подається у вигляді:

$$\overline{u}_{1}^{(0)}(t) = \beta_{i} \cdot \psi_{i}(t); \qquad (5.72)$$

де константи $\beta_i = \frac{\int_0^T u_i^{(0)}(t)\psi_i(t)dt}{\int_0^T \psi_i^2(t)dt}, i = 1, 2, 3.$

Аналітичний вираз (5.72) є наслідками нерівностей (5.68) і, по суті, є необхідні умови оптимальності управлінь $\overline{u}_1^{(0)}(t)$, $\overline{u}_2^{(0)}(t)$, $\overline{u}_3^{(0)}(t)$ на відрізку часу [0, *T*] [463].

Сформулюємо загальний принцип фактичного визначення функцій $\psi_i(u^{-(0)}(t))$, які

визначають процедуру програмного налаштування коефіцієнтів підсилення $\overline{u}^{(0)}$ відповідно до виразу (5.72). Для цього спочатку знайдемо похідну від функціоналу $dJ(\overline{u}^{(0)} + \varepsilon v)$

$$d\varepsilon$$
 при $\varepsilon = 0$ та моменту часу $t = T$. Для досягнення цієї мети ми використаємо

формулу загального рішення у формі Коші:

$$\frac{dx\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)}{d\varepsilon} = x_0 \frac{dZ\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)}{d\varepsilon} + \frac{dZ\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)}{d\varepsilon} \cdot \int_0^T Z^{-1}\left(t,\overline{u}^{(0)}+\varepsilon\nu\right)f\left(t\right)dt + Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right) \cdot \int_0^T \frac{dZ^{-1}\left(t,\overline{u}^{(0)}+\varepsilon\nu\right)}{d\varepsilon}f\left(t\right)dt = x_0 Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right) \cdot \int_0^T B_i(t)\nu_i(t)dt + C \left(T,\overline{u}^{(0)}+\varepsilon\nu\right) \cdot \int_0^T B_i(t)\nu_i(t)d$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\sum_{i=1}^{3}B_{i}(t)\nu_{i}(t)dt\cdot\int_{0}^{T}Z^{-1}\left(t,\overline{u}^{(0)}+\varepsilon\nu\right)f(t)dt-Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\times$$

$$\times\int_{0}^{T}Z^{-1}\left(t,\overline{u}^{(0)}+\varepsilon\nu\right)f(t)dt\times\int_{0}^{t}\sum_{i=1}^{3}B_{i}(\tau)\nu_{i}(\tau)d\tau f(t)dt=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\sum_{i=1}^{3}B_{i}(t)\nu_{i}(t)dt\cdot\int_{0}^{T}Z^{-1}\left(t,\overline{u}^{(0)}+\varepsilon\nu\right)f(t)dt-Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\times$$

$$\times\int_{0}^{T}\int_{0}^{t}\sum_{i=1}^{3}B_{i}(\tau)\nu_{i}(\tau)d\tau d\left(\int_{0}^{t}Z^{-1}\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\int_{0}^{t}Z\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\int_{0}^{t}Z\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\int_{0}^{t}Z\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\int_{0}^{t}Z\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\int_{0}^{t}Z\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

$$+Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}\int_{0}^{t}Z\left(\tau,\overline{u}^{(0)}+\varepsilon\nu\right)f(\tau)d\tau\right)=x_{0}Z\left(T,\overline{u}^{(0)}+\varepsilon\nu\right)\cdot\int_{0}^{T}B_{i}(t)\nu_{i}(t)dt+$$

При t = T

$$\frac{dJ\left(\overline{u}^{(0)} + \varepsilon \nu\right)}{d\varepsilon} \bigg|_{\varepsilon=0} = 2x\left(T, \overline{u}^{(0)}\right) \frac{dx\left(T, \overline{u}^{(0)} + \varepsilon \nu\right)}{d\varepsilon} \bigg|_{\varepsilon=0} = 2\cdot\left(x_0 Z\left(T, \overline{u}^{(0)}\right) + Z\left(T, \overline{u}^{(0)}\right) \times \left(x_0 Z\left(T, \overline{u}^{(0)}\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right)\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right)\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right)\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right)\right) + \left(x_0 Z\left(T, \overline{u}^{(0)}\right) + \left(x_0 Z\left(T$$

де

$$\psi_{i}\left(t,\overline{u}^{(0)}\right) = 2 \cdot \left(Z\left(T,\overline{u}^{(0)}\right)x_{0} + Z\left(T,\overline{u}^{(0)}\right) \cdot \int_{0}^{T} Z^{-1}\left(\tau,\overline{u}^{(0)}\right)f\left(\tau\right)d\tau\right) \cdot \left(Z\left(T,\overline{u}^{(0)}\right)x_{0} + Z\left(T,\overline{u}^{(0)}\right) \cdot \int_{0}^{T} Z^{-1}\left(\tau,\overline{u}^{(0)}\right)f\left(\tau\right)d\tau\right)B_{i}(t).$$
(5.75)

З (5.75) видно, що функції $\psi_i(t, u^{(0)})$ залежать за індексом *i* через відповідну функцію $B_i(t)$. Результати визначення виду функцій $\psi_i(t, u^{(0)})$ відповідно до оптимального управління $\overline{u}^{(0)}$ та виду системи (5.59).

273

Спосіб наближеної побудови оптимального управління відповідно до [463], що ґрунтується на застосуванні (5.72) і на припущенні

$$\overline{u}_{i}^{(l+1)} = \alpha \left(\overline{u}^{(l)}\right) \beta_{i} \left(\overline{u}^{(l)}\right) \psi_{i} \left(\overline{u}^{(l)}\right);$$
(5.76)

де $u^{-(l)} = \begin{pmatrix} -(l) & -(l) & -(l) \\ u_1 & u_2 & u_3 \end{pmatrix} - l$ -е послідовне наближення, а постійні множники β мають ви-

гляд
$$\beta_i(\overline{u}^{(l)}) = \frac{\int_0^1 \overline{u}^{(l)}(t)\psi_i(t,\overline{u}^{(l)})dt}{\int_0^T \psi_i^2(t,\overline{u}^{(l)})dt}$$
. Величина $\alpha(\overline{u}^{(l)})$ вибирається так, щоб
 $\int_0^T \sum_{i=1}^3 \left(\overline{u}_i^{(l+1)}(t)\right)^2 dt = \varphi$, тобто $\int_0^T \sum_{i=1}^3 \left(\overline{u}_i^{(l+1)}(t)\right)^2 dt = \sum_{i=1}^3 \int_0^T \left(\overline{u}_i^{(l+1)}(t)\right)^2 dt = \alpha^2(\overline{u}^{(l)}) \times$
 $\times \sum_{i=1}^3 \frac{\left(\int_0^T \overline{u}^{(l)}(t)\psi_i(t,\overline{u}^{(l)})dt\right)^2}{\left(\int_0^T \psi_i^2(t,\overline{u}^{(l)})dt\right)^2} \int_0^T \psi_i^2(t,\overline{u}^{(l)})dt = \sum_{i=1}^3 \frac{\left(\int_0^T \overline{u}^{(l)}(t)\psi_i(t,\overline{u}^{(l)})dt\right)^2}{\int_0^T \psi_i^2(t,\overline{u}^{(l)})dt}.$
Отже, $\alpha(\overline{u}^{(l)}) = \sqrt{k \left(\sum_{i=1}^3 \frac{\left(\int_0^T \overline{u}^{(l)}(t)\psi_i(t,\overline{u}^{(l)})dt\right)^2}{\int_0^T \psi_i^2(t,\overline{u}^{(l)})dt}\right)^2}.$

Отже, відповідно до [465], формується послідовність, що наближає оптимальне управління $\overline{u}^{(l)}$ протягом усього інтервалу спостереження [0, *T*]. Важливо відзначити, що у [465] не визначається, на якому етапі побудови наближеного управління слід припинити вибір. Після зафіксування певного наближеного управління $\overline{u}^{(l)}(t)$ визначаються коефіцієнти регулятора, що змінюються на інтервалі [0, *T*]). Проте таке управління втрачає здатність коригування у випадку перевищення значення помилки регулювання, спричиненого, наприклад, зафіксованим недостатньо великим кроком наближення чи наявністю непередбаченого випадкового впливу функції *f*(*t*) (навіть

якщо вона розглядається як детермінована). Припускається, що час *T* не охоплює весь період спостереження динамічного процесу, а лише є коротким відрізком алгоритмічної крокової дискретизації (не тимчасовим кроком дискретизації, використовуваним у обчисленнях). Зазначається, що весь час спостережень розбивається на тимчасові відрізки довжиною *T*: [0, *T*], [0, 2*T*], [2*T*, 3*T*], ... На кожному окремому відрізку [*sT*, (*s* + 1)*T*], *s* = 0, 1, 2, ..., застосовується метод програмного налаштування коефіцієнтів підсилення. В якості початкового наближення $\overline{u}^{(1,s)}$ використовуються постійні значення $\overline{u}^{(2,s+1)}(sT)$, які були отримані на попередньому кроці алгоритму за допомогою управління $\overline{u}^{(2,s+1)}(sT)$ на момент часу *sT* для відповідного інтервалу алгоритмічної дискретизації [(*s* – 1)*T*, *sT*]. При цьому початкова точка x_0 (5.61) також задається значенням $x\left(sT, \overline{u}^{(2,s+1)}\right)$, отриманим в граничний момент часу. На цьому етапі визначається таке наближення [463]:

$$\overline{u}_{i}^{(2,s)}(t) = \alpha \left(\overline{u}^{(2,s+1)}(sT) \right) \beta_{i} \left(\overline{u}^{(2,s+1)}(sT) \right) \psi_{i} \left(t, \overline{u}^{(2,s+1)}(sT) \right);$$
(5.77)

де функції $\psi_i(t, \overline{u}^{(2,s+1)}(sT))$, i = 1, 2, 3 знаходяться за (5.75), з урахуванням часового зсуву t = t + sT для всіх функцій, що входять до (5.75):

$$\psi_{i}\left(t,\overline{u}^{(2,s+1)}\left(sT\right)\right) = 2x\left(sT,\overline{u}^{(2,s-1)}\right)Z\left((s+1)T,\overline{u}^{(2,s+1)}\left(sT\right)\right) + Z\left((s+1)T,\overline{u}^{(2,s-1)}\left(sT\right)\right)\times$$

$$\times \int_{sT}^{(s+1)T} Z^{-1}\left(\tau,\overline{u}^{(2,s-1)}\left(sT\right)\right), f\left(\tau\right)d\tau \right) \cdot \left(x\left(sT,\overline{u}^{(2,s-1)}\right)Z\left((s+1)T,\overline{u}^{(2,s-1)}\left(sT\right)\right) +$$

$$+ Z\left((s+1)T,\overline{u}^{(2,s-1)}\left(sT\right)\right) \cdot \int_{sT}^{(s+1)T} Z^{-1}\left(\tau,\overline{u}^{(2,s-1)}\left(sT\right)\right), f\left(\tau\right)d\tau \right)B_{i}(t).$$
(5.78)

Отже, підсумкові вирази визначення α і β_i мають вигляд [463]:

$$\alpha\left(\overline{u}^{(2,s-1)}(sT)\right) = \sqrt{\varphi} \cdot \left(\sum_{i=1}^{3} \frac{\left(\int_{0}^{(s+1)T} \overline{u}^{(2,s-1)}(sT)\psi_{i}\left(t,\overline{u}^{(2,s-1)}(sT)\right)dt\right)^{2}}{\int_{0}^{(s+1)T} \psi_{i}^{2}\left(t,\overline{u}^{(2,s-1)}(sT)\right)dt}\right)^{-1}; \quad (5.79)$$

$$\beta_{i}\left(\overline{u}^{(2,s-1)}(sT)\right) = \frac{\left(\int_{0}^{(s+1)T} \overline{u}^{(2,s-1)}(sT)\psi_{i}\left(t,\overline{u}^{(2,s-1)}(sT)\right)dt}{\int_{0}^{(s+1)T} \psi_{i}^{2}\left(t,\overline{u}^{(2,s-1)}(sT)\right)dt}. \quad (5.80)$$

Отримані результати є підгрунтям для алгоритму програмного налаштування коефіцієнтів підсилення, який буде виконувати роль «вчителя» в нейромережевому налаштуванні коефіцієнтів регулятора [457, 458]. На кожному такті нейронна мережа отримує вихідну величину та формує коефіцієнти управління для регулятора, які передаються йому нарізно з поточним значенням зворотного зв'язку e(k). Регулятор, у свою чергу, визначає керуючий сигнал, використовуючи вираз:

$$u(k) = u(k-1)u_1(k)(e(k) - e(k-1)) + u_2(k)e(k) + u_3(k)(e(k) - 2e(k-1) + e(k-2)); (5.80)$$

що застосовується для дискретних регуляторів та подає його на об'єкт управління – ГТД вертольотів. Навчання нейронної мережі відбувається в режимі реального часу за помилкою зворотного зв'язку. Закон управління $u(t) = k_p e(t) + k_i \int_0^t e(\tau) d\tau + k_d \frac{de(t)}{dt}$, реалізо-

ваний регулятором, є гіперплощиною в чотиривимірному просторі. Покращення якості управління забезпечується при заміні гіперплощини деякою гіперповерхнею, для опису якої можна перейти від стандартної структури нейронної мережі до складнішої структури, що містить нелінійності. Для розв'язання поставленої задачі у [457, 458] застосовано дискретний підхід до моделювання регулятора, замінюючи похідну та інтеграл відношеннями скінчених різниць:

$$u(n) = k_{p}e(n) + k_{i}\Delta t \sum_{k=0}^{0} e(k) + \frac{k_{d}}{\Delta t} (e(n) - e(n-1)); \qquad (5.81)$$

де n – момент часу, u_n визначає вхід ГТД вертольоту у момент $t = nT_0$, e_n – помилка між бажаним r_n та реальним y_n значеннями виходу, тобто $e_n = r_n - y_n$, T_0 визначає одиничний інтервал часу. При обмеженні двома доданками у (5.81) отримано [457, 458]

$$u(n) = k_p e(n) + s_i (e(n) + e(n-1)) + s_d (e(n) - e(n-1));$$
 (5.82)

де $s_i = k_i \Delta t$, $s_d = \frac{k_d}{\Delta t}$, Δt – крок дискретизації за часом.

При створенні регулятора у [457-459] застосована динамічна мережа прямого зв'язку, де в першому шарі використані нейрони з радіально-базисною функцією активації, а в другому шарі – адаптивні нейрони (адаліни) із лінійною функцією активації. Під час тестування отримано оптимальні налаштування нейронної мережі, що забезпечують мінімальне перерегулювання при заданому часі перехідного процесу [466]. В якості входів регулятора використовуються такі послідовності: опорний сигнал визначає кінцевий стан ГТД вертольоту, вихід регулятора – зворотній зв'язок з виходу регулятора, помилка об'єкта – різниця між опорним сигналом та реальним виходом ГТД вертольоту, інтегрована помилка – кумулятивна помилка, яку регулятор накопичує протягом роботи ГТД вертольоту, вихід об'єкта – сигнал на виході ГТД вертольоту. Вибір конкретних вхідних послідовностей є обґрунтованим [455–459], оскільки деякі з них призначаються певним складовим сигналу управління. Наприклад, вихід об'єкта та вихід регулятора визначають диференціальну складову, а корекція параметрів предиктора реалізує функцію диференціювання. Послідовність «інтегрована помилка» враховується тільки для інтегральної складової і впливає лише на неї, у той час, як інші вхідні послідовності впливають на всі нейрони обох шарів. Для створення механізму адаптації в системі, де вони контролюють параметри регулятора на нижньому рівні, у [457-459] доведено доцільність використання НЛР, які включаються у систему послідовно разом із ГТД вертольоту, діючи як нелінійний елемент, що вносить корективи.

З огляду на те, що НЛР має три входи, для формулювання закону управління необхідно використовувати три лінгвістичні змінні. Правила управління повинні бути подані у такому вигляді [457, 458]:

Якщо
$$e(n) = e^*(n)$$
 i $\frac{\partial e(n)}{\partial t} = \frac{\partial e^*(n)}{\partial t}$ i $\int e(n)dt = \int e^*(n)dt$ то $u(n) = u^*(n)$; (5.83)

де
$$e(n)$$
, $e^*(n)$, $\frac{\partial e(n)}{\partial t}$, $\frac{\partial e^*(n)}{\partial t}$, $\int e(n)dt$, $\int e^*(n)dt$, $u(n)$, $u^*(n)$ – помилка управління, її

похідна, інтеграл помилки, сигнал управління та відповідні їм лінгвістичні значення.

При використанні *N* термінів для опису помилки регулятор потребує лише *N* правил, які оптимізуються. Закон управління (5.82) описується нелінійною функцією, і її симетричність дозволяє настроювати лише два параметри [463]. Коефіцієнти регулятора у (5.83) відповідають «вагам», що впливають на пропорційну, диференційну та інтегральну складові закону управління. У структурі НЛР ці «ваги» представлені коефіцієнтами денормалізації *ДН_П*, *ДН_I* і *ДН_Д*. Розглядаючи синтез НЛР як завдання поліпшення якості регулятора, можна запропонувати алгоритм із двох кроків:

1. Синтез лінійного ПІД-регулятора з параметрами k_{Π} , k_{I} і $k_{\mathcal{A}}$, що виступають коефіцієнтами денормалізації.

2. Налаштування нелінійних функцій для нечіткого закону управління по кожній з вхідних змінних.

Отже, на першому кроці отримують базові коефіцієнти підсилення, а на другому – додаткові коефіцієнти підсилення, залежні від вхідного сигналу. Зважаючи на це, (5.82) модифікується до вигляду:

$$u(n) = k_{\Pi}\theta_1 + s_I\theta_2 + s_{\Pi}\theta_3; \qquad (5.84)$$

Пошук коефіцієнтів k_{Π} , s_I і s_{Π} виконувався з метою мінімізації цільової функції

$$F(n) = \sum_{i=1}^{M} \left(\theta_{1}^{i}(n) + \theta_{2}^{i}(n) + \theta_{3}^{i}(n) \right).$$
(5.85)

З урахуванням введення НЛР до модифікованої структурної схеми контуру підтримки частоти обертів вільної турбіни ГТД вертольотів (рис. 5.25) пропонується створену у [458] динамічну мережу прямого зв'язку модифікувати до гібридної нейро-нечіткої мережі типу ANFIS (рис. 5.26).



Рисунок 5.26 – Модифікований нейромережевий опис НЛР в контурі підтримки частоти обертів вільної турбіни ГТД вертольотів (авторський доробок)

На рис. 5.26 ∆ – затримка на один такт, а псевдолінійна ланка з амплітудним пригніченням реалізована у вигляді додаткового шару з лінійними нейронами, що мають функцію сигмоїдну активацію. Псевдолінійна ланка з фазовим випередженням реалізована у вигляді паралельного шару з лінійними нейронами, що мають функцію сигмоїдну активацію. Матриця ваг вихідного шару містить коефіцієнти регулятора, і матрицю ваг V можна вважати визначеною за методом апроксимації інтегралу та похідної:

$$\mathbf{V} = \begin{pmatrix} 1 & 1 & 1 & 1 \\ 0 & -1 & 0 & 1 \\ 0 & 0 & -1 & 1 \end{pmatrix}.$$
 (5.86)

Грунтуючись на [458, 459] у структурі НЛР невідомі лише параметри активаційних функцій нейронів першого шару. Налаштування НЛР відбувається шляхом синтезу лінійного цифрового ПІД-регулятора, в процесі якого формується матриця ваг другого шару **W**, а також оптимізації параметрів нелінійних активаційних функцій нейронів першого шару, що формують нелінійний закон управління для задоволення визначеним критеріям якості. Припускається [458], що помилка управління нормалізована, а активаційна функція нейрона симетрична відносно нуля. Запропоновано застосовувати сім точок для оптимізації радіально-базової функції активації замість чотирьох, що дає вектор параметрів активації з шістьма змінними, як подано у: $(-a_7 \quad -a_6 \quad -a_5 \quad -a_5 \quad -a_4 \quad -a_3 \quad -a_2 \quad -a_1 \quad a_1 \quad a_2 \quad a_3 \quad a_4 \quad a_5 \quad a_6 \quad a_7);$ (5.87)

Враховуючи, що кожен доданок у (5.84) відповідає за певні характеристики перехідного процесу, другий варіант організації пошуку є кращим, оскільки він більш зрозумілий та вимагає менше обчислювальних витрат. У [458, 467] зазначено, що генетичний алгоритм, згідно з [467, 468], є ефективним інструментом оптимізації, який використовує універсальний метод глобального пошуку [455, 456]. Для його застосування параметри задачі кодуються у вигляді хромосом – альтернативних варіантів розв'язання. Популяцію формують усі хромосоми, які еволюціонують через генетичні операції відбору, схрещування та мутації. Відповідно до (5.87), хромосома складається з семи генів дійсного типу. Довжина хромосоми може бути вибрана більшою для підвищення точності представлення, але це також збільшує складність завдання оптимізації. Для виконання операції відбору потрібно мати значення відносної придатності кожної хромосоми P_i . Цю оцінку можна отримати, порівнюючи еталонний перехідний процес $y^*(t)$ з перехід-

ним процесом, отриманим під керуванням *i*-ї хромосоми $P_i = \frac{1}{1+E_i}$, $E_i = \sum_{k=1}^{N} |y_k^*(t) - y_k(t)|$.

Еталонний перехідний процес має відповідати заданим показникам якості, таким як час, перерегулювання, час встановлення тощо.

На рис. 5.27 наведено схематичне зображення структури САР, де використовується нейро-нечітка мережа типу ANFIS для налаштування коефіцієнтів НЛР [457, 458], де TD – оператор затримки. Розроблена САР на основі [469] визначає нейро-нечітку мережу як функціональний перетворювач, що генерує шукані коефіцієнти НЛР (k_{II} , k_{I} і $k_{Д}$) для заданого набору сигналів ($n_{CB \text{ max}}$, n_{CB} , u).



Рисунок 5.27 – Модифікована структура САР з НЛР з блоком автоналаштування на основі нейронної мережі (подальше дослідження автора [457, 458]

Для навчання нейро-нечіткої мережі в модифікованій структурі САР з НЛР обирається функція *E*, значення мінімізуються. Помилка управління *e_n* в момент часу *nT*₀ буде виконувати цю функцію [457, 458]:

$$E_n = \frac{e_n^2}{2}.$$
 (5.88)

Для збереження помилок у [457, 458] запропоновано використання раніше отриманих даних E_{n-p} , ..., E_{n-2} , E_{n-1} , E_n , де p – кількість попередньо збережених значень для навчання нейро-нечіткої мережі. Для моделювання у [457, 458] запропоновано використання дискретної моделі. Розглядаємо процес без ланки затримки $e^{-p\tau_{samp}}$, приймається k= K_n . Обираємо досить малий крок h і обчислюємо значення вихідного сигналу в дискретних точках часу (l = 0, 1, 2, ...). Вихідне значення визначається за рекурентними формулами квадратичної інтерполяції на основі значень сигналу з попередніх моментів часу. Диференціальне рівняння процесу на інтервалі (l-1) < $h \le hl$ має вигляд [458]:

$$T\frac{dy(\tau)}{d\tau} + y(\tau) = kx(\tau); \qquad (5.89)$$

де $\tau = t - h(l-1)$. При $\tau = 0$ значення $x((l-1)h) = x_{l-1}$, $y((l-1)h) = y_{l-1}$. При переході до зображень за Лапласом і розв'язуючи рівняння для *Y*(*p*), отримано [457, 458]:

$$Y(p) = \frac{y_{l-1}}{1+pT} + \frac{k(X(p) - x_{l-1})}{1+pT}.$$
(5.90)

При використанні квадратичної інтерполяції, сигнал x(t) в інтервалі [(l-1)h, lh]– визначається значеннями x для трьох разів $x_l = x(lh)$, $x_{l-1} = x((l-1)h)$, $x_{l-2} = x((l-2)h)$ тобто:

$$x(t) = x_{l-1} + \frac{x_l - x_{l-2}}{2h} + \frac{x_l - 2x_{l-1} + x_{l-2}}{h^2}$$
(5.91)

або в зображеннях за Лапласом

$$x(p) = \frac{x_{l-1}}{p} + \frac{x_l - x_{l-2}}{2hp^2} + \frac{x_l - 2x_{l-1} + x_{l-2}}{h^2 p^3}.$$
(5.92)

Виконуючи підстановку та обернене перетворення Лапласа для $\tau = h$, тобто в кінці інтервалу t = lh, отримано:

$$y_{l} = \gamma y_{l-1} + Ax_{l} + Bx_{l-1} + Cx_{l-2}; \qquad (5.93)$$

282

де

$$\begin{cases} \gamma = e^{\frac{h}{T}} \\ A = \frac{k}{2h^2} \left((1 - \gamma) \left(2T^2 - Th \right) + 2h^2 - 2Th \right); \\ B = -\frac{k}{h^2} \left((1 - \gamma) \left(2T^2 - h^2 \right) + h^2 - 2Th \right); \\ C = \frac{k}{2h^2} \left((1 - \gamma) \left(2T^2 + Th \right) - 2Th \right). \end{cases}$$
(5.94)

З урахуванням затримки *т_{затр}* отримано [458]:

$$y_{l} = \gamma y_{l-1} + A x_{l-\tau_{samp}} + B x_{l-\tau_{samp}-1} + C x_{l-\tau_{samp}-2}.$$
 (5.95)

Для тестування нейро-нечіткої мережі застосовано навчальну вибірку, що складається із 256 значень параметра n_{CB} . Відповідно до методики отримання однорідної та репрезентативної навчальної та тестової вибірок, у [457, 458] доведено, що вибірки є репрезентативними, критерій $\chi^2 = 0,687$ й не перевищує граничного значення 22,362,



Рисунок 5.28 – Графік продуктивності нейро-нечіткої мережі: 1 – навчання; 2 – валідація (авторський доробок [457, 458]

що свідчить про однорідність навчальної та тестової вибірок.

Нейро-нечітка мережа пройшла навчання відповідно до запропонованих алгоритмів протягом 1000 епох. Графік точності навчання подано на рис. 5.28, при чому стабільна СКВ становить 0,382. Результати тестування навчання нейронної мережі наведено на рис. 5.29, з яких випливає, що середнє значення градієнта дорівнює, а оптимальне значення коефіцієнта навчання не перевищує 1.

У [470] уточнено, що хоча контролер нейро-нечіткої мережі локалізує мінімум,

цей мінімум є лише локальним, і неможливо стверджувати про його оптимальність. Для уникнення вибору субоптимального локального мінімуму у цільовій функції потрібно повторити процес оптимізації кілька разів та обрати найкращий результат. Різні початкові значення параметрів НЛР можуть призвести до отримання різних оптимальних його параметрів.



Рисунок 5.29 – Графік результатів навчання нейро-нечіткої мережі: а – діаграма зміни градієнта; б – діаграма зміни коефіцієнта навчання нейронної мережі (авторський доробок [457, 458]

У процесі навчання нейро-нечіткої мережі на кожного циклі використовуються випадкові збурення, а час реакції системи враховується для обчислення цільової фу-



нкції та її градієнта. Це гарантує отримання локально оптимальних коефіцієнтів НЛР для різних збурень системи. Змінюючи розмір кроку та кількість збурень, можна підвищити чутливість результатів у процесі пошуку коефіцієнтів регулятора. Процес пошуку параметрів регулятора завершується, коли система досягає стійкого стану, визначеного розрахунком лінійної регресії останніх оцінок, та ітерацією до тих пір, поки ступінчата характеристика не досягає

значення сталого стану з похибкою 1 % (рис. 5.30).

У [457] відзначено, що ефективність навчання нейро-нечіткої мережі напряму залежить від низки параметрів, зокрема, коефіцієнту навчання (встановлений на рівні 1,5), кількості нейронів у шарі нормалізації (припускається 20), довжині лінії затримки вхідних сигналів (приймається значення 5) та кількості завершених епох навчання (з умовою 1000 епох). Одним із критеріїв оцінки якості навчання відповідно до [457] є кінцеве сумарне стандартне відхилення за кожну епоху, що визначається виразом:

$$E_{enox} = \sqrt{\frac{1}{M} \sum_{i=1}^{M} \left(\frac{1}{2} \sum_{k=1}^{m} \left(y_{k \, \text{sux}} - y_{k} \right)^{2} \right)};$$
(5.96)

де *M* – кількість елементів у навчальній вибірці, а навчання нейро-нечіткої мережі триває до досягнення одного з критеріїв зупинки, таких як закінчення визначеного часу, виконання певної кількості епох навчання або досягнення помилки за епоху, що не перевищує заданого порогового значення.

У [457] проведено додаткові дослідження задля визначення впливу різних параметрів навчання на якість нейро-нечіткої мережі. Досліджено вплив коефіцієнта швидкості навчання, вплив кількості нейронів у шарі нормалізації, Вплив довжини затримки вхідних сигналів, вплив кількості епох навчання. Результати досліджень представлені у табличному вигляді (табл. Д.23–Д.26) та на графіках (рис. 5.31), де а – графік впливу коефіцієнта швидкості навчання на підсумкове середньоквадратичне відхилення, б – графік впливу кількості нейронів у шарі нормалізації на підсумкове СКВ; в – графік впливу довжини лінії затримки на підсумкове СКВ; г – графік впливу кількості пройдених епох на підсумкове СКВ.





Рисунок 5.31 – Результати досліджень, що визначають вплив параметрів навчання на якість нейро-нечіткої мережі (авторський доробок [457])

Для оптимізації НЛР у [457] задані такі структурні параметри: коефіцієнт швид-



кості навчання (встановлений на рівні 1,5), кількість нейронів у шарі нормалізації (20), довжина лінії затримки вхідних сигналів (5) і кількість епох навчання (1000).

На першому етапі нейро-нечітка мережа була навчена оптимізовувати коефіцієнти лінійного ПІДрегулятора. Перехідний процес після оптимізації представлений кривою 1 на рис. 5.42, де лінійний закон управління призвів до помітного перерегулювання та великої статичної похибки. Крива 2 на рис.

5.32 показує, що перехідний процес при лінійному законі керування має аперіодичний характер, але статична похибка не зменшилася, а час наростання збільшився.

На другому етапі оптимізувалися параметри функції активації нейрона, що відповідає інтегральному компоненту ПІД-регулятора. Форма лінгвістичної змінної представлена на рис. 5.33 (крива 2), а перехідний процес позначений кривою 3 на рис. 5.34. Зазначається [457], що при зміні задачі перехідний процес залишається незмінним, оскільки коефіцієнти НЛР статичні, перерегулювання мале, а статична похибка – невелика. При четвертій і п'ятій зміні задачі очевидно, що перехідний процес стає



Рисунок 5.33 – Форма лінгвістичної змінної після оптимізації НЛР (авторський доробок [458]) ефективнішим. Початкові значення коефіцієнтів $k_{II} = 0,5, k_I = 5, k_{II} = 0,01$ були вдосконалені, і тепер $k_{II} = 0,425, k_I = 0,95,$ $k_{II} = 0,005$. Значення перерегулювання не перевищує 0,5 % [458].

На рис. 5.34 подані характеристики перехідного процесу по частоті обертання ротора вільної турбіни *n*_{CB} згідно з [458]. У табл. Д.27 поданий опис складових рис. 5.34. Як випливає з рис. 5.44, перехідний процес виявляється дуже близьким до еталонного процесу, і ПІД-ре-

гулятор з нейронною мережею забезпечує набагато більш високу якість управління, ніж ПД-регулятори різної архітектури (рис. 5.34, а – е).





Рисунок 5.34 – Результуючі графіки перехідних процесів за частотою обертів ротора вільної турбіни (авторський доробок [457])

На рис. 5.45 (а – показник точності, б – показник втрат) представлені графіки втрат і точності під час навчання (експеримент I) НЛР, побудованого на нейро-нечіткій мережі для управління параметром n_{CB} . На етапі навчання використовувалися значення 300 n_{CB} , а на етапі тестування – 50 n_{CB} . На рис. 5.46 (а – показник точності, б – показник втрат) представлені графіки втрат і точності під час навчання (експеримент II). На етапі навчання використовувалося значення 100 n_{CB} , а на етапі тестування – 50 значень n_{CB} . Як видно з рис. 5.35 і 5.36 у процесі навчання виникла властивість збіжності. Отже, функція втрат, яка була визначена для нейро-нечіткої мережі, функціонує правильно, а параметри навчання цієї мережі оновлюються правильно.



Рисунок 5.35 – Результати експерименту I: 1 – навчальна вибірка, 2 – тестова вибірка (авторський доробок [458])

На рис. Д.10 продемонстровано ситуацію, коли в якийсь момент виникає неочікувана помилка, що призводить до різкого зниження точності навчання нейронної мережі і припинення процесу навчання. Причину цієї нестабільності визначити не вдалося, тому було вирішено ігнорувати такі випадки та вимірювати максимальну точність, досягнуту до того, як це явище виникає. Експериментальні висновки підтверджують припущення, що НЛР на нейро-нечіткій мережі типу ANFIS, може успішно розв'язувати задачу управління параметром n_{CB} у складних умовах великих обсягів даних.



Рисунок 5.36 – Результати експерименту II: 1 – навчальна вибірка, 2 – тестова вибірка (авторський доробок [458])

Висновки до п'ятого розділу

1. Створено експертну систем моніторингу технічного стану ГТД вертольотів у польоті з використанням їх адаптованої математичної моделі та організацією контролю та діагностики на основі методів діагностичних матриць і нечіткої логіки. Розроблено алгоритм моніторингу технічного стану двигунів на основі модифікованих методів діагностичних матриць та правил нечіткої логіки, що дозволяє ефективно контролювати та діагностувати технічний стан двигунів вертольотів. Для реалізації цих методів створено прототип нечіткої експертної системи на основі нечіткої нейронної мережі Ванга-Мендала, яка може бути впроваджена на борту вертольоту. Дослідження дефекту компресора двигуна ТВ3-117 показало, що розроблені методи підвищують впевненість у прийнятті рішення щодо справності компресора до 0,86 порівняно з іншими підходами. Перевагою такої системи є можливість навчання нейронної мережі та корекція її налаштувань залежно від змінних термогазодинамічних параметрів двигуна.

2. Вперше розроблено метод нейро-нечіткого моніторингу витратою палива ГТД вертольотів, який, завдяки адаптивній нейро-нечіткій системі з використанням нечіткої логіки Сугено у вигляді п'ятишарової нейронної мережі, дозволяє управляти витратами
пального в реальному часі з точністю 99,2 %. Експериментально доведено, що для адаптації нейро-нечіткої мережі ANFIS та нечіткої логіки Сугено нульового порядку до задачі управління витратами пального ефективно використовувати гібридний метод навчання з 2...3 затриманими вхідними параметрами та двосторонніми гаусовими функціями належності. Реалізація цього методу знижує помилки першого та другого роду в 1,34...5,17 разів порівняно з іншими архітектурами нейронних мереж, а також зменшує кількість епох навчання на 105 разів порівняно з алгоритмом зворотного поширення.

3. Вперше розроблено метод нейро-нечіткого моніторингу для визначення технічного стану ГТД вертольотів на основі динаміки змін ККД компресора двигуна за допомогою ансамблю нейронних мереж «RBF – Персептрон – Нейро-нечіткий класифікатор», що дозволяє визначати поточний стан двигуна з точністю 99,62 % та швидко приймати рішення про можливість виконання (продовження) польоту. Реалізація цього методу забезпечує зменшення помилок першого та другого роду порівняно з іншими архітектурами нейронних мереж від 1,23 до 5,96 разів.

4. Розроблено метод підтримки швидкості обертів ротора вільної турбіни ГТД вертольотів, що за допомогою ПІД-контролера на основі динамічної нейронної мережі з радіально-базисною активацією в першому шарі та лінійними нейронами в другому шарі дозволив покращити якість перехідного процесу. Це забезпечило збільшення швидкості до 3 секунд, точність до ±0.05 % і усунення перенавантаження параметрів. Поліпшено схему підтримки швидкості вільної турбіни ГТД вертольотів шляхом використання ПІД-контролера з налаштуванням коефіцієнтів підсилення нейронною мережею, що дозволило зменшити час переходу. Дослідження показало, що застосування нелінійного ПІД-контролера на основі нейронної мережі дозволяє оптимізувати процес обертання вільної турбіни, знижуючи час переходу з 3 секунд до 0.75 секунди, покращуючи точність до 0.99523 та зменшуючи максимальну помилку до 0.025. Впровадження цього методу дозволяє знизити помилки першого та другого виду на 36–38 % порівняно з іншими архітектурами нейронних мереж.

Основні результати досліджень, викладені у розділі, опубліковано у наукових працях [432, 438–440, 444–446, 449–454, 457–460, 470–472].

РОЗДІЛ 6

МЕТОДИ ВІДНОВЛЕННЯ ВТРАЧЕНОЇ ІНФОРМАЦІЇ ПРИ ВІДМОВІ ДАТЧИ-КІВ ТА ЕКСПЕРТНА СИСТЕМА МОНІТОРИНГУ ГАЗОТУРБІННИХ ДВИГУ-НІВ ВЕРТОЛЬОТІВ

6.1. Розробка нейромережевого методу відновлення інформації при параметричній відмові одного з датчиків

На сучасному етапі розвитку вертолітної техніки ключовою задачею є забезпечення їх безпеки польотів та ефективного функціонування. Одним з критичних аспектів цієї задачі є виявлення параметричних відмов датчиків, а також деградації їх характеристик в процесі експлуатації. На борту вертольоту велика кількість датчиків відповідає за збір та передачу інформації про різні параметри польоту, такі як висота, швидкість, частота, температура тощо. Важливі рішення, пов'язані з безпекою та управлінням польотом, базуються на надійних даних, які забезпечують ці датчики [473, 474].

Метод мажоритарного контролю, зазначений у [475] і застосований професором Жернаковим С.В. [476, 477], відіграє значущу роль в розв'язанні цієї задачі. Суть методу мажоритарного контролю виявляється у тому, що, якщо серед набору датчиків, таких як Д1 і Д2 (що, наприклад, вимірюють частоту обертання ротора турбокомпресора n_{TK} і температуру газів перед турбіною компресора T_{Γ}^*), хоча б один з них виявляє характеристику, що відрізняється від еталонної, введення додаткового каналу вимірювання у вигляді математичної моделі дозволяє обчислювати середнє значення цього виміру (медіану). Отже, відновлюється втрачена інформація з датчика, що дозволяє забезпечити надійність і точність вимірювань. Однак, на відміну від класичних методів, мажоритарний контроль може продовжувати працювати і в умовах часткового відмову деяких датчиків.

З огляду на швидкі технологічні зміни і постійний розвиток вертолітної техніки, вдосконалення методів виявлення відмов датчиків стає актуальною задачею. Інтеграція новітніх технологій, таких як штучний інтелект і машинне навчання, може значно покращити ефективність систем виявлення та діагностики відмов, а також зменшити ймовірність помилок. Застосування передових методів обробки даних, аналізу великих обсягів інформації та автоматизованого виявлення аномалій стає необхідністю у сучасних умовах. Це дозволяє оперативно реагувати на відмови датчиків, забезпечуючи високий рівень безпеки та ефективності польотів вертольотів.

Отже, в контексті швидкого технічного прогресу і зростаючих вимог до безпеки, розвиток та удосконалення методів виявлення параметричних відмов датчиків залишається ключовою задачею для подальшого успішного функціонування вертольотів.

Один із випадків відмов ГТД вертольотів стосується датчиків, що можуть мати як короткочасний, так і тривалий характер відмови. Згідно з [476–478], для відновлення втраченої інформації під час параметричної відмови датчиків ГТД вертольотів вводиться інтелектуальний регулятор. Цей регулятор аналізує стан датчиків і, у випадку відмови одного з них, використовує обчислені значення необхідних параметрів ГТД вертольотів, сформовані вбудованою нейронною мережею, для генерації управлінських впливів на виконавчі механізми.

На практиці, у зв'язку з великими розмірами векторів вхідних і вихідних параметрів ГТД вертольотів, різноманіттям їх режимів роботи та значними витратами часу на навчання нейронної мережі, має сенс розглядати декомпозицію необхідної нейронної мережі і представити її у вигляді сукупності локальних нейронних мереж. Структура такої системи, що використовується як частина інтелектуального регулятора, зображена на рис. 6.1. Вона складається з базової нейронної мережі (БНМ), числа додаткових нейронних мереж (HM₁...HM_i) і логічних блоків (ЛБ), що визначають алгоритми взаємодії модулів в складі мережі. HM₁ – нейронна мережа, що обчислює значення частоти обертів ротора турбокомпресора *n*_{TK} в поточний момент часу за результатами вимірювання інших термогазодинамічних параметрів ГТД вертольотів, тобто, виконує функцію імітатора параметра *n*_{TK}. Аналогічно HM₂ – нейронна мережа, що обчислює значення температури газів перед турбіною компресора T_{Γ}^* , HM₃ – нейронна мережа, що обчислює значення частоти обертів ротора вільної турбіни *п*_{CB}. Варто зазначити, що система відновлення втраченої інформації (рис. 6.1) схильна до модифікації відповідно до інших датчиків, що реєструють той чи інший параметр на борту вертольоту шляхом додавання в неї нейронної мережі HM_k. ЛБ₁ – логічний блок, що комутує на входи нейронної мережі необхідні значення вимірюваних параметрів ГТД вертольотів n_{TK} , T_{Γ}^* , n_{CB} для виконання обчислень з метою парирування відмов датчиків; ЛБ2 та ЛБ3 – логічні блоки, що

підключають індивідуальні нейронні мережі замість датчиків, що відмовили, у разі необхідності парирування їх відмов; БНМ – базова нейронна мережа для визначення факту виникнення та локалізації місця відмови датчиків; **Y**^B – вектор відновлених параметрів ГТД вертольотів [479].



Рисунок 6.1 – Універсальна нейромережева схема відновлення значень параметрів ГТД вертольотів (авторський доробок [479] на основі [478])

У цій роботі в якості базової нейронної мережі використано персептрон архітектури 3–6–3, що має три входи і три виходи – за кількістю датчиків, що реєструють термогазодинамічні параметри ГТД вертольотів (використано варіант з трьома датчиками реєстрації (n_{TK} , T_{Γ}^* , n_{CB}). Вважається, що значення на *i*-у вході й *i*-у на виході БНМ складає одиницю у випадку, якщо *i*-й датчик є справним, та складає одиницю на вході і нуль на виході, якщо *i*-й датчик – несправний. Отже, БНМ – це нейронна мережа, що має кількість входів і кількість виходів, що дорівнює кількості датчиків для реєстрації параметрів ГТД вертольотів на борту вертольоту.

Оскільки термогазодинамічні параметри ГТД вертольотів, що реєструються на борту вертольоту, мають нелінійні залежності, то, відповідно до [480] в якості нейронних мереж $HM_1...HM_i$ виступають тришарові персептрони (рис. 6.2), в яких вхідний шар нейронів складається з вхідних сигналів нейронної мережі, які представлені вхідним сигналом x(t) і постійним сигналом, рівним 1. Постійний одиничний сигнал



забезпечує зміщення в рамках цієї задачі. Прихований шар складається з трьох нейронів з сигмоїдними функціями активації. Кожен нейрон цього шару відповідно до [480] описується такими рівняннями:

$$O_{j} = \frac{1}{1 + e^{S_{j}}}; \tag{6.1}$$

$$S_{j} = \sum_{i=1}^{m} W_{ij} O_{i};$$
 (6.2)

Рисунок 6.2 – Структура тришарового персептрону для реалізації $HM_1...HM_i$ [480]

де O_i – вихідний сигнал *i*-го нейрона вхідного шару; W_{ij} – синаптична вага *i*-го входу *j*-го нейрона прихованого шару; *m* – кількість нейронів у вхідному шарі.

Вихідний шар персептрона складається з одного нейрона, який створює сигнал $\hat{y}(t)$ як зважену суму вихідних сигналів нейронів прихованого шару, тобто:

$$y(t) = \sum_{j=1}^{n} V_j O_j;$$
 (6.3)

де O_j – вихідний сигнал j-го нейрона прихованого шару; V_j – синаптична вага j-го входу нейрона вихідного шару; *n* – кількість нейронів у прихованому шарі.

Регулювання синаптичних ваг персептрону V_i і W_{ii} здійснюється за допомогою методу зворотного поширення помилки [480], згідно з яким мінімізація критерію оптима-

льності $J(t) = \varepsilon^2(t) = \frac{(y(t) - y(t))^2}{2}$ виконується за допомогою градієнтної процедури:

$$V_{j}(t) = V_{j}(t-1) - \mu_{V} \frac{\partial J(t)}{\partial V_{j}} = V_{j}(t-1) - \mu_{V} \varepsilon(t) O_{j}; \qquad (6.4)$$

$$W_{ij}(t) = W_{ij}(t-1) - \mu_W W_{ij} = W_{ij}(t-1) - \mu_W \varepsilon(t) V_j(t) (1 - O_j) O_i;$$
(6.5)

де μ_V та μ_W – числові коефіцієнти, що визначають крок градієнтного пошуку та впливають на швидкість навчання.

Аналогічно до досліджень Жернакова С.В. [476, 477] проведено аналіз обчислювальних витрат нейромережевого алгоритму реалізації математичної моделі ГТД вертольотів на базі мікропроцесорного контролера Raspberry Pi NanoPi M1 Plus і нейрочипа Intel Neural Compute Stick 2. Їх технічні характеристики наведені у табл. Ж.1 [479, 481].

Час звернення до пам'яті при читанні/запису Т_{ТАМ} визначається згідно з виразом:

$$T_{TAM} = T_{BAT} + T_{DBT} + T_{BCT}; ag{6.6}$$

де T_{TAM} – час звернення до пам'яті; T_{BAT} – час готовності шини адреси; T_{DBT} – час готовності шини даних; T_{BCT} – час готовності шини управління.

Згідно з (6.6) отримано:

$$T_{TAM} = 0,7519 + 0,7519 + 0,7519 = 2,2557$$
 нс.

Розмір пам'яті, необхідний для нейронної мережі в ОЗП, визначається згідно з виразом:

$$V_{nn} = U\left(\sum_{i=1}^{3} N_i + N_c + \sum_{i=1}^{2} N_i N_{i+1}\right);$$
(6.7)

де U – число розрядів під час запису зміщення нейрона (4 байт); $\sum_{i=1}^{2} N_i N_{i+1}$ – кількість вагових коефіцієнтів нейронної мережі; N_i – кількість нейронів в *i*-му шарі нейронної мережі; N_c – кількість шарів нейронної мережі.

Для БНМ, що має структуру 3-6-3, отримано:

$$V_{nn} = 4 \cdot ((3+6+3)+3+(3\cdot 6+6\cdot 3)) = 204$$
 байт.

У процесі роботи нейронної мережі виконується низка математичних (додавання, множення, ділення) і логічних (порівняння) операцій. При цьому обчислюється зважена сума входів нейрона, до якої додається зсув. Отриманий результат подається на функцію активації нейрона. У даному випадку обрана раціональна сигмоїда [476, 477, 479, 481] z = f(x), яка обчислюється відповідно до виразу:

$$z = \frac{x}{|x|+c};\tag{6.8}$$

де c – крутизна сигмоїдної функції, при розрахунках приймалося c = 1.

При цьому, якщо на нейропроцесори Intel Neural Compute Stick 2 функції активації нейронів реалізуються апаратно, то на мікроконтролері Raspberry Pi NanoPi M1 Plus вони виконуються програмно. Для раціональної сигмоїди (6.8) отримано дві операції:

складання, ділення. Згідно з [476, 477, 479, 481] всього у процесі роботи БНМ виконується така кількість операцій:

$$OS = N_1 + \sum_{i=1}^{2} N_i N_{i+1} + \sum_{i=1}^{3} N_i;$$
(6.9)

$$OU = N_1 + \sum_{i=1}^{2} N_i N_{i+1} + \sum_{i=1}^{3} N_i;$$
(6.10)

$$T_f = \sum_{i=1}^3 N_i; (6.11)$$

де OS – число операцій додавання; OU – число операцій множення; T_f – число функцій активації; N_i – кількість нейронів в *i*-му шарі нейронної мережі.

Для обраної архітектури нейронної мережі 3-6-3 згідно з (6.7)-(6.11) отримано:

$$OS = 3 + (3 \cdot 6 + 6 \cdot 3) + (3 + 6 + 3) = 51;$$

 $OU = 3 + (3 \cdot 6 + 6 \cdot 3) + (3 + 6 + 3) = 51;$
 $T_f = 10.$

Вважаючи, що всі операції в мікроконтролері Intel Neural Compute Stick 2 виконуються за один такт, включаючи функцію активації нейрона, а також з огляду на розрядність, швидкість звернення до пам'яті і паралельність виконання алгоритму, маємо загальну кількість операцій:

$$O_{\text{Intel}} = \frac{51}{2} + \frac{51}{2} + \frac{3}{2} + \frac{6}{2} + \frac{3}{2} = 57.$$

Для мікроконтролера Raspberry Pi NanoPi M1 Plus час виконання всіх операцій (з урахуванням часу вибірки даних з пам'яті) обчислюється як [476, 477, 479, 481]:

$$T_{\text{Raspberry}} = O_d \cdot t_d + OS \cdot t_p + OU \cdot t_m + T_f \cdot t_p + V_{nn} \cdot t_{mem}; \qquad (6.12)$$

де t_d – час виконання команди ділення; t_p – час виконання команди додавання; t_m – час виконання команди множення; t_{mem} – час виконання вибірки даних з пам'яті.

Тоді згідно з (6.6) для Raspberry Pi NanoPi M1 Plus отримано:

 $T_{Raspberry} = 9.16,67 + 51.0,833 + 51.8,33 + 9.0,833 + 204.0,833 = 794,772$ Hc.

З огляду на різну розрядність процесора (32 розряди) і операндів (64 розряди), час обчислення збільшиться у два рази:

$$T_{Raspberry} = 794,772 \cdot 2 = 1589,544$$
 Hc.

Для нейропроцесора Intel Neural Compute Stick 2 цей час складає:

$$T_{Intel} = 57 \cdot 0,7519 + 204 \cdot 0,7519 = 196,246$$
 HC.

Звідси видно, що спеціалізований процесор Intel Neural Compute Stick 2 виконує реалізацію нейронної мережі у вісім разів швидше обчислювача на базі Raspberry Pi NanoPi M1 Plus.

На рис. 6.3 наведено узагальнений графік моделювання універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів (рис. 6.1) при короткочасовій відмові *i*-го датчика. Як видно, при відмові датчика за допомогою аналітичної зайвості, тобто застосування нейронної мережі (*r_{ii}*), можливе опосередковане вимірювання *i*-го термогазодинамічного параметра, що дозволяє зберегти необхідну якість процесів управління.

В ході експериментального дослідження універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів на авіаційному двигуні ТВЗ-117 моделювалися відмови датчиків реєстрованих на борту вертольоту параметрів n_{TK} , T_{Γ}^* , n_{CB} , а та-



Рисунок 6.3 – Результати чисельного моделювання при короткочасній відмові датчика *n*_{TK} (авторський доробок [479])

кож проводилася заміна сигналів вимірювання сигналами, отриманими розрахунком в ній. Під час введення сигналу відмови спочатку запускається алгоритм розпізнавання відмови. Відповідно до цього алгоритму, протягом часу, що дорівнює п'яти циклів розрахунку, реєструється останнє показання датчика перед його відмовою. Після цього значення датчика замінюється розрахованим значен-

ням відповідного параметра нейромережевої моделі (HM₁...HM_i).

На рис. 6.4 показані характеристики авіаційного двигуна ТВЗ-117 на сталих і перехідних режимах, отримані при роботі його САУ з реальними датчиками параметрів регулювання та їх заміні параметрами, розрахованими в універсальній нейромережевій схемі відновлення значень параметрів ГТД вертольотів.



Рисунок 6.4 – Графіки відмови термогазодинамічних параметрів ГТД вертольотів (1 – виміряно при справних датчиках, 2 – відновлено нейромережевою моделлю): а – параметр *n*_{*TK*}; б – параметр *T*^{*}_{*T*}; в – параметр *n*_{*CB*} (авторський доробок [479])

Наведені результати свідчать про прийнятну якість управління двигуном при роботі з універсальною нейромережевою схемою відновлення значень параметрів ГТД вертольотів. На сталих режимах найбільша розбіжність спостерігається на режимі малого газу (до 2...3 %). Величина похибки змінюється у різних експериментах через відмінності у ступені прогріву двигуна цьому режимі. Найбільша різниця виміряних і розрахованих значень спостерігається за параметром T_{Γ}^* і може досягати 10...20 К при рівні температури 600...700 К. Перехідні процеси при роботі універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів також близькі до процесів при датчиках, що працюють. Відмінності величини витрати на окремих ділянках не перевищують 3...5 %. Процеси зміни частоти обертання ротора турбокомпресора n_{TK} і n_{CB} розрізняються незначно.

Для компенсації відмов датчиків параметрів T_H і P_H , відповідно до [000] застосовано спосіб, побудований на введенні в схему (рис. 6.1) додаткового контуру із зворотним зв'язком для відновлення інформації. Його структура показана на рис. 6.4. У цьому контурі параметри T_H і P_H виступають у ролі регулюючих факторів двигуна. В якості параметрів регулювання використовуються розрахункові величини вимірюваних параметрів двигуна (n_{TK} , T_{Γ}^* , n_{CB}), а в якості уставок регулятора – їх вимірювані величини. Виконані розрахункові дослідження та експериментальна перевірка на двигуні цього методу відновлення. Вид процесу відновлення інформації за параметром T_H і P_H показано на рис. 6.5. В момент t_0 імітується відмова датчика. Після розпізнавання відмови включається алгоритм відновлення інформації. Максимальний час відновлення інформації (при обнуленні значень T_H і P_H у момент відмови) не перевищує 3...5 с, що для цих параметрів є прийнятним. Похибка відновлення інформації при використанні універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів не перевищує 0,005 за T_H і P_H в умовах M = 0, H = 0.

Важливим є забезпечення достатньої точності роботи універсальної нейромереже-



Рисунок 6.5 – Графіки відмови параметрів ГТД вертольотів (1 – виміряно при справних датчиках, 2 – відновлено нейромережевою моделлю): а – параметр *P_H*; б – параметр *T_H* (авторський доробок [479])

вої схеми відновлення значень параметрів ГТД вертольотів у різних умовах польоту та при зміні характеристик двигуна в процесі його експлуатації. Для ідентифікації універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів у контексті розв'язання задачі компенса-

ції відмов датчиків АПУ використано [482] метод корекції розрахункових параметрів, що одержуються з використанням цієї моделі. Цей метод відповідає такому математичному співвідношенню:

$$x_{\kappa op} = x_{posp} + \Delta x \left(x_{np} \right); \tag{6.12}$$

де $x_{\kappa op}$ – скориговане значення параметра x; x_{posp} – розрахункове значення параметра x, Δx – величина корекції, що задається у вигляді функції від приведеного значення x_{np} відповідного параметра.

Залежність $\Delta x(x_{np})$ формується та оновлюється у процесі функціонування ГТД вертольоту та його АПУ, при цьому згідно з [482] величина Δx визначається із співвідношення:

$$\Delta x = x_{gum} - x_{posp} + \Delta x; \tag{6.13}$$

де *х*_{вим} – виміряне значення параметра *х*.

За нормального функціонування ГТД вертольоту до спеціальних масивів помилок заносяться значення різниці Δx між виміряними і розрахованими за допомогою універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів величинами параметрів n_{TK} , T_{Γ}^* , n_{CB} тощо, а також розрахункові значення відповідних приведених параметрів. При цьому для отримання максимальної точності формування та оновлення масивів даних, що визначають залежність $\Delta x(x_{np})$, здійснюється тільки на режимах роботи двигуна, що встановилися.

При виявленні відмови датчика будь-якого параметра регулювання навчання нейромережевої моделі припиняється. Отримані до цього моменту масиви помилок залишаються незмінними та використовуються для формування поправок до розрахункових даних моделі.

Наприклад, при регулюванні температури газів перед турбіною компресора T_{Γ}^* може бути використана інформація датчика частоти обертання ротора вільної турбіни n_{CB} . У цьому випадку скоригована розрахункова величина температури газів перед турбіною компресора T_{Γ}^* визначається співвідношенням:

$$T^*_{\Gamma_{\kappa op}} = T^*_{\Gamma_{BUM}} + K_{T^*_{\Gamma}} \cdot \Delta n_{CB}; \qquad (6.14)$$

де $\Delta n_{CB} = n_{CB posp}$ різниця між виміряним n_{CB} та обчисленим $n_{CB posp}$ в універсальній нейромережевій схемі відновлення значень параметрів ГТД вертольотів значеннями частоти обертання ротора вільної турбіни, а $K_{T_{\Gamma}^*}$ – постійний коефіцієнт, що пов'язує значення T_{Γ}^* і n_{CB} в універсальній математичній моделі авіаційних двигунів з вільною турбіною.

Результати порівняльного аналізу нейромережевого методу з аналітичною (кусковолінійної) моделлю двигуна, а також поліноміальною регресійною моделлю, реалізованою на основі методу найменших квадратів поліномом дев'ятого порядку, наведені у табл. Ж.2. Її аналіз показує, що універсальна нейромережева схема відновлення значень параметрів ГТД вертольотів ефективніше розв'язує цю задачу: максимальна похибка ідентифікації не перевищила 0,762 %, що у 8,6 разів менше максимальної похибки кусково-лінійної моделі, і у 3,7 разів менше максимальної похибки поліноміальної моделі двигуна.

6.2. Розробка методу відновлення інформації при відмовах датчиків з використанням автоасоціативної нейронної мережі

Іншим альтернативним підходом до відновлення інформації є використання для цих цілей автоасоціативної нейронної мережі (АНМ), що володіє властивістю стиску і подальшого відновлення інформації. Відомі роботи професора Жернакова С.В. [483, 484], в яких показана можливість використання АНМ для відновлення виміряної інформації за відомими параметрами об'єкта. Недоліком даного підходу є висока похибка відновлення одиночних відмов датчиків БСКД: похибка відновлення значення з датчиків у разі обриву складає 4,5...5,0 %, а при поступовій відмові – до 5,5 %. Іншим підходом до відновлення втраченої інформації з датчиків на основі АНМ є використання буфера (стека пам'яті) задля збереження останнього правильного значення з відмовив датчика. Цей підхід був розглянутий у [485]. На відміну від [483, 484] у ньому розглядається метод визначення оптимального розміру горла АНМ, але була відсутня інженерна методика отримання працюючої АНМ для процесу відновлення втраченої з датчиків інформації. Дослідження методу головних компонент дозволяє побудувати АНМ оптимальної структури, використання якої для розв'язання даної задачі зменшує похибку відновлення втраченої інформації з датчиків. Відповідно до досліджень професора Жернакова С.В. [483, 484] у роботі розв'язується задача побудови АНМ, що забезпечує контроль та



відновлення інформації (у разі виникнення відмов) про технічний стан ГТД вертольотів за наявності *N* штатних датчиків.

На рис. 6.6 на ведено архітектуру автоасоціативної нейронної мережі, що складається з трьох шарів. При цьому АНМ здійснює дзе-

ркальне відображення вектору вхідних даних на себе. Стиснення інформації здійснюється у прихованому шарі АНМ («горлі»), відновлення інформації здійснюється у вихідному шарі. Принципова можливість використання стискаючого відображення становить основу методу основних компонентів [475]. За допомогою АНМ (рис. 6.6) [483–485] здійснюється виконання таких нелінійних перетворень:

$$\mathbf{T} = \mathbf{G}(\mathbf{Y}); \ \mathbf{Y}^{\mathbf{B}} = \mathbf{H}(\mathbf{T}); \tag{6.15}$$

де **Y** – вектор вхідних параметрів ГТД вертольоту розмірності n; **T** – вектор виходів прихованого шару розмірності k, причому k < n; **Y**^B – вихідний вектор виходів АНМ тієї ж розмірності n, що вектор **Y**; **H** і **G** – нелінійні оператори.

Особливістю навчання АНМ є те, що вектор її виходів Y^B повинен збігатися з вектором входів Y як на множині штатних значень компонент вектору Y (тобто при наявності справних датчиків), так і у разі виходу за межі допустимої області одного або декількох компонентів вектору Y (тобто при виникненні відмови датчиків). Розмір сумарної квадратичної помилки навчання відповідно до [485] складає:

$$E = \sum_{r=1}^{R} \sum_{i=1}^{n} \left(\varepsilon_{i}^{(r)}\right)^{2} = \sum_{r=1}^{R} \sum_{i=1}^{n} \left(Y_{i}^{(r)} - Y_{i}^{B(r)}\right)^{2};$$
(6.16)

де R – кількість випробувань (обсяг навчальної вибірки), не повинна перевищувати заданої малої величини Δ . Навчена АНМ проводить аналіз (фільтрацію) вектору вихідних параметрів ГТД вертольотів і, у разі присутності на вході аномальних результатів вимірювань, відновлює необхідну компоненту вектору **Y**, обчислюючи її очікуване (ймовірне) значення.

Наприклад, на рис. 6.7 наведено графік залежності помилки відновлення інформації мережею при відмові одного з датчиків (в даному випадку датчика частоти обертання ротора турбокомпресора авіаційного двигуна ТВЗ-117 [485]) від кількості нейронів в горлі АНМ, обчислений за формулою:

$$MSE = \frac{1}{n} \cdot \sum \left[x - \det(\operatorname{enc}(x)) \right]^2;$$
(6.17)

де x – вхідні дані, еnc(x) – вихід прихованого шару (закодовані дані), dec(enc(x)) – реконструйовані дані, n – кількість прикладів у навчальній вибірці.

На вісі абсцис відображено відносний розмір «горла» – відношення кількості нейронів у «горлі» до кількості вхідних/вихідних нейронів (4 нейрони). З рис. 6.7 видно, що оптимальний розмір «горла» у даному випадку становить 0,8 · 5,0 = 4,0, тобто кількість нейронів у «горлі» повинна бути рівною трьом.



Рисунок 6.7 – Графіки залежностей помилки навчання АНМ від числа нейронів прихованого шару (авторський доробок [485])

Поряд з питанням вибору структури АНМ, важливим етапом є етап відновлення інформації за результатами функціонування цієї нейронної мережі. У цій роботі використовується відомий підхід і зображений у вигляді функціональної схеми на рис. 6.8 [485].



Рисунок 6.8 – Функціональна схема відновлення інформації на основі АНМ (авторський доробок [485] на основі [483, 484])

Сигнали з датчиків одночасно поступають до стеку та системи допускового контролю [475], що виконує перевірку виміряних значень від датчиків. У випадку, якщо сигнали від датчиків знаходяться в межах допуску, вони без перешкод передаються в АПУ, що взаємодіє з виконавчими механізмами, впливаючи на роботу ГТД вертольоту. У випадку, коли будь-який з сигналів датчиків виходить за межі допуску, система допускового контролю виключає останнє значення цього сигналу зі стеку і передає його на відповідний вхід АНМ. АНМ відновлює цю інформацію та передає її до модифікованої закритої бортової нейромережевої АПУ ГТД вертольотів. Відповідно до [483, 484] На рис. 6.9 наведена схема процес відновлення інформації з датчиків на основі АНМ. Остання включається безпосередньо між датчиками $\mathcal{J}_1...\mathcal{J}_n$ (або в загальному інформаційному каналі) і модифікованою закритою бортовою нейромережевою АПУ ГТД вер-



Рисунок 6.9 – Функціональна схема управління ГТД вертольотів на основі АНМ (авторський доробок [485] на основі [483, 484]) тольотів. Перевагами цієї функціональної схеми є її простота в реалізації та зрозумілість роботи АНМ в складі системи управління. Для обчислення похибки відновлення втраченої інформації з датчиків використовується залежність, що має вигляд:

$$e = \left| \frac{real_{value} - nwa_{value}}{max_{value} - min_{value}} \right| \cdot 100\%;$$
(6.18)

де *real_{value}* – реальне значення параметра; *nwa_{value}* – відновлене значення параметра; *max_{value}*, *min_{value}* – максимальне і мінімальне значення параметра.

На основі базового алгоритму навчання АНМ пропонується модифікований метод її навчання з додаванням регуляризації до функції втрат та оновлення ваги для досягнення наступних цілей [486]:

Ціль 1. Запобігання перенавчанню. Регуляризація допомагає зменшити ризик перенавчання моделі, коли вона надто сильно адаптується до навчальних даних і втрачає здатність узагальнювати нові дані. Це особливо важливо у разі невеликих обсягів даних чи складних моделей.

Ціль 2. Поліпшення узагальнюючої здатності. Шляхом додавання регуляризації до функції втрат ми намагаємося створити більш стійку та узагальнюючу модель, яка не тільки добре працює на навчальних даних, але й здатна видавати хороші результати нових даних.

Ціль 3. Контроль складності моделі. Регуляризація допомагає контролювати

складність моделі, зменшуючи ваги та стримуючи їх зростання. Це дозволяє створювати простіші та інтерпретованіші моделі, що часто є бажаною властивістю в практичних завданнях.

Ціль 4. Підвищення стійкості навчання: Додавання регуляризації допоможе поліпшити стабільність процесу навчання, зменшуючи чутливість моделі до змін вхідних даних або параметрів навчання.

Нижче крок за кроком описаний запропонований модифікований алгоритм навчання АНМ з додаванням регуляризації до функції втрат і оновленням ваг.

Крок 1. На першому етапі здійснюється ініціалізація ваги нейронної мережі випадковими значеннями. Позначимо матрицю ваг $W^{(l)}$ між шаром l та l + 1.

Крок 2. Далі вхідні дані подаються на вхідний шар, при цьому здійснюється активація $a^{(0)} = x$. Для кожного шару *l* можна записати:

$$z^{(l+1)} = a^{(l)} \cdot W^{(l)} + b^{(l)}; \tag{6.19}$$

$$a^{(l+1)} = f(z^{(l+1)}); (6.20)$$

де f – функція активації, $b^{(l)}$ – вектор зміщень шарі l.

Крок 3. На цьому етапі проводиться порівняння отриманого виходу *a*^(*L*) з вхідними даними *х* за допомогою функції втрат *L* згідно з виразом:

$$L(x,a^{(L)}) = \frac{1}{2 \cdot n} \cdot \sum_{i=1}^{n} \left(x_i - a_i^{(L)}\right)^2 + \lambda_1 \cdot \sum_{l} \sum_{i,j} \left|W_{ij}^{(l)}\right| + \lambda_2 \cdot \sum_{l} \sum_{i,j} \left(W_{ij}^{(l)}\right)^2; \quad (6.21)$$

де n – кількість елементів вхідних даних, λ_1 і λ_2 – коефіцієнти регуляризації для L_1 і L_2 відповідно.

Крок 4. Застосовуючи правило ланцюжка для обчислення градієнтів функції втрат за параметрами АНМ, здійснюється оновлення ваги та зміщення мережі з використанням градієнтного спуску:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - lpha \cdot rac{\partial L}{\partial W_{ij}^{(l)}};$$

(6.22)

$$b_j^{(l)} = b_j^{(l)} - \alpha \cdot \frac{\partial L}{\partial b_j^{(l)}}.$$
(6.23)

Кроки 2-4 повторюються для кожної епохи навчання або доти, доки не буде

досягнуто критерію зупинки (наприклад, зменшення функції втрат до певного порогу).

На підставі запропонованого алгоритму навчання АНМ пропонується формулюється теорема про оновлення ваг в АНМ з використанням градієнтного спуску з регуляризацією L_1 і L_2 як: «При використанні градієнтного спуску з регуляризацією L_1 і L_2 для оновлення ваг АНМ, ваги мережі будуть оновлюватися таким чином:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha \cdot \left(\frac{\partial L}{\partial W_{ij}^{(l)}} + \lambda_1 \cdot \operatorname{sign}\left(W_{ij}^{(l)}\right) + 2 \cdot \lambda_2 \cdot W_{ij}^{(l)} \right) \rangle.$$

Доведення. Приймається $W_{ij}^{(l)}$ – вага між нейронами *i* та *j* на шарі *l*, α – швидкість навчання, λ_1 і λ_2 – коефіцієнти регуляризації L_1 і L_2 відповідно. Відповідно до алгоритму градієнтного спуску з регуляризацією L_1 і L_2 , оновлення ваг відбувається згідно з виразом:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha \cdot \frac{\partial L}{\partial W_{ij}^{(l)}} - \alpha \cdot \lambda_1 \cdot \operatorname{sign}\left(W_{ij}^{(l)}\right) - 2 \cdot \alpha \cdot \lambda_2 \cdot W_{ij}^{(l)}.$$
(6.24)

Далі здійснюється виведення частинних похідних функції втрат за вагами для оновлення:

$$\frac{\partial L}{\partial W_{ii}^{(l)}} = \frac{\partial L}{\partial a^{(l)}} \cdot \frac{\partial a^{(l)}}{\partial z^{(l)}} \cdot \frac{\partial z^{(l)}}{\partial W_{ii}^{(l)}}.$$
(6.25)

Після підстановки похідних функції втрат та активації отримано такий вираз:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha \cdot \left(\frac{1}{n} \cdot \left(a^{(L)} - x\right) \cdot f'(z^{(L)}) \cdot a^{(L)} + \lambda_1 \cdot \operatorname{sign}(W_{ij}^{(l)}) + 2 \cdot \alpha \cdot \lambda_2 \cdot W_{ij}^{(l)}\right).$$
(6.26)

Отже, згідно з (6.26) отримано оновлення ваг АНМ з урахуванням градієнта функції втрат та регуляризації L_1 і L_2 . У виведенні цього доказу теореми показано, як оновлюються ваги АНМ при використанні градієнтного спуску з регуляризацією L_1 і L_2 . Зокрема, видно, що оновлення вагів включає три компоненти:

1. Градієнт функції втрат за вагами, який відповідає за корекцію ваги з урахуванням помилки між виходом мережі та вхідними даними.

2. Регуляризація L1, що штрафує за абсолютне значення ваги. Це допомагає у зменшенні складності моделі та перешкоджає перенавчанню.

3. Регуляризація L2, що штрафує за квадрат ваг. Вона також допомагає контролювати складність моделі та зменшити перенавчання.

Отже, оновлення вагів враховує як помилку на навчальних даних, так і два види

регуляризації, що допомагає у створенні узагальнюючої та стійкої моделі.

В рамках розв'язання задачі відновлення інформації при відмовах датчиків з використанням АНМ здійснено модельний експеримент, за результатами якого отримано 5062 значень термогазодинамічних показників (подій) ГТД вертольоту (на прикладі авіаційного двигуна ТВЗ-117), з яких 4978 значень виділено як сприятливі події, а 84 – як несприятливі події. Оскільки несприятливих подій мало, то при навчанні моделі на цієї множині виникає висока ймовірність помилки першого роду (невірне значення термогазодинамічного показника виявлено вірним). Можливо навчити модель зі зміщенням найбільшої помилки в зону другого роду (вірне значення термогазодинамічного показника визнано невірним). При цьому помилка залишиться допустимою. У такому разі допустима частка вірних значень термогазодинамічних показників буде перерахована за універсальною математичною моделлю авіаційних двигунів з вільною турбіною. У цій роботі приймається, що модель навчається на сприятливих подіях. При навчанні виділяється головна компонента множини, а поверхня, що розділяє, зсувається до меж цієї множини. У разі виникнення відхилення моделі вище деякого порогового значення, подія визнається несприятливою. Набір ознак, методи попередньої обробки даних та усунення пропусків детально описані у [487]. Прийнято, що $\mathbf{Y} = (y_1, y_2, ..., y_p)$ – множина відгуків про події, $X_i^m = (x_{1i}, x_{2i}, \dots, x_{mi})$ – множина із *m* ознак *i*-ї події; $\mathbf{Y}^0 = \{y_i = 0 | y_i \in \mathbf{Y}, i = \overline{1, p}\}$ – клас сприятливих подій; $\mathbf{Y}^{1} = \left\{ y_{i} = 1 | y_{i} \in \mathbf{Y}, i = \overline{1, p} \right\}$ – клас несприятливих подій. Обсяг даних після усунення та обробки пропусків складає n = 4 - кількість нейронів вхідного і вихідного шарів; $v = 3 - кількість нейронів прихованого шару («горла»); <math>|\mathbf{Y}^0| = 2893, |\mathbf{Y}^1| = 66$. В якості вчителя використано $X_{i}^{\prime m} = (x_{1i}^{\prime}, x_{2i}^{\prime}, ..., x_{mi}^{\prime}) -$ дублікат множини ознак X_{i} . Тобто замість розв'язання задачі класифікації $F: X_i \to y_i$ отримано $F: X_i \to X'_i$. АНМ навчалася на множині \mathbf{Y}^0 і мінімальне відхилення навчання за кожним вихідним нейроном приймалося як порогове значення класифікації. Після навчання АНМ деяка тестова подія y_k оцінювалася як: $y_k = 1$, якщо виникло відхилення вище від порогового в одному з вихідних нейронів; $y_k = 0$, якщо відхилення по всіх вихідних нейронах не перевищувало порогового. Використано сигмоїдну функцію активації, функцію втрат – різницю по кожному вихідному нейрону. Навчання проводилося шляхом зворотного поширення

помилки [487].

Тестова множина складалася із 132 подій (всі події \mathbf{Y}^1 і, порівняно, 66 подій з \mathbf{Y}^0). Навчальна множина складалася з 2827 подій (всі інші події \mathbf{Y}^0). На тестовій множині досягнуто 100 % точності. При додаванні 12 несуттєвих ознак [487] досягнуто точності 99,53 %, де 0,47 % – помилка другого роду (4 вірних значень термогазодинамічного показника визнано невірним). Зазначається, що результати отримані на відносно невеликій тестовій множині. Для об'єктивної перевірки необхідний доступ до більшого обсягу несприятливих подій та різні етапи повторних тестувань.

Приймається, що V – множина нейронів прихованого шару. При цьому, в АНМ (рис. 6.6), для $F_1: X_i \to V$ і $F_2: A \to X'_i$ виконується

$$F_2(V): F_1^{-1}(X) + \varepsilon^n;$$
 (6.27)

де $\varepsilon^n = (\varepsilon_1, \varepsilon_2, ..., \varepsilon_n)$ – помилка навчання.

Вважається, що АНМ зробила навчання, якщо $\varepsilon^n = \sigma^n$, де $\sigma^n = (\sigma_1, \sigma_2, ..., \sigma_n)$ – непереборна помилка навчання [486]. Прихований шар V меншої розмірності підсилює значення, що дозволяють здійснити зворотне відображення $F_2(V)$ з найменшою помилкою $\varepsilon^n \to \sigma^n$, і послаблює значення, що вносять шум. Тоді $F_2(V)$ при $\varepsilon^n = \sigma^n$ є головною компонентою множини **X**ⁿ (рис. Ж.11).

Класифікація тестової події y_k можлива на площині помилок за рахунок оцінювання відхилень від головної компоненти $F_2(V)$. Оскільки навчання проводилося на множині \mathbf{Y}^0 , то передбачається, що відхилення для подій \mathbf{Y}^1 буде вищим. На площині помилок



Рисунок 6.10 – Графік класифікації на площині помилок (чорні точки – **Y**⁰, білі точки – **Y**¹) (авторський доробок [486] на основі [487])

події \mathbf{Y}^0 сконцентруються в зоні нуля, а \mathbf{Y}^1 розподіляться по всьому простору. Отже, класифікація на площині помилок буде простішою, ніж на площині ознак (рис. Ж.2).

Класифікація у просторі помилок (рис. Ж.2) може бути реалізованою окремими методами, зокрема, пороговою умовою (рис. 6.10) виду [487]:

$$y_{k} = \begin{cases} 1, \exists e_{j} > \sigma_{j}, \varepsilon_{j} \in \varepsilon_{k} \\ 0, \forall e_{j} > \sigma_{j}, \varepsilon_{j} \in \varepsilon_{k} \end{cases}$$
(6.28)

Помилками другого роду тут є викиди класу \mathbf{Y}^0 . Зменшення кількості викидів можливе рахунок збільшення даних класу \mathbf{Y}^0 – головна компонента множини буде сформована точніше. При цьому збільшити обсяг даних про вірні значення термогазодинамічних параметрів ГТД вертольотів простіше, ніж про аномальні. Слід зазначити, що на рис. Ж.2 і 6.10 представлені двовимірні площини. При класифікації у багатовимірному вигляді помилка значно нижча.

При навчанні АНМ виду $F: X_i \to y_i$ на подібній множині ризик перенавчання вкрай великий. Оскільки даних \mathbf{Y}^1 значно менше \mathbf{Y}^0 , роздільні поверхні можуть розподілитися як показано на рис. Ж.З [487].

На наступному етапі обчислювального експерименту здійснюється аналіз динаміки функції втрат [488] АНМ на етапах навчання та валідації моделі (рис. 6.11). Цей аналіз є графічне відображення зміни функції втрат у часі (кількість епох навчання) для навчального та валідаційного наборів даних. Рис. 6.11 дозволяє оцінити процес навчання моделі та її узагальнюючу здатність. Отримані результати визначення динаміки функції втрат на етапах навчання та валідації моделі дозволили зробити такі висновки:



1. Динаміка функції втрат дозволила оцінити ефективність навчання моделі. Зменшення функції втрат на навчальному наборі даних свідчить про те, що модель успішно навчається і виявляє закономірності даних.

Рисунок 6.11 – Графік динаміки функції втрат на етапах навчання та валідації моделі (авторський доробок [486])

При цьому функція втрат на наборі даних валідації також зменшується, що свідчить про виключення ефекту перенавчання.

2. Порівнян ня динаміки функції втрат на навчальному та валідаційній вибірці дозволило оцінити узагальнюючу здатність моделі. Зменшення функції втрат як на навчальному, і на валідаційній вибірці і закономірності в даних. При цьому функція втрат на наборі даних валідації також зменшується, що свідчить про виключення ефекту перенавчання. 3. Аналіз динаміки функції втрат також допоміг визначити, чи потрібне коригування параметрів навчання, таких як швидкість навчання чи коефіцієнти регуляризації. Оскільки функція втрат зменшується як на навчальному, так і на валідаційній вибірці, можливо, зміни параметрів навчання для покращення процесу навчання АНМ не потрібні.

Додатково оцінено дивергенцію Кульбака-Лейблера [489] (рис. 6.12), яка показує інформаційну розбіжність (відносну ентропію) двох ймовірнісних розподілів і розраховується як:

$$D_{KL}(P||Q) = \sum_{i=0}^{N} P(x_i) \cdot \log\left(\frac{P(x_i)}{Q(x_i)}\right);$$
(6.29)

де $P(x_i)$ – вихідний розподіл, $Q(x_i)$ – апроксимуючий розподіл.

Як видно із рис. 6.12, максимальне значення відхилення між двох ймовірнісних розподілів значень параметрів ГТД ТВЗ-117 не перевищує 0,025 (2,5 %) і не перевищує максимальне значення функції втрат на етапах навчання та валідації моделі, яке також складає 0,025 (2,5 %), можна судити про допустиме розходження ймовірнісних розподілів параметрів ГТД ТВЗ-117.



Для моделювання ситуації відмови одного зі штатних датчиків ГТД ТВЗ-117 у програмному комплексі LabVIEW створено віртуальну установку, яка моделює систему з трьома датчиками: датчик частоти

Рисунок 6.12 – Графік дивергенції Кульбака-Лейблера (авторський доробок [486])

обертання ротора турбокомпресора (Д-2М), датчик частоти обертання ротора вільної турбіни (Д-1М), датчик температури газів перед турбіною компресора (14 здвоєних термопар Т-102) (рис. Ж.4).

Використовуючи розроблену віртуальну установку, у програмному комплексі LabVIEW змодельовано одиничний відмову датчика (поломку), а також відновлення втраченої інформації за допомогою АНМ. Результати відновлення втраченої інформації АНМ при виході з ладу одного із штатних датчиків ГТД ТВЗ-117 (на прикладі датчика температури газу в передній частині турбіни компресора) наведені на рис. 6.13, а. Результати процесу відновлення втраченої інформації з датчиків БСКД «оптимальної» АНМ у разі одиночних відмов датчиків (їх обриві) приведені на рис. 6.13, б, де «біла лінія» – значення параметра, «зелена лінія» – відновлене значення сигналу за допомогою АНМ, «червона лінія» – значення параметра, отримане від датчика.



Рисунок 6.13 – Графіки результатів відновлення втраченої інформації: а – при відмові одного з штатних датчиків; б – у разі одиночних відмов датчиків (їх обриві) (авторський доробок [486] на основі [483, 484])

Недоліком підходу, наведеному на рис. 6.13, а є висока похибка відновлення одиночних відмов датчиків БСКД: похибка відновлення значення з датчиків у разі обриву складає 4,5...5,0 %, а при поступовій відмові – до 5,5 %. Інший метод відновлення втраченої інформації з датчиків на основі АНМ включає використання буфера (стека пам'яті) для збереження останнього правильного значення у випадку відмови датчика (рис. 6.13, б). Згідно з експериментальними дослідженнями з використанням «оптимальної» АНМ, виявлено, що похибка відновлення втраченої інформації з датчиків у випадку одиночних відмов становить 1,5...2,0 %, а при поступових відмовах не перевищує 2,5 %. Далі зниження похибки відновлення втраченої інформації з датчиків досягається за рахунок використання логіки виявлення відмов, що ідентифікує відмову та ізолює датчик, що відмовив.

Задля покращення ефективності та зниження похибки відновлення втраченої інформації, використовуються нові методи, вдосконалені на основі досліджень професора

Жернакова С.В. [483, 484]. Зокрема, дані з датчиків постійно записуються у буфер, де при активності датчика фіксується робоче значення, а при його відмові – використовується відновлене значення. Система автоматично виконує такі кроки: отримує вихідні дані з датчиків, використовуючи попереднє значення параметра датчика, що відмовив, з буфера, задає максимальну кількість обчислень, ініціює лічильник обчислень на рівні 0, проводить обчислення виходів АНМ в емуляторі, збільшує лічильник обчислень на 1 та передає результат системі управління. При цьому, в запропонованій системі передбачається застосування додаткової нейронної мережі для ідентифікації параметрів складних динамічних об'єктів [486]. Пропонована система реалізована у вигляді удосконаленої функціональної схеми, розробленої професором Жернаковим С.В. у [483, 484], в якій відбувається автоматичне відновлення втраченої інформації з датчиків, а при виявленні відмови датчика інтегрована система допускового контролю використовує обчислення АНМ для запису в буфер (стек-пам'ять) (рис. Ж.5). У випадку, коли покази датчика виходять за межі допустимого діапазону, система допускового контролю оголошує датчик несправним та для відновлення його значення використовує останнє записане значення в буфері. Графік процесу відновлення втраченої з датчика Т_Г інформації АНМ на основі





запропонованого (модернізованого) підходу зображена на рис. 6.14, де «біла лінія» – значення параметра, «зелена лінія» – значення відновленого сигналу за допомогою нейронної мережі, «червона лінія» – значення параметра, отриманого з датчика. Похибка відновлення інформації з датчика у випадку його обриву та при поступовій відмові не перевищує 0,25 %.

Згідно з рис. 6.13, 6.14 похибка відновлення інформації з датчика при його обриві та поступовій відмові не перевищує 0,25 %. Тому рекомендується використовувати методику професора Жернакова С.В. [483, 484] для розробки, навчання і тестування нейронних мереж з метою відновлення втраченої інформації з датчиків. Ця методика включає такі етапи: попередня обробка даних (нормалізація, калібрування, оцифрування) для навчання нейронної мережі; статистична обробка даних для виявлення грубих похибок вимірювань; масштабування даних; вибір архітектури та структури нейронної мережі; визначення розміру горла на основі результатів коваріаційного аналізу методом головних компонент; вибір функцій активації, алгоритму навчання; навчання нейронної мережі; тестування; оцінка ефективності розроблених нейронних мереж у процесі відновлення втраченої інформації з датчиків. Результати відновлення інформації АНМ у разі відмови датчика T_{Γ} наведені у табл. Ж.З.

При відмові інших датчиків похибка відновлення не перевищує значень наведених у табл. Ж.З. Аналіз отриманих результатів показує високу ефективність застосування АНМ у процесі відновлення інформації. Результати відновлення інформації у разі подвійних (кратних) відмов датчиків n_{TK} і T_r^* наведені у табл. Ж.4.

Аналіз табл. Ж.3 і Ж.4 показує, що застосування АНМ архітектури 4–3–4 із запропонованим удосконаленим методом її навчання у складі удосконаленої функціональної схеми відновлення інформації (рис. Ж.5) дозволяє 10 % точніше відновлювати втрачену інформацію при одиночній відмові (обриві) датчика ГТД вертольотів порівняно з АНМ архітектури 5–4–5 у складі базової функціональної схеми відновлення інформації, розробленої професором Сергієм Жернаковим [483, 484]. Також застосування АНМ архітектури 4–3–4 із запропонованим удосконаленим методом її навчання у складі удосконаленої функціональної схеми відновлення інформації (рис. Ж.5) дозволяє на 14 % точніше відновлювати втрачену інформацію при подвійній (кратній) відмові датчиків ГТД вертольотів порівняно з АНМ архітектури 5–4–5 у складі базової функціональної схеми відновлення інформації, розробленої професором Сергієм Жернаковим [483, 484]. Збільшення точності відновлення втраченої інформації на 10…14 % є критичним за умови експлуатації ГТД вертольотів.

Результати роботи запропонованої АНС із модифікованим алгоритмом її навчання оцінювалися за допомогою таких метрик [486] – точність (precision), повнота (recall), F-міра, AUC (Area Under Curve – площа під ROC кривою) (табл. 6.1):

$$Precision = \frac{TP}{TP + FP}; \ Recall = \frac{TP}{TP + FN}; \ F_{{}_{\textit{mipa}}} = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall};$$
(6.30)

$$TPR = \frac{TP}{TP + FN} \cdot 100\%; \ FPR = \frac{FP}{TN + FP} \cdot 100\%.$$
(6.31)

Таблиця 6.1 – Результати порівняльного аналізу запропонованої АНМ зі згортковим автокодером і класичними методами машинного навчання (авторський доробок [486])

Алгоритм відновлення втра-	Вид даних	Метрики оцінки методів			AUC	Час нав-
ченої інформації		Precision	Recall	F_{Mipa}		чання
Пропонована АНН	Норма	0.989	0.987	0.988	0,990	5 хвилин
	Аномалія	0.967	0.967	0.968		43 секунд
Згортковий автокодер	Норма	0.953	0.949	0.951	0,957	38 хвилин
	Аномалія	0.902	0.903	0.902		16 секунд
Лінійна регресія	Норма	0.772	0.622	0.594	0,654	2 хвилин
	Аномалія	0.685	0.522	0.466		11 секунд
Метод опорних векторів	Норма	0.902	0.903	0.902	0,904	6 хвилин
	Аномалія	0.788	0.781	0.784		11 секунд
Оптимізований метод опор- них векторів	Норма	0.949	0.943	0.945	0,948	18 хвилин
	Аномалія	0.795	0.798	0.793		24 секунд

6.3. Розробка методу парирування відмов в каналах вимірювань системи автоматичного управління газотурбінних двигунів вертольотів за допомогою фільтрації Калмана

Альтернативним підходом розв'язання задачі діагностики та парирування відмов датчиків параметрів ГТД вертольотів, що реєструються на борту вертольоту, є використання алгоритмів багатовимірної Калман-фільтрації з вбудованою логікою виявлення та локалізації відмови вимірювального каналу [490–493]. Математична модель двигуна включає відмовостійкий блок Калман-фільтрації з математичною моделлю каналу дозувальної голки. Цей блок отримує розрахункове значення термогазодинамічного параметру ГТД вертольоту та прогнозоване положення поршня дозувальної голки ($x_{зад}$) з модифікованої закритої бортової нейромережевої АПУ ГТД вертольотів. Вихід моделі дозувальної голки подається на вхід моделі диференціального клапана, де перетворюється на сигнал термогазодинамічного параметру ГТД вертольоту. Рекурсивний фільтр Калмана підключений на виході моделі дозуючої голки для коригування значень в умовах перешкод. Коефіцієнт Калмана адаптується в реальному часі для оптимальної оцінки переміщення поршня. Оскільки вимірюване значення використовується для отримання оптимальної оцінки, важливо надійно виявляти та локалізувати несправні вимірювальні

313



канали. Для досягнення цієї мети включено додаткову логіку в алгоритми Калман-фільтрації. Також використовувуються банки фільтрів Калмана [226, 494–505] (рис. 6.15) для оцінювання точності вимірювань групи датчиків, що дозволяє генерувати вектор відхилень:

$$\boldsymbol{\varepsilon}^{i} = \mathbf{x}_{opt}^{i} - \mathbf{z}_{mv}^{i}; \qquad (6.32)$$

де для *i*-датчика: ε^{i} – помилка оцінки, \mathbf{x}_{opt}^{i} – оптимальні оцінка (на виході відповідного фільтра Калмана), \mathbf{z}_{mv}^{i} – виміряне значення переміщення пор-

Рисунок 6.15 – Структура банку фільтрів Калмана [494]

шня. Для ідентифікації відмови датчиків обчислюється матриця зважених сум квадратів відхилень **WSSR** – ознака (або сигнатура) відмови [494–505], за допомогою матричного рівняння:

$$\mathbf{WSSR}^{i} = \frac{\mathbf{W}_{r}^{i} \left(\boldsymbol{\varepsilon}^{i}\right)^{I} \boldsymbol{\varepsilon}^{i}}{\boldsymbol{\Sigma}^{i}}; \qquad (6.33)$$

де матриця $\Sigma^{i} = diag \left[\mathbf{\sigma}^{i} \right]^{2}$.

Вектор σ^i є стандартними відхиленнями *i*-датчика, що нормує відхилення. Матриця скалярних вагових коефіцієнтів W_r містить параметри інженерної настройки, що вибираються так, щоб рівень елементів матриці **WSSR** не перевищував заданого порогового значення в умовах, коли всі датчики є справними. У випадку, коли W_r – одинична матриця, і $\varepsilon^i = \sigma^i$, відповідний елемент матриці WSSR буде дорівнювати числу вимірювальних каналів у групі. У випадку $\varepsilon^i \neq \sigma^i$ відповідно до [501–505] використовується спрощений вираз:

$$WSSR = \sum \frac{\varepsilon^2}{\sigma^2}.$$
 (6.34)

Важливо зазначити, що для одного каналу двоканального датчика також використовується вираз (6.34). Для виявлення відмови каналу одного датчика його відповідний **WSSR** порівнюється з граничним значенням, яке експертно визначається на основі статистичної обробки експериментальних даних для конкретного ГТД вертольоту. Також слід враховувати, що низьке порогове значення може призвести до помилкових спрацьовувань, а велике – до втрати чутливості системи до відмов. Відповідно до [501– 505] рекомендується вибирати значення сигнатури відмови в діапазоні 1,5...2 (обрано поріг, рівний 2).

Алгоритм виявлення та локалізації відмови каналу датчика ходу проілюстровано в табл. Ж.5. При інтеграції фільтрів банку Калмана з нейромережевими технологіями модифікована узагальнена структурна схема процесу настройки параметрів нейромережевої моделі ГТД вертольоту має вигляд, представлений на рис. Ж.6. Функціональні можливості банківських фільтрів Калмана наведені в табл. Ж.6.

Відповідно до [506], аналіз реальних шумів, отриманих у ході льотної експлуатації ГТД ТВЗ-117, виявив їх характеристики: середнє значення дорівнює нулю, постійна дисперсія та однакові спектри при розгляді як однієї великої вибірки, так і кількох вибірок. Отже, гіпотеза про ергодичність аналізованих процесів підтвердилася, оскільки середнє значення та дисперсія залишаються постійними як за часом, так і за кількістю реалізацій. Застосування критерію Пірсона підтверджує нормальність розподілу шумів, що дозволяє подальше використання фільтрів Калмана (включно з нейронними мережами, навченими з використанням фільтра Калмана) для цього типу процесів [506, 507]. Відповідно до [506] метою є мінімізація помилки як у модельному каналі (прогнозоване значення ідентифікованого параметра), так і в каналі вимірювання (поточні показання датчика) за чотирма параметрами: *G_T*, *n_{TK}*, *n_{CB}*, *T_Γ* [494–500]. У [490–493] застосовано класичний багатовимірний фільтр Калмана з обчисленням елементів матриці коефіцієнтів Калмана і кореляційної матриці, що оновлюється на кожному такті, що містить інформацію другого порядку про поверхню помилок. Це забезпечує методу розширеного фільтра Калмана перевагу порівняно з методами навчання першого порядку, такими як градієнтний спуск та його модифікації. Це дозволило у [490] навчити нейронну РБФ-мережу методом розширеного фільтра Калмана для дослідження ситуацій, коли всі вимірювальні канали АПУ ГТД вертольотів справні, і при відмові одного з каналів. Ключовим недоліком застосування класичного багатовимірного фільтра Калмана в даному контексті [490-493] є необхідність обчислення елементів матриці коефіцієнтів Калмана та кореляційної матриці на кожному такті, що потребує значних обчислювальних ресурсів. Для зменшення обчислювальної складності методу розширеного фільтра Калмана [490-493] створено використовувати альтернативний метод – фільтр Калмана з точками Чебишева, що дозволить уникнути необхідності обчислення якобіанів та матриць коваріації на кожному такті, оскільки точки Чебишева – це вузли, в яких інтерполяційний багаточлен Чебишева набуває максимальних значень за абсолютною величиною, що використовуються в методах чисельного аналізу, таких як інтерполяція та чисельне інтегрування, для зменшення помилок при виникненні за рівномірного розподілу точок [509, 510].

На першому етапі розробленого методу приймається, що x – вектор стану системи, z – вектор вимірів, \mathbf{F} – матриця переходу динамічної моделі системи, \mathbf{H} – матриця вимірів, \mathbf{Q} – коваріаційна матриця шуму процесу, \mathbf{R} – коваріаційна матриця шуму вимірів. Далі здійснюється ініціалізація початкового стану системи x_0 , матриці \mathbf{P}_0 і матриці виміровань \mathbf{H} . Після цього здійснюється вибір n точок Чебишева ξ_i в інтервалі [–1, 1] і відповідних ваг ω_i з подальшою мінімізацією функції вартості J, що враховує помилку оцінки стану системи, шляхом застосування методу оптимізації. Передбачається, що задана помилка оцінки стану системи e_k визначається як різниця між фактичним значенням та оціненим значенням стану системи:

$$e_k = x_k - x_k. \tag{6.35}$$

Функція вартості *J* як сума квадратів помилок оцінки кожної точки Чебишева визначається відповідно до виразу:

$$J = \sum_{i=1}^{n} \omega_i \cdot \left(e_k \left(\xi_i \right) \right)^2; \tag{6.36}$$

де ω_i – вага, що відповідає кожній точці Чебишева, $e_k(\xi_i)$ – помилка оцінки стану системи в точці Чебишева ξ_i .

Задача оптимізації (6.36) сформульована як:

$$Z = \min_{\omega_1, \omega_2, \dots, \omega_n} J \tag{6.37}$$

з обмеженнями

$$\sum_{i=1}^{n} \omega_i = 1, \ \omega_i \ge 0, \ i = 1, 2, ..., n.$$
(6.38)

Розв'язання задачі оптимізації (6.37) з обмеженнями (6.38) дозволить знайти оптимальні ваги ω_i , що мінімізують помилку оцінки стану системи при вибраних точках Чебишева. Для цього пропонується використовувати алгоритм оптимізації на основі еволюційних стратегій [511, 512], перевага якого перед іншими алгоритмами оптимізації, наприклад алгоритму градієнтного спуску, полягає в його здатності обходити локальні оптимуми і працювати в просторах функцій, де градієнти не визначені або неефективні.

На наступному етапі проводиться оновлення адаптивного порога для відмов шляхом обчислення адаптивного порога T_i на основі дисперсії σ_i^2 для кожного *i*-го вимірювального каналу. І тому адаптивний поріг T_i встановлюється як деяка функція кілька стандартних відхилень σ_i від середнього значення. Це дозволяє встановлювати пороги в залежності від статистичних характеристик даних, що робить їх більш адаптивними до змін даних. Приймається, k – коефіцієнт, що визначає, скільки стандартних відхилень передбачається використовувати як поріг. Тоді адаптивний поріг T_i для вимірювального каналу і обчислюється як:

$$T_i = k \cdot \sigma_i; \tag{6.39}$$

де σ_i – стандартне відхилення *i*-го вимірювального каналу.

Після обчислення адаптивного порогу здійснюється адаптивне оновлення матриці вимірювань **H** шляхом виключень вимірювальних каналів, які показують ознаки відмови, та оновлення матриці вимірювань **H**, виключаючи відповідні рядки. За умовою завдання задана матриця вимірювань **H** розмірності $m \times n$, де m – кількість вимірювань, а n – кількість станів або змінних станів, при цьому передбачається, що кожен вимірювальний канал має індикатори відмов, позначені як *fault_i*, де *i* – індекс вимірювального каналу. Нехай *fault_i* = 1 означає, що канал показує ознаки відмови. Тоді можливо створити нову матрицю вимірювань **H**', виключивши рядки, що відповідають каналам з ознаками відмови, тобто:

$$\mathbf{H'} = \begin{pmatrix} h_1 \\ h_2 \\ \dots \\ h_m \end{pmatrix}; \tag{6.40}$$

де $h_i - i$ -й рядок матриці **H**, що відповідає *i*-го виміру, для якого *fault*_i = 0.

Оновлена матриця вимірювань **H** міститиме лише рядки, які відповідають справним вимірювальним каналам, тобто $\mathbf{H} = \mathbf{H}'$. Це оновлення гарантує, що тільки справні вимірювальні канали будуть використовуватися при оновленні оцінки стану системи за допомогою фільтра Калмана.

Після цього здійснюється прогноз наступних станів системи та коваріаційної матриці помилки як:

$$x_{k+1} = F \cdot x_k; \tag{6.41}$$

$$P_{k+1}^- = F \cdot P_k \cdot F^T + Q. \tag{6.42}$$

Для кожної точки Чебишева і провадиться обчислення таких параметрів: – прогнозу виміру:

$$z_i = \mathbf{H} \cdot x_{k+1}. \tag{6.43}$$

– інновації:

$$y_i = z_i - \hat{z}_i. \tag{6.44}$$

- матриці Калмана:

$$K_{i} = P_{k+1}^{-} \cdot H^{T} \cdot \left(H \cdot P_{k+1}^{-} \cdot H^{T} + R \right)^{-1}.$$
(6.45)

- коригування прогнозу стану системи:

$$x_{k+1}^{+} = x_{k+1}^{-} + K_{i} \cdot y_{i}.$$
(6.46)

– оновлень коваріаційної матриці помилок:

$$P_{k+1}^{+} = P_{k+1}^{-} \cdot \left(I - K_i \cdot H \right).$$
(6.47)

На завершальному етапі здійснюється перевірка на відмови вимірювальних каналів. Перевіряється кожен вимір перевищення адаптивного порога T_i . Для кожного вимірювального каналу і перевіряється, чи перевищує нев'язка між поточним вимірюванням $\hat{z}_{k,i}$ і прогнозним вимірюванням $\hat{z}_{k,i}$ адаптивний поріг T_i як:

$$\left| \hat{z}_{k,i} - \hat{z}_{k,i} \right| > T_i. \tag{6.48}$$

Якщо нев'язка (6.48) перевищує поріг T_i це означає, що вимірювальний канал і показує ознаки відмови. Якщо вимірювальний канал і показує ознаки відмови, він виключається з оцінки стану. Оновлена матриця **H** міститиме лише ті рядки, які відповідають справним вимірювальним каналам, тобто виключаються рядки, що відповідають каналам з ознаками відмови, і формуємо нову матрицю $\mathbf{H} = \mathbf{H}'$ без цих рядків, де \mathbf{H}' – матриця вимірювань без рядків, що відповідають каналам із ознаками відмови. Після оновлення матриці **H** здійснюються повторні обчислення необхідних параметрів згідно (6.40)– (6.47). Повторення цієї процедури проводиться до тих пір, поки нев'язка (6.48) не перевищуватиме порога T_i . Отже, запропонований метод дозволяє швидко реагувати на відмови у вимірювальних каналах шляхом виключення відповідних каналів з оцінки стану та оновлення матриці вимірювань.

Створений метод діагностики та парування відмов вимірювальних каналів АПУ ГТД вертольотів з використанням модифікацій фільтру Калмана з точками Чебишева забезпечує збіжність оцінки стану системи до справжнього значення та стійкість системи до відмов вимірювальних каналів. Збіжність як обмеження різниці між істинним станом та оцінкою стану формулюється як:

$$\lim_{k \to \infty} \left(\mathbf{x}_k - \mathbf{x}_k \right) = 0; \tag{6.49}$$

де \mathbf{x}_k – вектор істинного стану системи в момент часу \mathbf{x}_k – оцінка стану, отримана з використанням модифікацій фільтра Калмана з точками Чебишева. Точки Чебишева рівномірно розподіляються за часовим інтервалом і враховуються при оновленні оцінки стану, що забезпечує більш точну оцінку навіть в умовах динаміки системи, що змінюється. Також механізми діагностики та парування відмов дозволяють системі швидко виявляти та компенсувати відмови у вимірювальних каналах. У результаті запропонований метод забезпечує збіжність оцінки стану системи до справжнього значення.

Оскільки для кожного *i*-го вимірювального каналу є адаптивний поріг T_i , який визначає максимально допустиму нев'язку між поточним виміром $z_{k,i}$ і прогнозним вимірюванням $\hat{z}_{k,i}$, то (6.48) є умовою стійкості системи до відмов, що означає стійкість оцінки стану системи за наявності відмов у вимірювальних каналах, оскільки запропонований метод дозволяє коректно виявляти та компенсувати ці відмови.

Для реалізації запропонованого методу діагностики та парування відмов вимірювальних каналів у АПУ ГТД вертольотів з використанням модифікацій фільтра Калмана з точками Чебишева з метою підвищення узагальнюючої здатності моделі та стійкості до різних типів даних та варіацій у даних доцільно застосувати модифіковану рекурентну нейронну мережу (рис. Ж.7) такої структури [496]:

1. Шар діагностики відмов – приймає на вхід часові послідовності вимірювань із

трьох вимірювальних каналів та реалізований як рекурентний шар, оскільки він має враховувати часові залежності у даних. Після рекурентного шару слід щільний шар або кілька щільних шарів для класифікації ймовірності наявності або відсутності відмов у кожному вимірювальному каналі.

2. Шар парирування відмов – аналізує прогнози від шару діагностики відмов та коригує оцінку стану системи у разі виявлення відмов та реалізований як рекурентний шар, за яким слідують щільні шари або комбінація згорткових та рекурентних шарів для аналізу просторових і часових закономірностей у даних.

3. Шар фільтрації та згладжування – покращує оцінку стану системи, враховуючи часові залежності та згладжуючи шуми та артефакти, та реалізований як рекурентний шар з кількома шарами рекурентних нейронів для обчислення часових залежностей.

4. Шар агрегації результатів – приймає на вхід прогнози та рішення від попередніх шарів та приймає остаточне рішення про стан системи та парирування відмов, та реалізований як щільний шар для об'єднання та обробки прогнозів.

Для навчання розробленої модифікованої рекурентної нейронної мережі для діагностики та парирування відмов вимірювальних каналів у АПУ ГТД вертольотів приймається, що $X = (x_1, x_2, ..., x_T)$ – задані тимчасові послідовності вимірювань вимірювальних каналів, де кожен x_t – вектор вимірювань на момент часу t, $Y = (y_1, y_2, ..., y_T)$ – відповідні мітки відмов для кожного вимірювального каналу, де кожен y_t може набувати значень 0 (норма) або 1 (відмова). Приймається, що запропонована модифікована рекурентна нейронна мережа складається з низки шарів: шару діагностики відмов, шару парування відмов, шару фільтрації та згладжування, та шару агрегації результатів, і є композицією функцій виду:

$$f(X) = A \Big[G \Big(H \Big(D(X) \Big) \Big) \Big]; \tag{6.50}$$

Для навчання запропонованої модифікованої рекурентної нейронної мережі у загальному вигляді використовується алгоритм зворотного поширення помилки (backpropagation) [512], згідно з яким необхідно мінімізувати функцію втрат L за параметрами мережі θ . Відповідно до запропонованої структури модифікованої рекурентної нейронної мережі функція втрат складається з декількох компонентів, що оцінюють якість діагностики відмов (L_{diazh}) та парирування відмов (L_{napup}), а також оцінку стану системи (*L*_{стан}), тобто:

$$\min_{\theta} L(f(X), Y).$$
(6.51)

Функція втрат $L \in$ узагальненою функцією втрат для діагностики відмов (L_{diach}), для парирування відмов (L_{napup}) та для оцінки стану системи (L_{cmah}) і визначається відповідно до виразу:

$$L = \alpha \cdot L_{\partial iar_{H}} + \beta \cdot L_{napup} + \gamma \cdot L_{cma_{H}}; \qquad (6.52)$$

де функції втрат для діагностики відмов (L_{diarh}), для парирування відмов (L_{napup}) та для оцінки стану системи (L_{cmah}) визначаються відповідно до виразів:

$$L_{\partial iach} = -\frac{1}{N} \cdot \sum_{i=1}^{N} \left(y_i \cdot \log\left(y_i\right) + \left(1 - y_i\right) \cdot \log\left(1 - y_i\right) \right) + \lambda_{\partial iach} \cdot RegTerm_1;$$
(6.53)

$$L_{napup} = -\frac{1}{N} \cdot \sum_{i=1}^{N} \left(y_i \cdot \log\left(y_i\right) + \left(1 - y_i\right) \cdot \log\left(1 - y_i\right) \right) + \lambda_{napup} \cdot RegTerm_2; \quad (6.54)$$

$$L_{cmaH} = \frac{1}{N} \cdot \left\| X_i - X_i \right\|^2 + \lambda_{cmaH} \cdot RegTerm_3;$$
(6.55)

де N – кількість прикладів у навчальному наборі, y_i і y_i – відповідні мітки та передбачені ймовірності відмов для *i*-го прикладу, y_i – передбачені ймовірності парирування відмов від нейронної мережі для *i*-го прикладу, X_i – передбачені значення стану системи, X_i – фактичні значення стану системи , λ_{diacn} , λ_{napup} , λ_{cman} – відповідні коефіцієнти регуляризації, які регулюють внесок регуляризації у загальну функцію втрат, $RegTerm_1$, $RegTerm_2$, $RegTerm_3$ – терміни регуляризації, які залежать від параметрів моделі та її складності. Варто відзначити, що додавання регуляризації в функції втрат може допомогти покращити узагальнюючу здатність моделі та зменшити ризик перенавчання, особливо за наявності великої кількості параметрів або невеликого обсягу даних. Методи вибору коефіцієнтів регуляризації наведено у [512].

Термін регуляризації зазвичай залежить від параметрів моделі та її складності. Один із поширених методів регуляризації – L_1 або L_2 регуляризація [513, 514] – додає штрафи за складність моделі, щоб запобігти перенавчанню (табл. Ж.7).

У (6.52) *α*, *β*, *γ* – коефіцієнти, що враховують відносний вплив кожної задачі на загальну функцію втрат, підходи до обчислення яких описані у [515]. У запропонованому

321

алгоритмі навчання модифікованої рекурентної нейронної мережі після кожної епохи навчання виконується фільтрація та згладжування прогнозів мережі з використанням запропонованого алгоритму фільтра Калмана з використанням точок Чебишева.

Отримані результати дозволяють сформулювати та довести дві теореми.

Теорема про збіжність алгоритму навчання модифікованої рекурентної нейронної мережі з використанням алгоритму фільтра Калмана з точками Чебишева: «При використанні алгоритму фільтра Калмана з точками Чебишева для оновлення параметрів модифікованої рекурентної нейронної мережі, послідовно мінімізуючи функцію втрат, навчання буде сходитися до локального раціонального рішення».

Доведення: Нехай задана нейронна мережа з архітектурою, визначеною в рамках запропонованого методу діагностики та парірування відмов вимірювальних каналів у АПУ ГТД вертольотів. Нехай також надано навчальний набір даних D і функція втрат $L(D, H, \Theta)$, що оцінює різницю між прогнозами моделі та фактичними значеннями. Для доведення того, що введення фільтра Калмана з точками Чебишева дозволяє ефективно враховувати шуми та невизначеності в даних, що полегшує збіжність процесу навчання, задається \mathbf{x}_t – вектор стану системи, \mathbf{z}_t – вимір, \mathbf{H}_t – матриця вимірювань, \mathbf{Q}_t – матриця коваріації процесу, \mathbf{R}_t – матриця підступності вимірювання. Оновлення стану за алгоритимом фільтра Калмана виражається як:

$$\mathbf{x}_{t} = \mathbf{F}_{t} \cdot \mathbf{x}_{t-1} + \mathbf{B}_{t} \cdot \mathbf{u}_{t} + \mathbf{K}_{t} \cdot \left(\mathbf{z}_{t} - \mathbf{H}_{t} \cdot \mathbf{x}_{t}\right), \tag{6.56}$$

де \mathbf{x}_t – оцінка стану на час t, \mathbf{F}_t – матриця переходу станів, \mathbf{B}_t – матриця управління, \mathbf{u}_t – вектор управління, \mathbf{K}_t – матриця Калмана.

Вираз (6.56) оновлення стану за алгоритмом фільтра Калмана інтегрує інформацію вимірювань та попередньої оцінки стану системи з урахуванням коваріації процесу та коваріації вимірів. Матриця переходу станів \mathbf{F} та вектор управління и використовуються для передбачення наступного стану системи на основі попереднього стану та зовнішнього управління. Матриця вимірів \mathbf{H} використовується для зіставлення очікуваного виміру з поточним станом системи. Матриця Калмана \mathbf{K} , що обчислюється на основі коваріації процесу \mathbf{Q} та коваріації вимірювань \mathbf{R} , визначає, як сильно коригувати передбачений стан системи на основі різниці між очікуваним та реальним виміром. Це дозволяє враховувати невизначеності даних, такі як шуми вимірювань і невідомі впливу на стан системи.

Для доведення того, що застосування регуляризації дозволяє контролювати складність моделі та запобігати її перенавчанню, що сприяє стабільнішій збіжності, вводиться регуляризація для контролю складності моделі виду:

$$\mathbf{L}_{per}(\mathbf{\Theta}) = \mathbf{L}(\mathbf{D}, \mathbf{H}, \mathbf{\Theta}) + \boldsymbol{\lambda} \cdot \boldsymbol{\Omega}(\mathbf{\Theta}); \qquad (6.57)$$

де L_{per}(Θ) – регуляризована функція втрат, L(D, H, Θ) – функція втрат без регуляризації, Ω(Θ) – штрафний член, λ – коефіцієнт регуляризації.

Вираз (6.57) дозволяє контролювати складність моделі та запобігати її перенавченню шляхом додавання штрафу за складність моделі до звичайної функції втрат. Регуляризація допомагає створити більш стійку модель, яка краще узагальнює дані і має меншу схильність до перенавчання, оскільки її компонент L(D, H, Θ) оцінює помилку моделі на навчальному наборі даних та спрямований на мінімізацію різниці між передбаченими та фактичними значеннями, $\Omega(\Theta)$ штрафує модель за складність і зазвичай виражається через норму параметрів моделі (наприклад, L1- або L2-норму) або інші міри складності моделі – число параметрів, а гіперпараметр λ регулює внесок регуляризації в порівнянні з основною функцією втрат, при цьому великі значення λ збільшують штраф за складність моделі, що призводить до більш простих моделей, в той час як маленькі значення дозволяють моделі підлаштовуватися під дані.

Для доказу того, що ітеративний процес мінімізації функції втрат з використанням градієнтних методів оновлення параметрів гарантує наближення до локального оптимуму, приймається, що процес навчання нейронної мережі з використанням алгоритму фільтру Калмана та регуляризації грунтується на ітеративному оновленні параметрів мережі:

$$\boldsymbol{\Theta}_{t+1} = \boldsymbol{\Theta}_t - \boldsymbol{\eta} \cdot \nabla \mathbf{L}_{reg} \left(\boldsymbol{\Theta}_t \right); \tag{6.58}$$

де Θ_t – параметри мережі на ітерації t, η – швидкість навчання.

Ітеративний процес мінімізації функції втрат з використанням градієнтних методів гарантує наближення до локального оптимуму функції втрат, оскільки градієнт функції втрат $\nabla L_{reg}(\Theta_t)$ вказує напрямок якнайшвидшого зростання функції втрат, при цьому обчислюється градієнт у поточній точці Θ_t , щоб зменшення функції втрат. Параметр η визначає розмір кроку, який робиться у напрямку антиградієнта, що дозволяє йому контролювати швидкість збіжності: великі значення η можуть прискорити навчання, але можуть призвести до розбіжності, а занадто малі значення можуть уповільнити навчання. Віднімання з поточних параметрів Θ_t добутку градієнта на швидкість навчання $\nabla L_{reg}(\Theta_t)$ наближає параметри локального мінімуму функції втрат. Це відбувається шляхом руху у напрямі якнайшвидшого зменшення функції втрат.

Отже, поєднання алгоритму фільтра Калмана з точками Чебишева, регуляризації та градієнтного спуску забезпечує збіжність процесу навчання нейронної мережі до локального оптимуму функції втрат.

Для доведення ергодичності процесу, перевірено виконання умови Слуцького, відповідно до якої автоковаріаційна функція ергодичного процесу має збігатися до нуля при збільшенні значення лага [496]. Результати проведених досліджень підтверджують відповідність гіпотези щодо ергодичності спостережуваних процесів. Графіки аналізу для n_{TK} , T_{Γ}^* , n_{CB} наведені на рис. 6.16.



Рисунок 6.16 – Графіки автоковаріаційної функції: а – параметр n_{TK} ; б – параметр n_{CB} ; в – параметр T_{Γ}^* (авторський доробок [496])

Аналіз реальних шумів, отриманих за даними льотної експлуатації ГТД ТВЗ-117, показав, що вони характеризуються нульовим математичним очікуванням, постійної дисперсією і однаковими спектрами щодо однієї вибірки великий тривалості і кількох вибірок. Отже, підтвердилася гіпотеза ергодичності аналізованих процесів, оскільки величини математичного очікування та дисперсії однакові як за часом, так і за кількістю реалізацій. Все це дозволяє зробити висновок про можливість застосування запропонованого алгоритму фільтра Калмана з використанням точок Чебишева для даного класу завдань – задачі діагностики та парування відмов вимірювальних каналів АПУ ГТД вертольотів.

На першому етапі обчислювального експерименту здійснювалося побудова кривої
навчання модифікованої рекурентної нейронної мережі (рис. 6.17, а) з метою аналізу змін функції втрат на навчальному та валідаційному наборах даних залежно від кількості ітерацій навчання, що допомагає оцінити ефективність навчання та виявити перенавчання або недонавчання моделі. Як видно із рис. 6.17, а, функція втрат як на навчальному, так і валідаційному наборах даних залишається стабільною протягом 1000 епох навчання і не виходить за межі від -0.025 до +0.025 (від -2.5 % до +2.5 %), що свідчить фактично про нульовий ризик перенавчання або недонавчання моделі. На рис. 6.17, б наведено графік розподілу метрики точності на навчальному та валідаційній вибірці в залежно від кількості ітерацій навчання, з якого випливає, що протягом 1000 епох навчання метрика точності фактично досягає значення 1 і, як наслідок, модель демонструє високий ступінь навчання та здатна давати точні передбачення на заданому наборі даних (табл. Б.3).



Рисунок 6.17 – Графік зміни функції втрат (а) і метрики точності (б) модифікованої рекурентної нейронної мережі (авторський доробок [512])



Рисунок 6.18 – Осцилограма зміни сигналу температури газу перед турбіною компресора на виході багатовимірного фільтра Калмана з точками Чебишева (авторський доробок [512]) Для проведення обчислювального експерименту, використовуючи віртуальну установку, розроблену у програмному комплексі LabVIEW (рис. Ж.4), у роботі розглядається вимірювальний канал температури газів перед турбіною компресора (14 здвоєних термопар T-102). На рис. 6.18 наведено результати комп'ютерного моделювання розробленого фільтра Калмана з точками Чебишева (біла крива — вихідний сигнал із датчика, червона крива — відновлений сигнал нейронною мережею, зелена крива — відфільтрований сигнал). Метою застосування запропонованого багатовимірного фільтра Калмана з точками Чебишева є визначення найбільш ймовірного значення вимірюваного за їх допомогою реального параметра — його оптимальної оцінки, отриманої з урахуванням «зашумленого» модельного (прогнозованого) значення та вимірювання датчика.

Аналогічно до [501–505], на наступному етапі обчислювального експерименту було змодельовано значення показників координатного вектору-стовпця датчика температури газу перед турбіною компресора в умовах шуму, що складається з гаусового шуму, з реального шуму даних експериментальних випробувань ГТД ТВЗ-117, високочастотної синусоїди та комбінованого шуму. Результати фільтрації під дією комбінованого шуму для різних вхідних сигналів, що змінюють ідентифіковані значення у всьому робочому діапазоні (розгін – режим роботи – скидання) по одній координаті – температура газу перед турбіною компресора – наведені на рис. 6.19, де біла крива описує зміну в часі координат вектору-стовпця вхідних даних розрахункових (модельних) значень n_{TK} , n_{CB} , T_{Γ} , червона крива описує зміну в часі координат вектор-стовпця, виміряних за датчики значень координат n_{TK} , n_{CB} , T_{Γ} , зелена крива описує зміну в часі координат вектору-стовпця оптимальних оцінок координат n_{TK} , n_{CB} , T_{Γ} , отриманих за допомогою традиційного багатовимірного фільтра Калмана з використанням нейронної мережі радіальних базисних функцій, синя крива описує зміну в часі координат вектору-стовпця оптимальних оцінок координат n_{TK} , n_{CB} , T_{Γ} , отриманих за допомогою запропонованого багатовимірного фільтра Калмана з точками Чебишева за допомогою модифікованої рекурентної нейронної мережі.



Рисунок 6.19 – Результати застосування запропонованого багатовимірного фільтра Калмана з точками Чебишева в робочому режимі в умовах комбінованого шуму (авторський доробок [512] на основі [501–505])

Проведені дослідження показали, що відносна похибка сигналів на виході моделі запропонованого багатовимірного фільтра Калмана з точками Чебишева для координат n_{TK} , n_{CB} , T_{Γ} не перевищує 0,125 %, що відповідає встановленим технічним вимогам до точності ідентифікації, в той час при застосуванні традиційного багатовимірного фільтра Калмана 0.25 % у [496] та 0,5 % у [501]. Отримані результати свідчать про зменшення похибки сигналів у 2 рази порівняно з [496] та у 4 рази – порівняно з [501].

На наступному етапі обчислювального експерименту згідно з обчисленими значеннями WSSR аналогічно [494–505] проводилося моделювання ситуацій, коли всі канали вимірювання n_{TK} , n_{CB} , T_{Γ} справні (враховуючи сигнал з меншим **WSSR** для виявлення та локалізації відмови) і випадок несправності каналу, що виник у момент часу t = 2,1 с (враховуючи сигнал зі справного датчика для виявлення та локалізації відмови) (рис. 6.20). При цьому значення поршня голки, що дозує, визначається співвідношенням:



$$X_{\mathcal{A}\Gamma} = k_1 \cdot n_{TK} \cdot k_2 \cdot n_{CB} \cdot k_3 \cdot e^{-k_4 \cdot T_{\Gamma}^*};$$
(6.59)

де $X_{\mathcal{I}\mathcal{I}}$ – сигнал положення поршня голки, що дозує, k_1 , k_2 , *k*₃, *k*₄ – коефіцієнти, що підбираються емпірично, для класу ГТД вертольотів шляхом аналізу експериментальних досліджень рекомендовані такі значення: $k_1 = 0,001, k_2 = 1,2,$ $k_3 = 0.8, k_4 = 0.0002.$

(6.59)

Оскільки однією із пріоритетних задач АПУ ГТД вертольотів [495] є забезпечення

Рисунок 6.20 – Результати моделювання ситуацій, коли обидва вимірювальні канали двоканального датчика справні і при несправності другого каналу

(авторський доробок [512] на основі [501-505]) стабільності параметрів роботи двигуна, шляхом коректного дозування подачі палива (витрати палива – G_T) в камеру згоряння, для забезпечення надійності вхідної інформації АПУ ГТД вертольотів проводиться фільтрація вхідних інформаційних потоків, для чого будується відмовостійкий блок фільтрації, що включає математичну модель каналу ДГ, що дозволяє отримати розрахункові дані про витрату палива по заданому значенню

положення поршня ДГ $X_{\mathcal{I}\Gamma}^{3a\partial}$. Вихідним сигналом моделі ДГ є прогнозоване (модельне) значення положення поршня $X_{\mathcal{I}\Gamma}$. При цьому передавальна функція ДГ має вигляд [495]:

$$W_{\mathcal{A}\Gamma}\left(p\right) = \frac{X_{\mathcal{A}\Gamma}^{3a\partial}}{X_{\mathcal{A}\Gamma}} = \frac{1}{0,1 \cdot p + 1}.$$
(6.60)

З огляду на, що АПУ ГТД вертольотів працює в умовах перешкод, як в каналі моделі (обумовлених її неточністю), так і в каналі вимірювання (обумовлених похибкою датчиків), для забезпечення надійності ідентифікації керуючого сигналу G_T на виході моделі ДГ підключений рекурсивний фільтр Калмана, основною властивістю якого є його здатність до адаптації – самокорекції в процесі фільтрації даних. Алгоритми самокорекції будуються на визначенні в поточний момент t_k оптимального коефіцієнта Калмана (K_k) в результаті розв'язання задачі мінімізації математичного очікування квадрата помилки ідентифікованого параметра min $M(e_{k+1}^2)$ з урахуванням оптимальної оцінки в попередній момент. Коефіцієнт Калмана задає розподіл усіх співвідношення модельної і виміряної складових в оптимальному значенні ідентифікованого $X_{ДT}$. Алгоритм Калман-фільтрації [495, 512] включає обчислення на кожному кроці:

$$M(e_{k+1}^{2}) = \frac{\sigma_{\eta_{k}}^{2}\left(M(e_{k}^{2}) + \sigma_{\xi_{k}}^{2}\right)}{M(e_{k}^{2}) + \sigma_{\xi_{k}}^{2}\sigma_{\eta_{k}}^{2}};$$
(6.61)

$$K_{k+1} = \frac{M(e_k^2) + \sigma_{\xi_k}^2}{M(e_k^2) + \sigma_{\xi_k}^2 \sigma_{\eta_k}^2};$$
(6.62)

$$X_{\mathcal{I}\Gamma_{k+1}}^{opt} = K_{k+1}Z_{\mathcal{I}\Gamma_{k+1}} + (1 - K_{k+1}) \Big(X_{\mathcal{I}\Gamma_{k}}^{opt} + \Delta X_{\mathcal{I}\Gamma_{k}} \Big).$$
(6.63)

де $M(e_{k+1}^2)$ – мінімальне значення математичного очікування квадрата помилки; ξ_k , η_k – похибки моделі і датчика; K_{k+1} – коефіцієнт Калмана; σ_{ξ_k} , σ_{η_k} – дисперсії моделі і датчика; $X_{\beta\Gamma_k}^{opt}$ – оптимальна оцінка ідентифікованої величини переміщення поршня; z_k – показання датчика переміщення поршня; $X_{\beta\Gamma_k} = X\Delta t$ – приріст переміщення поршня, отриманий на (k + 1)-му кроці за допомогою розробленої математичної моделі ДГ.

Спільне розв'язання диференціальних рівнянь (6.62)–(6.63) дозволило визначити передавальну функцію фільтра Калмана $W_K(p) = 1$.

Якість фільтрації багато в чому визначається валідністю використовуваних в обчисленнях вимірювань переміщення поршня ДГ. Реалізоване на практиці апаратне резервування передбачає дублювання вимірювань за допомогою двоканальної системи датчиків. У зв'язку з цим актуальною задачею є забезпечення надійної ідентифікації несправних інформаційних каналів, для чого пропонується в алгоритми Калман-фільтрації включати додаткову логіку виявлення та локалізації відмови (ВЛВ) каналу датчика, що забезпечує підвищення надійності [495, 512].

З виходу відмовостійкого блоку фільтрації (з вбудованим алгоритмом ВЛВ) сигнал ходу поршня надходить на диференційний клапан (регулятор перепаду тиску), математична модель якого будується на співвідношеннях:

$$G_{T_1} = G_T + \Delta G_T; \tag{6.64}$$

$$\frac{dG_T}{dt} = \frac{1}{T_1} \Big(G_{T_1} - G_T \Big); \tag{6.65}$$

де $T_1 = 0,05$ с, а залежності $\Delta G_T = f(X_{\mathcal{A}T}), G_{T_1} = f(X_{\mathcal{A}T})$ задаються у вигляді експериментальних таблиць. Вихідним параметром диференціального клапана є витрата палива G_T , який надходить на вхід моделі авіаційного двигуна ТВЗ-117.

Важливим показником надійності системи є її стійкість, що визначається видом частотних характеристик систем. Результати моделювання в середовищі MatLab логарифмічних амплітудо- і фазочастотних характеристик (ЛАЧХ і ЛФЧХ) з'єднання елементів, що включає фільтр Калмана з вбудованим блоком ВЛВ і диференційний клапан (регулятор перепаду тиску), наведені на рис. 6.28. На вхід послідовного з'єднання елементів подається сигнал $X_{д\Gamma}$ з виходу математичної моделі ДГ, на виході – сигнал витрати палива G_T .



Рисунок 6.21 – ЛАЧХ (а) і ЛФЧХ (б) блоку виявлення та локалізації відмов (авторський доробок [512] на основі [495])

Отримані в результаті модельного експерименту ЛАЧХ і ЛФЧХ відповідають класичному аперіодичної ланки першого порядку з параметрами (аналогічно як у [495, 512]): коефіцієнт підсилення визначається з 20lgk = 46 дБ і дорівнює $k \approx 200$; постійна часу $T_2 = \frac{1}{\omega_2} = 0,05$ с; нахил ЛАЧХ при $\omega > \omega_1$ дорівнює -20 дБ/дек; частота зрізу визна-

чається з
$$L(\omega_{3p}) \approx 20 \lg \left(\frac{k}{T\omega_{3p}}\right) = 0$$
 і дорівнює $\omega_{3p} = \frac{k}{T} \approx 4 \cdot 10^3$ рад/с; фаза на всьому діа-
пазоні частот змінюється від 0 до -90°; величина фази на частоті зрізу
 $\theta_{3p} = -\operatorname{arctg}(T_1\omega_{3p}) \approx -90^\circ$.

Передавальна функція розглянутого з'єднання елементів збігається з функцією передачі диференціального клапана (регулятора перепаду тиску):

$$W_{2}(p) = \frac{G_{T}(p)}{X_{\mathcal{A}\Gamma}(p)} = \frac{200}{0,05 \cdot p + 1}.$$
(6.66)

Це підтверджує правильність аналітичних перетворень, що дозволили обчислити передавальну функцію фільтра Калмана $W_K(p) = 1$. Крім того, результати модельного експерименту дозволяють стверджувати, що $W_{BЛB}(p) = 1$. Загальна передавальна функція відмовостійкого блоку введення вхідної інформації ГТД вертольотів складає:

$$W(p) = \frac{1}{0, 1 \cdot p + 1} \cdot \frac{200}{0, 05 \cdot p + 1}.$$
(6.67)

Оскільки корені характеристичного рівняння розглянутого блоку введення $p_1 = -10 \text{ c}^{-1}, p_2 = -20 \text{ c}^{-1} -$ дійсні і негативні, він є аперіодичною ланкою другого порядку (аналогічно як у [495]). ЛАЧХ і ЛФЧХ відмовостійкого блоку введення інформації представлені на рис. 6.22. Параметри відмовостійкого блоку введення інформації: ко-ефіцієнт підсилення визначається з 20lgk = 46 дБ і дорівнює $k \approx 200$; постійні часу: $T_2 = \frac{1}{\omega_2} = 0,05$ с; $T_2 = \frac{1}{\omega_1} = 0,1$ с; нахил ЛАЧХ при $\omega_1 < \omega < \omega_2$ дорівнює –20 дБ/дек, при $\omega > \omega_2$ дорівнює –40 дБ/дек.



Рисунок 6.22 – ЛАЧХ (а) і ЛФЧХ (б) відмовостійкого блоку введення вхідної інформації (авторський доробок [512] на основі [495])

Слід зазначити, що розглянутий блок охоплений через АПУ зворотним зв'язком, що підвищує його запас стійкості [495]: частота зрізу визначається з $L(\omega_{3p}) \approx 201g \left(\frac{k}{T_1 T_2 \omega_{3p}}\right) = 0$ і дорівнює $\omega_{3p} = \frac{k}{T_1 T_2} \approx 200$ рад/с; фаза на всьому діапазоні частот змінюється від 0 до -180° ; величина фази на частоті зрізу $\theta_{3p} = -\operatorname{arctg}\left((T_1 \omega_{3p}) + \operatorname{arctg}(T_2 \omega_{3p})\right) \approx -180^\circ.$

Отже, важливим результатом проведеного дослідження частотних характеристик є підтвердження того, що коефіцієнт підсилення розробленого блоку виявлення та локалізації відмов дорівнює одиниці, і відсутні додаткові фазові зрушення, викликані можливим чистим запізненням, обумовленим особливостями застосовуваних алгоритмів виявлення відмов у вимірювальних каналах та Калман-фільтрації вхідних даних моделі газотурбінного двигуна ТВ3-117. Отже, демонструється їхній незначний вплив на стійкість системи автоматичного управління газотурбінного двигуна ТВ3-117. Перевірка ефективності запропонованого алгоритму багатовимірного фільтра Калмана з точками Чебишева показала, що відносна середня похибка в динаміці становить 0,124 %, а в статиці при максимальній витраті палива $G_T = 330$ кг/год знижується до 0,097 %. Це відповідає сучасним вимогам точності алгоритмів ідентифікації в контурі дозування палива ГТД вертольотів, у тому числі газотурбінного двигуна ТВ3-117.

На етапі порівняльного аналізу запропонованого методу діагностики та

парування відмов у каналах вимірювання АПУ ГТД вертольотів з відомими проводилася оцінка помилок 1-го та 2-го роду (табл. Ж.8) для запропонованого алгоритму багатовимірного фільтра Калмана з точками Чебишева без застосування нейронних мереж, як у [494], із застосуванням РБФ-мережі, як у [495], та із застосуванням запропонованої модифікованої рекурентної нейронної мережі. Порівняльний аналіз показав, що застосування модифікованої рекурентної нейронної мережі знижує помилки 1-го та 2-го роду у 1,24...1,71 разів у порівнянні із застосуванням РБФ-мережі [495] та у 1,70...2,90 разів – у порівнянні без застосування нейронних мереж [494].

Розроблено низку додаткових методів і моделей.

У [516] розроблено нейромережеву систему для прогнозування аномальних даних у сенсорних системах, яка за допомогою препроцесора, предиктора, реконструктора та детектора аномалій забезпечує прогнозування аномалій з точністю до 98,2 %. У межах цього методу було розроблено модель препроцесора на основі SARIMAX, що дозволяє враховувати автокореляцію, сезонні коливання та зовнішні регресори, забезпечуючи точність прогнозування часових рядів до 97,9 %. Модель предиктора на базі модифікованої мережі LSTM з додатковими шарами Dropout та Dense забезпечує прогнозування даних із сенсорів з похибкою не більше 0,218 %, що підтверджено експериментами на прикладі температури газів двигуна TB3-117. Модель реконструктора дозволяє відновлювати пропущені значення часових рядів та замінювати викиди на синтетичні значення з точністю до 98,73 %. Детектор аномалій, використовуючи концепцію дисонансу, виявляє аномалії сенсорних даних з похибками I та II типу менше 1,12 % та 1,01 % відповідно, забезпечуючи час виявлення менш ніж 1,611 секунди, що підтверджує високу ефективність системи.

У [517] застосовано нейромережевий підхід для виявлення несправностей ротора турбокомпресора, таких як, відключення датчиків. Розроблено математичну модель для імітації одиничних і каскадних збоїв, яка враховує динаміку системи через диференціальні рівняння зі змінними коефіцієнтами та зовнішніми збуреннями. Архітектура нейронної мережі NARX із алгоритмом навчання на основі зворотного поширення похибки забезпечила точність виявлення відключень датчиків до 99,3 %, перевершивши комбінований генетичний алгоритм на 4,19 % за точністю. Апаратний стенд у середовищі Matlab Simulink продемонстрував середню похибку моделювання 1,04 % при 15 °C i 2,58 % при 24 °C, а метрики Precision (0,987), Recall (1,0), F1-score (0,993) та AUC (0,874) підтвердили високу ефективність у розрізненні нормальних і аварійних станів.

У [518] запропоновано метод створення інтелектуальної системи моніторингу динамічних об'єктів, що базується на самоперевірювальних сенсорах, здатних автономно збирати, обробляти та аналізувати дані в реальному часі, адаптуючись до змін середовища та коригуючи похибки вимірювань. Основна характеристика сенсорної системи описана аналітичним виразом, який враховує впливові змінні, часовий дрейф і калібрувальні параметри, що підвищує точність і стабільність вимірювань. Застосування нечіткої логіки дозволяє уточнювати коефіцієнт масштабування та ефективно розподіляти коригувальні значення, забезпечуючи високу точність результатів. Діагностика технічного стану сенсорів здійснюється за допомогою LSTM-мереж, інтегрованих з класифікатором більшості та блоком прийняття рішень на основі нечіткої логіки [519, 520]. Експерименти на двигуні ТВЗ-117 підтвердили високу ефективність системи, яка досягає 99,5 % точності у відновленні сенсорних даних під час переривань і демонструє мінімальні рівні хибних спрацювань. Порівняння з іншими підходами, такими як GRU та лінійні мережі, підтвердило перевагу запропонованого методу.

У [521] розроблено нейромережевий метод моніторингу сенсорів ГТД вертольотів, яка демонструє високу ефективність виявлення аномалій та відновлення даних, досягаючи точності 99,327 % після 200 епох навчання. Гібридна архітектура LSTM/GRU забезпечує послідовну обробку даних і збереження ключової інформації з попередніх станів, що є критичним для аналізу часових рядів та визначення залежностей. Модулі *Sensor_Fail_Clean* та *Sensor_Fail_Norm* адаптивно дискретизують і квантують вхідні дані, підвищуючи їх якість перед передачею в нейронну мережу. Запропонований алгоритм навчання, який базується на часовій регуляризації та комбінованому методі оптимізації (SGD з RMSProp), пришвидшує збіжність мережі та підвищує стійкість до проблем затухання градієнтів, скорочуючи час навчання до 4 хвилин 13 секунд при точності 0,993. У порівнянні з альтернативними підходами, такими як автоасоціативна нейронна мережа та модель SARIMAX з LSTM, запропонований метод перевершує їх за всіма основними метриками, включаючи точність, прецизійність і F1-міру. Обчислювальні

експерименти підтвердили гіпотезу висококорельованих сенсорів і продемонстрували ефективність методу у виявленні відмов, зокрема мінімізацію пропущених детекцій (13 хибнонегативних результатів під час аналізу швидкості ротора компресора).

6.4. Формування і доведення теореми про структурну реконфігурацію автоматизованої підсистеми управління газотурбінних двигунів вертольотів

У межах створеного нейромережевого методу відновлення інформації при параметричній відмові одного з датчиків виникає необхідність розв'язати задачу структурної реконфігурації АПУ ГТД вертольотів після виявлення і локалізації відмови, наприклад, датчика частоти обертів ротора турбокомпресора (n_{TK}). У цьому плані можна застосувати два відкаліброваних датчика – температури повітря на вході в двигун (T_H) і температури газу перед турбіною компресора (T_T^*). Необхідними також є три датчика атмосферного тиску (P_H), частоти обертів ротора вільної турбіни (n_{CB}) і кута установки лопаток напрямних турбокомпресора (α), а також наявність електронного регулятора двигуна (h). На підставі вищезазначеного застосовується бортовий алгоритм F обчислення і обмеження обертів ротора турбокомпресора шляхом впливу на подачу палива двигуна (масова витрата палива).

Особливості розв'язання задачі структурної реконфігурації АПУ ГТД вертольотів після виявлення і локалізації відмови дозволили сформулювати теорему «Про структурну реконфігурацію АПУ ГТД вертольотів»: «При виявленні і локалізації відмови датчика частоти обертів ротора турбокомпресора (*n*_{*TK*}) АПУ ГТД вертольотів може бути структурно переконфігурована для забезпечення безперебійного функціонування та збереження стійкості систем вертольоту». У табл. Ж.9 наведено основі етапи її доведення.

Для підтвердження правильності формулювання теореми, а також задля визначення структурної реконфігурації, слід прийняти, що стан системи описується вектором стану *x*, при цьому *u* – вхідна команда, *y* – вихідна величина, *d* – вектор параметрів відмов. Тоді математична модель системи описується системою диференціальних рівнянь виду:

$$\begin{cases} \frac{\partial x}{\partial t} = f(x, u, d);\\ y = h(x, u, d); \end{cases}$$
(6.68)

При урахуванні впливу відмови датчика частоти обертів ротора турбокомпресора система диференціальних рівнянь (6.35) набуде виду:

$$\begin{cases} \frac{\partial x}{\partial t} = f\left(x, u, d, \Delta n_{TK}\right);\\ y = h\left(x, u, d, \Delta n_{TK}\right); \end{cases}$$
(6.69)

де Δn_{TK} – відхилення частоти обертів ротора турбокомпресора.

Отже, при виявленні і локалізації відмови датчика частоти обертання ротора турбокомпресора АПУ ГТД вертольотів переходить до альтернативної структури, що описується новими диференціальними рівняннями:

$$\begin{cases} \frac{\partial x_{_{HOB}}}{\partial t} = f_{_{HOB}} \left(x_{_{HOB}}, u_{_{HOB}}, d_{_{HOB}} \right); \\ y_{_{HOB}} = h_{_{HOB}} \left(x_{_{HOB}}, u_{_{HOB}}, d_{_{HOB}} \right); \end{cases}$$
(6.70)

де *х*_{нов}, *у*_{нов}, *d*_{нов} – нові вектори стану, вхідних команд та параметрів відмов відповідно.

На наступному етапі вводяться конкретні математичні вирази для нової структури системи, що враховують вплив відмови датчика частоти обертання ротора турбокомпресора. Ці вирази можуть бути виведені на основі аналізу фізичних закономірностей системи. Наприклад, можливий вигляд нового диференціального рівняння для частоти обертання ротора турбокомпресора у випадку виявленої відмови:

$$\frac{\partial n_{TKHOB}}{\partial t} = g\left(x_{HOB}, u_{HOB}, d_{HOB}, \Delta n_{TK}\right).$$
(6.71)

Аналогічно можна вивести нові рівняння для інших важливих параметрів системи.

Для отримання математичних виразів нової структури системи, враховуючи відмову датчика частоти обертів ротора турбокомпресора, на наступному етапі здійснюється спрощення моделі системи. Приймається, що відмова впливає лише на диференціальне рівняння, що описує частоту обертання ротора турбокомпресора. Введемо нову величину δn_{TK} – відхилення від нормального значення n_{TK} :

$$\delta n_{TK} = n_{TK} - n_{TKHOPM}; \tag{6.72}$$

де *п*_{*ТКнорм} –* нормальне значення частоти обертів ротора турбокомпресора.</sub>

Відповідно, модель для величини δn_{TK} має вигляд:

$$\frac{\partial \delta n_{TK}}{\partial t} = g\left(x, u, d, \Delta n_{TK}\right). \tag{6.73}$$

3 урахуванням (6.73) система диференціальних рівнянь (6.70) набуде вигляду:

$$\begin{cases} \frac{\partial x_{_{HOB}}}{\partial t} = f_{_{HOB}} \left(x_{_{HOB}}, u_{_{HOB}}, d_{_{HOB}}, \delta n_{_{TK}} \right); \\ y_{_{HOB}} = h_{_{HOB}} \left(x_{_{HOB}}, u_{_{HOB}}, d_{_{HOB}}, \delta n_{_{TK}} \right). \end{cases}$$
(6.74)

Система диференціальних рівнянь (6.74) є новою структурою АПУ ГТД вертольотів, що враховує вплив відмови датчика частоти обертів ротора турбокомпресора. Вона може бути використані для динамічного моделювання та аналізу стійкості системи після виявлення відмови.

На наступному етапі здійснюється аналіз стійкості нової системи та підтверджується, що вона забезпечує безперебійне функціонування АПУ ГТД вертольотів при виявленні відмови датчика частоти обертів ротора турбокомпресора. Цей аналіз може включати в себе лінійну або нелінійну стійкість та перевірку виконання важливих обмежень управління та вихідних величин системи.

Аналіз стійкості нової системи після виявлення відмови датчика частоти обертів ротора турбокомпресора можна провести, використовуючи лінійну апроксимацію або нелінійний аналіз, залежно від характеру рівнянь. Для лінійного аналізу використовуються лінійні апроксимації навколо рівноважного стану. Позначимо рівноважний стан системи як $\bar{x}_{{}_{HOB}}, \bar{d}_{{}_{HOB}}, \bar{\delta}n_{{}_{TK}}$. Тоді лінійні відхилення можна визначити як:

$$\begin{aligned} x_{HOB} &= x_{HOB} - x_{HOB}; \\ u_{HOB} &= u_{HOB} - \overline{u}_{HOB}; \\ d_{HOB} &= d_{HOB} - \overline{d}_{HOB}; \\ \delta n_{TK} &= \delta n_{TK} - \overline{\delta} n_{TK}. \end{aligned}$$
(6.75)

Лінійні рівняння можуть бути визначені за допомогою лінійних апроксимацій системи диференціальних рівнянь (6.41) та функцій вихідного сигналу. Наприклад:

$$\begin{cases} \frac{\partial x_{HOB}}{\partial t} = Ax_{HOB} + Bu_{HOB} + Ed_{HOB} + F\delta n_{TK};\\ y_{HOB} = Cx_{HOB} + Du_{HOB} + Gd_{HOB} + H\delta n_{TK}; \end{cases}$$
(6.76)

де матриці *A*, *B*, *C*, *D*, *E*, *F*, *G*, *H* є лінійними функціями від стану, входу, параметрів відмов та відхилення від нормального значення частоти обертів ротора турбокомпресора.

Для аналізу стійкості можна використовувати теорію лінійної стійкості та критерії

стійкості, такі як власні числа матриці А. Якщо всі власні числа матриці А мають від'ємні дійсні частини, то система буде лінійно стійкою.

Якщо аналіз виконується для нелінійної моделі, тоді використовуйте методи, такі як аналіз Ляпунова [522], щоб визначити стійкість системи вздовж траєкторій нелінійних диференціальних рівнянь. Цей аналіз допоможе визначити, чи нова структура системи забезпечує стійке функціонування АПУ ГТД вертольотів після виявлення відмови датчика частоти обертів ротора турбокомпресора.

Для аналізу стійкості системи за допомогою методу аналізу Ляпунова, потрібно визначити функцію Ляпунова та вивести умови стійкості [523]. У цьому випадку ми будемо використовувати лінійну апроксимацію нової системи після виявлення відмови датчика частоти обертів ротора турбокомпресора. Приймається, що \bar{x}_{HOB} , \bar{d}_{HOB} , $\bar{\delta}n_{TK}$ мають рівноважні значення. Розглянемо квадратичну функцію Ляпунова для системи:

$$V(x_{HOB}, u_{HOB}, d_{HOB}, \delta n_{TK}) = x_{HOB}^{T} P x_{HOB} + u_{HOB}^{T} Q u_{HOB} + d_{HOB}^{T} R d_{HOB} + \delta n_{TK}^{2}; \quad (6.77)$$

де P, Q, R – симетричні позитивно визначені матриці.

Обчислимо похідну функції Ляпунова за часом:

$$\frac{\partial V}{\partial t} = \frac{\partial V}{\partial x_{HOB}} \frac{\partial x_{HOB}}{\partial t} + \frac{\partial V}{\partial u_{HOB}} \frac{\partial u_{HOB}}{\partial t} + \frac{\partial V}{\partial d_{HOB}} \frac{\partial d_{HOB}}{\partial t} + 2\delta n_{TK} \frac{\partial \delta n_{TK}}{\partial t}.$$
(6.78)

Враховуючи лінійні рівняння системи, можемо виразити деякі частини похідної:

$$\frac{\partial V}{\partial t} = x_{HOB}^{T} \left(A^{T} P + P \cdot A \right) x_{HOB} + u_{HOB}^{T} \left(B^{T} P + Q \cdot B \right) u_{HOB} + d_{HOB}^{T} \left(E^{T} P + R \cdot E \right) d_{HOB} + 2\delta n_{TK} \frac{\partial \delta n_{TK}}{\partial t}.$$
(6.79)

$$\frac{\partial V}{\partial t} = x_{\text{HOB}}^{T} \left(A^{T} P + P \cdot A \right) x_{\text{HOB}} + u_{\text{HOB}}^{T} \left(B^{T} P + Q \cdot B \right) u_{\text{HOB}} + d_{\text{HOB}}^{T} \left(E^{T} P + R \cdot E \right) d_{\text{HOB}} + 2\delta n_{TK} \frac{\partial \delta n_{TK}}{\partial t} < 0.$$
(6.80)

Для аналізу стійкості системи за допомогою методу Ляпунова, розглянемо функцію

338

Ляпунова, яка включає в себе квадратичні вирази для відхилень стану від рівноважного стану. Позначимо вектор відхилень як

$$\mathbf{Z} = \left(x_{HOB}, u_{HOB}, d_{HOB}, \delta n_{TK}\right)^{T}.$$
(6.81)

Приймається, *P* – симетрична позитивно визначена матриця та вводиться функція Ляпунова:

$$V(\mathbf{z}) = \mathbf{z}^T P \mathbf{z}. \tag{6.82}$$

Обчислюється похідна функції Ляпунова вздовж траєкторії системи:

$$\frac{\partial V}{\partial t} = \frac{\partial V}{\partial \mathbf{z}} \frac{\partial \mathbf{z}}{\partial t} = \mathbf{z}^T P \frac{\partial \mathbf{z}}{\partial t}.$$
(6.83)

З використанням лінійних рівнянь системи, виразимо похідну:

$$\frac{\partial V}{\partial t} = \mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + 2\delta n_{TK} \frac{\partial \delta n_{TK}}{\partial t}.$$
(6.84)

За умови стійкості необхідно, щоб усі члени, крім останнього, були від'ємними або невід'ємними:

$$\frac{\partial V}{\partial t} \le 0 \Longrightarrow \mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} \le -2\delta n_{TK} \frac{\partial \delta n_{TK}}{\partial t}.$$
(6.85)

Для забезпечення цього, необхідно вибрати матрицю Р так, щоб вона була позитивно визначеною, і щоб головна діагональ $(A^T P + P \cdot A)$ мала від'ємні елементи. Ця умова може використовуватися для визначення параметрів матриці *P* та встановлення умов стійкості для системи відносно відмови датчика частоти обертів ротора турбокомпресора. Але цей аналіз є лінійним і базується на лінійній апроксимації реальної системи. З урахуванням умов стійкості та з врахуванням аналізу Ляпунова можна припустити, що система є стійкою. За умови стійкості, визначеної аналізом Ляпунова, використовуючи квадратичну функцію Ляпунова, отримано:

$$\mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} \leq -2\delta n_{TK} \frac{\partial \delta n_{TK}}{\partial t}.$$
(6.86)

Нерівність (6.86) вказує на те, що відхилення від рівноважного стану (**z**) зростає або залишається стійким, що гарантує стійке функціонування системи. Для ще більш деталізованого та розширеного доведення теореми з урахуванням нелінійності та інших аспектів, які можуть впливати на стійкість, використовується додатковий математичний

апарат (табл. Ж.10) [522].

Використання додаткового математичного апарату (табл. Ж.10) дозволяє врахувати більше деталей та вдосконалити та розширити доведення теореми з урахуванням специфічних властивостей АПУ ГТД вертольотів та відмов датчика частоти обертів ротора турбокомпресора.

Розглянемо можливі нелінійні елементи системи. Наприклад, можливо врахувати нелінійну функцію обмеження для обертів ротора турбокомпресора або нелінійні зв'язки між різними станами системи. Припустимо, що функція обмеження обертів має вигляд:

$$f\left(\delta n_{TK}\right) = k\left(\delta n_{TK}\right)^{n}; \qquad (6.87)$$

де *k* – константа.

Модифікуємо рівняння системи (55), додаючи цей нелінійний елемент:

$$\frac{\partial n_{TK}}{\partial t} = g\left(x, u, d, \Delta n_{TK}\right) + k\left(\delta n_{TK}\right)^n.$$
(6.88)

Введемо функцію Ляпунова для нелінійного випадку:

$$V(\mathbf{z}) = \mathbf{z}^{T} P \mathbf{z} + k \left(\delta n_{TK}\right)^{n}.$$
(6.89)

Обчислимо похідну функції Ляпунова з урахуванням нелінійного елементу:

$$\frac{\partial V}{\partial t} = \mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + n \cdot k \left(\delta n_{TK} \right)^{(n-1)} \left(g \left(x, u, d, \Delta n_{TK} \right) + k \left(\delta n_{TK} \right)^{n} \right).$$
(6.90)

Умови стійкості для системи з урахуванням нелінійних елементів набуде вигляду:

$$\mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + n \cdot k \left(\delta n_{TK} \right)^{(n-1)} \left(g \left(x, u, d, \Delta n_{TK} \right) + k \left(\delta n_{TK} \right)^{n} \right) \leq 0.$$
(6.91)

Це є розширеною умовою стійкості, яка враховує кубічний нелінійний елемент у системі. Враховуючи нелінійний елемент $k(\delta n_{TK})^n$ вираз (6.91) характеризує вплив цього елементу на похідну функції Ляпунова. Умова стійкості вимагає, щоб у виразі для $\frac{\partial V}{\partial t}$ був від'ємний член. Для досягнення цього враховується взаємодія нелінійного елементу та інших членів:

$$n \cdot k \left(\delta n_{TK} \right)^{(n-1)} \left(g \left(x, u, d, \Delta n_{TK} \right) + k \left(\delta n_{TK} \right)^n \right) \leq -\mathbf{z}^T \left(A^T P + P \cdot A \right) \mathbf{z}.$$
(6.92)

Вираз (6.92) є розширеною умовою стійкості для системи з урахуванням нелінійних елементів.

Розглянемо додаткові умови для дослідження стійкості системи. Додамо умову, пов'язану з градієнтом функції $g(x,u,d,\Delta n_{TK})$, щоб отримати більш детальний аналіз. Припустимо, що градієнт цієї функції обмежений деякою константою *M*:

$$\left\|\nabla g\left(x, u, d, \Delta n_{TK}\right)\right\| \le M. \tag{6.93}$$

Умова (6.93) вказує на те, що градієнт функції *g* не зростає необмежено і дозволяє додатково контролювати нелінійні ефекти в системі. Враховуючи цю умову, умова стійкості (6.91) розширюється таким чином:

$$\mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + n \cdot k \left(\delta n_{TK} \right)^{(n-1)} \left(g \left(x, u, d, \Delta n_{TK} \right) + k \left(\delta n_{TK} \right)^{n} \right) + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| \leq 0; \quad (6.94)$$

де λ – параметр, що впливає на вагу умови градієнта.

Додатковою умовою стійкості може бути врахування обмеженості самої системи або обмеженості її похідних. Наприклад, можна ввести умову обмеженості вектору стану **z** або його похідних. Припустимо, що існує константа *B* така, що $\|\mathbf{z}\| \le B$. Ця умова вказує на обмеженість амплітуди стану системи. Таким чином, додаткова умова має вигляд:

$$\|\mathbf{z}\| + \boldsymbol{\beta} \le 0; \tag{6.95}$$

де β – параметр, який враховує вагу умови обмеженості стану системи. Ця умова вказує на те, що сума амплітуди стану та певного додаткового члена, зваженого параметром β , повинна залишатися від'ємною для забезпечення стійкості системи.

Зважаючи на додаткову умову обмеженості стану системи, умова стійкості (6.94) розширюється таким чином:

$$\mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + n \cdot k \left(\delta n_{TK} \right)^{(n-1)} \left(g \left(x, u, d, \Delta n_{TK} \right) + k \left(\delta n_{TK} \right)^{n} \right) + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \left\| \mathbf{z} \right\| + \beta \leq 0;$$
(6.95)

де $\lambda > 0$ і β – параметри, що впливають на вагу умови градієнта і обмеженості стану відповідно.

Припустимо, що існує константа $\alpha > 0$, така що для всіх $\mathbf{z} \neq 0$ виконується:

$$\mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + \alpha \left\| \mathbf{z} \right\|^{2} \le 0.$$
(6.96)

Ця умова гарантує, що система має сталу чутливість і є асимптотично стійкою. Інтегруючи це в умову стійкості, отримаємо:

$$\mathbf{z}^{T} \left(A^{T} P + P \cdot A \right) \mathbf{z} + n \cdot k \left(\delta n_{TK} \right)^{(n-1)} \left(g \left(x, u, d, \Delta n_{TK} \right) + k \left(\delta n_{TK} \right)^{n} \right) + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right) \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK} \right\| + \lambda \left\| \nabla g \left(x, u, d, \Delta n_{TK}$$

$$+ \|\mathbf{z}\| + \beta + \alpha \|\mathbf{z}\|^{2} \le 0;$$
(6.97)

де $\lambda > 0$, $\alpha > 0$ і β – параметри, що враховують вагу умови градієнта, обмеженості стану і сталої чутливості відповідно.

Задля структурної переконфігурації для забезпечення безперебійного функціонування припускається, що АПУ ГТД вертольотів має таку узагальнену структуру:

$$n_{TK} \to h \to F \to G_T; \tag{6.98}$$

де *n*_{*TK*} – датчик частоти обертів ротора турбокомпресора; *h* – електронний регулятор двигуна; *F* – бортовий алгоритм обчислення і обмеження оборотів ротора турбокомпресора; *G*_{*T*} – масова витрата палива.

Відповідно до умови датчик *n*_{TK} відмовив. Приймається, що також відомі такі залежності:

$$\begin{cases} F\left(n_{TK}, T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha\right) = n_{TK}; \\ h\left(n_{TK}, T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha\right) = h\left(n_{TK}\right); \\ G_{T}\left(n_{TK}, T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha\right) = G_{T}\left(n_{TK}\right); \end{cases}$$
(6.99)

Тоді нова структура АПУ ГТД після реконфігурації буде мати такий вигляд:

$$T_H, T_{\Gamma}^*, P_H, n_{CB}, \alpha \to h \to F \to G_T.$$
(6.100)

Приймається, що нові залежності *F* і *h* після реконфігурації будуть поданими в такому вигляді:

$$\begin{cases} F\left(T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha\right) = n_{TK}; \\ h\left(T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha\right) = h\left(n_{TK}\right). \end{cases}$$
(6.101)

Тоді нова система АПУ ГТД вертольотів буде стабільна, якщо нова система *F* і *h* буде стабільна.

Нехай нова система F і h є стабільною. Тоді для будь-якого початкового значення n_{TK} нова система буде прагнути до значення n_{TK} , при якому система F і h буде стабільна. Нехай це значення n_{TK} дорівнює n_{TK}^* . Тоді для будь-якого початкового значення G_T нова система буде прагнути до значення m, при якому система F і h буде стабільна. Нехай це значення G_T дорівнює G_T^* . Отже, нова система АПУ ГТД вертольотів буде стабільна.

Приклад.

Нехай нова система *F* і *h* буде мати такий вигляд:

$$\begin{cases} F(T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha) = n_{TK}^{*} = n_{TK}^{*} - k(T_{H} - T_{\Gamma}^{*}) + k(P_{H} - P_{H}^{*}); \\ h(T_{H}, T_{\Gamma}^{*}, P_{H}, n_{CB}, \alpha) = h(n_{TK}^{*}) = h(n_{TK}^{*}) - k(\alpha - \alpha^{*}); \end{cases}$$
(6.102)

де k – коефіцієнт реконфігурації; n_{TK}^* – значення n_{TK} , при якому система F і h буде стабільна; P_H^* – значення P_H , при якому система F і h буде стабільна; α^* – значення α , при якому система F і h буде стабільна.

У [522] створено метод визначення значень термогазодинамічних параметрів, за яких перебудована АПУ залишається стабільною, використовуючи методи чисельної оптимізації для отримання оптимальних параметрів. Проведено оцінку точності розв'язання задачі багатокритеріальної оптимізації за показниками MIGD та MHV у разі повільних і швидких змін: доведено, що для повільних змін оптимальним є використання попередніх параметрів, а для швидких – методів із перезапуском. Адекватність моделі підтверджено середньоквадратичною похибкою (не перевищує 0,4 %, у разі білого шуму – 0,77 %), регресійним аналізом (коефіцієнт детермінації 0,986) та крос-валідацією (різниця з максимальною середньоквадратичною похибкою становить 3,88 %).

6.5. Розробка бортової нейромережевої експертної системи моніторингу газотурбінних двигунів вертольотів

З метою забезпечення безпеки та ефективності польотів екіпаж вертольоту повинен мати здатність отримувати різноманітну інформацію та приймати обгрунтовані рішення під час польотів. Переконавшись, що необхідні для польоту засоби та обслуговування в робочому стані, екіпаж може приступити до польоту. Аналіз польотів показав, що часто причиною авіаційних подій є дефекти технічного стану ГТД вертольотів [524], а також неправильне оцінювання командира вертольоту його професійних здібностей разом із недооцінкою впливу відхилень у нормальній роботі ГТД вертольоту під час прийняття рішень про польоти. Часто екіпаж повинен отримувати інформацію про зміни у функціонуванні ГТД вертольоту в обмежений термін. Навіть за умов проведення консультацій та надання необхідної інформації для підготовки до польоту, іноді необхідно надавати інформацію екіпажу під час польоту для безпечного завершення місії. У сучасних умовах надзвичайно важливо, щоб пілоти вміли оцінювати вхідну інформацію про технічний стан ГТД вертольоту та правильно на неї реагувати. Тому важливо готувати та подавати інформацію так, щоб полегшити її сприйняття.

З метою вищенаведеного набула подальшого розвитку нейромережева модель аналізу можливості виконання польоту (рис. Ж.8), вперше розроблена професором Шмельовою Т.Ф. [525, 526], побудована за допомогою тришарового персептрону, яку навчено модифікованим алгоритмом зворотного поширення помилки методом градієнтного наближення. Це дозволяє подолати локальні нерівності поверхні помилки та уникнути застрягання в локальних мінімумах. Процес навчання припиняється, коли помилка досягає мінімального значення і не зменшується більше. Вхідними параметрами першого шару моделі є чинники, що аналізують стан підчинників (результати розв'язання прикладних задач моніторингу ГТД вертольотів) відповідно до розроблених критеріїв. Відповідно до досліджень професора Шмельової Т.Ф. [525, 526] кожному вхідному параметру відповідає бінарний вектор, який відображає відповідність (1) або невідповідність (0) визначеним умовам певного підчинника. Виходи першого шару є вхідними параметрами другого шару і відображають стан чинників. Бінарний вектор відображає оцінку стану чинника (чи задовольняють вони необхідні умови для виконання польоту): «1» – чинники відповідають, «0» – не відповідають. Вихідним параметром моделі є оцінка щодо можливості виконання польоту *P*: *p*₁ – політ можливий (1), p_2 – політ неможливий (0), $P = \{p_x\}, x = \overline{0,1}$. Вхідні компоненти і відповідний їм вихід задаються відповідно до навчальної вибірки.

У [527] розроблено нейромережеву модель аналізу можливості виконання польоту, подальшим розвитком якої є розроблена у даній роботі модель аналізу можливості здійснення польоту вертольоту (рис. Ж.8) з урахуванням результатів моніторингу технічного стану авіаційного двигуна. Базова нейромережева модель аналізу можливості виконання польоту побудована на основі персептрону, навчання проводилось з учителем процедурою зворотного поширення помилки. Аналіз алгоритму зворотного поширення помилки показує, що при виборі *Error* занадто маленький алгоритм може не завершитися, а при виборі *Error* занадто великий, ми можемо навчити багатошарову нейронну мережу, яка практично не застосовується в силу неадекватних і недостовірних результатів. З метою усунення цього недоліка здійснено модифікацію алгоритму зворотного поширення помилки (табл. Ж.11).

У табл. Ж.11 індекс *j* характеризує нейрони наступного шару стосовно шару *i*, t_j – еталонне значення, L – кількість навчальних векторів. На рис. Ж.9 наведено графіки порівнянь результатів навчання тришарового персептрону з використанням стандартного алгоритму зворотного поширення помилки (1) і модифікованого алгоритму зворотного поширення помилки (2), з якого видно, що помилка навчання нейронної мережі при 200 епохах навчання не перевищує 0,0275 порівняно з 0,6659 при використанні алгоритму зворотного поширення помилки.

Створення бортової нейромережевої експертної системи для моніторингу та управління ГТД вертольотів грунтується на кількох ключових передумовах [528–532]:

1. ГТД вертольотів є складними технічні системами, що включають множину компонентів та підсистем. Моніторинг та управління такою складною системою потребує точного аналізу різних параметрів та оперативного реагування на зміни у роботі двигуна.

2. Необхідність раннього виявлення та запобігання дефектам, оскільки ефективне функціонування вертольотів залежить від надійності та справності їх двигунів. Раннє виявлення потенційних проблем або дефектів в ГТД вертольотів дозволяє запобігти можливим поломкам і збільшити термін служби обладнання.

3. Великий обсяг даних, оскільки сучасні вертольоти обладнані безліччю сенсорів та систем, що збирають великий обсяг даних про роботу двигуна. Нейромережеві системи добре підходять обробки та аналізу великих обсягів даних, що дозволяє виявляти закономірності і аномалії.

4. Комплексність задач – різні задач, такі як ідентифікація, класифікація, діагностика, прогнозування тощо, потребують різноманітних методів обробки даних. Нейронні мережі надають гнучкість та здатність навчатися на основі досвіду, що робить їх ефективними для вирішення різноманітних завдань.

5. Швидкий відгук та автоматизація – у бортових системах вертольотів потрібен швидкий відгук на зміни в роботі двигуна. Нейронні мережні системи можуть забезпечувати автоматичну обробку даних та швидке прийняття рішень без затримок, що є важливим для забезпечення безпеки польотів. 6. Навчання на основі досвіду – нейронні мережні моделі можуть навчатися на основі досвіду роботи з реальними даними, що дозволяє системі поступово покращувати свою продуктивність та адаптуватися до змін в умовах експлуатації.

Основні вимоги до сучасних систем моніторингу технічного стану авіаційних двигунів включають в себе використання кількісних та якісних моделей, гібридність баз знань, гнучкий інтерфейс, підтримку різних типів даних, протоколювання користувача, можливість розширення та віддалений доступ (табл. 6.2).

Таблиця 6.2 – Аналіз сучасних експертних систем та їхніх підходів (авторський доробок)

Підхід	Опис
Підхід 1	Зміна традиційної архітектури експертних систем на нові принципи, включаючи явне визначення
	понять і відносин в предметній області.
Підхід 2	Використання нейронних мереж у традиційних архітектурних експертних системах, де нейронні ме-
	режі реалізують традиційні компоненти, дозволяючи неявно визначати поняття та відносини. Цей
	підхід особливо ефективний для складних предметних областей.
Висновок	Розвиток нейромережевих експертних систем включає зміну традиційної архітектури та їх викорис-
	тання в традиційних системах, що відкриває нові перспективи для розробки в ефективних рішень,
	особливо в складних предметних областях.

Керуючись дослідженнями професора Жернакова [533–538] запропоновано бортову нейромережеву експертну систему моніторингу технічного стану ГТД вертольотів [539] (рис. 6.23), що розв'язує прикладні задачі моніторингу технічного стану ГТД вертольотів в умовах бортової реалізації, такі як, задача класифікації режимів роботи ГТД вертольотів в польотних режимах; задача ідентифікації динамічної багаторежимної моделі ГТД вертольоту (на перехідних режимах роботи двигуна); задача контролю технічного стану ГТД вертольотів; задача діагностики дефектів в основних вузлах проточної частини ГТД вертольотів; задача прогнозування динаміки зміни термогазодинамічних параметрів ГТД вертольотів; задача ідентифікації потенційних дефектів основних вузлів проточної частини ГТД вертольотів на основі прогнозування їх робочого стану; задача налагодження дозатора палива ГТД вертольотів; задача тренд-аналізу параметрів ГТД вертольотів.



Рисунок 6.23 – Структура бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів (авторський доробок [539] на основі [124])

На рис. 6.23 позначено: БД – база даних; СУБД – система управління базою даних; БКЗ – база концептуальних знань; БЕЗ – база експертних знань; БЗП – база знань прецедентів; СУБЗ – система управління базами знань; ПЗ – програмне забезпечення; ОПР – особа, яка приймає рішення.

Основними завданнями бази знань бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів є обробка вимірювань, реєстрація і відображення результатів, а також контроль, діагностика, прогноз технічного стану двигунів тощо. Нейромережевий прототип системи створено на базі гібридної експертної оболонки та середовища моделювання MATLAB, з можливістю промислової реалізації (рис. Ж.10).

Експертна система, віднесена до четвертого покоління, володіє динамічною базою знань і логічним виведенням, включає адаптивні властивості та розвинений інтерфейс. Застосовується два режими роботи: експертний і користувацький, де система розв'язує завдання моніторингу технічного стану ГТД вертольотів [540–547]. Система включає нейромережеву базу знань (рис. Ж.11), бази нечітких правил та прецедентів, а також можливість обміну даними в режимі реального часу. Основні компоненти – керуюча програма-монітор і машина логічного виводу, яка використовує вирішувачі, планувальник і модуль прийняття рішення. База знань об'єднує експертні та нейромережеві знання, а система управління базами здійснює координацію між ними.

Дані, що враховують особливості конкретного двигуна, надходять до

нейромережевих модулів через базу даних випробувань (БДВ), керовану СУБД, що вбудована в експертну систему. Контроль СУБЗ і СУБД виконується вирішувачем під час розв'язання задачі моніторингу технічного стану ГТД вертольотів. Процес моніторингу розділений на етапи, які включають перетворення даних, статистичну обробку, класифікацію ідентифікацію тощо. Схема функціонування показана на рис. Ж.12, де дані використовуються для обробки нейромережевою системою, а нейромережеві модулі можуть працювати незалежно, взаємодіючи з іншими компонентами системи. Програма-монітор, реалізована на мові Go, oб'єднує нейромережеві модулі, розроблені в середовищі МАТLAB, та забезпечує взаємодію з СУБД.

Основні особливості програмної реалізації модулів нейромережевої експертної системи включають автоматизацію створення за допомогою майстер-утиліт, об'єктно-орієнтований підхід для гнучкого інтерфейсу, автономну роботу модулів, розширюваність та переносимість, незалежність від типу та форми вхідних даних, можливість навчання в режимі реального часу, просте вбудовування та видалення, зручний інтерфейс, та методика роботи, що включає в себе налаштування, розробку концептуальної моделі, формування баз знань, налагодження, тестування та оцінку якості рішень.

Для порівняння ефективності розв'язання прикладних задач моніторингу технічного стану ГТД вертольотів у польотних режимах з використанням нейронних мереж і традиційних методів – статистичної оброки інформації пропонується використовувати єдину метрику – комплексний показник якості *MAD*, який запропоновано обчислювати відповідно до виразу:

$$MAD = \frac{\sum_{i=1}^{n} \left(Accuracy_{i} + \left(1 - Loss_{i}\right) + Recall_{i} + Precision_{i} + F_{i}\right) + \frac{1}{n} \cdot \frac{t_{i}}{t_{\max}}}{6 + \frac{1}{n} \cdot \frac{t_{\max}}{t_{\min}}}; \quad (6.103)$$

де Accuracy_i, Precision_i, Recall_i, Loss_i, F_i – метрики якості нейронної мережі в *i*-й прикладній задачі моніторингу ГТД вертольотів, t_i – нормалізований час виконання *i*-ї прикладної задачі моніторингу ГТД вертольотів, t_{max} – максимальний час виконання серед усіх прикладних задач моніторингу ГТД вертольотів, t_{min} – мінімальний час виконання серед усіх прикладних задач моніторингу ГТД вертольотів.

У (6.35) параметр «ресурс» визначається як середній час виконання нейронною

мережею кожної прикладної задачі моніторингу ГТД вертольотів. Це обґрунтування параметра «ресурс» базується на таких чинниках:

1. Кількість прикладних задач моніторингу ГТД вертольотів: чим більше задач, тим більше часу потрібно їх виконання.

2. Складність задач: чим складніше *i*-та прикладна задача моніторингу ГТД вертольотів, тим більше часу потрібно їх виконання.

3. Тип нейронної мережі: складніші архітектури нейронних мереж вимагають більше часу для виконання.

4. Розмір вхідних даних: чим більший розмір вхідних даних, тим більше часу потрібно їх обробки.

За підсумками цих чинників можна дійти висновку, що параметр «ресурс» є значної характеристикою якості нейронної мережі.

Пропонована метрика МАД має низку переваг перед класичними метриками:

1. Вона враховує всі основні показники якості нейронної мережі, включаючи точність, повноту, точність, F-міру і середній час. Це дозволяє отримати повніше уявлення про якість нейронної мережі.

2. Вона не використовує вагові коефіцієнти, що робить її об'єктивнішою. Використання вагових коефіцієнтів може призвести до викривлення оцінки якості нейронної мережі.

3. Вона має діапазон значень від 0 до 1, що дозволяє легко порівнювати з іншими метриками.

У табл. Ж.12 наведено значення метрик *Accuracy*, *Precision*, *Recall*, *Loss*, *F*-міри для усіх прикладних задач моніторингу ГТД вертольотів, а також обчислені їх середні значення. У табл. Ж.13 приведено порівняння пропонованої метрики *MAD* з класичними метриками якості.

Отже, пропонована метрика *MAD* є новою, унікальною та єдиною метрикою для визначення якості нейронної мережі, враховує як напрямок, і величину помилки, і навіть не чутлива до викидів, що робить її більш стабільною мірою якості, ніж метрики, чутливі до викидів. Вона має низку переваг перед класичними метриками, включаючи урахування всіх основних показників якості нейронної мережі, відсутність вагових коефіцієнтів і діапазон значень від 0 до 1. Чисельне порівняння показало, що пропонована метрика *MAD* більш точно відображає якість нейронної мережі, ніж класичні метрики. Це говорить про те, що вона точніше відображає якість нейронної мережі. Загалом пропонована метрика *MAD* є перспективним інструментом для оцінки якості нейронних мереж. Вона може бути використана для оцінки якості нейронних мереж, що використовуються у різних задачах, включаючи моніторинг ГТД вертольотів у польотних режимах.

Для обгрунтування надійності пропонованої метрики MAD представимо її у багатовимірному контексті для врахування множинності міток як:

$$MAD = \frac{\sum_{i=1}^{n} \left(\frac{1}{n} \cdot \sum_{i=1}^{n} \frac{|y_i \cap \hat{y}_i|}{|y_i \cup \hat{y}_i|} + (1 - \sum_{i=1}^{n} (y_i \cap \hat{y}_i)^2) + \sum_{i=1}^{n} \frac{|y_i \cap \hat{y}_i|}{|\hat{y}_i|} + \sum_{i=1}^{n} \frac{|y_i \cap \hat{y}_i|}{|y_i|} + \sum_{i=1}^{n} \frac{2 \cdot |y_i \cap \hat{y}_i|}{|y_i| + |\hat{y}_i|} \right) + \frac{1}{n} \cdot \frac{t_i}{t_{\max}}}{6 + \frac{1}{n} \cdot \frac{t_{\max}}{t_{\min}}},$$

де Accuracy = $\frac{1}{n} \cdot \sum_{i=1}^{n} \frac{|y_i \cap \hat{y}_i|}{|y_i \cup \hat{y}_i|}$, Loss = $\sum_{i=1}^{n} (y_i \cap \hat{y}_i)^2$, Precision = $\sum_{i=1}^{n} \frac{|y_i \cap \hat{y}_i|}{|y_i|}$, Recall = $\sum_{i=1}^{n} \frac{|y_i \cap \hat{y}_i|}{|y_i|}$, $F = \sum_{i=1}^{n} \frac{2 \cdot |y_i \cap \hat{y}_i|}{|y_i| + |\hat{y}_i|}$, y_i – множина реальних міток для *i*-го об'єкта, \hat{y}_i – множина передбачених міток для *i*-го об'єкта, $|y_i \cap \hat{y}_i|$ – кількість правильно передбачених міток, $|y_i \cup \hat{y}_i|$ – загальна кількість унікальних міток (об'єднання реальних та передбачених).

Отже, пропонована метрика *MAD* забезпечує комплексну оцінку якості моделей класифікації, враховуючи точність (Accuracy), втрати (Loss), точність передбачень (Precision), повноту (Recall), баланс між ними (F-міра) та швидкодію (час виконання). Її ключовими властивостями є нормалізація значень для уникнення перекосів, відсутність вагових коефіцієнтів для збереження об'єктивності та обмеженість діапазону всіх показників у межах [0, 1], що забезпечує порівнянність моделей. Урахування часу виконання через нормалізовані співвідношення підвищує її практичну цінність. *MAD* підходить для багатомірних задач завдяки адаптації до багатокласових і багатоміткових даних, не залежить від специфічних припущень щодо розподілу даних і є універсальною. Порівняно з традиційними метриками, *MAD* є більш комплексною, об'єктивною, зручною для використання, адже всі показники зводяться до одновимірного числового значення в уніфікованому діапазоні, що полегшує аналіз та інтерпретацію.

6.6. Розробка програмного забезпечення моніторингу газотурбінних двигунів вертольотів «MONITOR»

Зазначається, що на бортовій панелі вертольоту відображаються параметри авіаційного двигуна, що реєструються під час експлуатації, штатними датчиками.

Розроблену у цій роботі експертну систему моніторингу (рис. Ж.13) пропонується підключати до бортової системи вертольоту, що передає дані, які реєструються штатними датчиками, на зазначену систему. Далі остання визначає додаткові параметри двигуна відповідно до нейромережевих моделей ГТД вертольотів і висвітлює їх чисельні значення на розташованій у кабіні вертольоту дисплей.

Принцип роботи розробленої системи ґрунтується на нейромережевій експертній системі, яка, використовуючи для обчислень ті чи інші термогазодинамічні параметри, може класифікувати режими роботи двигуна, а також здійснювати контроль, діагностику, прогнозування тощо технічного стану ГТД вертольоту.

Такий підхід дозволяє здійснювати безперервний моніторинг технічного стану ГТД вертольоту, контроль параметрів його технічного стану, діагностику основних вузлів його проточної частини, прогнозувати тренд того чи іншого термогазодинамічного параметра. Розроблена інтелектуальна система дозволяє провести діагностику вузлів двигуна задля виявлення в ньому дефектів. Нейромережева експертна система дозволяє прогнозувати технічний стан двигуна, здійснювати тренд-аналіз його параметрів – основних і додаткових. А налаштування двигуна і відновлення втраченої інформації у випадку відмови штатних датчиків дозволяє зорієнтуватись у переналаштовуванні необхідних параметрів, висвітлених на панелі бортової системи. Кінцевим результатом стає надання рекомендацій командиру екіпажу вертольоту про можливість продовження польоту.

Отже, розроблена експертна система створює і реалізує умови для модернізації бортової системи контролю – панелі приладів.

На рис. 6.24 і Ж.14 наведено структурну схему і зовнішній вигляд експериментальної установки відповідно, що використовувалась для розв'язання прикладних задач моніторингу технічного стану ГТД вертольотів.



Рисунок 6.24 – Структурна схема експериментальної установки (авторський доробок)

Експерименти було здійснено на режимі запуску двигунів вертольоту на ТОВ «ЕЙР ТАУРУС» на вертольоті Мі-8МТВ, до складу силової установки якого входять два двигуни ТВЗ-117. Експериментальна установка складалась із ноутбука з розробленим програмним забезпеченням (тестова версія програмного засобу «MONITOR»), в якому реалізовані нейромережеві методи розв'язку прикладних задач моніторингу технічного стану ГТД вертольотів, та модулю збору даних (16-канальний USB-інтерфейс STM32F103C8T6 Туре-С 12-бітний модуль збору даних), паралельно приєднаного до панелі приладів в кабіні вертольоту.

Програмний засіб «MONITOR» реалізує бортову нейромережеву експертну систему моніторингу технічного стану ГТД вертольотів відповідно до структурної схеми, наведеної на рис. 6.25.



Рисунок 6.25 – Синтезована структурна схема моніторингу ГТД вертольотів (авторський доробок)

Підсистема попередньої обробки вхідних даних (іншими словами, блок передпольотної підготовки) (1) складається з блоку обробки значень реєстрованих на борту вертольоту термогазодинамічних параметрів ГТД вертольотів (n_{TK} , T_{Γ}^* , n_{CB} тощо), блоку обробки значень параметрів атмосфери (h, T_H, P_H, ρ) (2) та блоку введення інформації щодо польотної місії (наприклад, час польоту, відстань тощо) (3). Відповідно до отриманих значень вищезазначених параметрів у блоках попередньої обробки вхідних даних (4) й ідентифікації (5*), відповідно, здійснюється формування однорідної і репрезентативної навчальної і тестової вибірок для подальших досліджень за допомогою нейромережевої моделі, ідентифікація параметрів робочого процесу ГТД вертольотів (відповідно до аналітичних виразів, наведених у [204], а також з використанням відповідних нейромережевих моделей). З метою динамічного моніторингу відхилень поточних значень параметрів робочого процесу ГТД вертольотів від оптимального у блоці оптимізації (6) здійснюється визначення оптимальних параметрів робочого процесу конкретного ГТД вертольоту відповідно до поточних умов його експлуатації, використовуючи створену нейромережеву модель. Задля ідентифікації поточного класу роботи ГТД вертольотів у блоці класифікації (7) здійснюється відповідне встановлення за нейромережевою моделлю: H_1 – клас сталих режимів, H_2 – клас режимів, що супроводжуються лінійним трендом параметрів, H_3 – клас перехідних режимів роботи (станів), H_4 – клас невстановлених режимів роботи (розгін, дроселювання).

* Зауваження: три стрілочки від блоку ідентифікації означаються задачі нейромережевої ідентифікації багаторежимної моделі ГТД вертольотів за: 1– параметрами, що реєструються на борту вертольоту; 2 – параметрами, що обчислюються за математичною моделлю; 3 – параметрами, що обчислюються за математичною моделлю (зворотна багаторежимна модель ГТД вертольотів).

Підсистема нейромережевого моніторингу (8) реалізує безпосередньо розв'язання прикладних задач (розділ 3) за допомогою створених нейромережевих моделей: задача ідентифікації динамічної багаторежимної моделі ГТД вертольоту (на перехідних режимах роботи двигуна); задача контролю технічного стану ГТД вертольотів; задача діагностики дефектів в основних вузлах проточної частини ГТД вертольотів; задача прогнозування динаміки зміни термогазодинамічних параметрів ГТД вертольотів; задача ідентифікації потенційних дефектів основних вузлів проточної частини ГТД вертольотів на основі прогнозування їх робочого стану; задача налагодження дозатора палива ГТД вертольотів; задача проточної намогою стану ГТД вертольотів на основі прогнозування їх робочого стану; задача налагодження дозатора палива ГТД вертольотів; задача тренд-аналізу параметрів ГТД вертольотів; задача діагностики передпомпажного стану ГТД вертольотів.

Підсистема результатів моніторингу складається з блоку візуалізації (9), блоку обробки результатів моделювання (10) та блоку формування рекомендацій (11). Блок візуалізації відображає значення параметрів атмосфери, значення реєстрованих на борту вертольоту термогазодинамічних параметрів, поточні й оптимальні параметри робочого процесу (а також значення їх відхилень), клас режиму роботи двигуна, результати розв'язання прикладних задач моніторингу. Блок обробки результатів моделювання нормалізує отримані результати відповідно до бінарної класифікації: A = 1 - задовільний результат, <math>A = 0 - незадовільний результат. Блок формування рекомендацій базується на нейромережевій моделі аналізу можливості здійснення польоту (пункт 6.4),яка здійснює нейромережевий аналіз результатів відповідно до бінарної класифікації і видає рекомендації щодо можливості здійснення польоту. Відзначаються деякі особливості бінарної класифікації: якщо через деякий час в межах польотної місії прогнозується виникнення потенційних дефектів в основних вузлах ГТД вертольотів, виникнення тренду того чи іншого параметра, можливе явище помпажу, то результат відповідної прикладної задачі фіксується як незадовільний.

Паралельно основних підсистем функціонує підсистема відновлення інформації у вигляді універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів (рис. 6.1). Ця підсистема функціонує у трьох варіаціях: 1 – нейромережевий блок $HM_1...HM_i \in T$ ришаровим персептроном (рис. 6.2), 2 – нейромережевий блок $HM_1...HM_i \in AHM$ (рис. 6.6), 3 – нейромережевий блок $HM_1...HM_i \in P E \Phi$ -мережа з лініями затримки, що навчена за алгоритмом багатовимірного фільтра Калмана (рис. 6.20). Вибір варіації нейромережевого блоку $HM_1...HM_i$ здійснюється командиром екіпажу вертольоту на етапі передпольотної підготовки. Функціонування підсистеми відновлення інформації паралельно з іншими дозволяє безперервно отримувати значення реєстрованих на борту вертольоту термогазодинамічних параметрів ГТД вертольотів навіть у випадку відмови відповідного датчика.

На підставі вищевикладеного створено концептуальну модель програмного засобу «MONITOR» (рис. Ж.15), на якій відображено процес моніторингу технічного стану ГТД вертольотів як на етапі передпольотної підготовки, так і в режимі польоту вертольоту. Керуючись результатами досліджень професора Шмельової Т.Ф. [525, 526] до концептуальної моделі додано можливість урахування аеронавігаційної, картографічної, метеорологічної й нормативної інформації при прийнятті рішення щодо можливості здійснення польоту вертольоту у вигляді модуля вибору та оцінювання факторів [548]. Це дозволило створити схему розподілу інформаційних потоків програмного засобу «MONITOR» (рис. Ж.16) з метою прийняття рішення щодо можливості здійснення польоту.

Для реалізації бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів створено програмний засіб «MONITOR» відповідно до створених структурної схеми моніторингу (рис. 6.25), концептуальної моделі (рис. Ж.15) і структурної схеми розподілу інформаційних потоків (рис. Ж.16). Програмний засіб «MONITOR» розроблено в середовищі програмування Borland Delphi 7. Програмний засіб «MONITOR» призначений для використання командиром екіпажу і другим пілотом вертольоту як допоміжний модуль, що здійснює безперервний моніторинг технічного стану ГТД вертольотів і, як наслідок, надає рекомендації щодо можливості здійснення польоту залежно від стану двигуна. Незважаючи на нейромережеву базу, програмний засіб «MONITOR» має зручний інтерфейс користувача, що спрощує процес взаємодії з командиром екіпажу і другим пілотом вертольоту у режимі польоту.

При запуску програми користувач (командир екіпажу і другий пілот вертольоту) має ввести свій персональний логін і пароль (рис. 6.26, а), що ідентифікують його прізвище, ім'я, по батькові, посаду та інші персональні дані.



Рисунок 6.26 – Інформаційні діалогові вікна при вході (авторський доробок): а – вікно авторизації користувача; б – вікно завантаження інформації із бази даних; в – діалогове вікно введення передпольотної інформації; г – діалогове вікно вибору варіації нейромережевої схеми відновлення значень параметрів ГТД вертольотів

Після авторизації командир екіпажу обирає із бази даних вертольотів необхідний за бортовим номером (наприклад, RF-00000). Відповідно до нього, програма автоматично завантажує із бази даних інформацію щодо двигунів силової установки вертольоту за введеним серійним номером (рис. 6.26, б). Разом з тим, з бази даних завантажуються еталонні значення параметрів відповідних двигунів.

Після завантаження інформації щодо параметрів ГТД вертольотів за бортовим

номером командир екіпажу повинен ввести у відповідні поля спеціального діалогового вікна передпольотну інформацію (рис. 6.26, в), а саме: основні метеорологічні параметри й параметри з плану польоту (Flight Plan). При натисканні кнопки «Назад» здійснюється повернення до вікна завантаження інформації із бази даних (рис. 6.26, б), а при натисканні кнопки «Далі» – перехід до вибору варіацій універсальної нейромережевої схеми відновлення значень параметрів ГТД вертольотів (рис. 6.1) шляхом встановлення відповідного прапорця (рис. 6.26, г). При натисканні «Назад» здійснюється повернення до вікна введення перепольотної інформації, а при натисканні кнопки «Далі» – перехід, безпосередньо, до інтерфейсу користувача програми (рис. Ж.17).

У правому верхньому кутку зазначено інформацію про тип вертольоту, його бортовий номер, тип правого і лівого двигунів, їх серійний номер. Розташована знизу цієї інформації зелена або червона індикація свідчить про ввімкнутий або вимкнутий правий та лівий двигун відповідно (зелена – двигун ввімкнений, червона – двигун вимкнутий). Програмний засіб «MONITOR» складається із меню: «Файл», «Двигун», «Задача», «Мова» й «Справка» (рис. 6.27) і головного діалогового вікна.

Файл Двигун Задача Мова	Задача Мова Справка	Мова Справка
Відкрити	Динамічна ідентифікація	English
Польотна місія	Контроль технічного стану	Українська
База даних	Діагностика дефектів	Г
Зберегти	Прогнозування динаміки	
2	Прогнозування дефектів	
а Двигун Задача Мова Спра	Налагодження дозатора палива	Справка
Лівий двигун	Тренд-аналіз	Справка про MONITOR
Правий двигун	Передпомпажний стан	Про програму
б	В	Д

Рисунок 6.27 – Вид меню програмного засобу «MONITOR»: а – «Файл», б – «Двигун», в – «Задача», г – «Мова», д – «Справка»

Вкладка «Файл» (рис. 6.27, а) містить у собі таке меню:

1. «Відкрити» – відкриття для післяпольотного аналізу польотної місії з результатами моніторингу правого чи лівого ГТД вертольоту за будь-якого значення часу з точністю до 1 с.

2. «Польотна місія» – можливість в режимі реального часу повернутись до спеціального діалогового вікна зміни (редагування) передпольотної інформації (рис. 6.27, в).

3. «База даних» – вхід до бази даних програмного засобу «MONITOR». При натисканні на цей рядок меню з'являється вікно авторизації, Базу даних може відкрити та редагувати лише ті користувачі, яким надані такі права розробником.

4. «Зберегти» – збереження польотної місії з результатами моніторингу правого чи лівого ГТД вертольоту, які аналізуються у розборі польоту.

У вкладці «Двигун» (рис. 6.27, б) користувач ставить прапорець на рядок вибору «Правий двигун» або «Лівий двигун». Залежно від цього діалогове вікно програми буде містити інформацію щодо стану правого чи лівого двигуна.

У вкладці «Задача» (рис. 6.27, в) користувач ставить прапорець на рядок вибору комплексної задачі моніторингу або відповідної прикладної задачі моніторингу технічного стану правого чи лівого ГТД вертольоту. Залежно від цього діалогове вікно програми буде містити інформацію щодо результатів обраної прикладної задачі моніторингу правого чи лівого правого чи лівого ГТД вертольоту. На рис. Ж.18 наведено приклад розв'язання задачі контролю технічного стану ГТД вертольотів (відповідно до п. 3.2).

У вкладці «Мова» (рис. 6.27, г) користувач обирає мову інтерфейс програм – українську або англійську шляхом встановлення відповідного прапорця.

У вкладці «Справка» (рис. 6.27, д) міститься «Керівництво для розробника», «Керівництво для користувача», «Справка про MONITOR» й «Про програму». При натисканні та кожен рядок з'являється відповідне діалогове вікно.

Слід звернути на наявність кнопок «Оптимізація» і «Робочий процес», що розташовані в лівому нижньому куті інтерфейсу користувача програмного засобу «MONITOR» (рис. Ж.17). При натисканні на кнопку «Робочий процес» перед користувачем з'являється діалогове вікно з обчисленими параметрами робочого процесу правого чи лівого ГТД вертольоту відповідно до математичної моделі [204]. Значення кожного параметра супроводжується відповідною індикацією, що означає таке: зелена – відхилення значень параметра від еталонного менше 1,0 %, жовта – відхилення значень параметра від еталонного менше перебуває у межах від 1,0 до 3,0 %, помаранчева – відхилення значень параметра від еталонного менше перебуває у межах від 3,0 до 5,0 %, червона – відхилення значень параметра від еталонного більше 5,0 %. Відзначено, що параметри робочого процесу ГТД вертольотів у програмному засобі «MONITOR» подаються як у фізичних величинах (відповідно до системи CI), так і в

357

нормованих, визначених відповідно до (2.10).

При натисканні на кнопку «Оптимізація» перед користувачем з'являється діалогове вікно з оптимальними параметрами робочого процесу правого чи лівого ГТД вертольоту із супроводженням відповідної індикації: зелена – відхилення значень оптимального параметра від поточного менше 1,0 %, жовта – відхилення значень оптимального параметра від поточного менше перебуває у межах від 1,0 до 3,0 %, помаранчева – відхилення значень оптимального параметра від поточного менше перебуває у межах від 3,0 до 5,0 %, червона – відхилення значень оптимального параметра від поточного більше 5,0 %.

Головне інтерфейсу ліалогове вікно користувача засобу програмного «MONITOR» (рис. Ж.16) містить інформаційне поле «Реєстровані параметри», що відображає значення реєстрованих на борту вертольоту параметрів (див. табл. А.1) у фізичних і нормованих величинах. Індикація кожного параметру аналогічна описаній вище. Інформаційне поле «Результати комплексного моніторингу» відображає кінцеві результати розв'язання кожної прикладної задачі відповідно до індикації: зелена - задовільний розв'язок, червона - незадовільний розв'язок. Індикація, що розташована нижче цього інформаційного поля, містить одну із рекомендацій щодо можливості здійснення польоту шляхом нейромережевого аналізу отриманих результатів прикладних задач моніторингу (див. п. 6.4) відповідно до створеної наукової концепції моніторингу технічного стану ГТД вертольотів.

Кнопка «Назад», що розташована у лівому нижньому куті в кожному додатковому діалоговому вікні, дозволяє користувачеві повернутись до головного діалогового вікна інтерфейсу програмного засобу «MONITOR».

Наведений опис функціональних можливостей програмного засобу «MONITOR» констатує можливість командиру екіпажу і другому пілоту вертольоту в режимі реального часу автоматично здійснювати моніторинг ГТД вертольотів, отримати рекомендації щодо технічного стану ГТД вертольотів й можливості здійснення польоту. Отримана інформація може стати вирішальною при продовженні польоту чи здійсненні негайної посадки вертольоту.

Застосування програмного засобу «MONITOR» для реалізації бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів є важливим кроком у вдосконаленні авіаційної безпеки та оптимізації експлуатації вертольотів. Для ефективного використання цього програмного засобу пропонується перелік рекомендацій щодо наявності додаткових знань екіпажу вертольоту (табл. 6.3).

Таблиця 6.3 – Пропонований перелік рекомендацій щодо наявності додаткових знань екіпажу вертольоту (авторський доробок)

Найменування	Опис
Технічна експертиза	Члени екіпажу повинні мати глибокі знання щодо будови та принципу роботи ГТД ве-
	ртольотів. Розуміння основних систем та їх взаємодії допоможе краще розуміти інфор-
	мацію, яку надає програмний засіб.
Навички роботи з систе-	Екіпаж повинен бути здатний ефективно взаємодіяти з програмним засобом
мами моніторингу	«MONITOR». Це включає у себе здатність правильно інтерпретувати інформацію,
	отриману від системи моніторингу, та вчасно реагувати на будь-які попередження чи
	рекомендації.
Навички аналізу та вирі-	Екіпаж повинен мати досвід та навички аналізу та вирішення технічних проблем, що
шення проблем	можуть виникнути під час польоту. Розуміння даних, наданих системою моніторингу,
	є важливим для визначення стану обладнання та прийняття вірних рішень.
Вміння взаємодії з борто-	Екіпаж повинен бути знайомий з іншими бортовими системами та обладнанням верто-
вим обладнанням	льоту, які можуть взаємодіяти з програмним засобом «MONITOR». Це допоможе за-
	безпечити повністю функціональну інтеграцію та взаємодію різних систем.
Навички реагування на	Екіпаж повинен бути підготовлений до екстрених ситуацій, що можуть виникнути че-
екстрені ситуації	рез технічні проблеми. Знання процедур аварійного реагування та швидке прийняття
	рішень є критичним у таких ситуаціях.
Висновок	Успішне впровадження програмного засобу «MONITOR» вимагає від екіпажу ве-
	ртольоту комплексу знань та навичок, що охоплюють технічні аспекти верто-
	льоту, вміння взаємодіяти з сучасним бортовим обладнанням та ефективно реагу-
	вати на технічні аспекти польоту.

Висновки до шостого розділу

1. Удосконалено нейромережевий метод відновлення, адаптований до ГТД вертольотів, яка дозволяє відновлювати термогазодинамічні параметри з точністю до 99.7 % при виході з ладу датчиків. Сформульовано математичну задачу для визначення місця та локалізації несправності датчиків вертольотів за допомогою багатокласової байєсівської класифікації, що підвищує точність виявлення до 99.6...99.7 %. Запропоновано використання байєсівської нейронної мережі для локалізації несправностей датчиків з точністю не менше 95 %. Покращено алгоритм навчання байєсівської нейронної мережі, що забезпечує точність навчання майже 100 % і зниження втрат до 2.5 %. Створено віртуальну установку в LabVIEW для моделювання роботи системи з трьома датчиками, що дозволило підтвердити високу точність відновлення параметрів з помилкою не більше 3...5 %.

2. Набув подальшого розвитку метод відновлення втрачених даних у випадку відмови датчиків ГТД вертольотів за допомогою автоасоціативної нейронної мережі (автокодера), що забезпечує точність відновлення до 99 %, що підтверджено метриками Precision, Recall та F-measure. Удосконалено основний алгоритм навчання автокодера шляхом додавання регуляризації до функції втрат, що зменшує ризик перенавчання моделі. Експериментально доведено, що цей підхід забезпечує максимальну втрату не більше 2.5 %. Вперше було сформульовано та доведено гіпотезу оновлення ваг у автокодері з використанням градієнтного спуску з регуляризацією, що підтверджує ефективність та знижує ризик перенавчання моделі.

3. Набув подальшого розвитку метод парирування відмов вимірювальних каналів автоматичної системи керування складних динамічних об'єктів, який, завдяки використанню багатовимірного фільтра Калмана з точками Чебишева, реалізованого за допомогою модифікованої рекурентної нейронної мережі, дозволяє з точністю 99.8 % виявляти та локалізувати відмови датчиків. Вперше запропоновано реалізацію цього фільтра, що включає вхідний шар, шар діагностики відмов, шар захисту від відмов, шар фільтрації та згладжування, а також шар агрегації результатів, що забезпечує точність діагностики відмов 99.8 %, захисту від відмов 99.8 % та оцінки стану системи 99.8 %. Експериментально доведено, що використання модифікованої рекурентної нейронної мережі зменшує помилки першого та другого виду в 1.24...1.71 рази порівняно з нейронними мережами радіально-базисних функцій і в 1.70...2.90 рази порівняно з методами без нейронних мереж.

4. Запропоновано архітектуру нейромережевої експертної системи моніторингу ГТД вертольотів, визначено функції та склад нейронних мережевих модулів, що реалізують технології обробки інформації та прийняття рішень на різних етапах моніторингу. Розроблено програмне забезпечення експертної системи «MONITOR». Система дозволяє ефективно обробляти результати льотних випробувань, що значно знижує витрати на моніторинг технічного стану ГТД вертольотів під час експлуатації завдяки використанню апріорної та апостеріорної інформації, методів штучного інтелекту та оптимізації прийняття рішень. Розроблена система інтегрована в бортову систему контролю і взаємодіє з системами управління двигуном, підвищуючи якість контролю та надійність двигуна.

Основні результати досліджень, викладені у розділі, опубліковано у наукових працях [479, 481, 485, 486, 494–500, 512, 516–514, 527–532, 539–548].
ВИСНОВКИ

Дисертація присвячена вирішенню актуальної науково-технічної проблеми – розробці математичного і програмного забезпечення моніторингу і управління експлуатацією ГТД вертольотів задля підтримки безпеки польотів вертольотів у реальному часі шляхом застосування нейромережевих технологій і розробки експертної системи.

1. Розроблено архітектуру експертної системи моніторингу і управління експлуатацією ГТД вертольотів у режимі льотної експлуатації задля прийняття своєчасного рішення щодо здійснення польоту на основі проведеного порівняльного аналізу сучасного математичного і програмного забезпечення, а також типової архітектури експертної системи моніторингу та управління експлуатацією складних динамічних об'єктів та їх адаптації до вимог сучасних технологій і динамічного розвитку авіаційної галузі.

2. Розроблено метод побудови нейромережевої моделі процесів класифікації, контролю, діагностики, прогнозування, налагодження, тренд-аналізу параметрів двигунів, що базується на алгоритмі формування однорідної і репрезентативної навчальної і тестової вибірок, який забезпечує достовірність визначення можливості здійснення польоту на рівні 99 %.

3. Розроблено методи розв'язання прикладних задач моніторингу, застосування яких за рахунок модифікованих алгоритмів навчання і архітектур нейронних мереж на рівні 99,5 % зі зменшенням абсолютної похибки до 4,5 разів.

4. Розроблено модель триканальної АПУ з додатковим каналом управління частотою обертів ротора вільної турбіни та програмними модулями адаптивного управління, застосування якої в експертній системі дозволило покращити показники якості каналів управління до 64,29 % порівняно із традиційними двоканальними бортовими системами.

5. Набули подальшого розвитку нейро-нечіткі методи моніторингу, які, шляхом застосування гібридних класифікаторів еволюційної діагностичної матриці з модернізованими нечіткими правилами, адаптовані до змінних умов експлуатації та роботи в умовах неоднозначності, дозволили з впевненістю не нижчою за 0,79 приймати оптимальні рішення щодо справності вузлів двигуна, а також збільшити точність контролю витрати палива до 99,2 %, визначення зміни ККД компресора до 99,62 %.

6. Набули подальшого розвитку методи відновлення даних у разі відмови штатних

сенсорів із застосуванням лінійних, автоасоціативних, РБФ-мереж з алгоритмом багатовимірного фільтра Калмана з поліномом Чебишева, що дозволяє здійснювати реконструкцію параметрів двигуна в реальному часі з максимальною похибкою 0,762 % та здійснити структурну переконфігурацію АПУ для забезпечення безперебійного функціонування та збереження стійкості систем вертольоту.

7. Розроблено прототип експертної системи моніторингу і управління експлуатацією ГТД вертольотів, що включає розроблену АПУ й нейромережеві модулі моніторингу, застосування якої за рахунок модифікацій її основних модулів забезпечило якість прийняття рішення щодо можливості експлуатації двигуна на рівні 99,2 %.

8. Розроблені моделі та методи реалізовані у вигляді програмного засобу «MONITOR», застосування функціональних можливостей якого надає можливість в режимі реального часу здійснювати обчислення параметрів двигунів та отримати рекомендації щодо здійснення польоту з використанням штучних нейронних мереж. Ефективність розробленого програмного засобу «MONITOR» підтверджується результатами впровадження в TOB «ЕЙР ТАУРУС», у військову частину 2269 Національної гвардії України Міністерства внутрішніх справ України у вигляді бортової системи моніторингу ГТД вертольотів, що застосовуються на вертольотах державної авіації України, а також в Департамент авіаційної безпеки Міністерства внутрішніх справ України.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. So G.-B. A Novel CEM-Based 2-DOF PID Controller for Low-Pressure Turbine Speed Control of Marine Gas Turbine Engines. *Processes*. 2024. Vol. 12, no. 9. MDPI AG, 1916. doi: 10.3390/pr12091916.

2. Xiao W., Chen Y., Zhang H. and Shen D. Remaining Useful Life Prediction Method for High Temperature Blades of Gas Turbines Based on 3D Reconstruction and Machine Learning Techniques. *Applied Sciences*. 2023. Vol. 13, no. 19. 1079. doi: 10.3390/app131911079.

3. Li T., Liu Y., and Chen Z. Design of Gas Turbine Cooling System Based on Improved Jumping Spider Optimization Algorithm. *Machines*. 2022. Vol. 10, no. 10. 909, doi: 10.3390/machines10100909.

4. Gurrola Arrieta M. de J., Botez R. M. and Lasne A. An Engine Deterioration Model for Predicting Fuel Consumption Impact in a Regional Aircraft. *Aerospace*. 2024. Vol. 11, no. 6. P. 426. doi: 10.3390/aerospace11060426.

5. Терещенко Ю. М. Газотурбінні двигуни літальних апаратів. Київ : Вища школа, 2000. 319 с.

6. González M. P. V., González Meije A., Muro A. P., García-Martínez M. and Caballero B.
G. Failure analysis of a fuel control pressure tube from an aircraft engine. *Engineering Failure Analysis*. 2021. Vol. 126, Aug. 2021. 105452. doi: 10.1016/j.engfailanal.2021.105452.

7. Balli O. Exergetic, sustainability and environmental assessments of a turboshaft engine used on helicopter. *Energy*. 2023, Vol. 276, 127593. doi: 10.1016/j.energy.2023.127593

8. Zheng X., Zeng H., Wang B., Wen M., Yang H., Sun, Z. Numerical simulation method of surge experiments on gas turbine engines. *Chinese Journal of Aeronautics*. 2023. Vol. 36 (3). P. 107–120.

9. Castiglione, T.; Perrone, D.; Strafella, L.; Ficarella, A.; Bova, S. Linear Model of a Turboshaft Aero-Engine Including Components Degradation for Control-Oriented Applications. *Energies*. 2023, Vol. 16(6), 2634. doi: 10.3390/en16062634

10. Abdalla M. S. M., Balli O., Adali O. H., Korba P., Kale U. Thermodynamic, sustainability, environmental and damage cost analyses of jet fuel starter gas turbine engine. *Energy*. 2023, Vol. 267, 126487. doi: 10.1016/j.energy.2022.126487

11. Ntantis E. L., Botsaris P. Diagnostic methods for an aircraft engine performance. *Journal of Engineering Science and Technology*. 2015. Vol. 8(4). P. 64–72. doi: 10.25103/jestr.084.10

12. Puchikov Y., Molodtsov N., Rugain A. and Popov D. Problems of continued

airworthiness the aircraft fleet of Ukraine. *Proceedings of the National Aviation University*. 2014. Vol. 61, no. 4. Pp. 105–110. doi: 10.18372/2306-1472.61.7595.

13. Goncharenko A. V. Alternativeness of control and power equipment repair versus purchasing according to the preferences of the options. *Electronics and Control Systems*. 2016. Vol. 4, no. 50. doi: 10.18372/1990-5548.50.11396.

14. Dmitriev S., Burlakov V., Popov O., and Popov D. Technological processes and quality control in aircraft engine maintenance. *Aviation*. 2015. Vol. 19, no. 3. P. 133–137. doi: 10.3846/16487788.2015.1107306.

15. Li Y. Development of Digital Flow Valve Applied to Aero-Engine Fuel Control and Research on Performance of Its Flow Characteristics. *Machines*. 2024. Vol. 12, no. 12, 936. doi: 10.3390/machines12120936.

16. Zhou H., Farsi M., Harrison A., Parlikad A.K., and Brintrup A. Civil aircraft engine operation life resilient monitoring via usage trajectory mapping on the reliability contour. *Reliability Engineering & System Safety*. 2023. Vol. 230, 108878. doi: 10.1016/j.ress.2022.108878.

17. Ebrahimi A., Rolt A., Jafari S., and Anton J. H. A review on liquid hydrogen fuel systems in aircraft applications for gas turbine engines. *International Journal of Hydrogen Energy*. 2024.
Vol. 91. P. 88–105. doi: 10.1016/j.ijhydene.2024.10.121.

18. Zhou H., Parlikad A. K., Brintrup A., and Harrison A. A copula-based quantified airworthiness modelling for civil aircraft engines. *Probabilistic Engineering Mechanics*. 2023. Vol. 73, 103481. doi: 10.1016/j.probengmech.2023.103481.

19. Boehm R. C., Faulhaber C., Behnke L., and Heyne J. The effect of theoretical SAF composition on calculated engine and aircraft efficiency. *Fuel.* 2024. Vol. 371, 132049. doi: 10.1016/j.fuel.2024.132049.

20. Sasi S., Mourouzidis C., Rajendran D. J., Roumeliotis I., Pachidis V., and Norman J. Ammonia for civil aviation: A design and performance study for aircraft and turbofan engine. *Energy Conversion and Management*. 2024. Vol. 307, 118294. doi: 10.1016/j.enconman.2024.118294.

21. Cai C., Chen H., Fang J., Zheng Q., Chen C., and Zhang H. Thermodynamic analysis of a novel precooled supersonic turbine engine based on aircraft/engine integrated optimal design. *Energy*. 2023. Vol. 280, 128161. doi: 10.1016/j.energy.2023.128161.

22. Liu X., Shi J., Qi Y., and Yuan Y. Design for aircraft engine multi-objective controllers with switching characteristics. *Chinese Journal of Aeronautics*. 2014. Vol. 27, no. 5. P. 1097–1110.

doi: 10.1016/j.cja.2014.08.002.

23. Huda Z. and Edi P. Materials selection in design of structures and engines of supersonic aircrafts: A review. *Materials & Design* (1980–2015). 2013. Vol. 46. P. 552–560. doi: 10.1016/j.matdes.2012.10.001.

24. Nicolosi F., Vecchia P. Della, and Corcione S. Design and aerodynamic analysis of a twinengine commuter aircraft. Aerospace Science and Technology. 2015. Vol. 40. P. 1–16. doi: 10.1016/j.ast.2014.10.008.

25. Atkinson S. Fire seal is designed for use on aircraft with engines that operate at high temperatures. *Sealing Technology*. 2020. Vol. 2020, no. 11. P. 5–5. doi: 10.1016/s1350-4789(20)30352-4.

26. Cao J. and Ding S. Sensitivity Analysis for Safety Design Verification of General Aviation Reciprocating Aircraft Engine. *Chinese Journal of Aeronautics*. 2012. Vol. 25, no. 5. P. 675–680. doi: 10.1016/s1000-9361(11)60433-0.

27. Xianghua J. and Ran D. Optimal Design Aircraft Engine Mount Systems. *Procedia Engineering*. 2015. Vol. 99. P. 1297–1301. doi: 10.1016/j.proeng.2014.12.662.

28. Zhou Y. et al. Theoretical model for high-altitude gas exchange process in multi-fuel poppet valves two-stroke aircraft engine. *Energy Conversion and Management*. 2024. Vol. 301, 118028. doi: 10.1016/j.enconman.2023.118028.

29. Li J., Yang Z., Zhou X., Song C., and Wu Y. Advancing the Diagnosis of Aero-Engine Bearing Faults with Rotational Spectrum and Scale-Aware Robust Network. *Aerospace*. 2024. Vol. 11, no. 8, 613. doi: 10.3390/aerospace11080613.

30. Peng Z., Wang Q., Liu Z., and He R. Remaining Useful Life Prediction for Aircraft Engines under High-Pressure Compressor Degradation Faults Based on FC-AMSLSTM. *Aerospace*. 2024. Vol. 11, no. 4, 293. doi: 10.3390/aerospace11040293.

31. Kim S., Im J.H., Kim M., Kim J., Kim Y.I. Diagnostics using a physics-based engine model in aero gas turbine engine verification tests. *Aerospace Science and Technology*. 2023. Vol. 133, 108102. doi: 10.1016/j.ast.2022.108102.

32. Владов С. І., Шмельова Т. Ф., Шмельов Ю. М. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах за допомогою нейромережевих технологій : Монографія. Кременчук : ПП Щербатих О. В., 2020. 200 с.

33. Владов С. І., Шмельов Ю. М., Буряк Д. Є., Сєдов М. В Щодо питання контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 в умовах його бортової експлуатації. *Авіація, промисловість, суспільство* : матеріали I Міжнародної науковопрактичної конференції, 14 травня 2020 р. Кременчук : КЛК ХНУВС, 2020. Ч. 1. С. 117–120.

34. Zhang S., Ma A., Zhang T., Ge N., and Huang X. A Performance Simulation Methodology for a Whole Turboshaft Engine Based on Throughflow Modelling. *Energies*. 2024. Vol. 17, no. 2, 494. doi: 10.3390/en17020494.

35. Xu L., Bo S., Hongde Y. and Lei W. Evolution of Rolls-royce Air-cooled Turbine Blades and Feature Analysis. *Procedia Engineering*. 2015. Vol. 99. P. 1482–1491. doi: 10.1016/j.proeng.2014.12.689.

36. Wang Y., Ji C., Xi Z., Zhang H., Zhao Q. An adaptive matching control method of multiple turboshaft engines. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 123 (part C), 106496. doi: 10.1016/j.engappai.2023.106496

37. Shen Y., Khorasani K. Hybrid multi-mode machine learning-based fault diagnosis strategies with application to aircraft gas turbine engines. *Neural Networks*. 2020. Vol. 130, Pp. 126–142. doi: 10.1016/j.neunet.2020.07.001

38. Jiang P., Xiong S., Xu W., Du Z., He X. Experimental study on the influence of inlet velocity and fuel/air ratio on outlet temperature profile performance in a turboshaft engine combustor. *Fuel.* 2024. Vol. 357 (part A), 129715. doi: 10.1016/j.fuel.2023.129715

39. Chen X., Hong J., Wang Y., Ma Y. Fatigue failure analysis of the central-driven bevel gear in a turboshaft engine arising from multi-source excitation. *Engineering Failure Analysis*. 2021. Vol. 119, 104811. doi: 10.1016/j.engfailanal.2020.104811

40. Djeddi C., Hafaifa A., Iratni A., Hadroug N., Chen X. Robust diagnosis with high protection to gas turbine failures identification based on a fuzzy neuro inference monitoring approach. *Journal of Manufacturing Systems*. 2021. Vol. 59. P. 190–213. doi: 10.1016/j.jmsy.2021.02.012

41. Liu J. Gas path fault diagnosis of aircraft engine using HELM and transfer learning. *Engineering Applications of Artificial Intelligence*. 2022. Vol. 114, 105149. doi: 10.1016/j.engappai.2022.105149

42. Hassannayebi E., Nourian R., Mousavi S.M., Alizadeh S.M.S., Memarpour M. Predictive analytics for fault reasoning in gas flow control facility: A hybrid fuzzy theory and expert system approach. *Journal of Loss Prevention in the Process Industrie*. 2022. Vol. 77, 104796. doi: 10.1016/j.jlp.2022.104796

43. Hanachi H., Liu J., Mechefske C. Multi-mode diagnosis of a gas turbine engine using an

adaptive neuro-fuzzy system. *Chinese Journal of Aeronautic*. 2018, Vol. 31:1. P. 1–9. doi: 10.1016/j.cja.2017.11.017

44. Bazazzadeh M., Badihi H., Shahriari A. Gas Turbine Engine Control Design Using Fuzzy Logic and Neural Networks. *International Journal of Aerospace Engineering*. 2011. Vol. 2011, 156796. doi: 10.1155/2011/156796.

45. Кучмистенко О. В., Шавранський М. В., Незамай Б. С., Малько О. Г. Синтез системи керування газотурбінним двигуном на базі нечіткої логіки. *Методи та прилади контролю якості*. 2021. № 1 (46). С. 53–62. doi: 10.31471/1993-9981-2021-1(46)-53-62

46. Ogaji S. O. T., Marinai L., Sampath S., Singh R., Prober S. D. Gas-Turbine Fault Diagnostics: A Fuzzy-Logic Approach. *Applied Energy*. 2005. Vol. 82. P. 81–89. doi: 10.1016/j.apenergy.2004.07.004.

47. Shen Y., Khorasani K. Hybrid multi-mode machine learning-based fault diagnosis strategies with application to aircraft gas turbine engines. *Neural Networks*. 2020. Vol. 130. P. 126–142. doi: 10.1016/j.neunet.2020.07.001

48. Gu Z., Li Q., Pang S., Zhou W., Wu J., Zhang C. Turbo-shaft engine adaptive neural network control based on nonlinear state space equation. *Chinese Journal of Aeronautics*. 2024. Vol. 37:4. P. 493–507. doi: 10.1016/j.cja.2023.08.012

49. Tayarani-Bathaie S.S., Khorasani K. Fault detection and isolation of gas turbine engines using a bank of neural networks. *Journal of Process Control.* 2015. Vol. 36. P. 22–41. doi: 10.1016/j.jprocont.2015.08.007

50. Tsoutsanis E., Qureshi I., Hesham M. Performance diagnostics of gas turbines operating under transient conditions based on dynamic engine model and artificial neural networks. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 236 (part B), 106936. doi: 10.1016/j.engappai.2023.106936

51. Han X., Huang J., Zhou X., Zou Z., Lu F., Zhou W. A novel, reduced-order optimization method for nonlinear model correction of turboshaft engines. *Journal of Mechanical Science and Technology*. 2024. Vol. 38, 2103–2122. doi: 10.1007/s12206-024-0340-5

52. Tayarani-Bathaie S. S., Vanini Z. N. S., Khorasani K. Fault Detection of Gas Turbine Engines Using Dynamic Neural Networks. 2012 25th IEEE Canadian Conference on Electrical and Computer Engineering (CCECE), Montreal, QC, Canada, 29 April – 02 May 2012. doi: 10.1109/ccece.2012.6334837.

53. Tayarani-Bathaie S. S., Khorasani K. Fault Detection and Isolation of Gas Turbine

367

Engines Using a Bank of Neural Networks. *Journal of Process Control*. 2015. Vol. 36. P. 22–41. doi: 10.1016/j.jprocont.2015.08.007.

54. Tayarani-Bathaie S. S., Sadough Vanini Z. N., Khorasani K. Dynamic Neural Network-Based Fault Diagnosis of Gas Turbine Engines. *Neurocomputing*. 2014. Vol. 125. P. 153–165. doi: 10.1016/j.neucom.2012.06.050.

55. Pogorelov G. I., Kulikov G. G., Abdulnagimov A. I., Badamshin B. I. Application of Neural Network Technology and High-Performance Computing for Identification and Real-Time Hardware-in-the-Loop Simulation of Gas Turbine Engines. *Procedia Engineering*. 2017. Vol. 176. P. 402–408. doi: 10.1016/j.proeng.2017.02.338.

56. Talebi S. S., Madadi A., Tousi A. M., Kiaee M. Micro Gas Turbine Fault Detection and Isolation with a Combination of Artificial Neural Network and Off-Design Performance Analysis. *Engineering Applications of Artificial Intelligence*. 2022. Vol. 113. 104900. doi: 10.1016/j.engappai.2022.104900.

57. Климова Я. Р., Владов С. И., Бойко С. Н. К вопросу проблематики определения в полете комплекса летных характеристик эффективности вертолетов с турбовальными двигателями. *Авіація і космонавтика* : матеріали IX Всеукраїнської науково-практичної конференції, 17 квітня 2018 р. Кривий Ріг : КК НАУ, 2018. С. 58.

58. Климова Я. Р., Владов С. И. Проблематика информационного обеспечения определения, диагностики и прогнозирования летных характеристик вертолета. *Авіація і космонавтика* : матеріали IX Всеукраїнської науково-практичної конференції, 17 квітня 2018 р., Кривий Ріг. Кривий Ріг : КК НАУ, 2018. С. 59.

59. Arush I. and Pavel M. D. Helicopter gas turbine engine performance analysis: A multivariable approach. *Proceedings of the Institution of Mechanical Engineers*. Part G: Journal of Aerospace Engineering. 2017. Vol. 233, no. 3. P. 837–850. doi: 10.1177/0954410017741329.

60. Taha S., Ismail F., and Thiruchelvam S. Gas Turbine Performance Monitoring and Operation Challenges: A Review. *Gazi University Journal of Science*. 2023. Vol. 36, no. 1. Gazi University Journal of Science. P. 154–171. doi: 10.35378/gujs.948875.

61. Han P., Liang Q., Vanem E., Knutsen K. E. and Zhang H. Assessing Helicopter Turbine Engine Health: A Simple Yet Robust Probabilistic Approach. *Annual Conference of the PHM Society*. 2024. Vol. 16, no. 1. doi: 10.36001/phmconf.2024.v16i1.4186.

62. Vishwanatha A. N. Rao et al. Challenges in Engine Health Monitoring Instrumentation During Developmental Testing of Gas Turbine Engines. *Lecture Notes in Mechanical Engineering*. Springer Singapore. 2020 Aug. 01. P. 275–295. doi: 10.1007/978-981-15-5039-3 16.

63. Tovkach S. Control Laws of the Aviation Gas Turbine Engine. *Electronics and Control Systems*. 2022. № 2. P. 20–25. doi: 10.18372/1990-5548.72.16938.

64. Dediu G., Crunteanu D. E. Automatic Control System for Gas Turbines Test Rig. *Applied Mechanics and Materials*. 2013. Vol. 436. P. 398–405. doi: 10.4028/www.scientific.net/amm.436.398.

65. Yepifanov S. Aircraft Turbine Engine Automatic Control Based on Adaptive Dynamic Models. *Transactions on Aerospace Research*. 2020. № 4(261). P. 61–70. doi: 10.2478/tar-2020-0021.

66. Petunin V. I. Methods of Coordination and Adaptation of Automatic Control Systems for Gas Turbine Engines with Channel Selectors. *Russ. Aeronaut.* 2022. Vol. 65. P. 288–296. doi: 10.3103/S1068799822020088

67. Valeev S., Kondratyeva N. Design of Nonlinear Control of Gas Turbine Engine Based on Constant Eigenvectors. *Machines*. 2021. Vol. 9 (3). 49. doi: 10.3390/machines9030049.

68. Gurevich O., Smetanin S., Trifonov M. Automatic Control to Reduce the Effect of Deterioration of Gas Turbine Engine Components on Its Performance Characteristics. *AIAA Propulsion and Energy 2021 Forum*, 2021. doi: 10.2514/6.2021-3734.

69. Vladuca I., Borzea C. I., Letitia Vasile M., Balan G. I., Savescu A., Mitru A., Niculescu D. F., Valentin Nechifor C., Useriu D., Stanescu T., Badea P. G., Ciobanu R. *Automation Control System for Naval Propulsion Retrofitting. 2021 International Conference on Applied and Theoretical Electricity (ICATE)*, Craiova, Romania, 27–29 May 2021. doi: 10.1109/icate49685.2021.9465065.

70. Kulyk M. S., Kozlov V. V., Volianska L. G. Automation control system of technical condition of gas turbine engine compressor. *Aerospace technic and technology*. 2019. № 8 (160). P. 121–128. doi: 10.32620/aktt.2019.8.18.

71. Petunin V. I., Frid A. I. Analysis and Synthesis of Logical-Dynamic Systems of Automatic Control of a Gas-Turbine Engine. *Journal of Computer and Systems Sciences International*. 2012. Vol. 51. P. 818–832. doi: 10.1134/s1064230712060093.

72. Владов С. І., Пономаренко А. В., Гвоздік С. Д. Постановка задачі контролю і діагностики технічного стану авіаційного двигуна ТВЗ-177 на основі багаторівневої системи управління. *Новітні технології сучасного суспільства (HTCC-2018)* : матеріали Всеукраїнської науково-практичної конференції, 12 грудня 2018 р. Чернігів : Чернігівський національний технічний університет, 2018. С. 148–149.

73. Xiao D., Lin Z., Yu A., Tang K. and Xiao H. Data-driven method embedded physical

knowledge for entire lifecycle degradation monitoring in aircraft engines. *Reliability Engineering* & *System Safety*. 2024. Vol. 247. 110100. doi: 10.1016/j.ress.2024.110100.

74. Yang Q., Tang B., Li Q., Liu X. and Bao L. Dual-frequency enhanced attention network for aircraft engine remaining useful life prediction. *ISA Transactions*. 2023. Vol. 141. Pp. 167–183. doi: 10.1016/j.isatra.2023.06.020.

75. Syta A., Czarnigowski J., Jakliński P. and Marwan N. Detection and identification of cylinder misfire in small aircraft engine in different operating conditions by linear and non-linear properties of frequency components. *Measurement*. 2023. Vol. 223. 113763. doi: 10.1016/j.measurement.2023.113763.

76. Marin G. E., Titov A. V., Akhmetshin A. R., Ishalin A. V. Increasing the Efficiency of a Conversion Gas Turbine Engine by Adding Hydrogen to Fuel Gas. *International Journal of Hydrogen Energy*. 2025. Vol. 97. P. 649–656. doi: 10.1016/j.ijhydene.2024.11.304.

77. Antonov D. V., Cherkasov R. E., Gneusheva V. V., Mikulich M. E., Strizhak P. A., Yanovskiy L. S. Comprehensive Approach to Static Firing Tests of Micro Gas Turbine Engines Powered by Liquid Fuels. *Energy*. 2024. Vol. 313. 133870. doi: 10.1016/j.energy.2024.133870.

78. Nikolaidis T., Li Z., Jafari S. Advanced Constraints Management Strategy for Real-Time Optimization of Gas Turbine Engine Transient Performance. *Applied Sciences*. 2019. Vol. 9 (24). 5333. doi: 10.3390/app9245333.

79. Zhu L., Liu J., Ma Y., Zhou W., Yu D. A Corrected Equilibrium Manifold Expansion Model for Gas Turbine System Simulation and Control. *Energies*. 2020. Vol. 13 (18). 4904. doi: 10.3390/en13184904.

80. De Giorgi M. G., Strafella L., Ficarella A. Neural Nonlinear Autoregressive Model with Exogenous Input (NARX) for Turboshaft Aeroengine Fuel Control Unit Model. *Aerospace*. 2021. Vol. 8 (8). 206. doi: 10.3390/aerospace8080206.

81. Peng D., Yin S., Li K., Luo H. An SW-ELM Based Remaining Useful Life Prognostic Approach for Aircraft Engines. *IFAC-PapersOnLine*. 2020. Vol. 53. P. 13601–13606. doi: 10.1016/j.ifacol.2020.12.853.

82. Rabcan J., Levashenko V., Zaitseva E., Kvassay M., Subbotin S. Non-Destructive Diagnostic of Aircraft Engine Blades by Fuzzy Decision Tree. *Engineering Structures*. 2019. Vol. 197. 109396. doi: 10.1016/j.engstruct.2019.109396.

83. Madhavan S., Jain R., Sujatha C., Sekhar A. S. Vibration Based Damage Detection of Rotor Blades in a Gas Turbine Engine. *Engineering Failure Analysis*. 2014, Vol. 46, P. 26–39.

doi: 10.1016/j.engfailanal.2014.07.021.

84. Zhang X., Zhong M., Ooi K. T., Zhang T. Incipient Instability Real-Time Warning via Adaptive Wavelet Synchrosqueezed Transform: Onboard Applications from Compressors to Gas Turbine Engines. *Energy*. 2024. Vol. 308, 132925. doi: 10.1016/j.energy.2024.132925.

85. Kalyani S., Venkata Rao K., Mary Sowjanya A. A Time Image Net Sequence Learning for Remaining Useful Life Estimation of Turbofan Engine in Aircraft Systems. *Structural Durability & Health Monitoring*. 2021. Vol. 15. P. 317–334. doi: 10.32604/sdhm.2021.016975.

86. Li Z., Nikolaidis T., Nalianda D. Recursive Least Squares for Online Dynamic Identification on Gas Turbine Engines. *Journal of Guidance, Control, and Dynamics*. 2016. Vol. 39(11). P. 1–8. doi: 10.2514/1.G000408.

87. Pu X., Liu S., Jiang H. Observable degree analysis of heavy-duty gas turbine based on SVD method. In Proceedings of the 2011 Second International Conference on Mechanic Automation and Control Engineering, Inner Mongolia, China, 15–17 July 2011. doi: 10.1109/MACE.2011.5988569.

88. Tsoutsanis E., Qureshi I., Hesham M. Performance diagnostics of gas turbines operating under transient conditions based on dynamic engine model and artificial neural networks. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 236 (part B), 106936. doi: 10.1016/j.engappai.2023.106936.

89. Chen M., Chen H., Zhang H. Central cone film cooling scheme of turbofan engine based on multi-fidelity simulation. *Applied Thermal Engineering*. 2024. Vol. 253, 123811. doi: 10.1016/j.applthermaleng.2024.123811.

90. Wei Z., Ma Y., Yang N., Ruan S., Xiang C. Reinforcement learning based power management integrating economic rotational speed of turboshaft engine and safety constraints of battery for hybrid electric power system. *Energy*. 2023. Vol. 263 (part B), 125752. doi: 10.1016/j.energy.2022.125752.

91. Sheng H., Chen Q., Li J., Jiang W., Wang Z., Liu Z., Zhang T., Liu Y. Research on dynamic modeling and performance analysis of helicopter turboshaft engine's start-up process. *Aerospace Science and Technology*. 2020. Vol. 106, 106097. doi: 10.1016/j.ast.2020.106097.

92. Wu X., Hu X., Xiang X., Lin S., You J., Tian F. An analysis approach for micro gas turbine engine's performance by experiment and numerical simulation. *Case Studies in Thermal Engineering*. 2023. Vol. 49, 103305. doi: 10.1016/j.csite.2023.103305.

93. Gao H., He A., Gao Z., Na Y., Deng Y. Flight dynamics characteristics of canard

371

rotor/wing aircraft in helicopter flight mode. *Chinese Journal of Aeronautics*. 2019, Vol. 32:7. P. 1577–1587. doi: 10.1016/j.cja.2019.04.002.

94. Cihangir S.A., Aygun H., Turan O. Energy and performance analysis of a turbofan engine with the aid of dynamic component efficiencies. *Energy*. 2022. Vol. 260, 125085. doi: 10.1016/j.energy.2022.125085.

95. Osegi E.N., Jagun Z.O.O., Chujor C.C., Anireh V.I.E., Wokoma B.A., Ojuka O. An evolutionary programming technique for evaluating the effect of ambient conditions on the power output of open cycle gas turbine plants – A case study of Afam GT13E2 gas turbine. *Applied Energy*. 2023. Vol. 349, 121661. doi: 10.1016/j.apenergy.2023.121661.

96. Sharma K.K., Jee G., Rajeev U.P., Padmakumar E.S. Modeling of the Helicopter Underslung Aircraft's Lateral-Directional Dynamics. *IFAC-PapersOnLine*. 2022. Vol. 55:1. P. 174–179. doi: 10.1016/j.ifacol.2022.04.029.

97. Djeddi C., Hafaifa A., Iratni A., Hadroug N., Chen X. Robust Diagnosis with High Protection to Gas Turbine Failures Identification Based on a Fuzzy Neuro Inference Monitoring Approach. *Journal of Manufacturing Systems*. 2021. Vol. 59. P. 190–213. doi: 10.1016/j.jmsy.2021.02.012.

98. Zhang C., Gümmer V. Multi-Objective Optimization and System Evaluation of Recuperated Helicopter Turboshaft Engines. *Energy*. 2020. Vol. 191, 116477. doi: 10.1016/j.energy.2019.116477.

99. Thibault N., Bourdon A., Rémond D., Lecouvreur D. Dynamic Models for Power Transmission Monitoring in Non-Stationary Conditions Based on IAS Signals. *Mechanism and Machine Theory*. 2024. Vol. 201, 105733. doi: 10.1016/j.mechmachtheory.2024.105733.

100. Zhang T., Zhang Z., Zhu X., Chen B., Li J., Zhong Y. Aircraft Engine Danger Areas Incursion Detection Using Keypoint Detection and IoT. *Alexandria Engineering Journal*. 2024. Vol. 93. P. 7–21. doi: 10.1016/j.aej.2024.03.003.

101. Yang P., Yue W., Li J., Bin G., Li C. Review of Damage Mechanism and Protection of Aero-Engine Blades Based on Impact Properties. *Engineering Failure Analysis*. 2022. Vol. 140, 106570. doi: 10.1016/j.engfailanal.2022.106570.

102. Narimani M., Emami S. A., Castaldi P. Intelligent Control for Aerospace Engineers: A Novel Educational Framework. *IFAC-PapersOnLine*. 2024. Vol. 58(16). P. 41–46. doi: 10.1016/j.ifacol.2024.08.459.

103. Wang B., Wang F., Zhang X., Wang J., Xue T. Numerical analysis of cooling efficiency

for turboshaft engines with converging-diverging film cooling holes. *International Journal of Thermal Sciences*. 2023. Vol. 185, 108044. doi: 10.1016/j.ijthermalsci.2022.108044.

104. Jiang P., Xiong S., Xu W., Du Z., He X. Experimental study on the influence of inlet velocity and fuel/air ratio on outlet temperature profile performance in a turboshaft engine combustor. *Fuel.* 2024. Vol. 357 (part A), 129715. doi: 10.1016/j.fuel.2023.129715

105. Han D., Pastrikakis V., Barakos G.N. Helicopter performance improvement by variable rotor speed and variable blade twist. *Aerospace Science and Technology*. 2016. Vol. 54. P. 164–173. doi: 10.1016/j.ast.2016.04.011.

106. Singh R., Maity A., Nataraj P.S.V. Dynamic modeling and robust nonlinear control of a laboratory gas turbine engine. *Aerospace Science and Technology* 2022, Vol. 126, 107586. doi: 10.1016/j.ast.2022.107586.

107. Khattak W. R., Salman A., Ghafoor S., Latif S. Multi-Modal LSTM Network for Anomaly Prediction in Piston Engine Aircraft. *Heliyon*. 2024. Vol. 10, e25120. doi: 10.1016/j.heliyon.2024.e25120.

108. Lyu K., Tan X., Liu G., Zhao C. Sensor Selection of Helicopter Transmission Systems Based on Physical Model and Sensitivity Analysis. *Chinese Journal of Aeronautics*. Vol. 2014. Vol. 27. P. 643–654. doi: 10.1016/j.cja.2014.04.025.

109. Alozie O., Li Y.-G., Wu X., Shong X., Ren W. An Adaptive Model-Based Framework for Prognostics of Gas Path Faults in Aircraft Gas Turbine Engines. *International Journal of Prognostics and Health Management*. 2019. Vol. 10. doi: 10.36001/ijphm.2019.v10i2.2728.

110. Xiao D., Lin Z., Yu A., Tang K., Xiao H. Data-Driven Method Embedded Physical Knowledge for Entire Lifecycle Degradation Monitoring in Aircraft Engines. *Reliability Engineering & System Safety*. 2024. Vol. 247, 110100. doi: 10.1016/j.ress.2024.110100.

111. Fentaye A. D., Zaccaria V., Kyprianidis K. Aircraft Engine Performance Monitoring and Diagnostics Based on Deep Convolutional Neural Networks. *Machines*. 2021. Vol. 9, 337. doi: 10.3390/machines9120337.

112. Lee H., Li G., Rai A., Chattopadhyay A. Health Monitoring Framework for Aircraft Engine System Using Deep Neural Network. In Proceedings of the Annual Conference of the PHM Society. 2019. Vol. 11. doi: 10.36001/phmconf.2019.v11i1.869.

113. Lin L., Wu J., Fu S., Zhang S., Tong C., Zu L. Channel Attention & Temporal Attention Based Temporal Convolutional Network: A Dual Attention Framework for Remaining Useful Life Prediction of the Aircraft Engines. *Advanced Engineering Informatics*. 2024. Vol. 60, 102372. doi: 10.1016/j.aei.2024.102372.

114. Zhang S., Ma A., Zhang T., Ge N.. Huang X. A Performance Simulation Methodology for a Whole Turboshaft Engine Based on Throughflow Modelling. *Energies*. 2024. Vol. 17(2), 494. doi: 10.3390/en17020494

115. Ebrahimi A., Rolt A., Jafari S., Anton J. H. A Review on Liquid Hydrogen Fuel Systems in Aircraft Applications for Gas Turbine Engines. *International Journal of Hydrogen Energy*. 2024.
Vol. 91. P. 88–105. doi: 10.1016/j.ijhydene.2024.10.121.

116. ElSaid A., Wild B., Higgins J., Desell T. Using LSTM Recurrent Neural Networks to Predict Excess Vibration Events in Aircraft Engines. In Proceedings of the 2016 IEEE 12th International Conference on e-Science (e-Science). 2016. doi: 10.1109/escience.2016.7870907.

117. Zheng. Q., Zhang H., Li Y., Hu Z. Aero-Engine Onboard Dynamic Adaptive MGD Neural Network Model Within a Large Flight Envelope. *IEEE Access*. 2018. Vol. 6, 45755–45761. doi: 10.1109/access.2018.2789935.

118. Wang K., Liao Z., Xu M., Li M., Duan B., Liu J., Song Z. Robust Acceleration Schedule Design for Gas Turbine Engine Using Multilayer Perceptron Network with Adaptive Sample Class Weighting. *Aerospace Science and Technology*. 2024. Vol. 154, 109500. doi: 10.1016/j.ast.2024.109500.

119. Nail B., Benrabeh D., Tibermacne I. E., Napoli C., Nabil H., Abdelaziz R. Gas Turbine Vibration Monitoring Based on Real Data Using Neuro-Fuzzy System. *Diagnostyka*. 2024. Vol. 25. P. 1–9. doi: 10.29354/diag/181190.

120. Wei W. Identification method for helicopter flight dynamics modeling with rotor degrees of freedom. *Chinese Journal of Aeronautics*. 2014. Vol. 27:6. P. 1363–1372. doi: 10.1016/j.cja.2014.10.002.

121. Xiong M., Wang H. Digital Twin Applications in Aviation Industry: A Review. *The International Journal of Advanced Manufacturing Technology*. 2022. Vol. 121, 5677–5692. doi: 10.1007/s00170-022-09717-9.

122. Vlasenko D., Inkarbaieva O., Peretiatko M., Kovalchuk D., Sereda O. Helicopter Radio System for Low Altitudes and Flight Speed Measuring with Pulsed Ultra-Wideband Stochastic Sounding Signals and Artificial Intelligence Elements. *Radioelectronic and Computer Systems*. 2023. Vol. 3. P. 48–59. doi: 10.32620/reks.2023.3.05.

123. Машошин О. Ф. Діагностика авіаційних газотурбінних двигунів із використанням інформаційного потенціалу контрольованих параметрів: дис. ... доктора техн. наук: 05.22.14.

2005. 233 с.

375

124. Жернаков С. В. Контроль і діагностика технічного стану авіаційних двигунів на основі інтелектуального аналізу даних: дис. ... доктора техн. наук: 05.13.01. 2005. 364 с.

125. Mashoshin O. F., Zontov G. S. Diagnostics of aircraft gas turbine engine by the presence of harmful impurities in the air conditioning system. *Scientific Bulletin of MSTU CA*. 2014. No. 205. P. 44–48.

126. Mashoshin O. F., Bigus A. V. Information support for diagnostic processes of aircraft equipment. *Scientific Bulletin of MSTU CA*. 2002. No. 49. P. 44–48.

127. Mashoshin O. F., Bigus A. V. Forecasting the technical condition of a gas turbine engine based on rotor coasting. *Scientific Bulletin of MSTU CA*. 2003. No. 66. pp. 101–106.

128. Владов С. І., Климова Я. Р., Плужник З. І. Аналіз інформаційних діагностичних ознак системи ідентифікації технічного стану двигуна ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали І Всеукраїнської науково-практичної конференції молодих вчених, курсантів та студентів, 27 квітня 2018 р. Кременчук : КЛК НАУ, 2018. С. 141–143.

129. Владов С. І., Семенов В. О., Гвоздік С. Д. Параметрична класифікація станів авіаційного двигуна ТВЗ-117 як об'єкта діагностики. *Інформаційні технології в соціокультурній сфері, освіті, науці та економіці* : матеріали щорічної Міжнародної науково-практичної конференції, 17–18 квітня 2019 р. Київ. : Київський національний університет культури і мистецтв, 2019. С. 30–32.

130. Шмельов Ю. М., Владов С. І. Постановка задачі використання теорії інформації для розв'язку задачі контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Інформаційні технології в соціокультурній сфері, освіті, науці та економіці* : матеріали щорічної Міжнародної науково-практичної конференції, 17–18 квітня 2019 р. Київ : Київський національний університет культури і мистецтв, 2019. С. 181–184.

131. Владов С. І., Васильєв Д. О., Телешун В. Я., Юрко О. О., Москалець Т. В., Гарніс С. Використання методу згорток частинних параметрів контролю до узагальненого показника для контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XVIII Міжнародної науково-технічної конференції, 1–3 листопада 2019 р., Кременчук–Хургада. Кременчук : КрНУ, 2019. С. 38–39.

132. Владов С. І., Плужник З. І., Матусєв А. О., Коваль І. М., Юрко О. О., Москалець Т. В., Проворова-Кім М. Метод узагальненої оцінки технічного стану авіаційного двигуна

ТВЗ-117. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XVIII Міжнародної науково-технічної конференції, 1–3 листопада 2019 р., Кременчук–Хургада. Кременчук : КрНУ, 2019. С. 125–127.

133. Владов С. І., Шмельов Ю. М., Матусєв А. О., Плужник З. І. Вибір інформаційного критерію для контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали І Міжнародної науково-практичної конференції, 14 травня 2020 р. Кременчук : КЛК ХНУВС, 2020. Ч. 1. С. 354–357.

134. Владов С. І., Шмельов Ю. М., Назаренко Н. П., Донченко Я. В. Щодо питання використання ентропійного підходу для контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали І Міжнародної науково-практичної конференції, 14 травня 2020 р. Кременчук : КЛК ХНУВС, 2020. Ч. 1. С. 357–361.

135. Шмелев Ю. Н., Владов С. И., Бойко С. Н., Климова Я. Р., Вишневский С. Я. Информационно-диагностическая система состояния двигателя вертолета Ми-8МТВ при его эксплуатации в реальных режимах работы. Вісник Хмельницького національного університету. 2018. № 3.2018. С. 241–245.

136. Шмелев Ю. Н., Владов С. И., Климова Я. Р. Информационная система диагностики работы двигателя вертолета Ми-8МТВ. *Перспективні напрямки наукової думки* : матеріали Міжнародної науково-практичної конференції, 18 квітня 2018 р., Тернопіль. Одеса : Друкарня «Друкарик», 2018. Т. 5. С. 55–57.

137. Муслухов І. І. Підвищення ефективності бортових алгоритмів моніторингу параметрів газотурбінного двигуна на основі технології нейронних мереж: дис. ... канд. техн. наук: 05.13.01. 2007. 161 с.

138. Muslukhov I. I., Zhernakov S. V. The task of monitoring the information channels of an aircraft gas turbine engine under on-board conditions. *Bulletin of the SSAU*. 2007. Vol. 1. No. 2. P. 157–161.

139. Muslukhov I. I., Vasiliev V. I., Zhernakov S. V. Using neural network information technologies to improve the fault tolerance of an aircraft engine. *Computer science and information technology CSIT'2003* : Proceedings of the 5th international conference, 2003, Ufa. Vol. 2. P. 91–96.

140. Muslukhov I. I., Zhernakov S. V. Increasing the accuracy of monitoring measurements of gas-dynamic parameters of gas turbine engines in real time. *Computer science and information technology CSIT'2007*: Proceedings of the 9th international conference, 2007, Ufa. Vol. 2. P. 108–112.

141. Vasiliev V. I., Idrisov I. I. Algorithms for designing and analyzing the stability of an intelligent gas turbine control system. *Bulletin of USATU*. 2008. Vol. 11. No. 1 (28). P. 34–42.

142. Vasiliev V. I., Yamalov I. U., Idrisov I. I., Bureeva T. M. Synthesis of algorithms and modeling of control processes in emergency situations. *Computer science and information technology CSIT'2005* : Proceedings of the 7th international conference, 2005. Vol. 2. P. 122–125.

143. Idrisov I. I. Algorithm of adaptive neural network control of gas turbine engines. *Computer engineering and new information technologies*. 2007. No. 6. P. 64–69.

144. Ідрісов І. І. Алгоритми адаптації та забезпечення відмовостійкості систем управління газотурбінними двигунами на основі технологій нейронних мереж: дис. ... канд. техн. наук: 05.13.01. 2009. 150 с.

145. Єнчев С. В. Синтез інтелектуальних систем керування авіаційними газотурбінними двигунами. дис. ... д-ра техн. наук : 05.05.03. Київ, 2020. 326 с.

146. Єнчев С. В. Динамічна оптимізація системи автоматичного керування авіаційного газотурбінного двигуна. *Вісник двигунобудування*. 2018. № 2. С. 64–69.

147. Єнчев С. В., Павелко О. В. Динамічний синтез лінійної двомірної системи регулювання гвинтовентиляторів ТГВД Д-27. *Наукоємні технології*. 2013. № 4 (16). С. 14–19.

148. Єнчев С. В., Товкач С. С. Дослідження структури та інформаційних потоків у електронній системі керування авіаційними газотурбінними двигунами. *Науковий вісник Херсонської державної морської академії*. 2012. № 1 (6). С. 356–361.

149. Єнчев С. В., Таку С. О. Забезпечення відмовостійкості нечіткої інтелектуальної системи керування авіаційними двигунами. *Вчені записки Таврійського національного університету імені В. І. Вернадського*. Серія: Технічні науки. 2019. № 2. Т. 30 (69). Ч. 1. С. 29–34.

150. Панин В. В., Енчев С. В. Оценка технического состояния системы автоматического управления винтовентилятором авиадвигателя. *Вісник Центрального наукового центру Транспортної академії України*. 2010. Вип. 13. С. 136–139.

151. Єнчев С. В., Таку С. О. Розробка адаптивного нейромережевого регулятора інтелектуальної системи керування авіаційним двигуном. *Вчені записки Таврійського національного університету імені В. І. Вернадського.* Серія: Технічні науки. 2018. № 6. Т. 29 (68). С. 34–39.

152. Єнчев С. В., Гашко А. М. Синтез адаптивного нейромережевого регулятора авіаційного газотурбінного двигуна. *Наукоємні технології*. 2013. № 4 (16). С. 10–13.

153. Єнчев С. В., Таку С. О. Синтез алгоритмів налаштування параметрів нейромережевого регулятора авіаційного газотурбінного двигуна. *Наукоємні технології*. 2018. № 4 (40). С. 535–543.

154. Панін В. В., Єнчев С. В., Товкач С. С. Комбіновані моделі обробки інформації в електронних системах керування авіаційних двигунів. *Авіаційно-космічна техніка і технологія*. 2013. № 8 (105). С. 235–239.

155. Панін В. В., Єнчев С. В., Таку С. О. Формування структури інтелектуальної системи автоматичного керування авіаційним ГТД. *Авіаційно-космічна техніка і технологія*. 2013. № 7 (104). С. 181–185.

156. Yenchev S. V., Mazur T. A., Tovkach S. S. Fuzzy Automatic Control System Synthesis of the Propeller Fan the Aviation Gas Turbine Engine. *Electronics and Control Systems*. 2018. № 58. Vol. 4. P. 56–63.

157. Петунін В. І. Синтез логіко-динамічних систем автоматичного керування газотурбінними двигунами на основі координації та адаптації каналів керування: дис. ... докт. техн. наук: 05.13.01. 2011. 332 с.

158. Petunin V. I. Synthesis of automatic control systems for gas-turbine engines with a channel selector. *Bulletin of USATU*. 2008. Vol. 11. No. 1 (28). P. 3–10.

159. Petunin V. I. Features of synthesis of multivariate automatic control systems with a channel selector. *Bulletin of USATU*. 2008. Vol. 11. No. 1 (28). P. 11–17.

160. Petunin V. I. Equivalent structures of an algebraic selector based on continuous logic. *Bulletin of USATU*. 2009. Vol. 12. No. 1 (30). P. 40–45.

161. Petunin V. I., Frid A. I. Analysis and synthesis of automatic control systems for gasturbine engines with a channel selector under interference. *Aerospace instrumentation*. 2011. No. 3. P. 3–10.

162. Petunin V. I. Improving the statistical accuracy of automatic control systems with a channel selector under interference. *Control systems and information technologies*. 2011. No. 1 (43). P. 61–64.

163. Petunin V. I. Mathematical models of multivariate automatic control systems with a channel selector. *Bulletin of Ufa State Agrarian University*. 2011. Vol. 15. No. 2 (42). P. 52–58.

164. Trunev A. P. Modeling of turbulent flow in a cavity based on the Navier-Stokes equations. *Polythematic online electronic scientific journal of the Kuban State Agrarian University*. 2015. No. 119 (05). P. 1–23.

165. Trunev A. P. Turbulence Theory and Modeling of Turbulent Transport in the Atmosphere. *Polythematic Online Electronic Scientific Journal of the KSAU*. 2010. No. 05 (059). P. 179–243.

166. Trunev A. P. Turbulence Theory and Model of Roughness Density Influence. *Polythematic Online Electronic Scientific Journal of the KSAU*. 2010. No. 04 (058). P. 348–382.

167. Trunev A. P. Theory and constants of near-wall turbulence. *Polythematic online electronic scientific journal of Kuban State Agrarian University*. 2010. No. 04 (058). P. 383–394.

168. Trunev A. P. Physical mechanisms of turbulent viscosity and turbulence modeling based on the Navier-Stokes equations. *Polythematic online electronic scientific journal of KSAU*. 2016. No. 04 (118). P. 1469–1487.

169. Владов С. І., Шмельов Ю. М., Пилипенко Л. М., Подгорних Н. В., Назаренко Н. П., Тутова Н. В., Дєрябіна І. О. Математичне моделювання робочих процесів авіаційного газотурбінного двигуна ТВЗ-117 для контролю і діагностики його технічного стану. *Вісник Херсонського національного технічного університету*. 2020. № 1 (72). С. 18– 34. doi: 10.35546/kntu2078-4481.2020.1.1.2.

170. Шмелев Ю. Н., Владов С. И., Климова Я. Р. Разностная аппроксимация уравнений Навье-Стокса для решения задачи моделирования процессов, протекающих в двигателе вертолета Ми-8МТВ. *Перспективні напрями розвитку науки та техніки* : матеріали XVIII Міжнародної науково-практичної конференції, 23 березня, 2018 р. Вінниця : Наука та практика, 2018. Ч. 2. С. 4–10.

171. Владов С. И., Климова Я. Р. К вопросу формирования информативных диагностических каналов, исходя из рабочих процессов, протекающих в двигателе вертолета Ми-8МТВ. *Авіація, промисловість, суспільство* : матеріали I Всеукраїнської науково-практичної конференції молодих вчених, курсантів та студентів, 27 квітня 2018 р. Кременчук : КЛК НАУ, 2018. С. 136–138.

172. Владов С. І., Пономаренко О. В., Тутова Н. В. Застосування математичного моделювання термогазодинамічних процесів в авіаційному двигуні ТВЗ-117 задля контролю і діагностики його технічного стану. *Авіація, промисловість, суспільство* : матеріали II Всеукраїнської науково-практичної конференції молодих вчених, курсантів та студентів, 15 травня 2019 р. Кременчук : КЛК НАУ, 2019. С. 254–256.

173. Владов С. І., Семенов В. О., Пономаренко О. В. Щодо питання чисельного розв'язку рівнянь Нав'є-Стокса для опису термогазодинамічних процесів, що відбуваються

в авіаційному двигуні ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали II Всеукраїнської науково-практичної конференції молодих вчених, курсантів та студентів, 15 травня 2019 р. Кременчук : КЛК НАУ, 2019. С. 256–258.

174. Владов С. І., Шмельов Ю. М., Семенов В. О. Задача математичного моделювання робочих процесів авіаційного двигуна ТВЗ-117 для контролю і діагностики його технічного стану в польотних режимах. *Актуальні проблеми сучасної науки в дослідженнях молодих учених* : матеріали науково-практичної конференції, 15 травня 2020 р. Харків : ХНУВС, 2020. С. 339–345.

175. Degi D. V., Starchenko A. V. Numerical solution of the Navier-Stokes equations on computers with parallel architecture. *Bulletin of TSU*. 2012. No. 2 (18). P. 88–98.

176. Bogoslovsky N. N., Esaulov A. O., Starchenko A. V. Parallel implementation of the SIMPLE computational fluid dynamics algorithm. *Siberian School Seminar on Parallel Computing*. 2002. P. 118–124.

177. Владов С. І., Шмельов Ю. М., Семенов В. О., Васильєв Д. О. Використання методу релаксації для розв'язку рівнянь робочих процесів авіаційного двигуна ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали І Міжнародної науково-практичної конференції, 14 травня 2020 р. Кременчук : КЛК ХНУВС, 2020. Ч. 1. С. 365–368.

178. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Моделювання газодинамічних процесів, що протікають у двигуні вертольоту Мі-8МТВ. *Вчені записки Таврійського національного університету імені В.І. Вернадського*. Серія: Технічні науки. 2018. Т. 29 (68), № 2. С. 29–34.

179. Shmelov Y. M., Vladov S. I., Klimova Y. R., Lashko A. O. Modeling of the threedimensional non-stationary gas dynamic flow in the aviation engine TV3-117. *Innovative approaches to the development of science*. 2018. Part 2. P. 136–140.

180. Владов С. І., Клімова Я. Р., Юрко О. О. Застосування перетворень Гілберта для діагностування стану двигуна вертольоту Мі-8МТВ. *Наука у контексті сучасних глобалізаційних процесів* : матеріали V Міжнародної науково-практичної конференції, 30 березня 2018 р. Дніпро : НБК, 2018. Ч. 1. С. 48–54.

181. Владов С. І., Шмельов Ю. М., Дерев'янко І. Г., Пилипенко Л. М., Дєрябіна І. О. Застосування спектрального методу оцінювання інтервальної достовірності прогнозування технічного стану авіаційного двигуна ТВЗ-117. Вісник Кременчуцького національного університету імені Михайла Остроградського. 2019. Вип. 6/2019 (119). С. 77–83.

doi: 10.30929/1995-0519.2019.6.77-83.

182. Wang Y., Pan M., Zhou W., Huang J. Direct Thrust Control for Variable Cycle Engine Based on Fractional Order PID-Nonlinear Model Predictive Control under off-Nominal Operation Conditions. *Aerospace Science and Technology*. 2023. Vol. 143, 108726. doi: 10.1016/j.ast.2023.108726.

183. Pasieka M., Grzesik N., Kuźma K. Simulation modeling of fuzzy logic controller for aircraft engines. *International Journal of Computing*. 2017. Vol. 16(1). P. 27–33. doi: 10.47839/ijc.16.1.868.

184. Sheng H., Chen Q., Li J., Jiang W., Wang Z., Liu Z., Zhang T., Liu Y. Research on Dynamic Modeling and Performance Analysis of Helicopter Turboshaft Engine's Start-up Process. *Aerospace Science and Technology*. 2020. Vol. 106, 106097. doi: 10.1016/j.ast.2020.106097.

185. Шмелев Ю. Н., Владов С. И., Климова Я. Р. Реализация динамической нейронной сети для диагностики и прогнозирования состояния авиационного двигателя вертолета Ми-8MTB. *IT перспектива* : материалы 5-й всеукраинской конференции в сфере IT, 21 апреля 2018 г. Кременчуг : КрНУ, 2018. С. 63–66.

186. Lyu K., Tan X., Liu G., Zhao C. Sensor Selection of Helicopter Transmission Systems
Based on Physical Model and Sensitivity Analysis. *Chinese Journal of Aeronautics*. 2014. Vol. 27.
P. 643–654. doi: 10.1016/j.cja.2014.04.025.

187. Владов С. І., Матусєв А. О. Перспективи використання математичної авіаційного двигуна ТВЗ-117 в умовах льотної експлуатації повітряного судна. *Авіація та космонавтика* : матеріали XII Всеукраїнської науково-практичної конференції, 20 квітня 2021 р., Кривий Ріг. С. 53.

188. Владов С. І., Яковенко І. П. Топологічна модель авіаційного газотурбінного двигуна і перспективи її використання. *Авіація та космонавтика* : матеріали XII Всеукраїнської науково-практичної конференції, 20 квітня 2021 р., Кривий Ріг. С. 56.

189. Владов С. І., Янкевич Н. С.: Щодо питання використання математичних моделей авіаційного двигуна ТВЗ-117 під час його бортової експлуатації. *Авіація та космонавтика* : матеріали XII Всеукраїнської науково-практичної конференції, 20 квітня 2021 р., Кривий Ріг. С. 58.

190. Давиденко М. Ф., Дятловська В. Л., Сіора А. С. Напрямки розвитку сучасних математичних моделей робочих процесів газотурбінних двигунів. *Актуальні проблеми сучасної науки в дослідженнях молодих учених* : матеріали науково-практичної конференції,

15 травня 2020 р. Харків : ХНУВС, 2020. С. 348-350.

191. Подгорних Н. В., Дерев'янко І. Г., Царенко А. О. Універсальна математична модель газотурбінного двигуна. *Актуальні проблеми сучасної науки в дослідженнях молодих учених* : матеріали науково-практичної конференції, 15 травня 2020 р. Харків : ХНУВС, 2020. С. 380–382.

192. Пономаренко А. В., Яніцький А. А., Гвоздік С. Д. Візуалізація математичних імітаційних мережевих моделей ГТД в системі моделювання DVIG. *Актуальні проблеми сучасної науки в дослідженнях молодих учених* : матеріали науково-практичної конференції, 15 травня 2020 р. Харків : XHVBC, 2020. С. 383–385.

193. Krivosheev I. A., Ivanova O. N., Goryunov I. M. Use of simulation network modeling tools for gas turbine engines at the stage of model identification based on test results. *Bulletin of USATU*. 2005. Vol. 6, No. 1 (12). P. 65–75.

194. Бойко Л. Г., Демик А. Е., Пижанкова Н. В. Метод расчета термогазодинамических параметров турбовального двигателя на основе повенцового описания лопаточных машин. Часть II. Определение параметров ступеней и многоступенчатых компрессоров. *Авіаційно-космічна техніка і технологія*. 2019. № 1 (153). С. 18–28. doi: 10.32620/aktt.2019.1.02

195. Alexiou A., Mathiodakis K. Gas Turbine Engine Perfomance Application Using an Object-Oriented Simulation Tool. *ASME TurboExpo 2006*, Barcelona, Spain, May 8–11, 2006. No. 2006-GT-9033. 9 p.

196. Єпішев Н. І. Дослідження характеристик і параметрична діагностика авіаційних газотурбінних двигунів, що працюють в наземних умовах: дис. ... канд. техн. наук: 05.07.07. 1983. 204 с.

197. Бойко Л. Г., Даценко В. А. Расчетное исследование характеристик турбовального двигателя с использованием двумерного подхода к моделированию компрессора. *German International Journal of Modern Science*. 2021. № 8. С. 33–38.

198. Kazhaev V. P., Kiselev D. Yu., Kiselev Yu. V. Diagnostic model of a helicopter turboshaft engine. *Informatics, computer engineering and control.* 2023. Vol. 25. No. 1. P. 99–106.

199. Gerasimov A. B., Sundukov M. Yu. Numerical study of the possibility of reliable diagnostics of a gas-turbine engine based on gas-dynamic parameters using a linear mathematical model. *Bulletin of SSAU*. 2011. No. 3 (27). P. 29–36.

200. Efimov V. V., Nezametdinov R. Sh. Mathematical model of specific fuel consumption of the TV3-117 engine. *Scientific Bulletin of MSTU CA*. 2014. No. 200. P. 11–15.

201. Владов С. І., Янкевич Н. С., Ходін Д. С. Застосування універсальної математичної моделі авіаційних газотурбінних двигунів вертольотів в умовах бортової експлуатації повітряного судна. *Новітні технології сучасного суспільства (HTCC-2021)* : матеріали ІІ Міжнародної науково-практичної конференції обдарованої учнівської та студентської молоді, 17 грудня 2021 р., Чернігів. Ч. 1. С. 26–29.

202. Владов С. І., Плужник З. І., Матусєв А. О. Математична модель авіаційного двигуна ТВЗ-117 задля контролю і діагностики його технічного стану в умовах бортової експлуатації. *Авіація, промисловість, суспільство* : матеріали II Міжнародної науковопрактичної конференції, 12 травня 2021 р., Кременчук. Кременчук : КЛК ХНУВС, 2021. Ч. 1. С. 357–361.

203. Владов С. І., Подгорних Н. В., Телешун В. Я. Математична модель компресора авіаційного двигуна ТВЗ-117 задля його контролю і діагностики технічного стану в умовах бортової експлуатації повітряного судна. *Шлях успіху і перспективи розвитку* (до 26 річниці заснування Харківського національного університету внутрішніх справ) : матеріали міжнародної науково-практичної конференції, 20 листопада 2020 р. Харків. С. 112–116.

204. Інтелектуальні системи автоматизації : монографія / С. І. Владов та ін. Кременчук : ПП Щербатих О. В., 2021. 322 с. doi: 10.30837/978-617-639-347-4

205. Жернаков С. В., Кривошеев И. А. Поддержка принятия решений при структурном синтезе в САПР двигателей. *Информационные технологии*. 2000. № 12. С. 17–30.

206. Жернаков С. В., Кривошеев И. А. Использование сетевых методов представления математических моделей в САПР двигателей. *Информационные технологии*. 1999. № 5. С. 17–26.

207. Владов С. І., Шмельов Ю. М., Пилипенко Л. М., Котляров К. Г., Грибанова С. А., Гусарова О. В. Розробка інформаційної та динамічної моделей контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Сучасний стан наукових досліджень та технологій в промисловості.* 2019. № 4 (10). С. 44–54. doi: 10.30837/2522-9818.2019.10.044.

208. Vladov S., Shmelov Yu., Samoilenko M., Podhornykh N., Shmelova T. Development of a complex of functional models for the process of control and diagnostics of the TV3-117 aircraft engine technical state at flight modes. *Proceedings of the National Aviation University*. 2019. No. 4 (81). P. 19–28. doi: 10.18372/2306-1472.81.14597.

209. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Застосування методології системного аналізу до вирішення проблеми ідентифікації технічного стану авіаційного двигуна ТВ3-

383

117. *Молодь в науці: дослідження, проблеми, перспективи* : матеріали Регіональної науково-практичної конференції студентів, аспірантів та молодих науковців, 06–08 червня 2018 р. Вінниця : ВНТУ. С. 278–282.

210. Владов С. І., Пономаренко А. В., Гвоздік С. Д. Обґрунтування застосування методології системного аналізу в задачах контролю і діагностики технічного стану авіаційного двигуна ТВЗ-177 в польотних режимах. *Новітні технології сучасного суспільства (НТСС-2018)* : матеріали Всеукраїнської науково-практичної конференції, 12 грудня 2018 р. Чернігів : Чернігівський національний технічний університет, 2018. С. 143–144.

211. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Щодо питання розробки інформаційної системи ідентифікації технічного стану авіаційного турбовального двигуна TB3-117. *Наукові дослідження : закономірності та парадокси* : матеріали Міждисциплінарної науково-практичної конференції, 18 травня 2018 р. Київ : Юдіна Л. І., 2018. С. 20–22.

212. Владов С. І., Шмельова Т. Ф., Шмельов Ю. М. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах за допомогою нейромережевих технологій : Монографія. Кременчук : ПП Щербатих А. В., 2020. 200 с.

213. Владов С. И., Климова Я. Р., Васильев Д. А. К вопросу контроля и диагностики технического состояния масляной системы авиационных двигателей с применением нейронных сетей. *Авіація, промисловість, суспільство* : матеріали І Всеукраїнської науковопрактичної конференції молодих вчених, курсантів та студентів, 27 квітня 2018 р. Кременчуг : КЛК НАУ, 2018. С. 138–139.

214. Климова Я. Р., Шмелев Ю. Н., Владов С. И. Диагностика состояния двигателя вертолета Ми-8МТВ с применением нейронных сетей. *22-й Международный молодежный форум «Радиоэлектроника и молодежь в XXI веке»* : материалы тематической конференции форума «Компьютерные системы и сети управления», Харьков, 17–19 апреля, 2018 г. Харьков : ХНУРЭ, 2018. Т. 5. С. 197–198.

215. Шмелев Ю. Н., Владов С. И., Климова Я. Р. Нейросетевая модель для диагностики состояния двигателя вертолета Ми-8МТВ. *ProfIT Conference* : материалы I Международной научно-практической конференции IT-профессионалов и аналитиков компьютерных систем, посвященная 50-летию кафедры информатики ХАИ, 24–26 апреля 2018 г. Харьков : ХАИ им. Н. Е. Жуковского, 2018. С. 40–41.

216. Владов С. І., Васильєв Д. О., Бражник О. О. Використання нейромережевих

технологій для контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Об'єднані наукою* : матеріали VII Всеукраїнської науково-практичної конференції студентів, аспірантів та молодих вчених, 12–13 листопада 2020 р., Київ. Київ : КНУ імені Тараса Шевченка, 2020. С. 179–181.

217. Владов С. І., Телешун В. Я., Яковенко І. П. Синтез узагальненої нейронної мережі для контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Об'єднані наукою* : матеріали VII Всеукраїнської науково-практичної конференції студентів, аспірантів та молодих вчених, 12–13 листопада 2020 р., Київ. Київ : КНУ імені Тараса Шевченка, 2020. С. 182–184.

218. Владов С. І., Янкевич Н. С., Ходін Д. С. Нейромережева модель моніторингу технічного стану авіаційних двигунів вертольотів у польотних режимах. *«ТАК» Телекомунікації, автоматизація, комп'ютерно-інтегровані та інформаційні технології* : матеріали Всеукраїнської науково-практичної конференції молодих учених, 01–02 грудня 2021 р., Покровськ. С. 70–72.

219. Владов С. І., Янкевич Н. С., Матусєв А. О. Щодо питання використання нейронних мереж для ідентифікації та діагностики авіаційного двигуна ТВЗ-117. *Інформаційні технології в соціокультурній сфері, освіті, науці та економіці* : матеріали міжнародної науково-практичної конференції студентів та молодих вчених, 21–22 квітня 2021 р., Київ. С. 35–38.

220. Владов С. І., Янкевич Н. С. Перспективи застосування нейронних мереж у задачах моніторингу авіаційних двигунів вертольотів. *Інформаційні технології в соціокультурній сфері, освіті та економіці* : матеріали міжнародної науково-практичної конференції студентів та молодих вчених, 19–20 квітня 2022 р., Київ. С. 39–42.

221. Владов С. І., Шмельов Ю. М., Пилипенко Л. М., Назаренко Н. П., Тутова Н. В., Дерев'янко І. Г., Пономаренко А. В. Реалізація компонентних математичних моделей авіаційного двигуна ТВЗ-117 на основі семантичної мережі. *Вчені записки Таврійського національного університету імені В.І. Вернадського*. Серія: Технічні науки. 2020. Том 31 (70). № 2. Част. 1. С. 35–43. doi: 10.32838/2663-5941/2020.2-1/06.

222. Vladov S. Vysotska V. Neural network methods for monitoring dynamic objects (Neural network methods for monitoring helicopter turboshaft engines at flight operation mode : monograph). London : Lambert Academic Publishing, 2024. 210 p.

223. Владов С. І., Шмельов Ю. М., Сіора А. С., Дятловська В. Л., Пономаренко А. В.,

Вакуленко Р. А. Особливості технічної реалізації штучного нейрона для розв'язання задач контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Вісник Херсонського національного технічного університету*. 2020. № 3 (74). С. 58–69. doi: 10.35546/kntu2078-4481.2020.3.7.

224. Владов С. І. Розробка штучного нейрону для розв'язку задачі контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Новітні технології сучасного суспільства (НТСС-2019)* : матеріали Всеукраїнської науково-практичної конференції, 12 грудня 2019 р. Чернігів : Чернігівський національний технічний університет, 2019. С. 148–149.

225. Владов С. І., Дєрябіна І. О., Подгорних Н. В., Грибанова С. А., Яніцький А. А. Проблеми і перспективи застосування нейронних мереж у задачах моніторингу технічного стану авіаційних двигунів вертольотів у польотних режимах. *Вісник Херсонського національного технічного університету*. 2021. № 4 (79). С. 64–73. doi: 10.35546/kntu2078-4481.2021.4.7.

226. Владов С. И., Климова Я. Р. Применение адаптивного метода обучения нейронной сети для диагностики двигателя вертолета Ми-8МТВ. *Інформаційні технології: наука, техніка, технологія, освіта, здоров'я (MicroCAD-2018)* : матеріали XXVI Міжнародної науково-практичної конференції, 16–18 травня, 2018 р., Харків. Харків : НТУ «ХПІ», 2018. Ч. 1. С. 14.

227. Владов С. І., Шмельов Ю. М., Грибанова С. А., Гусарова О. В., Подгорних Н. В. Метод підвищення робасності нейромережевої моделі контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 в польотних режимах. *Вісник Кременчуцького національного університету імені Михайла Остроградського*. 2020. Вип. 1/2020 (120). С. 113–119. doi: 10.30929/1995-0519.2020.1.113-119.

228. Novikova S. V., Kremleva E. Sh. Increasing the robustness of a neural network model for GTE monitoring based on reduction. *Aircraft, aircraft engines and methods of their operation*. 2019. No. 3. P. 17–26.

229. Zhernakov S. V. Algorithms for monitoring and diagnostics of an aircraft GTE in the conditions of on-board implementation based on neural network technology. *Bulletin of USATU*. 2010. Vol. 14. No. 3 (38). P. 42–56.

230. Vasiliev V. I., Zhernakov S. V., Muslukhov I. I. On-board algorithms for monitoring gas turbine engine parameters based on neural network technology. *Bulletin of USATU*. 2009. Vol. 12. No. 1 (30). P. 61–74.

231. Avgustinovich V. G. Mathematical modeling of aircraft engines. PSTU Publishing House, 2008. 100 p.

232. Numerical modeling of non-stationary phenomena in turbomachines / Avgustinovich V. G. et al.; edited by Avgustinovich V. G., Shmotin Yu. N. Mechanical engineering, 2005. 536 p.

233. Novikova S. V., Tutubalin P. I., Snegurenko A. P., Yakhina R. R. The Optimal Aircraft Gas Turbine Engine Control in Low Gas Mode in the Conditions of External Additive Noise. *Journal of Physics: Conference Series.* 2021. Vol. 1745, 012039. doi: 10.1088/1742-6596/1745/1/012039.

234. Про затвердження Авіаційних правил України «Технічні вимоги та адміністративні процедури для льотних екіпажів цивільної авіації» : Наказ Державної авіаційної служби України від 20.07.2017 р. № 575.

235. Vladov S., Vysotska V., Vasylenko V., Lytvyn V., Nazarkevych M., Fedevych O. Influence of the Neural Network Morphology Symmetry on the Complex Dynamic Objects' Diagnostics. *Symmetry*. Vol. 17. Issue 1. 2025. 35. doi: 10.3390/sym17010035

236. Vladov S., Shmelov Y., Yakovliev R. Modified Helicopters Turboshaft Engines Neural Network On-board Automatic Control System Using the Adaptive Control Method. *CEUR Workshop Proceedings*. 2022. Vol. 3309. P. 205–224.

237. Владов С. И., Климова Я. Р. Применение адаптивного метода обучения нейронной сети для диагностики двигателя вертолета Ми-8МТВ. *Інформаційні технології: наука, техніка, технологія, освіта, здоров'я (MicroCAD-2018)* : матеріали XXVI Міжнародної науково-практичної конференції, 16–18 травня, 2018 р., Харків. Харків : НТУ «ХПІ», 2018. Ч. 1. С. 14.

238. Владов С. І., Матусєв А. О., Плужник З. І., Коваль І. М. Нейромережева система контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Новітні технології сучасного суспільства (НТСС-2020)* : матеріали І Міжнародної науково-практичної конференції обдарованої учнівської та студентської молоді, 17 грудня 2020 р., Чернігів. С. 45–48.

239. Владов С. І., Янкевич Н. С., Плужник З. І. Використання алгоритмічної моделі при розв'язанні задачі ідентифікації авіаційного двигуна ТВЗ-117 в умовах його бортової експлуатації. *Харківський національний університет внутрішніх справ: 20 років у статусі національного* : матеріали міжнародної науково-практичної конференції, 02 березня 2021 р., Харків. С 179–181.

240. Vladov S., Shmelov Y., Yakovliev R., Kozlovskaya T., Petchenko M. Helicopters Turboshaft Engines Intelligent Control Algorithms Synthesis, Taking into Account Required Quality Provision. *CEUR Workshop Proceedings*. 2023. Vol. 3468. P. 71–90.

241. Kim H.-Y. Statistical Notes for Clinical Researchers: Chi-Squared Test and Fisher's Exact Test. *Restorative Dentistry & Endodontics*. 2017. Vol. 42. P. 152. doi: 10.5395/rde.2017.42.2.152.

242. Kovtun V., Grochla K., Połys K. Investigation of the Information Interaction of the Sensor Network End IoT Device and the Hub at the Transport Protocol Level. *Electronics*. 2023. Vol. 12. 4662. doi: 10.3390/electronics12224662.

243. Cosenza P., Fauchille A.-L., Prêt D., Hedan S., Giraud A. Statistical Representative Elementary Area of Shale Inferred by Micromechanics. *International Journal of Engineering Science*. 2019. Vol. 142. P. 53–73. doi: 10.1016/j.ijengsci.2019.05.012.

244. Rusyn B., Lutsyk O., Kosarevych R., Kapshii O., Karpin O., Maksymyuk T., Gazda J. Rethinking Deep CNN Training: A Novel Approach for Quality-Aware Dataset Optimization. *IEEE Access.* 2024. Vol. 12. P. 137427–137438. doi: 10.1109/access.2024.3414651.

245. Stefanovic C. M., Armada A. G., Costa-Perez X. Second Order Statistics of -Fisher-Snedecor Distribution and Their Application to Burst Error Rate Analysis of Multi-Hop Communications. *IEEE Open Journal of the Communications Society.* 2022. 3. P. 2407–2424. doi: 10.1109/ojcoms.2022.3224835.

246. Avram F., Leonenko N.N., Šuvak N. Hypothesis testing for Fisher–Snedecor diffusion. *Journal of Statistical Planning and Inference*. 2012. Vol. 142:8. P. 2308–2321. doi: 10.1016/j.jspi.2012.02.055.

247. Hu Z., Kashyap E., Tyshchenko O.K. GEOCLUS: A Fuzzy-Based Learning Algorithm for Clustering Expression Datasets. *Lecture Notes on Data Engineering and Communications Technologies*. 2022. Vol. 134. P. 337–349. doi: 10.1007/978-3-031-04812-8_29

248. Lytvyn V., Dudyk D., Peleshchak I., Peleshchak R., Pukach P. Influence of the Number of Neighbours on the Clustering Metric by Oscillatory Chaotic Neural Network with Dipole Synaptic Connections. *CEUR Workshop Proceedings*. 2024. Vol. 3664. P. 24–34.

249. Бакулевський В. Л. Вибір оптимальної моделі нейромережі для розрахунку втрат електроенергії в повітряних лініях електропередачі з урахуванням температурного чинника і графіків навантаження. *Наукові праці Донецького національного технічного університету*. 2011. Вип. 11 (186). С. 31–35.

250. Бакулевський В. Л. Застосування нейронних мереж для розрахунків технічних втрат електроенергії в повітряних лініях електропередач напругою 6–35 кВ. *Вісник Приазовського технічного університету. Технічні науки.* 2015. Вип. 30. С. 152–160.

251. Бакулевський В. Л. Підвищення точності розрахунку втрат електроенергії в повітряних лініях 6-35 кВ шляхом врахування кліматичних факторів : дис. ... канд. техн. наук : 05.14.02. Харків, 2017. 201 с.

252. Hogan D., Elshaw J., Koschnick C., Ritschel J. Cost Estimating Using a New Learning Curve Theory for Non-Constant Production Rates. *Forecasting*. 2020. Vol. 2. No. 4. P. 429–451. doi: 10.3390/forecast2040023.

253. Tkachenko A. Y., Kuz'michev V. S., Krupenich I. N., Rybakov V. N. Gas turbine engine optimization at conceptual designing. *MATEC Web of Conferences*. 2016. Vol. 77. No. 1. 01027. doi: 10.1051/matecconf/20167701027.

254. Musa G., Alrashed M., Muhammad N. M. Development of big data lean optimisation using different control mode for Gas Turbine engine health monitoring. *Energy Reports*. 2021. Vol. 7. P. 4872–4881. doi: 10.1016/j.egyr.2021.07.071.

255. Kirchner M. R., Ball E., Hoffler J., Gaublomme D. Reachability as a Unifying Framework for Computing Helicopter Safe Operating Conditions and Autonomous Emergency Landing. *IFAC-PapersOnLine*. 2020. Vol. 53. Issue 2. P. 9282–9287. doi: 10.1016/j.ifacol.2020.12.2381.

256. Владов С. І., Шмельов Ю. М., Пилипенко Л. М., Подгорних Н. В., Назаренко Н. П., Тутова Н. В., Дєрябіна І. О. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 із застосуванням модернізованих методів найменших квадратів й зрівнювання. *Вчені записки Таврійського національного університету імені В.І. Вернадського.* Серія: Технічні науки. 2020. Том 31 (70). № 1. Част. 1. С. 14–20. doi: 10.32838/2663-5941/2020.1-1/03.

257. Владов С. І., Семенов В. О., Дерев'янко І. Г. Розробка математичної моделі контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 з використанням модернізованих методів зрівнювання й найменших квадратів. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали щорічної Міжнародної науково-практичної конференції, 18–19 квітня 2019 р. Київ : Київський національний університет культури і мистецтв, 2019. С. 150–152.

258. Lin X., Sun R., Wang Y. Improved key performance indicator-partial least squares method for nonlinear process fault detection based on just-in-time learning. *Journal of the Franklin Institute*. 2023. Vol. 360. Issue 1. P. 1–17. doi: 10.1016/j.jfranklin.2022.11.029.

259. Владов С. І., Подгорних Н. В., Турков В. Є. Постановка задачі оптимізації і вибору значень параметрів робочого процесу авіаційних двигунів вертольотів в умовах льотної експлуатації. *Авіація, промисловість, суспільство* : матеріали II Міжнародної науковопрактичної конференції, 12 травня 2021 р., Кременчук. Кременчук : КЛК ХНУВС, 2021. Ч. 1. С. 354–357.

260. Vladov S., Shmelov Y., Yakovliev R. Optimization of Helicopters Aircraft Engine Working Process Using Neural Networks Technologies. *CEUR Workshop Proceedings*. 2022. Vol. 3171. P. 1639–1656.

261. Zelenkov Yu. A. Method of multicriterial optimization based on approximate models of the object under study. *Computational methods and programming*. 2010. Vol. 11. P. 250–260.

262. Zelenkov Yu. A. Optimization of the working disk of the high-pressure turbine of a gas turbine engine. *Bulletin of the NNU*. 2011. No. 3 (2).

263. Владов С. І., Янкевич Н. С., Плужник З. І. Багатокритеріальна оптимізація параметрів технічного стану авіаційного двигуна ТВЗ-117 з використанням нейронних мереж. *Наукові та освітні трансформації в сучасному світі* : матеріали Всеукраїнської міждисциплінарної науково-практичної конференції, 15 липня 2021 р., Чернігів. С. 373–376.

264. Seibold D. R., Meyers R. A. Group Argument: A Structuration Perspective and Research Program. *Small Group Research*. 2007. Vol. 38. No. 3. P. 312–336. doi: 10.1177/1046496407301966.

265. Zelenkov Yu. A. Approximation of functions based on radial neural networks generated using evolutionary algorithms. *Bulletin of the RSATA*. 2004. No. 1–2(4–6). P. 87–93.

266. Alexandrov A., Dudarov S. One-dimensional alternative for multidimensional neural network of radial basis functions. *Advances in chemistry and chemical technology* vol. 32, no. 11 P. 13–15, 2022.

267. Vichugov V. N. Modified gradient algorithm for training radial-basis neural networks. *Bulletin of TPU*. 2009. Vol. 315. No. 5. P. 149–152.

268. Vladov S., Yakovliev R., Vysotska V., Uhryn D., Ushenko Y., Karachevtsev. A. Polymorphic Radial Basis Functions Neural Network. *International Journal of Intelligent Systems*

and Applications (IJISA). Vol. 16. No. 4. 2024. P. 1-21. doi: 10.5815/ijisa.2024.04.01.

269. Markin I., Dudarov S. An artificial neural network of radial basis functions using a perceptron as an output layer. *Advances in chemistry and chemical technology*. 2022. Vol. 36. No. 11. P. 74–76.

270. Li M., Ma H., Lv S., Wang L. and Deng S. Enhanced NSGA-II-based feature selection method for high-dimensional classification. *Information Sciences*. 2024. Vol. 663, 120269. doi: 10.1016/j.ins.2024.120269.

271. Zhang Z., Cheng X., Xing Z., Gui X. Pareto multi-objective optimization of metro train energy-saving operation using improved NSGA-II algorithms. *Chaos, Solitons & Fractals*. 2023. Vol. 176. 114183. doi: 10.1016/j.chaos.2023.114183.

272. Gao P., Wang Y., Wang H., Song C., Ye S., Wang X. A Pareto front-based approach for constructing composite index of sustainability without weights: A comparative study of implementations. *Ecological Indicators*. 2023. Vol. 155. 110919. doi: 10.1016/j.ecolind.2023.110919.

273. Polkovnikova N. Hybrid expert system based on probabilistic deterministic models. *Engineering Sciences*. 2015. No. 6 (167). P. 168–179.

274. Ye Q., Wang W., Li G., Dai R. A self-organizing assisted multi-task algorithm for constrained multi-objective optimization problems. *Information Sciences*. 2024. Vol. 664. 120339. doi: 10.1016/j.ins.2024.120339.

275. Du K.-J., Li J.-Y., Wang H., Zhang J. Multi-objective multi-criteria evolutionary algorithm for multi-objective multi-task optimization. *Complex & Intelligent Systems*. 2023. Vol. 9. P. 1211–1228. doi: 10.1007/s40747-022-00650-8.

276. Liguo T., Novikova S. Application of step-by-step training method for evolutionary algorithm in multicriterial optimization problems. *Bulletin of VKGEU*. 2022. Vol. 14. No. 3 (55). P. 114–125.

277. Ulizko M., Pronicheva L., Artamonov A., Tukumbetova R. R. Complex Objects Identification and Analysis Mechanisms. *Brain-Inspired Cognitive Architectures for Artificial Intelligence: BICA*AI 2020.* 2021. Pp. 517–526. doi: 10.1007/978-3-030-65596-9_63

278. Arkov V., Evans C., Fleming P. J., Hill D. C., Norton J. P., Pratt I., Rees D., Rodriguez-Vazquez K. *Annual Reviews in Control*. 2000. Vol. 24. P. 67–81. doi: 10.1016/S1367-5788(00)90015-4 279. Evans C., Fleming P. J., Hill D. C., Norton J. P., Pratt I., Rees D., Rodriguez-Vazquez K. Application of system identification techniques to aircraft gas turbine engines. *Control Engineering Practice*. 2001. Vol. 9. Issue 2. P. 135–148. doi: 10.1016/S0967-0661(00)00091-5.

280. Yepifanov S. Aircraft Turbine Engine Automatic Control Based on Adaptive Dynamic Models. *Transactions on Aerospace Research*. 2020. Vol. 4. P. 61–70. doi: 10.2478/tar-2020-0021.

281. Tovkach S. S. Control Programs of the Aviation Gas Turbine Engine in the Modes of Acceleration, Gas Reset, Start-up. Optimization and Estimation of the Quality of Control Programs. *Electronics and Control Systems*. 2022. № 4(74). P. 27–38. doi: 10.18372/1990-5548.74.17293.

282. Vasiliev V. I., Ilyasov B. G. Intelligent control systems using genetic algorithms. *Information Technologies*. 2002. No. 12. P. 29–34.

283. Galuev G. A. Intelligent environments of the new generation: the state of the problem and prospects for solution. *Artificial Intelligence*. 2004. No. 3. P. 523–533.

284. Leonov A. A., Leonova M. A., Fedoseyev Yu. N. Synthesis of a neural network for solving the problem of identifying the state of an object. *Neuroinformatics*. 2000. Vol. 1. P. 100–109.

285. Nechaev Yu. I., Degtyarev A. B., Kiryukhin I. A. Synthesis of a self-organizing neural network in the problem of identifying the states of a complex dynamic object. *Neuroinformatics*. 2001. Vol. 2. P. 169–177.

286. Han Y., Huang G., Song S., Yang L., Wang H., Wang Y. Dynamic Neural Networks: A Survey. *Computer Science*. 2021. Vol. 1. P. 1–5. doi: 10.48550/arXiv.2102.04906.

287. Hu C., Luo J., Kong X., Feng X. Novel fault subspace extraction methods for the reconstruction-based fault diagnosis. *Journal of Process Control.* 2021. Vol. 105. P. 129–140. doi: 10.1016/j.jprocont.2021.07.008.

288. Владов С. І., Плужник З. І. Діагностика авіаційних двигунів вертольотів у польотних режимах з використанням нейронних мереж. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали міжнародної науковопрактичної конференції, 20–21 квітня 2022 р., Київ. С. 28–31

289. Zhernakov S. V. Identification of GTD parameters by a hybrid ensemble of neural networks. *Neuroinformatics-2000*: Scientific and technical conference. 2000. P. 117–126.

290. Zhernakov S. V. Parametric identification of GTD by a hybrid ensemble of neural networks. *Neurocomputers: development and application*. 2001. No. 4–5, 2001. P. 31–35.

291. Zhernakov S. V. Storage of an information portrait of an aircraft gas turbine engine based on neural networks. *Neurocomputers: development and application*. 2001. No. 4–5, 2001. P. 44–51.

292. Zhernakov S. V. Recognition of aircraft engine parameters using neural networks. *Automation and modern technologies*. 2003. No. 4. P. 29–31.

293. Zhernakov S. V. Identification of aircraft engine parameters based on neural networks. *Information technologies*. 2003. No. 12, 2003. P. 31–39.

294. Владов С. І., Янкевич Н. С.. Лінійна математична модель авіаційного двигуна ТВЗ-117. *Авіація та космонавтика* : матеріали XII Всеукраїнської науково-практичної конференції, 20 квітня 2021 р., Кривий Ріг. С. 57.

295. Vladov S., Shmelov Yu., Kotliarov K., Hrybanova S., Husarova O., Derevyanko I., Chyzhova L. Onboard parameter identification method of the TV3-117 aircraft engine of the neural network technologies. *Transactions of Kremenchuk Mykhailo Ostrohradskyi National University*. 2019. Issue 5/2019 (118). P. 90–96. doi: 10.30929/1995-0519.2019.5.90-96.

296. Владов С. І., Дєрябіна І. О., Гусарова О. В., Пилипенко Л. М., Пономаренко А. В. Ідентифікація багаторежимної моделі авіаційних двигунів вертольотів у польотних режимах з використанням модифікованого градієнтного алгоритму навчання радіальнобазисних нейронних мереж. *Вісник Херсонського національного технічного університету*. 2021. № 4 (79). С. 52–63. doi: 10.35546/kntu2078-4481.2021.4.6.

297. Владов С. І. Постановка задачі ідентифікації параметрів авіаційного двигуна ТВ3-117 на основі технології нейронних мереж. *Новітні технології сучасного суспільства (HTCC-2019)* : матеріали Всеукраїнської науково-практичної конференції, 12 грудня 2019 р. Чернігів : Чернігівський національний технічний університет, 2019. С. 145–147.

298. Владов С. І., Шмельов Ю. М., Пилипенко Л. М., Тутова Н. В., Москалик В. М. Лінійна адаптивна бортова математична модель авіаційного двигуна ТВЗ-117 в умовах його бортової експлуатації. *Авіація, промисловість, суспільство* : матеріали І Міжнародної науково-практичної конференції, 14 травня 2020 р. Кременчук : КЛК ХНУВС, 2020. Ч. 1. С. 361–365.

299. Vladov S., Shmelov Y., Yakovliev R., Petchenko M., Drozdova S. Neural Network Method for Helicopters Turboshaft Engines Working Process Parameters Identification at Flight Modes. 2022 IEEE 4th International Conference on Modern Electrical and Energy System

393

(*MEES*), Kremenchuk, Ukraine, October 20–22, 2022. P. 604–609. doi: 10.1109/MEES58014.2022.10005670.

300. Vladov S., Shmelov Y., Yakovliev R., Petchenko M., Drozdova S. Helicopters Turboshaft Engines Parameters Identification at Flight Modes Using Neural Networks. *IEEE 17th International Conference on Computer Science and Information Technologies (CSIT)*, Lviv, Ukraine, November 10–12, 2022. P. 5–8. doi: 10.1109/CSIT56902.2022.10000444.

301. Владов С. І., Олексієнко Е. С. Інформаційна модель авіаційних двигунів вертольотів. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали Міжнародної науково-практичної конференції, 20–21 квітня 2023 р., Київ. С. 22–24.

302. Владов С. І., Дроздова С. П., Олексієнко Е. С. Нейромережева бортова інформаційна модель авіаційних двигунів вертольотів. *Авіація, промисловість, суспільство* : матеріали IV Міжнародної науково-практичної конференції, 18 травня 2023 р., Кременчук. Кременчук : КЛК ХНУВС, 2023. С. 252–254.

303. Тюментцев Ю. В. Нейромережеве моделювання адаптивних динамічних систем: дис. ... докт. техн. наук: 05.13.01. 2016. 466 с.

304. Vladov S., Yakovliev R., Hubachov O., Rud J., Stushchanskyi Y. Neural Network Modeling of Helicopters Turboshaft Engines at Flight Modes Using an Approach Based on "Black Box" Models. *CEUR Workshop Proceedings*. 2024. Vol. 3624. P. 116–135.

305. Sahoo H. K., Dash P. K., Rath N. P. NARX model based nonlinear dynamic system identification using low complexity neural networks and robust H_{∞} filter. *Applied Soft Computing*. 2013. Vol. 13. Issue 7. P. 3324–3334. doi: 10.1016/j.asoc.2013.02.007.

306. Bahlawan H., Morini M., Pinelli M., Ruggero Spina P., Venturini M. Development of Reliable NARX Models of Gas Turbine Cold, Warm, and Hot Start-Up. *Journal of Engineering for Gas Turbines and Power*. 2018. Vol. 140. doi: 10.1115/1.4038838.

307. Shmelov Y., Vladov S., Kryshan O., Shmelova A., Nosach I. Control and diagnostics of the technical state of the aircraft engine TV3-117 on the basis of intellectual data analysis in flight modes. *IEEE Ukraine SYW-2018 Congress :* Student, Young Professional and women in engineering, 02–06 October 2018. P. 13–18.

308. Владов С. І., Жидких Т. М. Бортова нейромережева експертна система моніторингу авіаційних двигунів вертольотів. *Інформаційні технології в соціокультурній*

сфері, освіті та економіці : матеріали Міжнародної науково-практичної конференції здобувачів освіти і молодих учених, 19–20 квітня р., Київ. С. 29–31.

309. Pujol J. The solution of nonlinear inverse problems and the Levenberg-Marquardt method. *Geophysics*. 2007. Vol. 72. Issue 4. P. W1–W16. doi: 10.1190/1.2732552.

310. Vysotska V., Vladov S., Yakovliev R., Yurko A. Hybrid Neural Network Identifying Complex Dynamic Objects: Comprehensive Modelling and Training Method Modification. *CEUR Workshop Proceedings*. Vol. 3702. 2024. P. 124–143.

311. Makhotilo K., Voronenko D. Modification of the Levenberg-Marquardt algorithm to improve the accuracy of predictive models of connected energy consumption in everyday life. *Bulletin of the National Technical University "KhPI" A series of "Information and Modeling*. 2005. Vol. 56. P. 83–90.

312. Zhernakov S. V., Ravilov R. F. Identification of the inverse multi-mode model of a gas turbine engine by the parameters of its oil system based on neural network technology. *Bulletin of ISTU*. 2011. No. 3(51). P. 126–129.

313. Shmelov Yu., Vladov S., Derevyanko I., Dieriabina I., Chyzhova L. Identification of rear model of TV3-117 aircraft engine based on the basis of neuro-multi-functional technologies. *Innovative technologies and scientific solutions for industries*. 2019. No. 1 (7). P. 43–49. doi: 10.30837/2522-9818.2019.7.043.

314. Vasiliev V. I., Zhernakov S. V. Classification of gas turbine engine operating modes using neural networks. *Bulletin of USATU*. 2009. Vol. 12. No. 1 (30). P. 53–60.

315. Шмельов Ю. М., Владов С. І., Кришан О. Ф., Гвоздік С. Д., Чижова Л. І. Розробка методу класифікації режимів роботи авіаційного двигуна ТВЗ-117 на основі нейромережевих технологій. *Сучасний стан наукових досліджень та технологій в промисловості.* 2018. № 4 (6). С. 93–101. doi: 10.30837/2522-9818.2018.6.093.

316. Vladov S., Shmelov Y., Yakovliev R. Modified Neural Network Method for Classifying the Helicopters Turboshaft Engines Ratings at Flight Modes. *2022 IEEE 41st International Conference on Electronics and Nanotechnology (ELNANO).* Kyiv, Ukraine, October 10–14, 2022. P. 535–540. doi: 10.1109/ELNANO54667.2022.9927108.

317. Шмелев Ю. Н., Владов С. И., Пономаренко А. В., Юрко А. А. Классификация режимов работы авиационного двигателя ТВЗ-117 на основе нейронных сетей. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XVII Міжнародної науковотехнічної конференції, 02–04 листопада 2018 р., Кременчук–Хургада. Кременчук : КрНУ, 2018. С. 59–61.

318. Voronenko M., Nikytenko D., Krejci J., Savina N., Lytvynenko V. Assessing the Possibility of a Country's Economic Growth Using Static Bayesian Network Models. *CEUR Workshop Proceedings*. 2020. Vol. 2608. P. 462–473.

319. Zaidan M. A., Harrison R. F., Mills A. R., Fleming P. J. Bayesian Hierarchical Models for Aerospace Gas Turbine Engine Prognostics. *Expert Systems with Applications*. 2015. Vol. 42. P. 539–553. doi: 10.1016/j.eswa.2014.08.007.

320. Vladov S., Avkurova Z., Lytvyn V., Zhovnir Y. Analytical Neural Network System for the Helicopter Turboshaft Engines Operating Modes Classification. *International Journal of Computing*. 2024. Vol. 23. Issue 3. P. 342–359. doi: 10.47839/ijc.23.3.3653.

321. Vladov S., Scislo L., Sokurenko V., Muzychuk O., Vysotska V., Osadchy S., Sachenko A. Neural Network Signal Integration from Thermogas-Dynamic Parameter Sensors for Helicopters Turboshaft Engines at Flight Operation Conditions. *Sensors*. 2024. Vol. 24, Issue 13, 4246. doi: 10.3390/s24134246.

322. Владов С. И., Бойко С. Н., Городний А. Н., Климова Я. Р., Вершняк Л. В. Применение уравнений марковского процесса при диагностике состояния авиационного двигателя вертолета Ми-8МТВ при его эксплуатации в реальных режимах работы. *Технічні науки та технології*. 2018. № 1 (11). С. 131–139.

323. Шмелев Ю. Н., Владов С. И., Бойко С. Н., Климова Я. Р., Вишневский С. Я. Информационно-управляющая система определения беспрерывного марковского процесса при имитации работы двигателя вертолета Ми-8МТВ. *Вісник Хмельницького національного університету*. Хмельницький. 2018. № 2. С. 283–290.

324. Vladov S., Shmelov Yu., Shmelova T. Modeling of the TV3-117 aircraft engine technical state as part of the helicopter power plant in the form of the Markov process of death and reproduction. *CEUR Workshop Proceedings*. 2020. Vol. 2740. P. 400–407.

325. Владов С. І., Клімова Я. Р. Передумови застосування рівнянь марківського процесу при діагностуванні відмови двигуна вертольоту Мі-8МТВ. *Проблеми та перспективи розвитку сучасної науки в країнах Європи та Азії* : матеріали Міжнародної науково-практичної інтернет-конференції, 27–28 лютого 2018 р. Переяслав-Хмельницький : TOB «Колібрі 2011», 2018. С. 32–34.
326. Владов С. И., Климова Я. Р. Уравнения марковского процесса некоторых типов при диагностике отказа двигателя вертолета Ми-8МТВ. *Актуальні питання сьогодення* : матеріали Міжнародної науково-практичної конференції, 20 березня 2018 р., Вінниця. Одеса : Друкарик» (ФОП Гуляєва В. М.), 2018. Т. 9. С. 110–114.

327. Владов С. И., Климова Я. Р., Корниенко А. И. Метод определения вероятностей состояния двигателя вертолета Ми-8МТВ в условии летных испытаний. *Авіація та космонавтика: стан, досягнення і перспективи* : матеріали Всеукраїнської науковопрактичної конференції молодих учених та курсантів, 12 квітня 2018 р. Кропивницький : КЛА НАУ, 2018. С. 26–27.

328. Владов С. І., Клімова Я. Р. Інформаційна система визначення безперервного марківського процесу при імітації роботи двигуна вертольоту Мі-8МТВ. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та праві* : матеріали Міжнародної науково-практичної конференції студентів і молодих учених, 18–19 квітня, 2018 р. Київ : Київський національний університет культури і мистецтв, 2018. С. 24–26.

329. Vladov S., Shmelov Y., Yakovliev R. Control and Diagnostics of TV3-117 Aircraft Engine Technical State in Flight Modes Using the Matrix Method for Calculating Dynamic Recurrent Neural Networks. *CEUR Workshop Proceedings*. 2021. Vol. 2864. P. 97–109. doi: 10.32782/cmis/2864-9.

330. Владов С. І., Семенов В. О., Янкевич Н. С. Матричний метод розрахунків рекурентних нейронних мереж для розв'язання задач контролю і діагностики авіаційного двигуна ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали II Міжнародної науковопрактичної конференції, 12 травня 2021 р., Кременчук. Кременчук : КЛК ХНУВС, 2021. Ч. 1. С. 361–364.

331. Chen Q., Sheng H., Liu T. Fuzzy logic-based adaptive tracking weight-tuned direct performance predictive control method of aero-engine. *Aerospace Science and Technology*. 2023. Vol. 140, 108494. doi: 10.1016/j.ast.2023.108494.

332. Pang S., Li Q., Ni B. Improved nonlinear MPC for aircraft gas turbine engine based on semi-alternative optimization strategy. *Aerospace Science and Technology*. 2021. Vol. 118, 106983. doi: 10.1016/j.ast.2021.106983.

333. Kupka J. On approximations of Zadeh's extension principle. *Fuzzy Sets and Systems*. 2016. Vol. 283. P. 26–39. doi: 10.1016/j.fss.2015.03.014.

397

334. Li Z., Nikolaidis T., Nalianda D. Recursive Least Squares for Online Dynamic Identification on Gas Turbine Engines. *Journal of Guidance, Control, and Dynamics*. 2016. Vol. 39(11). P. 1–8. doi: 10.2514/1.G000408.

335. Tsoutsanis E., Meskin N., Benammar M., Khorasani K. A dynamic prognosis scheme for flexible operation of gas turbines. *Applied Energy*. 2016. Vol. 164. P. 686–701. doi: 10.1016/j.apenergy.2015.11.104.

336. Pu X., Liu S., Jiang H. Observable degree analysis of heavy-duty gas turbine based on SVD method. *In Proceedings of the 2011 Second International Conference on Mechanic Automation and Control Engineering*, Inner Mongolia, China, 15–17 July 2011. doi: 10.1109/MACE.2011.5988569.

337. Tsoutsanis E., Qureshi I., Hesham M. Performance diagnostics of gas turbines operating under transient conditions based on dynamic engine model and artificial neural networks. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 236 (part B), 106936. doi: 10.1016/j.engappai.2023.106936.

338. Shmelov Yu., Vladov S., Derevyanko I., Dieriabina I., Chyzhova L. The problem of identification of TV3-117 aircraft engine dynamic multi-model in flight envelope. *Transactions of Kremenchuk Mykhailo Ostrohradskyi National University*. 2019. Issue 1/2019 (114). P. 27–32. doi: 10.30929/1995-0519.2019.1.27-32.

339. Владов С. І., Москалик В. М., Сіора А. С., Дєрябіна І. О., Гвоздік С. Д. Аналіз динаміки авіаційного двигуна ТВЗ-117 із використанням нейронної мережі Елмана. *Вісник Херсонського національного технічного університету.* 2020. № 4 (75). С. 42–52. doi: 10.35546/kntu2078-4481.2020.4.5.

340. Владов С. І., Телешун В. Я.. Васильєв Д. О., Яковенко І. П. Динамічна нейромережева модель контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 в умовах бортової експлуатації повітряного судна. *Новітні технології сучасного суспільства (НТСС-2020)* : матеріали І Міжнародної науково-практичної конференції обдарованої учнівської та студентської молоді, 17 грудня 2020 р., Чернігів. С. 48–51.

341. Владов С. І., Плужник З. І. Перспективи використання нейронних мереж для контролю та діагностики технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах. *Авіація та космонавтика* : матеріали XII Всеукраїнської науково-практичної конференції, 20 квітня 2021 р., Кривий Ріг. С. 54.

342. Владов С. І., Янкевич Н. С., Плужник З. І. Перспективи використання нейронних мереж для ідентифікації авіаційного двигуна ТВЗ-117 в динаміці. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали Міжнародної науковопрактичної конференції, 22–23 квітня 2021 р., Київ. С. 54–56.

343. Shmelov Y., Vladov S., Kryshan O., Tsarenko A., Lashko A., Chyzhova L., Ivanchenko L. Implementation of neural network algorithms for monitoring and diagnosing the technical condition of the aircraft engine TV3-117 using modern onboard computing devices. *2019 IEEE 2nd Ukraine Conference on Electrical and Computer Engineering (UKRCON-2019)*, Lviv, Ukraine, 02–06 July 2019. P. 876–882.

344. Vladov S., Banasik A., Sachenko A., Kempa W., Sokurenko V., Muzychuk O., Pikiewicz P., Molga A., Vysotska V. Intelligent Method of Identifying the Nonlinear Dynamic Model for Helicopter Turboshaft Engines. *Sensors*. 2024. Vol. 24, Issue 19, 6488. doi: 10.3390/s24196488.

345. Sheng H., Chen Q., Li J., Jiang W., Wang Z., Liu Z., Zhang T., Liu Y. Research on dynamic modeling and performance analysis of helicopter turboshaft engine's start-up process. *Aerospace Science and Technology*. 2020. Vol. 106, 106097. doi: 10.1016/j.ast.2020.106097.

346. Filippone A., Bojdo N. Turboshaft engine air particle separation. *Progress in Aerospace Sciences*. 2010. Vol. 46:5–6. P. 224–245. doi: 10.1016/j.paerosci.2010.02.001.

347. Lila V. B., Puchkov E. V. Methodology of training recurrent artificial neural network with dynamic stack memory. *Software & Systems*. 2014. Vol. 4:108. P. 132–135. doi: 10.15827/0236-235X.108.132-135.

348. Nako J., Psychalinos C., Elwakil A.S. One active element implementation of fractionalorder Butterworth and Chebyshev filters. *AEU – International Journal of Electronics and Communications*. 2023. Vol. 168, 154724. doi: 10.1016/j.aeue.2023.154724.

349. Шмелев Ю. Н., Владов С. И., Крышан А. Ф., Гвоздик С. Д. Применение нейросетевых технологий в системе контроля технического состояния авиационного двигателя ТВ3-117 в полетных режимах. *Радиотехника*. 2018. Вып. 194. С. 147–154.

350. Vladov S., Kotliarov K., Hrybanova S., Husarova O., Derevyanko I., Gvozdik S. Neuromechanical methods of control and diagnostics of the technical state of aircraft engine TV3-117 in film regions. *Visnyk of Kherson National Technical University*. 2020. No. 1 (72). Part 1. P. 141– 154. doi: 10.35546/kntu2078-4481.2020.1.1.17. 351. Vladov S., Shmelov Y., Yakovliev R. Methodology for Control of Helicopters Aircraft Engines Technical State in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. 2022. Vol. 3137. P. 108–125. doi: 10.32782/cmis/3137-10.

352. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Метод контролю технічного стану авіаційного двигуна ТВЗ-117 на основі нейронної мережі. *Тенденції та вектор розвитку науки в сучасному світі* : матеріали VI Міжнародної науково-практичної конференції, 30 квітня 2018 р. Дніпро : НБК, 2018. Ч. 1. С. 49–55.

353. Шмельов Ю. М., Владов С. І., Ходін Д. С. Контроль технічного стану авіаційних двигунів вертольотів у польотних режимах за допомогою нейронних мереж зі змінною пам'яттю. *Авіація, промисловість, суспільство* : матеріали III Міжнародної науково-практичної конференції, 12 травня 2022 р., Кременчук. Кременчук : КЛК ХНУВС, 2022. С. 184–187.

354. Yazar I., Caliskan F., Kiyak E. Multiple fault-based FDI and reconfiguration for aircraft engine sensors. *Aircraft Engineering and Aerospace Technology*. 2017. Vol. 89. No. 3. P. 397–405.

355. Sarkar S., Mukherjee K., Ray A., Yasar M. Fault Diagnosis and Isolation in Aircraft Gas Turbine Engines. *2008 American Control Conference*. 2008. P. 2166–2171.

356. Gupta S., Ray A., Sarkar S., Yasa M. Fault detection and isolation in aircraft gas turbine engines. Part 1: underlying concept. *Proceedings of the Institution of Mechanical Engineers*. 2008. Vol. 222, Part G: J. Aerospace Engineering. P. 307–318.

357. Zhernakov S. V. Application of Neural Network Technology for Diagnosing the Technical Condition of Aircraft Engines. *Intelligent Systems in Production*. 2006. No. 2. P. 70–83.

358. Шмельов Ю. М., Владов С. І., Клімова Я. Р., Котляров К. Г. Застосування нейронних мереж у задачі діагностування технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах. *Вісник Херсонського національного технічного університету*. 2018. № 2 (65). С. 80–90.

359. Vladov S., Shmelov Y., Yakovliev R. Modified Neural Network Method for Diagnostics the Helicopters Turboshaft Engines Operational Status at Flight Modes. *IEEE International Conference on System Analysis & Intelligent Computing (SAIC)*, Kyiv, Ukraine, October 04–07, 2022. P. 224–229. doi: 10.1109/SAIC57818.2022.9923025.

360. Владов С. І., Ходін Д. С. Застосування нейронних мереж у задачі діагностики авіаційних двигунів вертольотів. *Інформаційні технології в культурі, мистецтві, освіті,*

науці, економіці та бізнесі : матеріали Міжнародної науково-практичної конференції, 20–21 квітня 2022 р., Київ. С. 31–34.

361. Владов С. І., Матусєв А. О. Щодо питання діагностики авіаційних двигунів вертольотів з використанням нейронних мереж. *Інформаційні технології в соціокультурній сфері, освіті та економіці* : матеріали Міжнародної науково-практичної конференції студентів та молодих вчених, 19–20 квітня 2022 р., Київ. С. 36–39.

362. Владов С. І., Плужник З. І. Діагностика технічного стану авіаційних двигунів вертольотів у польотних режимах за допомогою нейромережевого ансамблю. *Авіація, промисловість, суспільство* : матеріали III Міжнародної науково-практичної конференції, 12 травня 2022 р., Кременчук. Кременчук : КЛК ХНУВС, 2022. С. 160–162.

363. Владов С. І., Олексієнко Е. С., Використання нейронних мереж в задачі бортового контролю газотурбінних двигунів вертольотів. *Авіація та космонавтика: напрями інноваційного розвитку* : матеріали 42 Всеукраїнської науково-практичної конференції, 12 квітня 2023 р., Кропивницький. С. 277–278.

364. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Застосування нейронних мереж у задачі прогнозування технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах. *Авіаційно-космічна техніка і технологія*. 2018. № 3 (147). С. 30–38.

365. Vladov S., Shmelov Y., Yakovliev R. Method for Forecasting of Helicopters Aircraft Engines Technical State in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. 2022. Vol. 3171. P. 974–985.

366. Shmelov Y., Vladov S., Tsarenko A., Derevyanko I., Dieriabina I., Chyzhova L., Ivanchenko L. Prediction of the technical condition of the TV3-117 aircraft engine in the conditions of on-board implementation based on neural network technologies. *2019 IEEE 2nd Ukraine Conference on Electrical and Computer Engineering (UKRCON-2019)*, Lviv, Ukraine, 02–06 July 2019. 2019. P. 883–888.

367. Fu J., Yang R., Li X., Sun X., Li Y., Liu Z., Zhang Y., Sunden B. Application of Artificial Neural Network to Forecast Engine Performance and Emissions of a Spark Ignition Engine. *Applied Thermal Engineering*. 2022. Vol. 201, 117749. doi: 10.1016/j.applthermaleng.2021.117749.

368. Yemelyanov V., Chernyi S., Yemelyanova N., Varadarajan V. Application of Neural Networks to Forecast Changes in the Technical Condition of Critical Production Facilities. *Computers & Electrical Engineering*. 2021. Vol. 93, 107225. doi: 10.1016/j.compeleceng.2021.107225.

369. Kononov E., Klyuev A., Tashkinov M. Prediction of Technical State of Mechanical Systems Based on Interpretive Neural Network Model. *Sensors*. 2023. Vol. 23 (4). 1892. doi: 10.3390/s23041892.

370. Matuszczak M., Żbikowski M., Teodorczyk A. Predictive Modelling of Turbofan Engine Components Condition Using Machine and Deep Learning Methods. *Eksploatacja i Niezawodność – Maintenance and Reliability*. 2021. Vol. 23(2). P. 359–370. doi: 10.17531/ein.2021.2.16.

371. Vladov S., Shmelov Y., Yakovliev R. Modified Method of Identification Potential Defects in Helicopters Turboshaft Engines Units Based on Prediction its Operational Status. *2022 IEEE 4th International Conference on Modern Electrical and Energy System (MEES)*, Kremenchuk, Ukraine, October 20–22, 2022. P. 556–561. doi: 10.1109/MEES58014.2022.10005605.

372. Владов С. І., Жидких Т. М., Ребров Д. О. Метод ідентифікації потенційних дефектів авіаційних двигунів вертольотів на основі прогнозування часових рядів. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали Міжнародної науково-практичної конференції, 20–21 квітня 2023 р., Київ. С. 25–27.

373. Владов С. І., Плужник З. І. Діагностика авіаційних двигунів вертольотів у польотних режимах з використанням нейронних мереж. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали Міжнародної науковопрактичної конференції, 20–21 квітня 2022 р., Київ. С. 28–31

374. Vysotska V., Lytvyn V., Vladov S., Yakovliev R., Volkanin Ye. Neural Network Method for Identifying Potential Defects in Complex Dynamic Objects. *CEUR Workshop Proceedings*. Vol. 3742. 2024. P. 44–65.

375. Wang X., Deng W., Meng Z., Chen D. Hybrid-attention mechanism based heterogeneous graph representation learning. *Expert Systems with Applications*. 2024. Vol. 250, 123963. doi: 10.1016/j.eswa.2024.123963

376. Han M., Fan L. A short-term energy consumption forecasting method for attention mechanisms based on spatio-temporal deep learning. *Computers and Electrical Engineering*. 2024. Vol. 114, 109063. doi: 10.1016/j.compeleceng.2023.109063

377. Xia T., Chen X. Category-learning attention mechanism for short text filtering. *Neurocomputing*. 2022. Vol. 510. P. 15–23. doi: 10.1016/j.neucom.2022.08.076

378. Khalitov R., Yu T., Cheng L., Yang Z. Sparse factorization of square matrices with

application to neural attention modeling. *Neural Networks*. 2022. Vol. 152. P. 160–168. doi: 10.1016/j.neunet.2022.04.014

379. Zeynali M., Seyedarabi H., Afrouzian R. Classification of EEG signals using Transformer based deep learning and ensemble models. *Biomedical Signal Processing and Control*. 2023. Vol. 86 (part A), 105130. doi: 10.1016/j.bspc.2023.105130

380. Li X., Sun Q.-L., Zhang Y., Sha J., Zhang M. Environmental Modelling & Software. 2024. Vol. 177, 106042. doi: 10.1016/j.envsoft.2024.106042

381. Chan J., Papaioannou I., Straub D. Bayesian improved cross entropy method for network reliability assessment. *Structural Safety.* 2023. Vol. 103, 102344. doi: 10.1016/j.strusafe.2023.102344

382. Liu B., Chen H., Li K., Ying Yang M. Transformer-based multimodal change detection with multitask consistency constraints. *Information Fusion*. 2024. Vol. 108, 102358. doi: 10.1016/j.inffus.2024.102358

383. Foroutan P., Lahmiri S. Deep learning-based spatial-temporal graph neural networks for price movement classification in crude oil and precious metal markets. *Machine Learning with Applications*. 2024. Vol. 16, 100552. doi: 10.1016/j.mlwa.2024.100552

384. Pei W., Xu W.N., Wu Z., Li W., Wang J., Lu G., Wang X. Saliency-aware regularized graph neural network. *Artificial Intelligence*. 2024. Vol. 328, 104078. doi: 10.1016/j.artint.2024.104078

385. Li Y., Jian C., Zang G., Song C., Yuan X. Node classification oriented Adaptive Multichannel Heterogeneous Graph Neural Network. *Knowledge-Based Systems*. 2024. Vol. 292, 111618. doi: 10.1016/j.knosys.2024.111618

386. Li J., Song Y., Song X., Wipf D. On the Initialization of Graph Neural Networks. *Proceedings of the 40th International Conference on Machine Learning*, Honolulu, Hawaii, USA, 2023. Pp. 19911-19931. doi: 10.48550/arXiv.2312.02622

387. Haidong S., Hongkai J., Huiwei Z., Fuan W. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis. *Mechanical Systems and Signal Processing*. 2017. Vol. 95. P. 187–204. doi: 10.1016/j.ymssp.2017.03.034

388. Li A., Feng C., Xu S., Cheng Y. Graph t-SNE multi-view autoencoder for joint clustering and completion of incomplete multi-view data. *Knowledge-Based Systems*. 2024. Vol. 284, 111323. doi: 10.1016/j.knosys.2023.111324

389. Шмельов Ю. М., Владов С. І., Кришан О. Ф., Гвоздік С. Д. Застосування нейронних мереж у задачі налагодженні параметрів авіаційного двигуна ТВЗ-117 у польотних режимах. *Вісник Херсонського національного технічного університету.* 2018. № 4 (67). С. 126–132.

390. Vladov S., Shmelov Y., Yakovliev R. Parameter Debugging (Regulation) Method of Helicopters Aircraft Engines in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. 2022. Vol. 3179. P. 1–14.

391. Zhernakov S. V., Kinarsky A. V. Debugging of aircraft gas turbine engine parameters based on neural network technologies. *UGATU Bulletin*. 2013. Vol. 17, No. 5 (58). P. 26–30.

392. Zhernakov S. V. Application of neural networks for debugging gas turbine engine parameters during operation. *Neurocomputers and their application*: VII Conference with International Participation. 2001. P. 161–165

393. Zhernakov S. V. Debugging of aircraft gas turbine engine parameters based on neural networks. *Instruments and systems. Management. Control. Diagnostics*. 2003. No. 12. P. 33–40.

394. Vysotska V., Lytvyn V., Nazarkevych M., Vladov S., Yakovliev R., Yurko A. Training Neural Network Method Modification for Forward Error Propagation Based on Adaptive Components. *CEUR Workshop Proceedings*. Vol. 3711. 2024. P. 138–168.

395. Владов С. І., Пилипенко Л. М., Тутова Н. В., Дєрябіна І. О., Яніцький А. А. Контроль і діагностика технічного стану авіаційного двигуна ТВЗ-117 шляхом аналізу тренду його параметрів. *Вісник Херсонського національного технічного університету.* 2021. № 1 (76). С. 87–98. doi: 10.35546/kntu2078-4481.2021.1.11.

396. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Modified Neural Network Method for Trend Analysis of Helicopter Turboshaft Engine Parameters at Flight Modes. *CEUR Workshop Proceedings*. 2023. Vol. 3347. P. 11–29.

397. Zhernakov S. V., Ravilov R. F. Trend analysis of aircraft gas turbine engines based on neural network technology. *Bulletin of USATU*. 2011. Vol. 15, No. 4 (44). P. 25–32.

398. Shmelova T., Shmelov Yu., Vladov S. Concept of building intelligent control systems for aircraft, unmanned aerial vehicles and aircraft engines. *2020 IEEE 6th International Conference on Methods and Systems of Navigation and Motion Control (MSNMC)*, Kyiv, Ukraine, October 2020. P. 14–19. doi: 10.1109/MSNMC50359.2020.9255509.

399. Владов С. І., Янкевич Н. С., Ходін Д. С. Застосування нейромережевих технологій

в задачах управління авіаційними газотурбінними двигунами вертольотів у польотних режимах. Управління високошвидкісними рухомим об'єктами та професійна підготовка операторів складних систем (з нагоди 70-річчя академії) : матеріали X Міжнародної науково-практичної конференції, 24 листопада 2021 р., Кропивницький. С. 41–43.

400. Владов С. І., Плужник З. І., Матусєв А. О. Нейромережева система автоматичного управління авіаційними двигунами вертольотів у польотних режимах. *«ТАК» Телекомунікації, автоматизація, комп'ютерно-інтегровані та інформаційні технології* : матеріали Всеукраїнської науково-практичної конференції молодих учених, 01–02 грудня 2021 р., Покровськ. С. 73–76.

401. Li S., Wang Y., Zhang H. Research on Adaptive Feedforward Control Method for Tiltrotor Aircraft/Turboshaft Engine System Based on Radial Basis Function Neural Network. *Aerospace Science and Technology*. 2024. Vol. 150, 109180. doi: 10.1016/j.ast.2024.109180.

402. Wang Y., Ji C., Xi Z., Zhang H., Zhao Q. An Adaptive Matching Control Method of Multiple Turboshaft Engines. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 123, 106496. doi: 10.1016/j.engappai.2023.106496.

403. Владов С. І., Янкевич Н. С. Перспективи застосування нейронних мереж у задачах моніторингу авіаційних двигунів вертольотів. *Інформаційні технології в соціокультурній сфері, освіті та економіці* : матеріали міжнародної науково-практичної конференції студентів та молодих вчених, 19–20 квітня 2022 р., Київ. С. 39–42.

404. Владов С. І., Назаренко Н. П., Тутова Н. В., Москалик В. М., Пономаренко А. В. Багатовимірна система автоматичного управління авіаційним двигуном ТВЗ-117 на базі нейромережевого регулятора. *Вісник Кременчуцького національного університету імені Михайла Остроградського*. 2020. Вип. 2/2020 (121). С. 79–84. doi: 10.30929/1995-0519.2020.2.79-84.

405. Владов С. І., Телешун В. Я., Коваль І. М., Юрко О. О. Багаторежимна постановка задачі синтезу нейромережевого регулятора системи автоматичного управління авіаційного двигуна ТВЗ-117. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XIX Міжнародної науково-технічної конференції, 6–8 листопада 2020 р., Кременчук–Хургада. Кременчук : КрНУ, 2020. С. 113–115.

406. Vladov S., Shmelov Y., Yakovliev R. Helicopters Aircraft Engines Self-Organizing Neural Network Automatic Control System. *CEUR Workshop Proceedings*. 2022. Vol. 3137. P. 28–47. doi: 10.32782/cmis/3137-3.

407. Владов С. І., Матусєв А. О., Яковенко І. П., Пінчук Ю. Б. Синтез каналів управління частотою обертання ротора турбокомпресора авіаційних двигунів вертольотів. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XIX Міжнародної науково-технічної конференції, 12–14 листопада 2021 р., Кременчук. Кременчук : КрНУ, 2021. С. 11–13.

408. Elizarov I., Soludanov M. Self-adjustable neural network control system of multilinked dynamic object. *Information processes and management*. 2006. No 1. P. 30–44.

409. Vasiliev V. I., Idrisov I. I. Algorithms for Designing and Stability Analysis of an Intelligent Control System for Gas Turbine Engines. *Bulletin of USATU*. 2008. Vol. 11. No. 1 (28). pp. 34–42.

410. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Modified Neural Network Fault-Tolerant Closed Onboard Helicopters Turboshaft Engines Automatic Control System. *CEUR Workshop Proceedings*. 2023. Vol. 3387. P. 160–179.

411. Sun B., van Kampen E.-J. Intelligent Adaptive Optimal Control Using Incremental Model-Based Global Dual Heuristic Programming Subject to Partial Observability. *Applied Soft Computing*. 2021. Vol. 103, 107153. doi: 10.1016/j.asoc.2021.107153.

412. Zhen M., Dong X., Liu X., Tan C. Accelerated Formulation of Optimal Control Law for Adaptive Cycle Engines: A Novel Design Methodology. *Aerospace Science and Technology*. 2024.
Vol. 148, 109076. doi: 10.1016/j.ast.2024.109076.

413. Chen Q., Sheng H., Zhang T. A Novel Direct Performance Adaptive Control of Aero-Engine Using Subspace-Based Improved Model Predictive Control. *Aerospace Science and Technology*. 2022. Vol. 128, 107760. Doi: 10.1016/j.ast.2022.107760.

414. Vysotska V., Vladov S., Volkanin Y., Siora A., Bulakh M., Muzychuk O., Koren O. The helicopter turboshaft engines parametric debugging using neural network technology. *CEUR Workshop Proceedings*. 2024. Vol. 3861. P. 1–15.

415. Liu H., Dong S., Jiang H., Zhou Y., Liu Y., Wu J. Task-Level Energy Efficiency Evaluation Method Based on Aero-Engine Thrust-Specific Fuel Consumption with Application to Environment Control System. *Machines*. 2022. Vol. 10(8), 643. doi: 10.3390/machines10080643.

416. García Nieto P., García-Gonzalo E., Bernardo Sánchez A., Menéndez Fernández M. A New Predictive Model Based on the ABC Optimized Multivariate Adaptive Regression Splines Approach for Predicting the Remaining Useful Life in Aircraft Engines. *Energies*. 2016. Vol. 9 (6), 409. doi: 10.3390/en9060409.

417. Владов С. І., Шаповал А. О. Перспективи розробки адаптивних алгоритмів моніторингу авіаційних двигунів вертольотів у польотних режимах. *Авіація та космонавтика* : матеріали II Міжнародної науково-практичної конференції, 18 квітня 2023 р., Кривий Ріг. С. 28.

418. Бахирєв І. В. Адаптивне управління газотурбінними установками при виробництві електроенергії з урахуванням збурень в електричній системі: дис. ... канд. техн. наук: 05.13.06. 2018. 122 с.

419. Vladov S., Shmelov Y., Yakovliev R. Modified Helicopters Turboshaft Engines Neural Network On-board Automatic Control System Using the Adaptive Control Method. *CEUR Workshop Proceedings*. 2022. Vol. 3309. P. 205–224.

420. Vladov S., Shmelov Y., Yakovliev R. Modified Searchless Method for Identification of Helicopters Turboshaft Engines at Flight Modes Using Neural Networks. *2022 IEEE 3rd KhPI Week on Advanced Technology*, Kharkiv, Ukraine, October 03–07, 2022. Pp. 257–262. doi: 10.1109/KhPIWeek57572.2022.9916422.

421. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Neural Network Method for Parametric Adaptation Helicopters Turboshaft Engines On-Board Automatic Control System Parameters. *CEUR Workshop Proceedings* (ISSN 1613-0073). 2023. Vol. 3403. P. 179–195.

422. Igumnov I. V., Kucyi N. N. Application of Nelder – Mead method when configuring the neural networks that implement PID regulation. *Modern Technologies. System Analysis. Modeling*. 2016. № 1 (49). P. 90–95.

423. Ігумнов І. В. Метод Нелдера-Міда для налаштування регулятора, що функціонує на основі штучних нейронних мереж: дис. ... канд. техн. наук: 05.13.05. 2020. 166 с.

424. Владов С. І., Матусєв А. О., Плужник З. І. Бортова система автоматичного управління авіаційних двигунів вертольотів на основі нейромережевих технологій. *Новітні технології сучасного суспільства (HTCC-2021)* : матеріали II Міжнародної науковопрактичної конференції обдарованої учнівської та студентської молоді, 17 грудня 2021 р., Чернігів. Ч. 1. С. 230–233.

425. Владов С. І., Шаповал А. О. Математична постановка параметричної адаптації закритої бортової системи автоматичного управління авіаційних двигунів вертольотів.

Авіація та космонавтика : матеріали II Міжнародної науково-практичної конференції, 18 квітня 2023 р., Кривий Ріг. С. 27.

426. Владов С. І., Олексієнко Е. С. Використання методу динамічної компенсації в інтелектуальній бортовій системі вертольотів. *Інформаційні технології в соціокультурній сфері, освіті та економіці* : матеріали Міжнародної науково-практичної конференції здобувачів освіти і молодих учених, 19–20 квітня 2023 р., Київ. С. 32–34.

427. Владов С. І., Щербина Д. О., Пономаренко А. О., Шаповал А. О. Нейромережевий метод параметричної адаптації параметрів бортової системи автоматичного управління авіаційних двигунів вертольотів. *Авіація, промисловість, суспільство* : матеріали IV Міжнародної науково-практичної конференції, 18 травня 2023 р., Кременчук. Кременчук : КЛК ХНУВС, 2023. С. 255–257.

428. Vysotska V., Vladov S., Pukach P., Lavrut O., Muzychuk O., Baranovskyi D., Severynenko D. The dual-channel logic controller synthesis for controlling complex dynamic objects. *CEUR Workshop Proceedings*. 2024. Vol. 3861. P. 28–41.

429. Pan M., Wang H., Zhang C., Xu Y. Fuzzy Control for Aircraft Engine: Dynamics Clustering Modeling, Compensation and Hardware-in-Loop Experimental Verification. *Aerospace*. 2024. Vol. 11 (8), 610. doi: 10.3390/aerospace11080610.

430. Mu J., Rees D., Liu G. P. Advanced Controller Design for Aircraft Gas Turbine Engines. *Control Engineering Practice*. 2005. Vol. 13. P. 1001–1015. doi: 10.1016/j.conengprac.2004.11.001.

431. Wang H., Wang D., Zhang G. Research of Neural Network PID Control of Aero-Engine. *Lecture Notes in Electrical Engineering*. 2011. Vol. 122. P. 337–343. doi: 10.1007/978-3-642-25553-3_42.

432. Vladov S., Sokurenko V., Muzychuk O., Sachenko A., Sachenko S., Kopamia L., Vysotska V. The Fuzzy Logic Application in Helicopter Turboshaft Engines Automatic Control Systems. *2024 IEEE 17th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, Lviv, Ukraine, October 08–12, 2024. P. 253–256. doi: 10.1109/TCSET64720.2024.10755839.

433. Jie M. S., Mo E. J., Hong G. Y., Lee K. W. Fuzzy Logic Controller for Turbojet Engine of Unmanned Aircraft. *Lecture Notes in Computer Science*. 2006. Vol. 4251. P. 29–36. doi: 10.1007/11892960 4.

434. Mpanza L. J., Pedro J. O. Optimised Tuning of a PID-Based Flight Controller for a Medium-Scale Rotorcraft. *Algorithms*. 2021. Vol. 14(6), 178. doi: 10.3390/a14060178.

435. Köprücü S., Öztürk M. Comparison of PID coefficients determination methods for aircraft pitch angle control. *Aerospace Research Letters (ASREL)*. 2024. Vol. 3(1). P. 15–26. doi: 10.56753/ASREL.2024.3.5.

436. Vasiliev V. I., Zhernakov S. V. Monitoring and Diagnostics of the Technical Condition of Aircraft Engines Based on Expert Systems. *Bulletin of USATU*. 2007. Vol. 9. No. 4 (22). P. 11–23.

437. Zhernakov S. V., Ravilov R. F. Monitoring and Diagnostics of the Technical Condition of an Aircraft Engine Based on the C-PRIZ Expert System. *Bulletin of USATU*. 2012. Vol. 16. No. 6 (51). P. 3–11.

438. Владов С. І. Розробка математичної моделі нечіткої експертної системи контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Інформаційні технології в культурі, мистецтві, освіті, науці, економіці та бізнесі* : матеріали щорічної Міжнародної науково-практичної конференції, 18–19 квітня 2019 р. Київ : Київський національний університет культури і мистецтв, 2019. С. 144–146.

439. Владов С. І., Шмельов Ю. М., Курбанов К. Р. Щодо питання контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 в польотних режимах за допомогою нечіткої експертної системи. *Актуальні проблеми сучасної науки в дослідженнях молодих учених* : матеріали науково-практичної конференції, 15 травня 2020 р. Харків : ХНУВС, 2020. С. 332–338.

440. Шмельов Ю. М., Владов С. І., Хебда А. С., Котляров К. Г. Застосування правил нечіткої логіки у задачі ідентифікації технічного стану авіаційного двигуна ТВЗ-117. *Вчені записки Таврійського національного університету імені В.І. Вернадського*. Серія: Технічні науки. 2018. Том 30 (69), № 3. С. 34–40.

441. Hušek P., Narenathreyas K. Aircraft Longitudinal Motion Control Based on Takagi– Sugeno Fuzzy Model. *Applied Soft Computing*. 2016. Vol. 49. P. 269–278. doi: 10.1016/j.asoc.2016.07.038.

442. Żyluk A., Kuźma K., Grzesik N., Zieja M., Tomaszewska J. Fuzzy Logic in Aircraft Onboard Systems Reliability Evaluation – A New Approach. *Sensors*. 2021. Vol. 21 (23), 7913. doi: 10.3390/s21237913.

443. Gandhi P., Nagaraj R., Sapam H. D. Designing Fuzzy Logic Controller for Auto Landing

of Flight. International Journal of Scientific & Engineering Research. 2016. Vol. 7 (5). P. 231–237.

444. Владов С. І., Москалик В. М., Подгорних Н. В., Гусарова О. В., Назаренко Н. П. Використання нечітких нейронних мереж в задачах контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117 у польотних режимах. *Вісник Херсонського національного технічного університету.* 2021. № 1 (76). С. 77–86. doi: 10.35546/kntu2078-4481.2021.1.10

445. Владов С. І., Янкевич Н. С., Плужник З. І., Саньков С. В. Контроль і діагностика технічного стану авіаційних двигунів вертольотів у польотних режимах з використанням нечітких нейронних мереж. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XIX Міжнародної науково-технічної конференції, 12–14 листопада 2021 р., Кременчук. Кременчук : КрНУ, 2021. С. 90–92.

446. Vladov S., Shmelov Y., Petchenko M. A Neuro-Fuzzy Expert System for the Control and Diagnostics of Helicopters Aircraft Engines Technical State. *CEUR Workshop Proceedings*. 2021. Vol. 3013. P. 40–52.

447. Slinin S., Rubinov V. Adaptation of hybrid neuro-fuzzy networks for classification of ground targets in the onboard computer system of military robotic systems. *Aerospace forces*. *Theory and practice*. 2020. No. 16. P. 125–135.

448. Wei Z., Jafari S., Zhang S., Nikolaidis T. Hybrid Wiener model: An on-board approach using post-flight data for gas turbine aero-engines modelling. *Applied Thermal Engineering*. 2021. Vol. 184, 116350. doi: 10.1016/j.applthermaleng.2020.116350

449. Vladov S., Bulakh M., Vysotska V., Yakovliev R. Onboard Neuro-Fuzzy Adaptive Helicopter Turboshaft Engines Automatic Control System. *Energies*. 2024. Vol. 17, Issue 16, 4195. doi: 10.3390/en17164195

450. Vladov S., Yakovliev R., Hubachov O., Rud J., Drodova S., Perekrest A. On-Board Method for Helicopters Turboshaft Engines Neuro-Fuzzy Fuel Consumption Control. *2023 IEEE 5th International Conference on Modern Electrical and Energy System (MEES)*, Kremenchuk, Ukraine, September 27–30, 2023. P. 495–500. doi: 10.1109/MEES61502.2023.10402511.

451. Vladov S., Yakovliev R., Hubachov O., Rud J. Neuro-Fuzzy System for Detection Fuel Consumption of Helicopters Turboshaft Engines. *CEUR Workshop Proceedings*. 2024. Vol. 3628. P. 55–72.

452. Mochurad L. I., Mamchur, M. V. (2024). Parallel and distributed computing

technologies for autonomous vehicle navigation. *Radio Electronics, Computer Science, Control.* 2024. No. (4). P. 111–121. doi: 10.15588/1607-3274-2023-4-11

453. Efimov V., Nezametdinov R. Mathematical model specific fuel consumption of the TV3-117. *Transport systems*. 2024. No. 200. P. 11–15.

454. Vladov S., Yakovliev R., Hubachov O., Mykolenko K., Drodova S., Stushchanskyi Y. Neural Network Method for Helicopters Turboshaft Engines Dynamic Efficiency Monitoring. *2023 IEEE 4 th KhPI Week on Advanced Technology*, Kharkiv, Ukraine, October 02–06, 2023. P. 160–165. doi: 10.1109/KhPIWeek61412.2023.10312883.

455. Chicherova E. Methods for Improvement of the Quality of the Power Turbine Speed Control of a Gas Turbine Engine. *Mechatronics, Automation, Control.* 2015. Vol. 16. No. 6 (2015). P. 402–408.

456. Chicherova E., Blokhin V., Konashkov S. The use of mathematical models for the development and refinement of the electronic part of the aircraft engine control system. *Science and technology*. 2015. Vol. 4(2015). P. 43–54.

457. Vladov S., Shmelov Y., Yakovliev R., Stushchankyi, Y., Havryliuk Y. Neural Network Method for Controlling the Helicopters Turboshaft Engines Free Turbine Speed at Flight Modes. *CEUR Workshop Proceedings*. 2023. Vol. 3426. P. 89–108.

458. Vladov S., Yakovliev R., Hubachov O., Rud J., Drodova S., Perekrest A. Modified Discrete Neural Network PID Controller for Controlling the Helicopters Turboshaft Engines Free Turbine Speed. *2023 IEEE 5th International Conference on Modern Electrical and Energy System (MEES)*, Kremenchuk, Ukraine, September 27–30, 2023. P. 797–802. doi: 10.1109/MEES61502.2023.10402433.

459. Vladov S., Vysotska V., Sokurenko V., Muzychuk O., Nazarkevych M., Romanchuk R. Electronic Dynamic Controller Model Based on Specific Characteristics Regulation. *2024 IEEE 19th International Conference on Computer Science and Information Technologies (CSIT)*, Lviv, Ukraine, October 16–19, 2024. doi: 10.1109/CSIT00000.2024.0000000

460. Vysotska V., Lytvyn V., Vladov S., Muzychuk O., Kryshan O. The controller synthesis automation using a dynamic mathematical model and genetic algorithms. *CEUR Workshop Proceedings*. Vol. 3842. 2024. P. 1–18.

461. Petukhov I., Mikhaylenko T., Yepifanov S., Shevchuk O. Study on accuracy of heat transfer coefficient determination in the bearing chamber for gas turbine. *Proceedings of ASME*

Turbo Expo 2020 Turbomachinery Technical Conference and Exposition. G2020-14304.

462. Najariyan M., Zhao Y. Granular fuzzy PID controller. *Expert Systems with Applications*.2021. Vol. 167, 114182. doi: 10.1016/j.eswa.2020.114182

463. Oganyan I. Mathematical model of fuel pump-regulator of helicopter turbo-shaft engine. *Aerospace Technic and Technology*. 2020. No. 17(167). P. 105–112. doi: 10.32620/aktt.2020.7.15

464. Zhao Y., Niu B., Zong G., Xu N., Ahmad A. M. Event-triggered optimal decentralized control for stochastic interconnected nonlinear systems via adaptive dynamic programming. *Neurocomputing*. 2023. Vol. 529, 126163. doi: 10.1016/j.neucom.2023.03.024

465. Fan Z.-X., Adhikary A. C., Li S., Liu R. Disturbance observer based inverse optimal control for a class of nonlinear systems. *Neurocomputing*. 2022. Vol. 500. P. 821–831. doi: 10.1016/j.neucom.2022.05.115

466. Mahmoodabadi M. J., Jahanshahi H. Multi-objective optimized fuzzy-PID controllers for fourth order nonlinear systems. *Engineering Science and Technology, an International Journal*. 2016. Vol. 19, Issue 2. P. 1084–1098. doi: 10.1016/j.jestch.2016.01.010

467. Chiroma H., Noor A. S. M., Abdulkareem S., Abubakar A. I., Hermawan A. H., Qin H., Hamza M. F., Herawan T. Neural Networks Optimization through Genetic Algorithm Searches: A Review. *Applied Mathematics & Information Sciences*. 2017. Vol. 11, Issue 6. P. 1543–1564. doi: 10.18576/amis/110602

468. Welper G. Universality of gradient descent neural network training. *Neural Networks*. 2022. Vol. 150. P. 259–273. doi: 10.1016/j.neunet.2022.02.016

469. Pomogaev A., Dementev D., Krasnenko D., Shtylenko A. Exploring the possibility of applying different neuronal activation functions to a single-circuit ACS. *Journal of Physics: Conference Series*. 2021. Vol. 1889, 022007. doi: 10.1088/1742-6596/1889/2/022007

470. Vladov S., Scislo L., Sokurenko V., Muzychuk O., Vysotska V., Sachenko A., Yurko A. The helicopter turboshaft engines gas-generator rotor r.p.m. neuro-fuzzy on-board controller. *Energies*. 2024. Vol. 17, Issue 16, 4033. doi: 10.3390/en17164033

471. Vladov S., Lytvynov O., Vysotska V., Vasylenko V., Pukach P., Vovk M. The helicopter turboshaft engines' innovative applied control system based on a neuro-fuzzy networks. *Applied System Innovation*. 2024. Vol. 7. Issue 6. 118. doi: 10.3390/asi7060118

472. Vladov S. Cognitive method for the fuzzy controller mathematical model synthesising, utilising a genetic algorithm for tuning. *Big Data and Cognitive Computing*. 2025. Vol. 9. Issue 1.

473. Zhernakov S. V. Detection of GTE failures using neural network models. *Aerospace Engineering*. 2000. No. 4, 2000. P. 26–31.

474. Zhernakov S. V., Muslukhov I. I. Neural network technologies for increasing the fault tolerance of GTE measuring channels. *Informatics and information technology* : Proceedings of the International Conference, 2003. V. 2. P. 91–96.

475. Єременко В. С., Осінцева М. Б. Застосування методу головних компонент в задачі аналізу спектрів вільних коливань. *Вісник Вінницького політехнічного інституту*. 2022. № 4. С. 6–12. doi: 10.31649/1997-9266-2022-163-4-6-12

476. Zhernakov S. V. Algorithms for monitoring and diagnostics of aircraft gas turbine engines in conditions of on-board implementation based on neural network technology. *Bulletin of USATU*. 2010. Vol. 14. No. 3 (38). P. 42–56.

477. Vasiliev V. I., Zhernakov S. V., Muslukhov I. I. On-board algorithms for monitoring gas turbine engine parameters based on neural network technology. *Bulletin of USATU*. 2009. Vol. 12. No. 1 (30). P. 61–74.

478. Vasiliev S., Badamshin R., Valeev S., Vasiliev V., Gvozdev V., Guzairov M., Zhernakov S., Ilyasov B., Kusimov S., Munasypov R., Raspopov Y., Frid A., L. Chernyakhovskaya. *Intelligent control and monitoring systems for gas turbine engines*. 2008. P. 327–390.

479. Vladov S., Yakovliev R., Vysotska V., Uhryn D., Ushenko Y. Universal On-board Neural Network System for Restoring Information in Case of Helicopter Turboshaft Engine Sensor Failure. *International Journal of Computer Network and Information Security (IJCNIS)*. 2024. Vol. 16. No. 4. P. 65–87. doi: 10.5815/ijcnis.2024.04.05

480. Dehtiarov O., Zaporozhets O., Ovcharova T. Identification of nonlinear transform function using artificial neural network. *Ukrainian Metrological Journal*. 2013. No. 2. P. 4–8.

481. Vladov S., Kotliarov K., Hrybanova S., Husarova O., Chyzhova L. On-board information restoring method in case of failure of one of the sensors of the aircraft engine TV3-117 based on neural network technologies. *Transactions of Kremenchuk Mykhailo Ostrohradskyi National University*. 2019. Issue 6/2019 (119). P. 91–98. doi: 10.30929/1995-0519.2019.6.91-98.

482. Golberg F., Gurevich O., Petukhov A. Mathematical model of an ACS GTE in a gas turbine engine to improve reliability and control quality. *Electronic journal "Proceedings of MAI"*. 2012. No. 58. P. 1–13.

483. Zhernakov S. V., Muslukhov I. I. Parrying failures of gas turbine engine sensors using

413

neural networks. Computer engineering and new information technologies. 2003. P. 35-41.

484. Zhernakov S. V., Muslukhov I. I. Neurocomputer for restoring lost information from standard sensors of the onboard monitoring and diagnostics system. *Neuroinformatics*. 2006. Part 3. P. 180–188.

485. Владов С. І., Долударєва Я. С., Сіора А. С., Пономаренко А. В., Яніцький А. А. Нейромережевий обчислювач задля відновлення втраченої інформації зі штатних датчиків бортової системи контролю і діагностики авіаційного двигуна ТВЗ-117. *Сучасний стан наукових досліджень та технологій в промисловості.* 2020. № 4 (14). С. 147–154.

486. Vladov S., Yakovliev R., Vysotska V., Nazarkevych M., Lytvyn V. The Method of Restoring Lost Information from Sensors Based on Auto-Associative Neural Networks. *Applied System Innovation*. 2024. Vol. 7. Issue 3. 53. doi: 10.3390/asi7030053.

487. Khusaenov A. A. Autoassociative neural networks in the classification problem with a truncated set. Intelligent Systems. *Theory and Applications*. 2022. Vol. 26. No. 2. P. 33–41.

488. Liu Y., Tan X., Bao Y. Machine learning-assisted intelligent interpretation of distributed fiber optic sensor data for automated monitoring of pipeline corrosion. *Measurement*. 2024. Vol. 226, 114190. doi: 10.1016/j.measurement.2024.114190.

489. Impraimakis M. A Kullback–Leibler divergence method for input–system–state identification. *Journal of Sound and Vibration*. 2024. Vol. 569, 117965. doi: 10.1016/j.jsv.2023.117965.

490. Siswantoro J., Prabuwono A. S., Abdullah A., Idrus B. A linear model based on Kalman filter for improving neural network classification performance. *Expert Systems with Applications*. 2016. Vol. 49. Pp. 112–122. doi: 10.1016/j.eswa.2015.12.012.

491. Luo Q., Li S., Yan X., Wang C., Zhou Z., Jia G. An improved two-phase robust distributed Kalman filter. *Signal Processing*. 2024. Vol. 220, 109438. doi: 10.1016/j.sigpro.2024.109438.

492. Li Y., Wahlberg B., Hu X., Xie L. Inverse Kalman filtering problems for discrete-time systems. *Automatica*. 2024. Vol. 163, 111560. doi: 10.1016/j.automatica.2024.111560.

493. Song X., Zheng W. X. A Kalman-filtering derivation of input and state estimation for linear discrete-time systems with direct feedthrough. *Automatica*. 2024. Vol. 161, 111453. doi: 10.1016/j.automatica.2023.111453.

494. Vladov S. Algorithms for diagnostic and parameter of failures of channels of

measurement of TV3-117 aircraft engine automatic control system in flight modes based of neural network technologies. *Proceedings of the National Aviation University*. 2020. No. 3 (84). P. 27–37. doi: 10.18372/2306-1472.84.14950.

495. Владов С. І., Ковальський В. С., Дятловська В. Л., Яніцький А. А., Вакуленко Р. А. Відмовостійкий алгоритм ідентифікації бортової математичної моделі авіаційного двигуна ТВЗ-117 в складі його системи автоматичного управління. Вісник Херсонського національного технічного університету. 2020. № 4 (75). С. 11–19. doi: 10.35546/kntu2078-4481.2020.4.1.

496. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Helicopters Turboshaft Engines Parameters Identification Using Neural Network Technologies Based on the Kalman Filter. *Communications in Computer and Information Science* (CCIS) book series (ISSN 1865-0929). 2023. Vol. 1980. P. 82–97. doi: 10.1007/978-3-031-48325-7 7.

497. Владов С. І., Пономаренко А. В., Телешун В. Я. Щодо питання діагностики та парирування відмов каналів вимірювання систем автоматичного управління авіаційним двигуном ТВЗ-117. *Авіація та космонавтика* : матеріали XI Всеукраїнської науковопрактичної конференції, 22 квітня 2020 р., Кривий Ріг. С. 41.

498. Владов С. І., Шмельов Ю. М. Навчання нейронної мережі методом розширеного фільтра Калмана для діагностики і парирування відмов датчиків авіаційного двигуна ТВЗ-117. *Авіація, промисловість, суспільство* : матеріали I Міжнародної науково-практичної конференції, 14 травня 2020 р. Кременчук : КЛК ХНУВС, 2020. Ч. 1. С. 351–354.

499. Владов С. І., Плужник З. І., Матусєв А. О., Юрко О. О., Бабич П. Л. Діагностика і парирування відмов датчиків витрати палива авіаційного двигуна ТВЗ-117 в польотних режимах з використанням банку фільтрів Калмана. *Фізичні процеси та поля технічних і біологічних об'єктів* : матеріали XIX Міжнародної науково-технічної конференції, 6–8 листопада 2020 р., Кременчук–Хургада. Кременчук : КрНУ, 2020. С. 7–9.

500. Владов С. І., Янкевич Н. С. Перспективи використання багатовимірного фільтра Калмана в задачах контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Авіація та космонавтика: напрями інноваційного розвитку* : матеріали 41 Всеукраїнської науково-практичної конференції, 14 квітня 2021 р., Кропивницький. С. 306–307.

501. Avgustinovich V. G., Kuznetsova T. A., Kurakin A. D., Fatykov A. I., Yakushev A. P. Linear adaptive on-board mathematical model of the engine to improve the reliability of automatic

control systems of aircraft gas turbine engines. *Aerospace Engineering*. 2015. No. 42. P. 47–60. doi: 10.15593/2224-9982/2015.42.04.

502. Kuznetsova T. A., Avgustinovich V. G., Yakushev A. P. Statistical analysis of processes in aircraft engine control systems with on-board mathematical models. *Scientific and Technical Bulletin of the TPU*. 2014. No. 35. P. 236–238.

503. Kuznetsova T. A., Avgustinovich V. G., Gubarev E. A. Algorithms for diagnostics and parrying failures of measurement channels of the automatic control system of an aircraft engine. *Electrical engineering, information technology, control systems*. 2015. No. 16. P. 5–14

504. Kuznetsova T. A., Gubarev E. A., Likhacheva Yu. V. Optimal filtering algorithms in problems of identification of parameters of automatic control systems of aircraft engines. *Information, measuring and control systems*. 2014. Vol. 12. No. 9. P. 12–20.

505. Kuznetsova T. A., Gubarev E. A., Likhacheva Yu. V., Yakushev A. P. Identification of parameters of gas-turbine engine control systems using a multidimensional Kalman filter. *Electrical engineering, information technology, control systems*. 2014. No. 10. P. 114–125

506. Sheng H., Chen Q., Li J., Jiang W., Wang Z., Liu Z., Zhang T., Liu Y. Research on dynamic modeling and performance analysis of helicopter turboshaft engine's start-up process. *Aerospace Science and Technology*. 2020. Vol. 106, 106097. doi: 10.1016/j.ast.2020.106097.

507. Yun P., Wu P., He S., Li X. A variational Bayesian based robust cubature Kalman filter under dynamic model mismatch and outliers interference. *Measurement*. 2022. Vol. 191, 110063. doi: 10.1016/j.measurement.2021.110063.

508. He J., Wang G., Yu H., Liu J. M., Peng B. Generalized minimum error entropy Kalman filter for non-Gaussian noise. *ISA Transactions*. 2023. Vol. 136. P. 663–675. doi: 10.1016/j.isatra.2022.10.040.

509. Liu Z., Chen S., Wu H., Liang F. Orthogonal Simplex Chebyshev-Laguerre Cubature Kalman Filter Applied in Nonlinear Estimation Systems. *Applied Sciences*. 2018. Vol. 8 (6), 863. doi: 10.3390/app8060863.

510. Biswas S. K., Qiao L., Dempster A. G. A quantified approach of predicting suitability of using the Unscented Kalman Filter in a non-linear application. *Automatica*. 2020. Vol. 241, 109241. doi: 10.1016/j.automatica.2020.109241.

511. Hoppe K., Giesa F., Schaldach G., Thommes M., Pieloth D. Optimization of filter structures by evolutionary strategies. *Materials Today Communications*. 2024. Vol. 38, 108510.

doi: 10.1016/j.mtcomm.2024.108510.

512. Vladov S., Muzychuk O., Vysotska V., Yurko A., Uhryn D. Modified Kalman Filter with Chebyshev Points Based on a Recurrent Neural Network for Automatic Control System Measuring Channels Diagnosing and Parring Off Failures. *International Journal of Image, Graphics and Signal Processing (IJIGSP)*. 2024. Vol. 16. No. 5. P. 36–61. doi: 10.5815/ijigsp.2024.05.04

513. Ruiz C., Alaíz C. M., Dorronsoro J. R.. Convex formulation for multi-task L1-, L2-, and LS-SVMs. *Neurocomputing*. 2021. Vol. 456. P. 599–608, doi: 10.1016/j.neucom.2021.01.137.

514. Hou Z., Yu L., Liang Y., Xu B., Lei Y. Integrating L1 and weighted L2 regularization for moving force identification from combined response measurements. *Measurement*. 2024. Vol. 228, 114337. doi: 10.1016/j.measurement.2024.114337.

515. Cao X., Luo H., Tai J., Jiang R., Wang G. Multi-agent target search strategy optimization: Hierarchical reinforcement learning with multi-criteria negative feedback. *Applied Soft Computing*. 2023. Vol. 149, part A, 110999. doi: 10.1016/j.asoc.2023.110999.

516. Vladov S., Vysotska V., Sokurenko V., Muzychuk O., Nazarkevych M., Lytvyn V. Neural Network System for Predicting Anomalous Data in Applied Sensor Systems. *Applied System Innovation*. 2024. Vol. 7. Iss. 5. Pp. 88. doi: 10.3390/asi7050088

517. Vladov S., Sachenko A., Sokurenko V., Muzychuk O., Vysotska V. Helicopters turboshaft engines neural network modeling under sensor failure. *Journal of Sensor and Actuator Networks*. 2024. Vol. 13. Iss. 5. P. 66. doi: 10.3390/jsan13050066

518. Vladov S., Vysotska V., Sokurenko V., Muzychuk O., Chyrun L. The Intelligent Data Measurement System Using Neural Network Technologies and Fuzzy Logic Under Operating Implementation Conditions. *Big Data and Cognitive Computing*. 2024. Vol. 8. Issue 12. P. 189. doi: 10.3390/bdcc8120189

519. Vladov S., Yakovliev R., Hubachov O., Mykolenko K., Drozdova S., Rud J. Modified Neuro-Fuzzy Failure Classifier of Helicopters Turboshaft Engines. *2023 IEEE 18th International Conference on Computer Science and Information Technologies (CSIT)*, Lviv, Ukraine, October 19–23, 2023. 4 p. doi: 10.1109/CSIT61576.2023.10324287

520. Vladov S., Yakovliev R., Hubachov O., Rud J. On-board Hybrid Neural Network Classifier of Helicopters Turboshaft Engines Operational Status. *CEUR Workshop Proceedings*. 2024. Vol. 3628. P. 262–281.

521. Vladov S., Scislo L., Szczepanik-Ścisło N., Sachenko A., Perzyński T., Vasylenko V.,

417

Vysotska V. The helicopter turboshaft engines' neural network system for monitoring sensors' failures. *Sensors*. 2025. Vol. 25. Issue 1. 990. doi: 10.3390/s25040990.

522. Vladov S., Kovtun V., Sokurenko V., Muzychuk O., Vysotska V. The Helicopter Turboshaft Engine's Reconfigured Dynamic Model for Functional Safety Estimation. *Electronics*. 2024. Vol. 13, Issue 17, 3477. doi: 10.3390/electronics13173477.

523. Vladov S., Sachenko A., Vysotska V., Volkanin Y., Kukharenko D., Severynenko D. The reliably stable neural network controllers' synthesis with the transient process parameters optimization. *Radioelectronic and Computer Systems*. 2024. Vol. 4 (112). No. 4. P. 178–191. doi: 10.32620/reks.2024.4.15.

524. Владов С. І., Янкевич Н. С., Плужник З. І. Прийняття рішень щодо можливості здійснення польоту вертольоту за результатами контролю і діагностики авіаційного двигуна. *Перспектива-2021* : матеріали всеукраїнської наукової очно-заочної конференції для творчої молоді України, 26 квітня 2021 р., Маріуполь. С. 632–636.

525. Шмельова Т. Ф. Науково-методологічні основи моделювання підтримки прийняття рішень в аеронавігаційній системі. дис. ... д-ра техн. наук : 05.22.13. Київ, 2013. 424 с.

526. Харченко В. П., Шмельова Т. Ф., Сікірда Ю. В. Прийняття рішень оператором аеронавігаційної системи : монографія. Кіровоград : Кіровоградська льотна академія Національного авіаційного університету, 2012. 292 с.

527. Владов С. І., Сіора А. С., Яніцький А. А., Дятловська В. Л. Шмельова Т. Ф. Нейромережевий аналіз прийняття рішень екіпажом повітряного судна щодо можливості здійснення польоту за результатами контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. Вісник Кременчуцького національного університету імені Михайла Остроградського. 2020. Вип. 3/2020 (122). С. 84–90. doi: 10.30929/1995-0519.2020.3.84-90.

528. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Характерні особливості інформаційної системи ідентифікації технічного стану авіаційного двигуна ТВЗ-117. *Весняні наукові читання* : матеріали XIX Міжнародної науково-практичної конференції, 18 квітня, 2018 р. Вінниця : Наука та практика, 2018. Ч. 6. С. 29–34.

529. Шмельов Ю. М., Владов С. І., Клімова Я. Р. Авіаційний двигун ТВЗ-117 як складний об'єкт спостереження. *Наука та освіта: Ключові питання сучасності* : матеріали Міжнародної науково-практичної конференції, 18 травня 2018 р., Чернігів. Одеса :

Друкарня «Друкарик», 2018. Т. 9. С. 7-10.

530. Владов С. І., Гвоздік С. Д., Дерев'янко І. Г. Передумови розробки експертної системи контролю і діагностики технічного стану авіаційного двигуна ТВЗ-117. *Авіація та космонавтика* : матеріали Х Всеукраїнської науково-практичної конференції, 16 квітня 2019 р. Кривий Ріг : КК НАУ, 2019. С. 57.

531. Шмельов Ю. М., Владов С. І., Дерев'янко І. Г. Основні вимоги до експертної системи контролю та діагностики технічного стану авіаційного двигуна ТВЗ-117. *Авіація та космонавтика* : матеріали Х Всеукраїнської науково-практичної конференції, 16 квітня 2019 р. Кривий Ріг : КК НАУ, 2019. С. 67.

532. Владов С. І., Плужник З. І. Щодо питання застосування експертних систем контролю та діагностики технічного стану авіаційного двигуна ТВЗ-117. *Авіація та космонавтика* : матеріали XI Всеукраїнської науково-практичної конференції, 22 квітня 2020 р., Кривий Ріг. С. 40.

533. Zhernakov S. V. Complex diagnostics and control of gas turbine engine parameters under uncertainty conditions based on the fuzzy expert system TILShell 3.0 +. *Information technologies*. 2000. No. 8. P. 36–43.

534. Zhernakov S. V. Parametric diagnostics of gas turbine engines based on a hybrid fuzzy expert system. *Aerospace engineering*. 2000. No. 5. P. 39–45.

535. Zhernakov S. V. Complex modeling of aircraft engine in the environment of hybrid expert systems. *Automation and modern technologies*. 2001. No. 5. P. 22–26.

536. Zhernakov S. V. Diagnostics and forecasting of gas-turbine engine condition by hybrid neuro-fuzzy expert systems. *Theory and control systems*. 1999. No. 5. P. 95–101.

537. Zhernakov S.V. Complex diagnostics and control of gas turbine engine oil system parameters using hybrid neuro-fuzzy expert systems. *Neuroinformatics*-2000. 2000. P. 115–123.

538. Zhernakov S.V. Complex diagnostics and control of gas turbine engine parameters under uncertainty conditions based on the TIL Shell 3.0 fuzzy expert system. *Information technologies*. 2000. no. 8. P. 36–43.

539. Shmelov Y., Vladov S., Klimova Y., Kirukhina M. Expert system for identification of the technical state of the aircraft engine TV3-117 in flight modes. *System Analysis & Intelligent Computing : IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)*, 08–12 October 2018. P. 77–82. doi: 10.1109/SAIC.2018.8516864.

419

540. Vladov S., Yakovliev R., Bulakh M., Vysotska V. Neural Network Approximation of Helicopter Turboshaft Engine Parameters for Improved Efficiency. *Energies*. 2024. Vol. 17, Issue 9, 2233. doi: 10.3390/en17092233.

541. Vladov S., Kovtun V., Sokurenko V., Muzychuk O., Vysotska V. Helicopter Turboshaft Engine Residual Life Determination by Neural Network Method. *Electronics*. 2024. Vol. 13, Issue 15, 2952. doi: 10.3390/electronics13152952.

542. Vladov S., Bulakh M., Czyżewski J., Lytvynov O., Vysotska V., Vasylenko V. Method for Helicopter Turboshaft Engines Controlling Energy Characteristics Through Regulating Free Turbine Rotor Speed and Fuel Consumption Based on Neural Networks. *Energies*. 2024. Vol. 17. Issue 22. 5755. doi: 10.3390/en17225755.

543. Vladov S., Bulakh M., Baranovskyi D., Kisiliuk E., Vysotska V., Romanov M., Czyżewski J. Application of the Integral Energy Criterion and Neural Network Model for Helicopter Turboshaft Engines' Vibration Characteristics Analysis. *Energies*. 2024. Vol. 17. Issue 22. 5776. doi: 10.3390/en17225776.

544. Vladov S., Bulakh M., Baranovskyi D., Sokurenko V., Muzychuk O., Vysotska V. Helicopter turboshaft engines combustion chamber monitoring neural network method. *Measurement*. 2025. Vol. 242. Part E. 116267. doi: 10.1016/j.measurement.2024.116267.

545. Vladov S., Bulakh M., Baranovskyi D., Vysotska V., Vasylenko V., Czyżewski J. Method of helicopter turboshaft engines protection during surge in starting mode. *Energies*. 2025. Vol. 18 (1). 168. doi: 10.3390/en18010168.

546. Vladov S., Shmelov Y., Yakovliev R., Petchenko M. Neural Network Method for Detecting and Diagnostics Helicopters Turboshaft Engines Surge at Flight Modes. *CEUR Workshop Proceedings*. 2023. Vol. 3392. P. 86–105. doi: 10.32782/cmis/3392-8.

547. Шмельов Ю. М., Владов С. І., Кришан О. Ф., Гвоздік С. Д. Моделювання перехідних процесів газодинамічного потоку в компресорі авіаційного двигуна ТВЗ-117. *Вісник Кременчуцького національного університету імені Михайла Остроградського*. 2018. Вип. 4/2018 (111). С. 36–42. doi: 10.30929/1995-0519.2018.4.36-42.

548. Vladov S., Shmelov Yu., Dieriabina I., Podhornykh N., Shmelova T. Development of an information system for decision support and automation of control of TV3-117 aircraft in critical situations based on knowledge engineering. *Proceedings of the National Aviation University*. 2020. No. 1 (82). P. 38–50. doi: 10.18372/2306-1472.82.14610.

додаток а.

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 1

Таблиця А.1 – Параметри ГТД вертольотів, що знаходяться в експлуатації [5]

-		1		
N⁰	Найменування	Одиниця ви-	Тип датчика	Примітка
3/П	параметру	міру	(приладу)	
	н 5 і	%	Д-2М,	Датчик – на коробці приводів. Вимі-
1	частота обертів	$n_{TK} = 100 \% =$	ІТЕ-2Т – олин	рювальний прилад – на лівій і правій
	турбокомпресора	19537 '/xB	на лва лвигуна	панелях прилалів
	Частота обертів	0%		
		$n_{\rm cm} = 15000$		
2	вільної турбіни	$n_{CB} = 15000$	Д-1М,	Дагчик – на вертолітному редукторі, ви-
2		7AB = 100 70	ITE-1T	мірювальний прилад – на лівій і правій
	несучого гвинта	$n_{HB} = 192.7 \text{XB}$		приладових дошках
		= 95,4 %	1.4	
	Температура газів перел	T • C	14 здвоєних	Датчики – на корпуст турбтни. вимпрю-
3	турбіною компресора	T_{Γ} , °C	термопар 1-102,	вальний прилад – на лівій приладової
			апаратура 21А-6	дошці
				Датчик – на корпусі компресора (пра-
Λ	Тиск масла на вході в дви-	$P_{\rm M}$ ${\rm KEC}/{\rm CM}^2$	ВД-8 або ІМД-	воруч), вимірювальний прилад – на
4	гун	I_M , KIC/CM	8, EMI-3PI	центральному пульті, табло – на лівій
				панелі приладів
			$2\pi m a 5 a \Pi 1$	Датчик – в трубопроводі відведення ма-
5	Температура масла на ви-	T_M , °C	21p a00 11-1,	сла в радіатор, прилад – на централь-
	ході з двигуна		EIVII-3P1	ному пульті
				Датчик – в трубопроволі вілвелення
6	Металева стружка в мас-	табло	CC-78	масла в раліатор, табло – на лівій па-
-	лосистемі			нелі прилалів
		-		Латчик – на перепускному клапані фі-
7	Стан паливного фільтра	табло	СП-0,4ЕТ	цьтра табио – на цівій панеці приладів
0	Difference Konstant and		MD 02 1 ID 500	датчик – на фланці корпусу компре-
0	вюрація корпусу двигуна	мм/с, табло	MID-05-1, ID-300	сора (крпплення двигуна), табло – на
				лівій панелі приладів
			ЕРД Датчики	Пульт контролю – на центральному
9	Робота електронного регу- лятора	табло	введення: $n_{m\kappa 1}$,	пульті кабіни, датчики ввелення – на
-		1	$n_{m\kappa 2}, n_{cm 1}, n_{cm 2},$	лвигунах і вертольоті
			$T_{\Gamma 1}, T_{\Gamma 2}, P_{ex}, T_{ex}$	doni finari i popiono ili
10	Режим роботи пригуча	табло	IP-117M	Один на два двигуна, на лівій панелі
10	тежим росоти двигуна	140,10	11 - 1 1 / WI	приладів

Таблиця А.2 – Цілі управління, ефективні критерії та шляхи формування діяльності моніторингу технічного стану ГТД вертольотів на різних рівнях [73]

Рівень управління Цілі управління		Критерії ефективності	Керуючі впливи
I. Виконавче	Підтримання необхідного	Точність (помилка) управ-	Управління двигуном
(автоматичне)	(оптимального) режиму	ління, критерій	(за допомогою виконавчих
управління	роботи двигуна	якості перехідних процесів	механізмів)
II. Контроль і діагностика	Забезпечення заданого рівня надійності (відмовостійкості системи)	Ймовірність безвідмовної ро- боти системи управління дви- гуна, середнє напрацювання на відмову	Команди на переключення резерву за- міни елементів
III. Управління процесом експлуатації	Підтримка необхідної ефективності функціонування двигуна	Коефіцієнт готовності двигуна, ймовірність виконання поставленої задачі, ресурс експлуатації двигуна	Терміни проведення ремон- тів (регламентних робіт, до- робок), вибір стратегії об- слуговування

Рівень управління експлуатацією	Математичні моделі		
«0» – об'єкт управління (елементи,	Динамічні моделі (лінеаризовані, багаторежимні, поелементні		
деталі, вузли, агрегати, підсистеми)	моделі)		
I – управління двигуном	Алгоритми управління (диференціальні, різницеві рівняння)		
II – контроль і діагностика двигуна	Логічні моделі, моделі прийняття рішення		
III – управління експлуатацією двигуна	Моделі ресурсу		

відно до рівнів управління [75]

Таблиця А.4 – Порівняння засобів штучного інтелекту [122]

Засоби	Переваги	Недоліки
Нейромережеві	1. Застосування в багатофакторних про-	1. Необхідність навчальної інформації пред-
	блеми з поганою формалізованістю зако-	ставницького набору прикладів «вхід-ви-
	номірностей.	хід».
	2. Високий ступінь розпаралелюваності	2. Повільність навчання.
	(швидкодія).	
	3. Здатність до навчання.	
Еволюційні	Високий ступінь розпаралелюваності	1. Апріорна невідомість ступеня ефективності в
(генетичні)	(швидкодія).	конкретному додатку.
		2. Швидшою є самоорганізація природної
		стихії, ніж інтелектуальний процес.
Продукційні	1. Можливість подання дескриптивно-	1. Складність виконання об'ємних баз правил,
	конструктивних знань і рефлексії.	недостатньо структуровані.
	2. Природність правил («якщо, то»).	2. Складність забезпечення коректності ви-
		сновків.
Об'єктно-оріє-	1. Структуровані.	1. Складність програмування (відхід від ідеа-
нтовані (сема-	2. Висока швидкодія механізмів насліду-	лів штучного інтелекту).
нтичні мережі,	вання властивостей, умовчання і тощо.	2. Недостатня виразність.
фрейми тощо)		
Логічні	1. Висока виразна сила.	1. Недостатня швидкодія, традиційні дода-
	2. Коректність.	тки – офлайн.
	3. Висока складність розв'язуваних	2. Традиційно погана сумісність з евристи-
	офлайн-задач.	ками і досвідом.
		3. Нерозв'язність великих логік.
		4. Недостатність однієї логіки.
Об'єктно-логі-	Об'єднання переваг об'єктно-орієнтова-	1. Недоліки логічних моделей.
чні	них і логічних.	2. Складність програмування.



Рисунок А.1 – Структурна схема уточненого етапу III в розробленій експертній сис-

темі (авторський доробок)



Рисунок А.2 – Удосконалена узагальнена функціональна модель IDEF0 моніторингу технічного стану і управління експлуатацією ГТД вертольотів у режимі льотної експлуатації [205–208] (авторський доробок)

додаток б.

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 2

Таблиця Б.1 – Основні види змін технічного стану ГТД вертольотів [226]

Вид	Чи викликані	Відповідні поправки
ЗМІНИ	· · · · · ·	
Детер-	Апріорно відомі зміни під впли-	у моделі передоачено коригування статичної характерис-
M1HO-	вом контрольованих чинників	тики для врахування зменшення ККД вузлів двигуна з пли-
BaH1	(умови польоту, напрацювання по	ном часу внаслідок експлуатації в польотних циклах. Відпо-
	ресурсу, величини відборів пові-	відні зміни параметрів (у відсотках) обчислюються за допо-
	тря тощо).	могою коефіцієнтів впливу ККД на параметри двигуна зале-
		жно від режиму роботи, з подальшим лінійним сумуванням.
Сто-	Зумовлені, наприклад, різним по-	Оскільки ГТД вертольоту – це стохастична система, що опи-
хасти-	чатковим тепловим станом рото-	сується простором станів великої розмірності із передісто-
чні	рів і статорів, зміни радіальних за-	рією, неможливо передбачити всі його поточні стани напере-
	зорів тощо), неконтрольованими	додні. Припускається, що більшість відхилень від базової ха-
	відборами повітря і потужності	рактеристики двигуна, враховуючи поправки, відобража-
	тощо.	ється відхиленнями коефіцієнта корисної дії компресора,
		турбіни компресора, витоками повітря вздовж зовнішнього
		контуру і величинами відборів повітря.
Випа-	Викликані неконтрольованою змі-	Для усунення випадкових помилок моделі в певному діапа-
дкові	ною конфігурації двигуна (пошко-	зоні передбачено, що інтегратор АПУ буде працювати на ста-
	дження лопаток турбокомпресора,	лому режимі, вирівнюючи модельні параметри до середніх
	забруднення проточної частини	значень, виміряних у справних керуючого і резервного кана-
	двигуна, несиметричне обтікання	лах, що забезпечить стійке виявлення відмов у каналі через
	повітрозабірника тощо).	модель та гладкий перехід до управління за модельними па-
		раметрами при відмові каналів.



Рисунок Б.1 – Структурно-логічна схема системи моніторингу технічного стану ГТД вертольотів у польотних режимах (авторський доробок [226])

Вузол двигуна	Параметр	Функціональна залежність	Визначення
Вхілний при-	повний тиск повітря за вхідним пристроєм, <i>P</i> [*] _{«х}	$P_{\rm ex_{np}}^* = f_1 \Big(G_{T_{np}} \Big)$	визначається аналітично
стрій	повна температура повітря за вхідним пристроєм, T_{ax}^*	$T^*_{\mathrm{ex}_{np}} = f_2\left(G_{T_{np}}\right)$	визначається аналітично
	частота обертання ротора турбокомпресора, <i>n_{TK}</i>	$n_{TK_{np}} = f_3\left(G_{T_{np}}\right)$	реєструється на борту вертольоту
Компресор	тиск повітря за компресором, P_{κ}^{*}	$\pmb{P}^*_{\!K_{np}}=f_4\!\left(G_{\!T_{np}}\right)$	визначається аналітично
	температура повітря за компресором, T_{K}^{*}	$T^*_{K_{np}} = f_5\left(G_{T_{np}}\right)$	визначається аналітично
Камера зго-	повний тиск газу за камерою згоряння, P_{T}^{*}	$\boldsymbol{P}_{\boldsymbol{\Gamma}_{np}}^{*} = f_{6}\left(\boldsymbol{G}_{\boldsymbol{T}_{np}}\right)$	визначається аналітично
ряння	температура газів перед турбіною компресора, T_r^*	$T^*_{\Gamma_{np}} = f_7\left(G_{T_{np}}\right)$	реєструється на борту вертольоту
Турбіна ком- пресора	повний тиск газу за турбіною компресора, P_{TK}^*	$P_{TK_{np}}^{*}=f_{8}\left(G_{T_{np}}\right)$	визначається аналітично
	температура газів за турбіною компресора, <i>т</i> _{тк}	$T^*_{TK_{np}} = f_9\left(G_{T_{np}}\right)$	визначається аналітично
	повний тиск газу за вільною турбіною, <i>р</i> [*]	$P_{CB_{np}}^* = f_{10}\left(G_{T_{np}}\right)$	визначається аналітично
Вільна турбіна	температура газу за вільною турбіною, T [*] _{CB}	$T^*_{CB_{np}} = f_{11}\Big(G_{T_{np}}\Big)$	визначається аналітично
	частота обертання ротора вільної турбіни, <i>п</i> _{СВ}	$n_{CB_{np}} = f_{12} \left(G_{T_{np}} \right)$	реєструється на борту вертольоту
Вихідний пристрій	повний тиск газу у вихідному пристрої, <i>P</i> [*] _c	$P_{C_{np}}^* = f_{13}\left(G_{T_{np}}\right)$	визначається аналітично
	температура газу у вихідному пристрої, T _c *	$T_{C_{np}}^{*} = f_{14}\left(G_{T_{np}}\right)$	визначається аналітично

Таблиця Б.2 – Термогазодинамічні параметри робочого процесу ГТД вертольотів (вхідні дані) (авторський доробок)

Таблиця Б.3 – Фрагмент даних випробувань авіаційного двигуна ТВЗ-117 (навчальна вибірка)* (авторський доробок)

Номер	$T^*_{arGamma}$	n _{TK}	n _{CB}
1	0,932	0,929	0,943
2	0,964	0,933	0,982
3	0,917	0,952	0,962
4	0,908	0,988	0,987
5	0,899	0,991	0,972
6	0,915	0,997	0,963
7	0,922	0,968	0,962
8	0,989	0,962	0,969
9	0,954	0,954	0,947
10	0,977	0,961	0,953
11	0,962	0,966	0,955
256	0,953	0,973	0,981

* В Керівництві з льотної експлуатації [234] вказуються характеристики атмосфери, в яких проводились випробування (зміни в цих параметрах вважаються знехтувано малими або несуттєвими для обраного контексту)

Номер	$P(T_{\Gamma}^{*})$	$P(n_{TK})$	$P(n_{CB})$
1	0,561	0,109	0,652
2	0,588	0,155	0,574
3	0,542	0,128	0,515
4	0,612	0,147	0,655
5	0,644	0,121	0,612
256	0,537	0,098	0,651

Таблиця Б.4 – Фрагмент матриці й
мовірностей χ^2

Таблиця Б.5 – Оцінка однорідності навчальної та тестової вибірок з використанням

критерію Фішера-Снедекора (авторський доробок)

Статистичні оцінки	Навчальна вибірка	Тестова вибірка (приймається 67 % навчальної вибірки)
Середнє	0,6214	0,6731
Дисперсія	0,04819	0,06168
Відношення більшої дисперсії до меншої	1,28	
$F_{\kappa p}$	3,44	

Таблиця Б.6 – Основні характеристики навчальної вибірки (відповідно до дослі-

Назва	Опис	Аналітичний вираз
Повнота нав- чальної вибі- рки	Відношення кількості навчальних екземплярів для кожного класу до загальної кількості ознак, викори- станих у наборі, і це відношення рухається в межах 35. Забезпеченість класів навчальними екземпля- рами є критерієм визначення повноти	$F_{HB} = \frac{N_F}{N}$, де N_F – число класів, що задо- вольняє вказаній умові, N – загальне число класів.
Рівномірність навчальної ви- бірки	Вказує на те, наскільки однаково розподілені навча- льні екземпляри серед різних класів.	$\Delta C = \sqrt{\frac{\sum_{i=1}^{k} ([C_i] - [C_k])^2}{k - 1}}, \text{ де } [C_i] - кіль-кість навчальних наборів для класу i.$
Нерівномір- ність навчаль- ної вибірки	Визначає ступінь нерівномірного розподілу навча- льних екземплярів між різними класами.	$R_{HB} = \sqrt{\frac{\sum_{i=1}^{k} \Delta C_i}{k}}$
Суперечність навчальної ви- бірки	Визначає кількість об'єктів, які мають спільні ознаки, але при цьому відносяться до різних класів.	$A_{HB} = \frac{N_A}{N}$, де N_A – кількість суперечливих наборів у вибірці, N – загальна кількість наборів.
Повторюва- ність навчаль- ної вибірки	Вказує на кількість ідентичних наборів, що входять до одного класу.	$P_{HB} = \frac{1}{n_c} \sum_{k=1}^{n_c} \frac{n_k^P}{n_k^C}, \text{ де } n_k^P \text{ і } n_k^C - відповідно кі-лькість наборів, що повторюються, і зага-льна кількість наборів для класу k, n_c - кіль-кість класів в навчальній вибірці.$

джень Бакулевського В.Л. [249-251])

Таблиця Б.7 – Помилки ресстрації термогазодинамічних параметрів ГТД вертольотів

Обсяг навчальної вибі-	СКВ, %			
рки (відповідно до	Помилка навчальної ви-	Помилка контрольної	Помилка тестової вибі-	
табл. 2.4)	бірки Е _{нв}	вибірки $ar{E}_{\it KB}$	рки Е _{тв}	
16	10,624	9,997	11,863	
32	8,357	8,074	10,526	
48	6,882	6,723	9,447	
64	5,314	5,011	8,211	
80	4,097	3,832	7,085	
96	2,932	2,428	5,431	
112	2,003	1,522	3,992	
128	1,238	0,933	2,985	
144	0,875	0,615	1,863	
160	0,611	0,488	0,927	
176	0,399	0,324	0,738	
192	0,215	0,196	0,516	
208	0,117	0,102	0,322	
224	0,086	0,063	0,107	
240	0,043	0,035	0,062	
256	0,025	0,025	0,026	

(авторський доробок)

Таблиця Б.8 – Основні висновки щодо доцільних обсягів навчальної і тестової вибірок

(авторський доробок на основі досліджень Бакулевського В.Л. [249–251])

Вибірка	Опис	Достатній обсяг
Навчальна	Використовується для тренування і навчання моделі, щоб вона мо-	256 (100 %)
	гла розв'язувати прикладні задачі моніторингу ГТД вертольотів на	
	основі наданої інформації.	
Контрольна	Слугує для контролю навчання нейронної мережі, вважається дос-	172 (67 % навчальної вибірки)
	татньою для її репрезентативності.	
Тестова	Використовується для перевірки адекватності побудованої моделі і	84 (33 % навчальної вибірки)
	контрольної вибірки.	

Таблиця Б.9 – Альтернативні метрики оцінювання масиву даних термогазодинамічних параметрів ГТД вертольотів (авторський доробок)

Тип	Метрика	Опис
1	2	3
Класифікація	F1-середнє гармонічне	Комбінує точність та повноту для невеличкої кількості даних
	Коефіцієнт Джині	Використовується для вимірювання ефективності моделей класифікації.
	AUC-ROC	Площа під кривою ROC вказує на якість бінарної класифікації.
Регресії	Середня абсолютна по-	Вимірює середню абсолютну величину відхилень між прогнозами та
	милка (МАЕ)	реальними значеннями.
	Коефіцієнт детермінації	Вказує на частку варіації відгуку, яка пояснюється моделлю (чим бли-
	(R-squared)	жче до 1, тим краще).
	Середня відсоткова по-	Вимірює середню відсоткову величину абсолютних відхилень.
	милка (МАРЕ)	
	Коефіцієнт кореляції	Вимірює ступінь лінійної залежності між реальними і прогнозованими
	Пірсона	значеннями.
Кластеризація	Силуетний коефіцієнт	Належить інтервалу [-1, 1], де високе значення вказує на добре визна-
		чені та взаємно відокремлені кластери.

1	2	3
Кластеризація	Відрегульований індекс Ренда	Порівнює пари об'єктів та визначає, чи вони потрапили в один і той же кластер в справжньому і припущеному розподілах. Значення ARI лежить в інтервалі [–1, 1], де 1 означає ідеальне співпадіння, 0 – випадкове розподілення, а –1 – повне неспівпадіння.
	Коефіцієнт Джині	Вимірює, наскільки добре кластери розділені за класами, враховуючи розміри кластерів та їхній вміст.
	Індекс Девіса-Болдіна	Використовує взаємні відстані між кластерами та їхнім розміром, щоб визначити якість кластеризації. Низьке значення вказує на кращу кла- стеризацію.
	Індекс Калінскі-Харабаса	Визначається як відношення між дисперсією всередині кластерів та між- кластерною дисперсією. Вище значення вказує на кращу кластеризацію.
Завдання з ран- жування	Середня точність (Mean Average Precision)	Визначає середню точність для ранжування об'єктів.
	Normalized Discounted Cumulative Gain	Використовується для оцінки якості ранжування.
	Коефіцієнт рангової ко- реляції Спірмена	Вимірює ступінь залежності між рангами двох змінних.
Висновок	Ці метрики можуть бути використані як альтернативи для оцінювання ефективності масиву даних термогазодинамічних параметрів ГТД вертольотів у відповідних прикладних задачах моніторингу ГТД вертольотів. Важливо вибирати метрику, яка найкраще відображає специфіку прикладних за-	

Таблиця Б.10 – Основні етапи модифікації масиву даних термогазодинамічних пара-

метрів ГТД вертольотів (у випадку неоднорідності навчальної і тестової вибірок)

(авторський доросок)			
Етап	Назва етапу	Опис етапу	
1	2	3	
Етап 1	Аналіз причин	Здійснюється аналіз причин, що можуть викликати відмінності між навчаль-	
	розбіжностей	ною і тестовою вибірками.	
Етап 2	Створення однорідних	Створюються підвибірки, які більш однорідні за певними критеріями (напри-	
	підвибірок	клад, незначна відмінність – у тисячних долях між значеннями термогазодина- мічних параметрів ГТД вертольотів), в межах навчальної та тестової вибірок.	
Етап 3	Повторна перевірка на	Здійснення повторної перевірки на однорідність навчальної і тестової вибірок	
	однорідність навчальної і	з урахуванням створених підвибірок за критеріями Фішера-Пірсона і Фішера-	
	тестової вибірок з ураху-	Снедекора та, за необхідністю альтернативними метриками оцінювання ма-	
	ванням створених підви-	сиву даних. Якщо за результатами перевірки навчальна і тестова вибірки не ϵ	
D 4	бірок	однорідними, то здійснюється перехід до етапу 4.	
Етап 4	Застосування технік	Збалансування вибірок – це практика коригування нерівномірності розподілу	
	збалансування вибірок	категории в навчальнии виогрці для підвищення об'єктивності та ефективності	
		моделеи машинного навчання. Основні застосування технік збалансування ви-	
		отрок включають:	
		Підзразковування – зменшення кількості екземплярів більшого класу, щоб	
		вирівняти розподіл;	
		падзразковування – додавання додаткових екземплярів меншого класу для	
		зоплышения иого представленості,	
		представленості.	
Етап 5	Повторна перевірка на од-	Здійснення повторної перевірки на однорідність навчальної і тестової вибірок	
	норідність навчальної і те-	з урахуванням створених підвибірок та застосування технік збалансування ви-	
	стової вибірок з урахуван-	бірок за критеріями Фішера-Пірсона і Фішера-Снедекора та, за необхідністю	
	ням створених підвибірок	альтернативними метриками оцінювання масиву даних. Якщо за результатами	
	та застосування технік	перевірки навчальна і тестова вибірки не є однорідними, то здійснюється пере-	
	збалансування вибірок	хід до етапу 6.	
Етап 6	Використання	Замість використання тестової вибірки здійснюється крос-валідація для отри-	
	крос-валідації	мання оільш стаоільних та об'єктивних оцінок термогазодинамічних парамет-	
		рів і і д вертольотів (крос-валідація – це процедура оцінювання і тестування	
		на декількох різних підвиоірках даних). жищо відповідно до значень основних	

(авторський доробок)

1	2	3
Етап 6	Використання	результуючих показників крос-валідації (наприклад, середнє значення поми-
	крос-валідації	лки, стандартне відхилення помилок, криві навчання та валідації, ROC-криві,
		матриці плутанини тощо) навчальна і тестова вибірки не є однорідними, то
		здійснюється перехід до етапу 7, в іншому випадку – завершення алгоритму.
Етап 7	Розширення даних	Збільшується обсяг даних термогазодинамічних параметрів ГТД вертольотів або
		розширюється вихідний датасет, щоб зробити вибірки більш презентативними.
Етап 8	Повторна перевірка на	Здійснення повторної перевірки на однорідність навчальної і тестової вибірок з
	однорідність навчальної і	урахуванням створених підвибірок, застосування технік збалансування вибірок і
	тестової вибірок з ураху-	розширення даних за критеріями Фішера-Пірсона і Фішера-Снедекора та, за необ-
	ванням створених підви-	хідності, альтернативними метриками оцінювання масиву даних. Якщо за резуль-
	бірок, застосування тех-	татами перевірки навчальна і тестова вибірки не є однорідними, то повторюється
	нік збалансування вибі-	виконання етапу 7 доти, поки навчальна і тестова вибірки не стануть однорідними.
	рок та розширення даних	

Таблиця Б.11 – Основні етапи модифікації масиву даних термогазодинамічних параметрів ГТД вертольотів (у випадку однорідності навчальної і тестової вибірок, але за

• • ••	•\			• 、
ВІДСУТНОСТІ ІХ	репрезентативності) (abi	горське	дослідження)

Номер етапу	Назва етапу	Опис етапу
Етап 1	Зміна алгоритму	Використання одного з наведених алгоритмів кластеризації:
	кластеризації	Алгоритм К-середніх – використовується для розділення даних на k класте-
		рів, де <i>k</i> – задана кількість.
		Ієрархічна кластеризація – здійснює кластеризацію шляхом побудови ієра-
		рхії кластерів, що може бути представлена у вигляді дерева (дендрограми).
		Щільнісний алгоритм для кластеризації просторових даних з присутністю
		шуму – кластеризує дані з врахуванням їх густини, здатний виявляти кластери
		будь-якої форми та розпізнавати шум.
		Кластеризація зсуву середнього – шукає максимум густини функції ймові-
		рності в просторі ознак для визначення кластерів.
		Агломеративно-ієрархічна кластеризація – також використовує ієрархічний
		підхід, але починає з окремих точок та об'єднує їх поступово.
		Моделі гаусової суміші – представляє кожен кластер як гаусіанський роз-
		поділ ймовірностей та призначає ймовірності кожній точці належати до різних
		кластерів.
		Алгоритм знаходження кластерів у просторових даних на основі щільності
		– аналізує дані на основі їх відстаней та густини, створюючи підхід для вияв-
		лення кластерів.
		Спектральна кластеризація – використовує спектральні методи для перет-
		ворення даних та визначення кластерів у новому просторі.
		Алгоритм поширення олизькості – визначає кластери на основі передачі
		повідомлень між точками даних.
		метод нечтткої кластеризації С-середніх – розпирення алгоритму К-серед-
		ніх, що дозволяє призначати слементи даних частково кількох кластерам.
		лящо за результатами кластеризаци з використанням поданих алгоритмив
		кластеризаци павчальна и тестова виогрки не с репрезентативними, то здисню-
Етап 2	Збільшення обсягу	Збільнихсться обсяг наних термогазолинамінних параметрів ГТЛ вертольотів або
	ланих	золышусться обсяг даних термогазодинамичних параметрів і 17 вертольотів аоб
Етап 3	Провелення по-	Провеления повторної кластеризації з використаниям поланих алгоритмів кла-
	вторної кластери-	стеризації навиальна і тестова вибірки не є репрезентативними то повторю-
	зації	сться виконання стапу 2 по тих піл локи навчальна і тестова вибірки не стануть
	Juli	репрезентативними.



Рисунок Б.2 – Схема утворення: а – діапазону найвигідніших параметрів для однопараметричних задач; б – області раціональних значень параметрів для двопараметричних задач [260, 261]



Рисунок Б.3 – Алгоритм методу багатокритеріальної оптимізації з використанням евристичних підходів – еволюційних і генетичних алгоритмів [262, 263]

Таблиця Б.13 – Основні етапи методу багатокритеріальної оптимізації [262, 263]

Етап	Опис
1	Генерується початкова навчальна вибірка x_s невеликого обсягу $s \in X$ на основі одного з методів планування експерименту, наприклад [262, 263]. Обчислюються вектори значень цільових функцій $f(x_s)$ і обмежень $g(x_s)$ і $h(x_s)$ у всіх отриманих точках.
2	На основі навчальної вибірки x_s і відповідних значень $f(x_s)$, $g(x_s)$ і $h(x_s)$ будуються наближені моделі $f(x)$,
	g(x) і $h(x)$ всіх досліджуваних залежностей.
3	На основі отриманих наближених моделей $f(x)$, $g(x)$ і $h(x)$ за допомогою алгоритму NSGA-II знаходиться
	вектор x _{опт} , який визначає Парето-оптимальну множину рішень задачі багатокритеріальної оптимізації.
4	У точках отриманої таким чином множини рішень x_{onm} обчислюються точні значення функцій $f(x_{onm})$, $g(x_{onm})$ і
	$h(x_{onm})$. Якщо умова закінчення обчислень не виконується, то все значення, отримані на точних моделях, до-
	даються в навчальну вибірку: $x_s = x_s + x_{onm}$, $f(x_s) = f(x_s) + f(x_{onm})$, $g(x_s) = g(x_s) + g(x_{onm})$, $h(x_s) = h(x_s) + h(x_{onm})$.
5	Здійснюється повернення до етапу 2, на якому знову будуються наближені моделі.
6	Визначаються умови закінчення обчислень:
	– сумарна відносна похибка е побудованих моделей досягає заданого мінімуму:
	$e = \frac{1}{k \cdot \left(n + p + q\right)} \cdot \sum_{j=1}^{n+p+q} \sqrt{\sum_{i=1}^{k} \left(\frac{M_{ij}\left(x\right) - F_{ij}\left(x\right)}{F_{ij}\left(x\right)}\right)^{2}} \le \varepsilon,$
	де k – кількість рішень в знайденому Парето-оптимальній множині; $M_{ij}(x)$ – значення однієї з функцій $f(x)$, $g(x)$ або $h(x)$, знайдене на основі її наближеною моделі; $F_{ij}(x)$ – значення тієї ж функції, знайдене на основі точної моделі, і ε – досить мале позитивне число. Виконання даної умови означає, що якість побудованих наближених моделей таке, що дозволяє їх використовувати замість точних;
	– знаходження одного або декількох векторів $f(x)$, що задовольняють заздалегідь визначеним вимогам $f(x) \le f_{gum}$ при дотриманні обмежень $g(x) > 0$ і $h(x) = 0$, де f_{gum} – задані експертом значення цільових функцій, достатні для забезпечення необхідних характеристик експлуатованого виробу;
	– перевищення допустимої кількості точних обчислень моделей;
	– перевищення допустимого часу обчислень.

Таблиця Б.14 – Недоліки еволюційного алгоритму навчання РБФ-мережі

Недолік	Опис
Початкова ініціаліза-	Випадкова ініціалізація параметрів з інтервалу (1,0; 1,0) може призводити до того, що деякі
ція параметрів	параметри будуть занадто близькими до меж цього інтервалу, що може обмежити маневре-
	ність алгоритму.
Функція пристосова-	Аналітичний вираз для обчислення пристосованості враховує тільки відхилення фактичного
ності	виходу мережі від очікуваного. Це може бути недостатньою мірою пристосованості для на-
	вчання з метою гармонійного функціонування мережі в різних умовах.
Механізм відбору для	Мутація особин базується на їх ранзі, але такий підхід може привести до того, що менш
мутації	пристосовані особини можуть бути обрані для мутації, у той час як більш пристосовані мо-
	жуть залишитися незмінними.
Метод мутації	Гаусівська мутація може призводити до того, що зміни в параметрах функції активації ста-
	ються надто великими або надто малими, що може ускладнити збіжність алгоритму.
«Жадібний» алгоритм	Використання «жадібного» алгоритму, де спроба видалення нейрона завжди проводиться
	перед спробою його додати, може призводити до пропускання оптимальних рішень, оскі-
	льки нейрони можуть бути видалені, навіть якщо є можливість поліпшення.
Елітизм	Використання принципу елітизму може призвести до недостатнього різноманіття в популя-
	ції та недостатньої розвиненості нових рішень.
Неуспішні мутації	У випадку неуспішної мутації особина копіюється без змін. Це може призвести до того, що
	погані рішення залишаються в популяції, не отримуючи достатнього шансу для поліпшення.

Таблиця Б.15 – Запропонований модифікований еволюційний алгоритм навчання

поліморфної РБФ-мережі (авторський доробок)

Номер	Назва етапу	Опис етапу
1	Покращена	Замість випадкової ініціалізації з інтервалу (1,0; 1,0), використовувати більш розумні методи
	ініціалізація	ініціалізації вагових коефіцієнтів, такі як методи, що враховують
		структуру задачі або використовують попередні знання.
		1. Не ініціалізація – ініціалізації спроектований спеціально для нейронних мереж і забезпе-
		чує більш ефективний старт навчання, особливо для функцій активації типу ReLU (Rectified
		Linear Unit). Ваги ініціалізуються відповідно до $w = \{\text{random}\} \cdot \sqrt{\frac{2}{N}}$, де N – розмір поперед-
		u oro uany (random) prazyc na ze no paropi koedinicuzu gri novnovavozi pyje r ininiazi
		пього шару, {тапионт; вказус на те, що ваговт косфіцієнти, які помножують вхід л, ініціал-
		2 Xavier/Glorot ініціалізація – збереження лисперсії вхолу і вихолу шару при множенні на
		вагові коефіцієнти. Ваги ініціалізуються відповідно до $w = \{\text{random}\} \cdot \sqrt{\frac{2}{N+M}}$, де M – роз-
		мір поточного шару.
		Використання попередніх знань – якщо є попередні знання про оптимальні вагові коефіціє-
		нти для схожих завдань чи даних, то можна використовувати це знання для ініціалізації ваг.
		Наприклад, якщи у вас є попередня навчена модель на схожих даних, то ваги можна ініціа-
		лізувати з цієї моделі.
2	Покраще-	Замість вибору особини для мутації на основі рангу, використовувати більш ефективні стра-
	ний відбір	тегії відбору, наприклад, турнірний відбір, де обираються кілька випадкових особин для по-
	для мутації	рівняння.
3	Розширена	Додаються додаткові критерії до функції пристосованості, щоб враховувати не тільки від-
	функція	хилення вихідних значень, але и інші характеристики неиронної мережі, такі як стійкість,
	пристосова-	швидкість навчання тощо. Оочислення пристосованості всіх осооин популяції здійснюється
	ності	як [261, 262] $e_m = \frac{1}{T} \cdot \sqrt{\sum_{i=1}^{T} (y(t) - z(t))^2}$, де T – кількість зразків у навчальній вибірці; $Y(t)$ і
		Z(t) – очікуване і фактичне значення на вихолі мережі. Механізм вілбору особини ґрунту-
		ється на її ранзі. Нехай К особин відсортовані за спаданням функції <i>е</i> ,, і їм присвоєні номери
		0, 1,, (K-1). Тоді особина з номером $(K-i)$ може бути відібрана для мутації з імовірністю
		$\left(\frac{K}{K}\right)^{-1}$
		$p(K-j) = j \cdot \left(\sum_{k=1}^{k} k\right)$. Перед початком мутації випадково вибирається ціле число <i>n</i> з інте-
		рвалу (1, <i>L</i>), визначальне номер нейрона, до якого буде застосовуватися операція мутації.
4	Удоскона-	Використовуються більш складні методи мутації, що дозволяють більше гнучкості у зміні
	лені методи	параметрів, наприклад, мутацію за допомогою еволюціиного стратегіі, що передоачає вико-
	мутаци	нання таких кроків:
		1. Виогр оатъкив – зазвичаи, виогр оатъкив може проводитися, наприклад, з використанням
		турнірного відоору, де кілька агентів випадковим чином обираються для порівняння, і з них
		2 Генерація мутацій — для коучого обраного батька строрюються його мутанти. Прийма
		2. Генерація мутація — для кожного обраного батька створюються ного мутанти. прийма- сться r_{-} вектор параметрів батька з $N(0, \sigma^2)$ – випалковий вектор з нормальним розполідом
		з середнім значенням 0 і лисперсією σ^2 Толі мутація виглялає як: $r_{\text{max}} = r + \sigma \cdot N(0, 1)$
		3. Застосування мутацій — до кожного параметра застосовуються випалкові зміни. Напри-
		клад. можна використати гаусівську мутацію $x_{\mu\rho\sigma} = x + \sigma \cdot N(0, 1)$.
		4. Оцінка пристосованості мутантів – для кожного нового агента обчислюється його прис-
		тосованість, наприклад, використовуючи фітнес-функцію <i>fitness</i> = $f(x_{\mu o \beta})$.
		5. Відбір нового покоління – Вибираються ті агенти, які мають найвищі значення пристосо-
		ваності. Це може бути вибір топових агентів з відсортованого списку за їх фітнес-функцією.
		6. Повторення – ці кроки повторюються для кількох поколінь, з метою покращення генети-
		чних характеристик агентів.
5	Динамічні	Впроваджуються динамічні стратегії для адаптації ймовірності мутації та інших параметрів
	стратегії	в процесі еволюції, що може покращити збіжність алгоритму.


Рисунок Б.4 – Блок-схема запропонованого еволюційно-градієнтного алгоритму навчання РБФ-мереж (авторський доробок з урахуванням [267])

Таблиця Б.16 – Експериментальна вибірка та результати навчання поліморфної

Но- мер	Gas temperature in front of the compressor turbine, $T_G(x_{HAB^{*}})$	Ступінь підвищення по- вного тиску в компре- copi (у _{навч})	Ступінь підвищення повного ти- ску в компресорі (<i>y_{RBF}</i>), обчисле- ний за допомогою поліморфної RBF-мережі	$\Delta y = y_{HaBY} - y_{RBF} $
1	0,932	0,860394	0,857214	0,00318 (0,32 %)
2	0,964	0,830571	0,833681	0,00311 (0,31 %)
3	0,917	0,895151	0,892011	0,00314 (0,31 %)
4	0,908	0,841192	0,844352	0,00316 (0,32 %)
32	0,924	0,881076	0,877886	0,00319 (0,32 %)

РБФ-мережі (авторський доробок)

Таблиця Б.17 – Результати порівняльного аналізу навчання РБФ-мереж різної архі-

тектури (авторський доробок)

Характеристика	Класична	З окремим прихованим шаром для кожної незалежної змінної і різною кількістю ра- ліально-базових функцій у кожній групі	РБФ-персептрон	Поліморфна
Похибка навчання, %	6,64	4,87	0,45	0,38
Похибка тестування, %	7,38	6,11	7,43	0,73
Час навчання, мс	1,0	1,0	1,0	1,0

Таблиця Б.18 – Процес пошуку Парето-оптимальної множини рішень (авторський

доробок [260, 268])

Ітерації	Перша іте-	Друга іте-	Третя іте-	Результат	
	рація	рація	рація		
Кількість рівнянь у навчальній вибірці		50	140	230	320
Кількість рівнянь, що задовольняють обмеження	М	10	45	110	200
Розмір оптимального набору Парето		8	15	24	40
Модель C_e	N_h	37	39	35	-
	e_m	0,00009	0,00011	0,00007	_
Модель σ_p	N_h	37	40	38	-
	e_m	0,02542	0,01768	0,34325	-
Модель h_z	N_h	40	35	36	-
	e_m	0,00005	0,00004	0,00004	—
Загальна відносна похибка моделей	е	0,0065	0,0054	0,0037	_

Таблиця Б.19 – Варіанти параметрів робочого процесу авіаційного ГТД ТВЗ-117 в

режимі льотної експлуатації вертольоту (авторський доробок [260, 268])

C_e кг/ $\mathrm{H}\cdot$ год	σ_p кг/мм 2	<i>h</i> _z , мм	π_K	T_{Γ}, \mathbf{K}	λ_B	λ_K	λ_{Γ}	λ_T	λ_{CT}
0,085	12,9	15	13,0	1310	0,685	0,250	0,25	0,640	0,682
0,089	17,4	15	10,9	1302	0,693	0,278	0,25	0,462	0,577
0,092	17,7	15	10,2	1308	0,693	0,299	0,25	0,468	0,581
0,096	17,5	15	8,7	1308	0,693	0,343	0,25	0,507	0,586
0,101	16,9	15	8,6	1354	0,693	0,343	0,25	0,539	0,593
0,109	17,0	15	8,7	1466	0,693	0,343	0,25	0,525	0,599
0,115	17,1	15	8,6	1545	0,693	0,343	0,25	0,508	0,575
0,124	17,7	15	8,2	1638	0,693	0,343	0,25	0,485	0,564
0,130	17,2	16	8,0	1699	0,693	0,343	0,25	0,505	0,542
0,137	21,5	19	6,9	1684	0,693	0,343	0,25	0,443	0,529
0,146	24,2	23	5,3	1686	0,693	0,343	0,25	0,469	0,511

Таблиця Б.20 – Результати обчислення середніх значень метрики *IGD* після 32 незалежного запуску наборів тестів TEST_1 – TEST_8 (автрський доробок)

Номер	Тестовий набір	Середнє значення метрики IGD					
		Розроблений алгоритм	SMEA	MDESL			
1	TEST_1	1,168	0,876	2,987			
2	TEST_2	1,225	0,924	3,118			
3	TEST_3	1,217	0,899	3,064			
4	TEST_4	1,435	1,022	3,522			
5	TEST_5	1,601	1,113	3,759			
6	TEST_6	1,484	1,095	3,602			
7	TEST_7	1,795	1,192	4,017			
8	TEST 8	1,652	1,156	3,838			

Таблиця Б.21 – Результати обчислення середніх значень метрики *HV* після 32 незалежного запуску наборів тестів TEST_1 – TEST_8 (автрський доробок)

Номер	Тестовий набір	Середнє значення метрики HV					
		Розроблений алгоритм	SMEA	MDESL			
1	TEST_1	5,622	3,832	1,922			
2	TEST_2	5,537	3,693	1,805			
3	TEST_3	5,558	3,713	1,818			
4	TEST_4	5,386	3,407	1,654			
5	TEST_5	5,117	3,235	1,588			
6	TEST_6	5,266	3,303	1,621			
7	TEST_7	5,026	3,092	1,377			
8	TEST_8	5,074	3,101	1,462			

Таблиця Б.22 – Результати навчання нейронної мережі персептрон

Алгоритм навчання	СКВ	Кількість епох навчання	Кількість кроків навчання
Back propagation	2,73024	1220	53
Conjugate gradient	4,00261	1360	61
Quick propagation	4,29965	1380	68
Quasi-Newton	4,31782	1420	72
Lewenberg-Marquardt	4,32009	1440	75

Таблиця Б.23 – Результати визначення середніх похибок та відхилення параметрів

Пополкота	Значення					
Параметр	C_EFF	Pi_C	N_TC	A_TC		
Відхилення <i>M</i> ₂ , %	2,162	2,339	2,246	2,401		
Відхилення М ₁ , %	0,923	0,766	0,814	0,808		
M_2 / M_1	2,342	3,053	2,759	2,972		



Рисунок Б.5 – Результуючі графіки розрахованих апроксимуючих Парето-фронтом із середніми значеннями метрики IGD у 32 незалежному прогоні наборів тестів TEST_1 – TEST_8 для запропонованого алгоритму та алгоритму SMEA





Рисунок Б.6 – Результуючі графіки демонструють еволюцію середніх значень метрики IGD та відповідних стандартних відхилень у наборах тестів TEST_1 – TEST_8.

Таблиця Б.24 – Чинники переходу від тришарового персептрона до гібридної мережі NARX з радіально-базисним шаром для ідентифікації термогазодинамічних парамет-

рів ГТД вертольотів

Чинник	Опис
Комплексність системи	ГТД вертольотів є складними динамічними системами з нелінійною поведінкою та
	взаємозв'язками між різними параметрами. Тришарові персептрони можуть бути не-
	достатньо гнучкими для моделювання такої складної системи.
Урахування динаміки	Гібридна мережа NARX надає можливість урахування динамічних властивостей сис-
	теми за часовими залежностями між входами та виходами. Це особливо важливо для
	передбачення параметрів робочого процесу двигуна, які можуть бути змінені в часі.
Обробка невизначеності	ГТД вертольотів піддаються різним зовнішнім впливам та змінам умов експлуатації.
	Гібридні мережі NARX з радіально-базисним шаром можуть краще адаптуватися до
	невизначеності даних і забезпечувати більш точне передбачення в різних умовах.
Використання контекстуальних	Гібридні мережі NARX з радіально-базисним шаром дозволяють включити у модель
даних	як поточні значення параметрів, а й історичні дані. Це може бути корисним для ана-
	лізу попередніх станів системи та виявлення патернів змін параметрів.

Таблиця Б.25 – Наукове обґрунтування особливості переходу від тришарового персе-

птрона до гібридної мережі NARX з радіально-базисним шаром

Назва	Опис				
Положення № 1. Інноваці	йне моделювання комплексних залежностей через поєднання нелінійних авторегресійних				
	моделей та радіально-базисних функцій				
Комбінування нелінійних	Нелінійні авторегресійні моделі NARX здатні вловлювати складні динамічні залежності				
авторегресійних моделей	між вхідними та вихідними змінними.				
та радіально-базисних фу-	Радіально-базисні функції вносять гнучкість у модель, що дозволяє адаптуватися до різних				
нкцій	форм даних, що особливо важливо при моделюванні термогазодинамічних параметрів з				
	нелінійною природою.				
Ефективне моделювання	Параметри робочого процесу ГТД вертольотів можуть демонструвати складні, нелінійні				
складних залежностей	залежності, які найкраще описуються гібридною мережею NARX з радіально-базисним				
	шаром. Це дозволяє більш точно прогнозувати зміни параметрів за різних умов експлуата-				
ції вертольоту.					
Положення № 2. Доцільн	ність розв'язання задачі ідентифікації ГТД вертольотів з використанням гібридної мережі				
NARX з радіально-баз	зисним шаром та порівняння її результатів з використанням тришарового персептрону				
Точність моделювання	Порівняння коефіцієнтів точності, наприклад, СКВ, на навчальній та тестовій вибірках.				
Узагальнення нових да-	Оцінюється, наскільки добре модель узагальнює свої знання нові дані, не використані під				
них	час навчання.				
Стабільність та стійкість	Аналіз стійкості моделей у різних умовах, включаючи зміни зовнішніх параметрів.				
Положення № 3. Одночасн	е використання результатів моделювання за допомогою тришарового персептрону та гібри-				
Дн	юї мережі NARX з радіально-базисним шаром на борту вертольоту				
Використання тришаро-	Використовується для швидкого оцінювання поточних термогазодинамічних параметрів				
вого персептрону	ГТД вертольотів та забезпечення реакції на умови, що швидко змінюються.				
Використання гібридної	Використовується для більш глибокого аналізу динамічних змін у параметрах, враховуючи				
мережі NARX з радіа-	часові залежності та передбачаючи майбутні значення.				
льно-базисним шаром					
Висновок					
Комбіноване використання тришарового персептрону та гібридної мережі NARX з радіально-базисним шаром дозволяє					
об'єднати переваги обох мо	оделей, забезпечуючи більш точне та гнучку ідентифікацію термогазодинамічних параметрів				
ГТД вертольоту у реальном	ГТД вертольоту у реальному часі.				



Рисунок Б.7 – Схема нейромережевої моделі ГТД вертольотів (авторський доробок [310])



Рисунок Б.8 – Розроблений програмний інтерфейс користувача (авторський доробок [310])

439

Таблиця Б.26 – Результати навчання нейронної мережі (авторський доробок [310] на

II	Централы	на похідна	Метод Б	ройдена	Аналітичне обчислення			
номер наоору даних	<i>t</i> , секунд	\mathbf{u}_{k+1}	<i>t</i> , секунд	\mathbf{u}_{k+1}	<i>t</i> , секунд	\mathbf{u}_{k+1}		
1 потік, 7 входів, 20 нейрої	нів у нелінійном	иу шарі, 5 нейр	онів у лінійном	у шарі і 1 нейр	он у вихідному	шарі, N = 256		
(загальний обсяг навчальної вибірки)								
Набір даних 1	121,382	0,988	11,785	0,985	58,639	0,983		
Набір даних 2	121,371	0,976	11,559	0,973	58,072	0,971		
Набір даних 3	120,989	0,995	10,082	0,992	56,537	0,990		
Набір даних 4	121,295	0,969	11,776	0,966	57,759	0,964		
6 потоків, 7 входів, 20 н	ейронів у нелін	ійному шарі, 5	нейронів у ліні	йному шарі і 1	нейрон у вихід	ному шарі,		
	N = 25	6 (загальний об	сяг навчальної	вибірки)				
Набір даних 1	40,193	0,988	3,902	0,985	19,417	0,983		
Набір даних 2	40,323	0,976	3,840	0,973	19,250	0,971		
Набір даних 3	39,669	0,995	3,306	0,992	18,281	0,990		
Набір даних 4	40,298	0,969	3,912	0,966	19,190	0,964		
12 потоків, 7 входів, 20 н	12 потоків, 7 входів, 20 нейронів у нелінійному шарі, 5 нейронів у лінійному шарі і 1 нейрон у вихідному шарі,							
	N = 256 (загальний обсяг навчальної вибірки)							
Набір даних 1	20,298	0,988	1,971	0,985	9,806	0,983		
Набір даних 2	20,262	0,976	1,930	0,973	9,695	0,971		
Набір даних 3	20,098	0,995	1,675	0,992	9,262	0,990		
Набір даних 4	20,216	0,969	1,963	0,966	9,627	0,964		

основі [311])

Таблиця Б.27 – Порівняльний аналіз точності нейромережевих і класичних методів ідентифікації параметрів робочого процесу ГТД вертольотів (авторський доробок [310])

	Абсолютна похибка, %						
Модель	ККД компре- сора	Ступінь підви- щення загального тиску в компресорі	Потужність на валу турбіни компресора	Робота на валу турбіни комп- ресора	Витрата па- лива в камері згоряння		
Класична	1,96	1,95	1,96	1,95	1,95		
Нейромережева:							
тришаровий персептрон	0,64	0,66	0,64	0,68	0,65		
гібридна мережа NARX	0,41	0,42	0,41	0,43	0,41		
гібридна мережа NARX з							
модифікованим алгоритмом							
Левенберга-Марквардта	0,26	0,27	0,26	0,28	0,26		

Таблиця Б.28 – Порівняльний аналіз точності нейромережевих і класичних методів ідентифікації параметрів робочого процесу ГТД вертольотів в умовах адитивного

шуму (авторський доробок [310])

	Абсолютна похибка, %						
Модель	ККД компре- сора	Ступінь підви- щення загального тиску в компресорі	Потужність на валу турбіни компресора	Робота на валу турбіни комп- ресора	Витрата па- лива в камері згоряння		
Класична	3,07	3,11	3,15	3,14	3,15		
Нейромережева:							
тришаровий персептрон	1,12	1,13	1,09	1,17	1,11		
гібридна мережа NARX	0,72	0,74	0,72	0,73	0,71		
гібридна мережа NARX з							
модифікованим алгоритмом							
Левенберга-Марквардта	0,42	0,43	0,41	0,42	0,40		

Таблиця Б.29 – Фрагмент навчальної вибірки для ідентифікації багаторежимної моделі ГТД вертольотів (на прикладі авіаційного двигуна ТВ3-117) (авторський доробок [310])

Вхідний пара-	Вихідні параметри ідентифікації взято шість параметрів, що обчислені за універсальною математичною							
метр	моделлю ГТД вертольотів							
$G_{T_{np}}$	$n_{TK_{np}}$	$G_{\!\scriptscriptstyle B_{np}}$	$P^*_{K_{np}}$	$T^*_{K_{np}}$	$T^*_{\Gamma_{np}}$	$P^*_{TK_{np}}$		
0,193	0,538	0,418	0,328	0,445	0,518	0,153		
0,131	0,348	0,252	0,205	0,254	0,476	0,056		
0,203	0,548	0,427	0,336	0,451	0,524	0,161		
0,480	0,798	0,757	0,643	0,809	0,758	0,500		
0,150	0,408	0,304	0,243	0,299	0,468	0,085		
0,353	0,712	0,619	0,505	0,668	0,671	0,336		
0,245	0,587	0,469	0,371	0,480	0,551	0,195		
0,733	0,904	0,928	0,851	0,930	0,859	0,774		
1,015	1,015	1,036	1,043	1,055	1,019	1,056		
0,141	0,379	0,279	0,225	0,275	0,470	0,070		
0,153	0,415	0,311	0,248	0,305	0,469	0,089		
0,562	0,837	0,825	0,719	0,861	0,793	0,595		
0,375	0,731	0,647	0,532	0,700	0,692	0,366		
0,133	0,356	0,259	0,210	0,259	0,474	0,059		
0,173	0,465	0,355	0,281	0,350	0,479	0,114		
0,134	0,358	0,260	0,211	0,261	0,474	0,060		



441



Рисунок Б.9 – Результати вимірювання метричної відстані у процесі кластеризації (авторський доробок [295])

Таблиця Б.30 – Аналіз похибки нейромережевих і класичного методів ідентифікації

Методи ідентифікації		Абсолютна похибка, %					
	$n_{TK_{np}}$	$G_{\!\scriptscriptstyle B_{\!\scriptscriptstyle np}}$	$P^*_{\!\scriptscriptstyle K_{np}}$	$T^*_{K_{np}}$	$T^*_{\Gamma_{np}}$	$P_{TK_{np}}^{*}$	
МНК	0,99	0,89	0,82	0,89	0,89	0,89	
Персептрон	0,38	0,63	0,58	0,63	0,62	0,55	
Традиційна РБФ-мережа	0,59	0,74	0,68	0,74	0,74	0,74	
Поліморфна РБФ-мережа	0,23	0,44	0,38	0,47	0,45	0,37	

Таблиця Б.31 – Аналіз похибки нейромережевих і класичного методів ідентифікації

в умовах дії шуму

Методи ідентифікації		Абсолютна похибка, %					
	$n_{TK_{np}}$	$G_{\!B_{\!np}}$	$P^*_{K_{np}}$	$T^*_{K_{np}}$	$T^*_{\Gamma_{np}}$	$P^*_{TK_{np}}$	
МНК	2,03	1,75	1,95	2,03	2,14	1,93	
Персептрон	0,65	0,72	0,78	0,73	0,83	0,84	
Традиційна РБФ-мережа	0,78	0,85	0,84	0,84	0,85	0,84	
Поліморфна РБФ-мережа	0,49	0,58	0,63	0,60	0,65	0,65	

Таблиця Б.32 – Порівняльний аналіз точності нейромережевих і класичного методів ідентифікації зворотної багаторежимної моделі авіаційного двигуна ТВЗ-117 (визна-

	••					•	`
чення	привеленоі	витрати	палива	3a H	епрямими	вимірю	ваннями)
1.1111/1	mpinderdenier	Dirparin	mainda			Diminpio	Danninn)

Метод ідентифікації	Середньо-	Абсолютна	Середньо-	Абсолютна
	квадратична	похибка (без	квадратична	похибка (з
	похибка (без	шуму), %	похибка (з	шумом), %
	шуму)		шумом)	
МНК	0,057	0,393	1,393	1,673
Персептрон	0,018	0,183	0,038	0,710
Традиційна РБФ-мережа	0,046	0,246	0,057	0,794
Поліморфна РБФ-мережа	0,007	0,151	0,014	0,555

Таблиця Б.33 – Бажані значення виходів нейромережевого класифікатора [314]

Destriction in a structure	Сигнали на виході нейронної мережі			
Розпізнані режими	F_1	F_2		
Сталий	0	0		
Розгін	1	0		
Дроселювання	0	1		



Рисунок Б.10 – Залежність похибки навчання нейронної мережі від ширини часового вікна (авторський доробок [320])

Таблиця Б.33 – Помилки класифікації режимів для різних архітектур нейронних ме-

	Помилка класифікації на	Помилка класифікації на	
Архпектура неиронної мережі	виході 1 (ε ₁)	виході 2 (ε ₂)	
Пропонований нейромережевий класифікатор	0,1632	0,0601	
Гібридна нейронна мережа на основі мереж АРТ-1 і ДАП	0,1812	0,0733	
Персептрон	0,4131	0,1322	
Елмана	0,3611	0,1681	
Хеммінга	0,4133	0,2988	
Мережа радіально-базисних функцій (РБФ)	0,4772	0,7891	
Хопфілда	0,4258	0,2654	
Самоорганізована карта Кохонена	0,4683	0,2913	
Мережа адаптивного резонансу	0,5117	0,8409	
Мережі векторного квантування сигналів	0,5532	0,9176	

реж, % (авторський доробок [320])

Таблиця Б.34 – Коефіцієнти якості класифікації режимів для різних архітектур ней-

ронних мереж, % (авторський доробок [320])

Архітектура нейронної мережі	Вихід 1 (<i>ε</i> ₁)	Вихід 2 (<i>ε</i> ₂)
Пропонований нейромережевий класифікатор	99,99	99,99
Гібридна нейронна мережа на основі мереж АРТ-1 і ДАП	99,99	99,99
Персептрон	99,96	99,99
Елмана	99,96	99,98
Хеммінга	99,95	99,97
Мережа радіально-базисних функцій (РБФ)	9995	99,92
Хопфілда	99,95	99,94
Самоорганізована карта Кохонена	99,96	99,92
Мережа адаптивного резонансу	99,94	99,87
Мережі векторного квантування сигналів	99,95	99,96

ДОДАТОК В.

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ З



Рисунок В.1 – Модифікована нейронна мережа Елмана з динамічною стековою пам'яттю як динамічна модель ГТД вертольотів (у цьому дослідженні параметр *n_{CB}* не враховується) (авторський доробок [344])



Рисунок В.2 – Реалізація шару з пам'яттю для модифікованої нейронної мережі Елмана з динамічною стековою пам'яттю [344]

Таблиця В.1 – Результати оцінки точності ідентифікації (авторський доробок [344])

Вихід нейронної мережі	Абсолютна похибка, %
Температура газів перед турбіною компресора	0,19
Частота обертання ротора турбокомпресора	0,25
Частота обертання ротора вільної турбіни	0,24

Таблиця В.2 – Порівняльний аналіз нейромережевого і класичного методів ідентифікації динамічної багаторежимної моделі ГТД вертольоту (на прикладі двигуна ТВЗ-117) в умовах білого шуму (авторський доробок [344])

Методи ідентифікації динамічної багаторежим-	Абсолютна		Абсолютна		Абсолютна	
ної моделі ГТД вертольоту	похибка, %		похибка, %		похиб	бка, %
	$(\sigma_T = 0,01)$		$(\sigma_T = 0,03)$		$(\sigma_T = 0,05)$	
	n _{TK}	T^*_{Γ}	n _{TK}	T^*_{Γ}	n _{TK}	T^*_{Γ}
Метод найменших квадратів	1,75	1,56	2,69	2,39	3,68	3,54
Нейронна мережа Елмана	0,54	0,43	0,57	0,46	0,61	0,49
Модифікована нейронна мережа Елмана	0,36	0,22	0,42	0,25	0,50	0,27



Рисунок В.3 – Блок-схема методу контролю технічного стану ГТД вертольотів у польотних режимах (авторський доробок [351])



Рисунок В.4 – Порівняння динаміки помилок класичних архітектур нейронних мереж, призначених для моніторингу складних динамічних об'єктів: 1 – рекурентна нейронна мережа; 2 – багатошаровий персептрон; 3 – згорткова нейронна мережа

(авторський доробок [351])



Рисунок В.5 – Результати навчання моделі за показником Accuracy: 1 – test; 2 – train (ав-

торський доробок [350])



Рисунок В.6 – Результати навчання моделі за показником Loss: 1 – test; 2 – train (авторський доробок [350])

Таблиця В.3 – Середні значення показників тестування LSTM мережі зі змінною

Accuracy	<i>F</i> -міра	Precision	Recall	Середній час, с	Середня точність	Точність дис-
						персії
0,98867	0,97234	0,94617	1,0	1204,12	0,99011	0,0000085

пам'яттю (авторський доробок [350])

Таблиця В.4 – Результати порівняльного аналізу точності контролю (авторський доробок [350])

Архітектура нейронної мережі	Абсолютна похибка (%)			
	Справний стан	Несправний стан	Невизначений стан	
Модифікована LSTM-мережа	0,64	0,64	0,65	
LSTM-мережа	1,32	1,32	1,35	
Багатошаровий персептрон	2,08	2,12	2,14	
Згорткова нейронна мережа	16,35	17,48	19,24	
Мережа Хопфілда	5,66	6,84	6,93	
Мережа Коско	8,32	8,78	8,81	
Мережа Джордана	3,76	3,77	3,89	
Мережа Елмана	3,35	3,35	3,46	

Таблиця В.5 – Перелік вхідних і діагностичних параметрів ГТД вертольотів (авторський доробок [359])

Вузол дви- гуна	Параметр	Визначення	Тип параметра
Duinună	повний тиск повітря за вхідним пристроєм	визначається аналітично [204]	вхідний
пристрій	повна температура повітря за вхідним при- строєм	визначається аналітично [204]	вхідний
	частота обертання ротора турбокомпресора	реєструється на борту верто- льоту	вхідний
	тиск повітря за компресором	визначається аналітично [204]	вхідний
Voumecon	температура повітря за компресором	визначається аналітично [204]	вхідний
компресор	витрата повітря через компресор	визначається аналітично [204]	вхідний
	ступінь підвищення загального тиску в компресорі	визначається аналітично [204]	діагностичний
	ККД компресора	визначається аналітично [204]	діагностичний
	механічний ККД компресора	визначається аналітично [204]	діагностичний
Камера згоряння	повний тиск газу за камерою згоряння	визначається аналітично [204]	вхідний
	температура газів перед турбіною компресора	реєструється на борту верто- льоту	вхідний
Камера	витрата палива в камері згоряння	а газів перед туроїною компресора реєструється на оорту верто- льоту ата палива в камері згоряння визначається аналітично [204]	вхідний
згоряння	коефіцієнт відновлення загального тиску газу в камері згоряння	визначається аналітично [204]	діагностичний
	площа поперечного перерізу камери згоряння	визначається аналітично [204]	діагностичний
	повний тиск газу за турбіною компресора	визначається аналітично [204]	вхідний
	температура газів за турбіною компресора	визначається аналітично [204]	вхідний
Турбіна	ККД турбіни компресора	визначається аналітично [204]	діагностичний
компресора	робота турбіни компресора	визначається аналітично [204]	діагностичний
	ступінь зниження загального тиску газу в тур- біні компресора	визначається аналітично [204]	діагностичний
	повний тиск газу за вільною турбіною	визначається аналітично [204]	вхідний
	температура газу за вільною турбіною	визначається аналітично [204]	вхідний
Вільна турбіна	частота обертання ротора вільної турбіни	реєструється на борту верто- льоту	вхідний
	коефіцієнт зниження загального тиску у віль- ній турбіні	визначається аналітично [204]	діагностичний

447

	енергетичний ККД вільної турбіни	визначається аналітично [204]	діагностичний
	коефіцієнт загального зниження тиску у віль-	визначається аналітично [204]	
	ній турбіні та вихідному пристрої		діагностичний
	повний тиск газу у вихідному пристрої	визначається аналітично [204]	вхідний
Вихідний	температура газу у вихідному пристрої	визначається аналітично [204]	вхідний
пристрій	загальний коефіцієнт відновлення тиску газу у	визначається аналітично [204]	
	вихідному пристрої		діагностичний

Таблиця В.6 – Бінарна класифікація технічних станів ГТД вертольотів (авторський доробок [359] на основі [357])

Номер стану	Виходи а	и ансамблю нейронних мереж		Локалізація дефекту
1	0	0	0	Еталонний стан (S_0)
2	0	1	0	Дефект компресора (S_1)
3	0	1	1	Дефект камери згоряння (S ₂)
4	1	0	0	Дефект турбіни компресора (S ₃)
5	1	1	0	Дефект вільної турбіни (S ₄)
6	1	0	1	Дефект вихідного пристрою (S ₅)

Таблиця В.7 – Результати навчання нейронної мережі персептрон (авторський доробок [359])

Алгоритм навчання	Помилка розпізнавання персептроном	Кількість кроків навчання
Back propagation	0,00011731	700
Conjugate gradient	0,00019935	800
Quick propagation	0,00018364	750
Quasi-Newton	0,00016997	800
Lewenberg-Marquardt	0,00014133	850
Delta bar delta	0,00015702	750
Back propagation	0,00014356	750

Таблиця В.9 – Опис блоків розробленого гібридного алгоритму навчання гібридної

нейронної мережі (авторський доробок [359])

Номер	Коментар
блоку	
1	2
1	нейронна мережа створюється з одним варіантом вхідного шару та декількома варіан-
	тами внутрішнього та вихідного шару
2	ініціалізація ваг нейронів першого шару здійснюється шляхом їх прирівнювання до оди-
	ниці
3	ініціалізація ваг нейронів прихованого та вихідного шару здійснюється випадковими
	малими значеннями від 0 до 1, причому потрібно використовувати різні діапазони ваг
	для різних варіантів шарів (наприклад, всі ваги першого варіанта шару зробити у діапа-
	зоні 00,5, а другого варіанта шару – у діапазоні 0,60,9
4	ініціалізація ваг зсуву першого шару здійснюється шляхом їх прирівнювання до нуля
5	ініціалізація ваг зсуву прихованого та вихідного шару здійснюється випадковими ма-
	лими значеннями від 0 до 1, причому потрібно використовувати різні діапазони ваг для
	різних варіантів шарів (наприклад, всі ваги першого варіанта шару зробити у діапазоні
	00,5, а другого варіанта шару – у діапазоні 0,60,9
6	нейронна мережа вважається навченою, якщо є хоча б один варіант вихідного та прихо-
	ваного шарів, у якому помилки вихідного шару не перевищують максимальну помилку
7	збереження ваг нейронів та зміщення варіантів вихідного та прихованого шару, відхи-
	лення вихідних значень яких не перевищують максимальну помилку для всіх навчаль-
	них наборів є кінцевим розв'язанням задачі навчання нейронної мережі

1	2
8	існує хоча б одна комбінація прихованого та вихідного шару, відхилення вихідних зна-
	чень від цільових значень якої не перевищують максимальну помилку для всіх навчаль-
	них прикладів
9	подати на вхід нейронної мережі навчальний приклад і отримати вихідні значення всіх
	шарів для кожного варіанта прихованого та вихідного шарів. У підсумку на виході буде
	багатовимірний масив, що містить виходи першого шару, кожного варіанта прихованого
	шару та кожної сукупності варіантів прихованого та вихідного шарів
10	існує хоча б один варіант вихідного шару, відхилення від цільових значень для якого не
	перевищують максимальної помилки
11	розрахунок зміни коефіцієнтів зміни ваг нейронів здійснюється для кожного вхідного,
	прихованого та вихідного шарів
12	розрахунок зміни коефіцієнтів зміни зсуву здійснюється для кожного вхідного, прихо-
	ваного та вихідного шарів
13	запам'ятати індекси вхідного та вихідного шарів з відхиленнями, що не перевищують
	максимальну помилку
14	час, що минув з початку моменту навчання, більший за максимальне значення часу на-
	вчання



Рисунок В.1 – Блок-схема розробленого гібридного алгоритму навчання гібридної нейронної мережі (авторський доробок [359])

Архітектура нейронних мереж	Accuracy	Loss
Розроблений нейромережевий класифікатор	0,998	0,0011
Повнозв'язана рекурентна нейронна мережа на базі персептрону (RTRN)	0,991	0,0045
Нейронна мережа Кохонена [357]	0,970	0,022
Тришаровий персептрон [357]	0,962	0,014
Нейронна мережа Коско	0,921	0,019
Нейронна мережа Елмана	0,899	0,032
Нейронна мережа Хеммінга	0,873	0,044
Нейронна мережа Хопфілда	0,854	0,056
Нейронна мережа Джордана	0,836	0,069
РБФ-мережа	0,817	0,091

Таблиця В.10 – Результати порівняльного аналізу (авторський доробок [359])



Рисунок В.2 – Узагальнена структура мережі GRNN (авторський доробок [365])



Рисунок В.3 – Структура RBF-шару мережі GRNN (авторський доробок [365])

Таблиця В.11 – Фрагмент навчальної вибірки під час експлуатації ГТД вертольоту (на прикладі двигуна ТВ3-117) (авторський доробок [365])

Час, год	n _{TK}	T_{Γ}
88,00	0,944	0,616
89,04	0,908	0,613
89,48	0,943	0,612
90,27	0,949	0,611
90,71	0,922	0,610
91,68	0,893	0,609
92,03	0,921	0,608
92,69	0,982	0,608
93,57	0,985	0,609
94,12	0,986	0,607
94,36	0,985	0,605

Таблиця В.12 – Статистика навчання мережі GRNN для параметра *n*_{TK} (авторський

доробок [365])

	T				
	Параметри алгоритму				
Підсумкові статистики	$\eta = 0,25$	$\eta = 0,5$	$\eta = 0,7$		
-	$\mu = 0.5$	$\mu = 0.9$	$\mu = 0.9$		
Математичне очікування помилки	0,1226	0,0519	0,0113		
Дисперсія помилки	0,0021	0,0011	0,0008		
Середньоквадратичне відхилення помилки	0,0458	0,0331	0,0283		

Таблиця В.13 – Статистика навчання мережі GRNN для параметра T_{\varGamma}^{*} (авторський

доробок [365])

	Параметри алгоритму				
Підсумкові статистики	$\eta = 0,25$	$\eta = 0,5$	$\eta = 0,7$		
	$\mu = 0,5$	$\mu = 0,9$	$\mu = 0.9$		
Математичне очікування помилки	0,1534	0,0582	0,0129		
Дисперсія помилки	0,0026	0,0014	0,0013		
Середньоквадратичне відхилення помилки	0,0510	0,0374	0,0361		

Таблиця В.14 – Результати порівняльного аналізу роботи класичних та нейромережевих

методів прогнозування технічного стану ГТД вертольотів

Методи прогнозування	Назва	ва Помилка прогнозу параметра двигуна					a
	методу		$n_{TK}, \%$		T_{Γ} , %		
		КП	СП	ДП	КП	СП	ДП
Класичні (без шуму)	МКС	0,528	0,661	1,317	0,365	1,155	1,556
	ME3	0,297	0,457	1,259	0,583	1,264	1,653
	МНК	0,692	0,795	1,693	0,936	1,446	2,552
Нейромережевий (без шуму)	HM	0,235	0,304	0,465	0,219	0,304	0,425
Класичні (з шумом)	МКС	1,524	1,863	2,408	1,227	1,373	1,969
	ME3	1,726	1,742	2,335	1,495	1,701	2,273
	МНК	2,148	2,204	2,447	1,883	2,431	3,378
Нейромережевий (з шумом)	HM	0,682	0,719	0,726	0,413	0,583	0,620



Рисунок В.4 – Графічна інтерпретація виявлення потенційних дефектів у ГТД вертольотів – фактичне значення термогазодинамічного показника відрізняється від прогнозованого «нормального» значення (авторський доробок [371, 374])

			SOTA-arc	chitectures	5		Doppos		2711 10	Doomoo		
Par	Simple AutoEncoder			AutoEncoder з викорис- танням нейронної ме- режі LSTM			тод з використанням нейронної мережі GRNN			користанням графової нейронної мережі		
rameter	Precision	Recall	F1-scope	Precision	Recall	F1-scope	Precision	Recall	F1-scope	Precision	Recall	F1-scope
n _{TK}	0.81	0.76	0.78	0.63	0.67	0.64	0.88	0.87	0.87	0.96	0.98	0.94
T_{Γ}	0.86	0.84	0.85	0.77	0.77	0.77	0.92	0.91	0.91	0.99	0.97	0.96
n_{CB}	0.61	0.57	0.57	0.67	0.64	0.67	0.79	0.78	0.78	0.95	1.0	0.93

Таблиця В.15 – Результати порівняльного аналізу (авторський доробок [374])

	Імовірність помилки при ідентифікації потенційного дефекту, %									
M '1''''	Дефект ко	Дефект компресора		ери згоряння	Дефект турбіни компре-					
Метод ідентифікаціі	Помилка	Помилка	Помилка Помилка		Помилка	Помилка				
	першого	другого	першого	другого	першого	другого				
	роду	роду	роду	роду	роду	роду				
Класичний метод	1 75	1 35	2 48	176	2.23	1 5 1				
(допусковий контроль)	1,75	1,55	2,40	1,70	2,23	1,51				
Нейромережеві методи:										
Simple AutoEncoder	1,15	0,94	1,24	1,09	1,23	1,06				
LSTM AutoEncoder	0,95	0,58	1,02	0,63	0,99	0,61				
нейронна мережа GRNN	0,62	0,31	0,61	0,29	0,60	0,27				
графова нейронна мережа	0,33	0,17	0,33	0,16	0,32	0,14				

Таблиця В.16 – Результати порівняльного аналізу (авторський доробок [374])

Таблиця В.17 – Фрагмент навчальної вибірки (авторський доробок [394])

n _{TK}	0,998	0,998	0,992	0,992	0,991	0,995	0,991	0,996	0,998	0,989	0,991	0,993
C_{num}	0,972	0,978	0,964	0,984	0,998	0,979	0,970	0,990	0,965	0,990	0,967	0,964

Таблиця В.18 – Результати визначення впливу коефіцієнта навчання на результуючу похибку (авторський доробок [394])

Номер	1	2	3	4	5	6	7	8	9	10
Коефіцієнт навчання	0,0001	0,0005	0,001	0,002	0,003	0,004	0,005	0,006	0,008	0,01
Стандартне відхилення	3,642	4,018	6,024	6,547	7,112	7,937	8,645	9,202	10,383	12,002

Таблиця В.19 – Результати визначення впливу кількості нейронів у прихованому

шарі на результуючу похибку (авторський доробок [394])

Номер	1	2	3	4	5	6	7	8	9	10
Кількість нейронів	2	5	10	15	20	25	30	35	40	45
Стандартне відхилення	8,307	8,865	4,317	6,997	9,005	10,513	11,817	9,545	8,997	10,816

Таблиця В.20 – Результати визначення впливу кількості епох навчання на результу-

ючу похибку (авторський доробок [394])

Номер	1	2	3	4	5	6	7	8	9	10
Кількість епох	0	20	40	60	80	100	150	200	300	500
Стандартне відхилення	25,346	22,717	19,657	14,008	7,856	3,358	3,358	3,358	3,358	3,358

Таблиця В.21 – Результати обчислення помилок першого і другого роду (авторський

доробок [394])

Тип нейронної мережі	Ймовірність помилки при визначенні граничного значення <i>п</i> _{тк}				
	Помилка першого роду	Помилка другого роду			
Запропонована нейронна мережа прямого поши-	0.57	0.38			
рення з адаптивними елементами	0,57	0,50			
Нейронна мережа прямого поширення з адаптив-					
ними елементами з використанням алгоритму	0,94	0,65			
Delta-Bar-Delta [391]					



Рисунок В.5 – Еліпс розсіювання параметрів ГТД [391–393]



Рисунок В.6 – Схема налагодження дозатора палива ГТД вертольоту із використанням алгоритму оптимізації (авторський доробок [390] на основі [391–393])

Таблиця В.22 – Результати розрахунку коефіцієнтів помилки та якості (авторський до-

Параметр	Запропонована нейронн	а мережа прямого поши-	Нейронна мережа прямого поширення з адапти-			
	рення з адаптивн	ними елементами	вними елементами з використанням алгоритму			
			Delta-Bar-Delta [391]			
	Knom	Кякість	Knom	Кякість		
Граничне значення <i>п_{тк}</i>	0,317	99,965	0,598	99,201		

робок [394])



Рисунок В.7 – Модифікована нейронна мережа Джордана з динамічною стековою пам'яттю (авторський доробок [393])

№ 3/П	Час год	Значення інтегрального критерію
1	0	-0,002
2	0,125	-0,002
3	0,25	-0,002
4	0,375	-0,002
5	0,5	-0,002
6	0,625	-0,002
7	0,75	-0,002
8	0,875	-0,002
9	1,0	-0,002
10	1,125	-0,002
11	1,25	-0,002
12	1,375	-0,002
13	1,5	-0,0017
14	1,625	-0,0004
15	1,75	0,0003
16	1,875	0,0007
17	2,0	0,0003
18	2,125	0,0003
19	2,25	0,0004
20	2,375	0,0015
21	2,5	0,01

Таблиця В.23 – Фрагмент навчальної вибірки (авторський доробок [393])

Таблиця В.24 – Навчальна вибірка нейронної мережі для розв'язання задачі тренданалізу часового ряду параметра температури газу перед турбіною компресора, отримана в результаті перетворення часового ряду методом ковзного вікна(авторсь-

кий доробок [393])

№ з/п	Входи	и нейронної мере	ежі, <i>х</i> і	Вихід нейронної мережі, у1
	x_1	x_2	<i>X</i> 3	
1	-0,002	-0,0017	-0,0004	0,0003
2	-0,0017	-0,0004	0,0003	0,0007
3	-0,0004	0,0003	0,0007	0,0003

Таблиця В.25 – Порівняльна оцінка визначення тренду (авторський доробок [394])

Критерії	Вимірю-	Час появи	Якість	Якість розпізнавання тренду при зміні		
	вальна	тренду (ви-	розпізна-	$\alpha, \%$ $\tau_0, \%$		σ_y (чутливість)
	вибірка	мірю-	вання, %			
		вання)				
Класичні	50	78	95	7095	9095	1025 вимірювань
Нейромережеві	50	45	100	95100	95100	35 вимірювань



Рисунок В.8 – Характеристики критеріїв тренду для 5 % рівня значимості у безрозмірних координатах (авторський доробок [394]): 1 – нейромережевий критерій (з використанням модифікованої нейронної мережі Джордана з динамічною стековою пам'яттю); 2 – нейромережевий критерій (з використанням ансамблю нейронних мереж, що складається з персептрона і РБФ мережі); 3 – *s*-критерій; 4 – *S*'-критерій; 5 – *r*-критерій Хальден-Аббе; 6 – модифікований *r*-критерій; 7 – *u*-критерій [393, 394]

Таблиця В.26 – Результати порівняння результатів розв'язання задачі тренд-аналізу параметрів ГТД вертольотів у польотних режимах (авторський доробок [394])

Архітектура нейронної мережі	Максимал	льна СКВ	Точність ро	зпізнавання
			тре	нду
	Тренд відсут-	Тренд прису-	Тренд відсут-	Тренд прису-
	ній	тній	ній	тній
Модифікована нейронна мережа Джордана з динаміч-	0,025	0,056	0,999	0,995
ною стековою пам'яттю				
Ансамбль нейронних мереж: персептрон + РБФ	0,087	0,117	0,932	0,916
мережа (запропоновано професором Жернако-				
вим С.В. [393])				
Нейронна мережа Джордана	0,093	0,128	0,901	0,887
Модифікована нейронна мережа Елмана з динаміч-	0,102	0,115	0,935	0,929
ною стековою пам'яттю (застосована у п. 3.1)				
Нейронна мережа Елмана	0,118	0,175	0,863	0,831
Модифікована LSTМ-мережа (застосована у п. 3.1)	0,134	0,204	0,814	0,798
LSTМ-мережа	0,159	0,261	0,776	0,732
Нейронна мережа Хопфілда	0,232	0,327	0,711	0,689
Нейронна мережа Хеммінга	0,261	0,401	0,688	0,613
Нейронна мережа Коско	0,298	0,437	0,652	0,606
Повнозв'язана рекурентна нейронна мережа RTRN	0,311	0,487	0,613	0,574

додаток г.

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 4

Таблиця Г.1 – Основні цілі розробки АПУ ГТД вертольотів

Ціль	Опис
Підвищення ефектив-	Оптимізація роботи ГТД вертольотів для досягнення максимальної потужності при міні-
ності	мальному споживанні палива. Це може включати удосконалення алгоритмів керування,
	використання передових технологій для моніторингу та діагностики стану двигуна
Забезпечення безпеки	Розробка систем, які автоматично реагують на виникнення аварійних ситуацій або неспра-
польоту	вностей, щоб забезпечити безпеку польоту. Це може включати адаптивні стратегії керу-
	вання в разі виникнення проблем.
Зменшення наванта-	Автоматизація багатьох функцій для зменшення навантаження на пілота, зокрема під час
ження на пілота	старту, посадки, а також у складних погодних умовах або під час тривалих польотів
Мінімізація впливу на	Розробка ефективних стратегій керування, спрямованих на зменшення викидів шкідливих
навколишнє середовище	речовин та покращення екологічних показників ГТД вертольотів
Надійність та стійкість	Забезпечення стійкості та надійності роботи САУ, враховуючи різні умови польоту та екс-
	плуатації
Адаптація до різних ре-	Розробка алгоритмів, які забезпечують оптимальне управління двигуном в різних режимах
жимів польоту	роботи, таких як прискорення (зі зміною швидкості) та підтримання сталої швидкості
Використання інтелек-	Впровадження штучного інтелекту, машинного навчання та інших передових технологій
туальних технологій	для аналізу великих обсягів даних, прогнозування та удосконалення стратегій керування.



Рисунок Г.1 – Багаторежимний нейромережевий регулятор на базі персептрона (авторський доробок [404, 405])



Рисунок Г.2 – Пропонована нейромережева АПУ ГТД вертольотів із взаємозв'язаними координатами [408]

Таблиця Г.2 – Вхідні дані режимів роботи авіаційного двигуна ТВЗ-117

Режим роботи авіаційного двигуна ТВЗ-117	Значення <i>п</i> _{ТК}	Значення T^*_{Γ}	Значення G _T
Номінальний (І крейсерський) режим (<i>M</i> ₁)	0,709	0,769	0,096
Надзвичайний режим (М2)	1,092	1,087	0,334





Рисунок Г.3 – Результати моделювання АПУ авіаційного двигуна ТВЗ-117: а – режим M_1 ; б – режим M_2 ; 1 – еталонна модель; 2 – модель з багаторежимним нейромережевим регулятором на основі персептрона; 3 – нейромережева АПУ ГТД вертольотів на базі саморегульованої нейронної мережі (авторський доробок [406] на основі [404])



Рисунок Г.4 – Схема проєкту відмовостійкої АПУ ГТД вертольотів з блоком нейромережевих регуляторів (авторський доробок [410] на основі [409])

Таблиця Г.3 – Значення коефіцієнтів передавальної функції [409]

Режим	a_0	a_1	b_0	b_1	b_2	b_3	b_4
1	1,93	2,26	0,12	1,54	6,35	5,65	2,73
2	2,04	3,11	0,12	1,82	9,21	1,21	4,11
3	1,79	8,97	0,12	2,93	35,73	60,09	1,57



Рисунок Г.5 – Модифікована структурна схема багаторежимного нейромережевого регу-

лятора [409]

Таблиця Г.4 – Етапи алгоритму зворотного поширення з регуляризацією [410]

Етап	Опис
1	Ініціалізація вагових коефіцієнтів W випадковими малими значеннями, вибір початкової η_0 і максимальної
	швидкості навчання η_{\max} , похибки контролю δ .
2	Нульова ініціалізація початкових значень зміни ваг ΔW .
3	Визначення похибки $E(k)$ згідно з $E(k) = \sum_{i} \sigma n_i^2 + 10 \sum_{i} \sigma T_{\Gamma_{OVER}}^2$, де k – номер ітерації; σn_i^2 – значення похи-
	бки регулювання по каналу частоти обертів ротора турбокомпресора. <i>n</i> _{TK} (або частоти обертів ротора вільної
	турбіни n_{CB}); $\sigma T_{\Gamma_{OVER}}^2$ – значення перерегулювання по каналу температурі газів перед турбіною компресора
	T_{Γ}^* . Використання квадратичного критерію при розрахунку похибки навчання нейронної мережі дозволяє
	підвищити точність ідентифікації параметрів бортової АПУ ГТД вертольотів за рахунок зменшення серед- ньоквадратичної похибки.
4	Якщо результат задовільний, а саме $ E(k) \leq \delta$, то навчання мережі не реалізовано; інакше здійснюється пере-
	хід до кроку 5.
5	Розрахунок значення градієнта функції втрат $\nabla E(k)$ на поточній ітерації.
6	Визначення параметра швидкості навчання для <i>i</i> -го шару згідно з виразом: $\eta_i = \eta_{\max} \cdot 1 + e^{- G_i }$, де η_{max} – макси-
	$\sum_{i=1}^{l} \mathbf{x}_{(i+1)i}$
	мальна швидкість навчання; $ \mathbf{G}_i = \frac{\frac{j-i+1}{i}}{i}$ – середнє арифметичне значення похибки для <i>i</i> -го рівня мережі;
	l – кількість нейронів у <i>j</i> -му наступному відносно <i>i</i> -го шару; х – матриця помилок мережі, де
	$\dim(\mathbf{x}) = [m_{\max} \times d]$, m_{\max} – максимальне значення нейронів серед усіх шарів нейронної мережі; d – кількість
	шарів нейронної мережі. У цьому випадку ми входи нейронної мережі визначаються як перший рівень.
7	Розрахунок зміни параметра згідно з виразом: $\Delta W(k) = \eta \cdot (E(k) + \rho \cdot W(k-1)) + \mu \cdot \Delta W(k-1)$, де η – коефіці-
	єнт, що характеризує швидкість підготовки; $ ho$ – коефіцієнт регуляризації; $\Delta W(k-1)$ – зміна ваги на поперед-
	ній ітерації; µ – моментний коефіцієнт; W(k – 1) – значення вагових коефіцієнтів на попередній ітерації.
8	Регулювання ваг нейронної мережі.
9	Перехід до кроку 3.

Таблиця Г.5 – Результати ідентифікації нейромережевого регулятора (авторський

доробок [410])

Метод розрахунку	$T^*_{\scriptscriptstyle \Gamma}$	n_{TK}	n _{CB}
Класичні методи:			
метод найменших квадратів	0,887	0,844	0,942
груповий метод обліку аргументів	0,663	0,701	0,817
Нейромережеві методи:			
персептрон (рис. 4.19)	0,267	0,318	0,441
модульна нейронна мережа	0,499	0,535	0,732
RBF	0,542	0,573	0,755

Таблиця Г.6 – Результати ідентифікації нейромережевого регулятора з додаванням

Метод розрахунку	T^*_{Γ}	n_{TK}	n _{CB}
Класичні методи:			
метод найменших квадратів	2,999	3,717	5,866
груповий метод обліку аргументів	2,618	2,962	1,957
Нейромережеві методи:			
персептрон (рис. 4.19)	0,535	0,604	0,695
модульна нейронна мережа	1,184	1,198	1,215
RBF	1,305	1,308	1,324

адитивного шуму (авторський доробок [410])

Таблиця Г.7 – Недоліки селективного управління (авторський доробок)

Недолік	Опис
1	Можливість появи «перекидання» по керованій координаті при перемиканні між регулюючими конту-
	рами пояснюється різницею динамічних характеристик ГТД вертольотів для різних каналів регулю-
	вання
2	При дії зовнішніх збурень АПУ може виявляти різноманітну реакцію, навіть за невеликих відхилень у
	значеннях змінних стану. Це також пояснюється мінливою структурою регулятора, оскільки послідов-
	ність активації керуючих контурів у перехідних процесах залежатиме від вектору стану.
3	У процесі експлуатації відбувається зміна статичних характеристик ГТД вертольотів через їх знос, а
	управляючі контури включають табличні налаштування коефіцієнтів регуляторів. При цьому сам ГТД
	вертольоту як об'єкт управління виявляє складні нелінійні властивості, обумовлені взаємозв'язками
	внутрішніх параметрів. Ці властивості відображені у табличних налаштуваннях коефіцієнтів регулято-
	рів. Через внутрішні взаємозв'язки зміна характеристик одного параметра може призвести до погір-
	шення якості регулювання для інших контурів.
4	Обмежене урахування роботи ГТД вертольотів на перехідних режимах роботи, що додатково погіршу ϵ
	якість управління його основними каналами – n_{TK} і T_{Γ}^* .
Висновки	1. Недоліки 1 – 4 створюють труднощі у процесі налаштування АПУ ГТД вертольотів, що призводить
	до ускладнення експлуатації нових ГТД вертольотів (наприклад, Turbomeca Makila 2A1, General
	Electric GE38 тощо). Цей процес стає більш витратним, і його негативний вплив позначається на якості
	електроенергії, що виробляється з точки зору підтримки необхідних параметрів.
	2. З метою подальшого поліпшення характеристик селективних АПУ, з урахуванням підвищення яко-
	сті управління ГТД вертольотів, доцільним є введення каналу управління частоти обертів ротора віль-
	ної турбіни <i>п_{СВ}</i> як параметра, що реєструється на борту вертольоту.
	3. Постає задача пошуку альтернативних варіантів модифікації рощробленої АПУ ГТД вертольотів шляхом
	застосування методів адаптивного управління для саморегулювання окремих коефіцієнтів регуляторів.

Таблиця Г.8 – Модулі адаптивного управління [418]

Назва модулю /	Схема	Опис
підмодулю		
1	2	3
Модуль сигна- льної адаптації	X_M → Модуль сигнальної х → адаптації → <i>Z</i>	Модуль приймає на вхід два вектори: x _M – вектор стану еталонної або налаштовувальної моделі, і x – укорочений вектор стану ГТД вертольоту. На основі отриманих даних проводиться обчислення вектору неузгодженості. Після цього проводиться розрахунок виваженої суми вектору неузгодженості, за яким слі- дує визначення значення сигнального впливу <i>z</i> .
Модуль пара- метричної ада- птації	$\mathbf{X}_{\mathbf{M}}$ Модуль step, s адаптації Δk_i , Δk_i , Δk_p , Δk_p , Δk_f	Модуль приймає на вхід параметри кроку розв'язку диференціальних рівнянь, вектор хм, що є станом ета- лонної або налаштовувальної моделі, і скорочений ве- ктор х, що описує стан ГТД вертольоту. На основі цих даних здійснюється розрахунок вектору неузгоджено- сті, за яким слідує обчислення виваженої суми цього вектору. Після цього проводиться розрахунок вихід- них змінних модуля, що являють собою збільшення коефіцієнтів регулятора Δk_i , Δk_p , Δk_f .

Закінчення таблиці Г.8

1	2	3
Підмодуль ета- лонної моделі	$x_i \longrightarrow$ Підмодуль eталонної step, s \rightarrow моделі x_M	На вхід модуля надходять значення термогазодинамі- чних параметрів ГТД вертольоту та крок розв'язу- вання диференціальних рівнянь. На основі отриманих даних послідовно розраховуються змінні стану мо- делі. Метод першого порядку використовується для розв'язування диференціальних рівнянь. Вектор стану еталонної моделі х м є вихідною змінною мо- дуля.
Підмодуль на- лаштовуваль- ної моделі	$\mathbf{x}_i \longrightarrow$ Підмодуль налаштовува льної моделі $\mathbf{x}_{\mathbf{M}}$	Модуль отримує на вхід скорочений вектор стану складної поелементної моделі (х) та крок розв'язання диференціальних рівнянь. На основі цих даних прово- диться розрахунок вектору похідних змінних стану ГТД вертольоту. Потім розраховуються вектори стану моделі. Після цього здійснюється обчислення різниці між векторами стану та похідними змінних стану ГТД вертольоту та моделі. На основі розрахованих різниць визначається сигнал нев'язки, який, у свою чергу, до- зволяє визначити збільшення матриць А м і В м. За по- треби проводиться динамічна компенсація. Потім фо- рмується вихідна змінна модуля – підсумковий вектор стану налаштовувальної моделі (хм).

Таблиця Г.9 – Блок-схеми роботи модулів з сигнальною та параметричною адаптацією

[418]



Таблиця Г.10 – Узагальнена інформація щодо модифікації бортової нейромережевої

Вид математичної моделі	Автор розробки	Тип застосованих моду-	Обраний тип нейронної
		лів / підмодулів	мережі (нейроконтро-
			лера)
Випадок 1. Математичний опис ме-	На основі досліджень	Модуль сигнальної адап-	Тип нейронної мережі –
тоду адаптивного управління з ета-	Бахірєва І.А. [418]	тації з підмодулем ета-	багатошаровий персепт-
лонною моделлю		лонної моделі	рон [419]
Випадок 2. Математичний опис	На основі досліджень	Модуль сигнальної адап-	Тип нейронної мережі –
безпошукового методу ідентифіка-	Бахірєва І.А. [418]	тації з підмодулем нала-	багатошарова нейронна
ції в реальному часі		штовувальної моделі	мережа NEWFF [420]
Випадок 3. Математичний опис за-	На основі досліджень	Модуль параметричної	Тип нейронної мережі –
дачі параметричної адаптації з ди-	Бахірєва І.А. [418]	адаптації з підмодулем	нейронна мережа пря-
намічною компенсацією		налаштовувальної моделі	мого поширення [421]

АПУ ГТД вертольотів (авторський доробок)

Таблиця Г.11 – Показники якості по *п*_{CB} еталонної моделі із сигнальним регулятором

(авторський доробок [419])

Тип регулятора	Максимальне відхилення, об/хв	Час перехідного процесу	Число коливань
Штатний	450	8,5	2
Адаптивний	320	3,7	0

Таблиця Г.12 – Поліпшення показників якості по *n*_{CB} еталонної моделі із сигнальним

регулятором (авторський доробок [419])

Поліпшення, %	30,18	58,37	100
Ділянка перехідного процесу, с	010	010	010

Таблиця Г.13 – Показники якості по *п*_{CB} еталонної моделі із сигнальним регулятором

(авторський доробок [419])

Тип регулятора	Максимальне відхилення, об/хв	Час перехідного процесу	Число коливань
Штатний	1080	4,8	0
Адаптивний	580	3,2	1

Таблиця Г.14 – Поліпшення показників якості по *n*_{CB} еталонної моделі із сигнальним

регулятором (авторський доробок [419])

Поліпшення, %	43,24	60,96	_
Ділянка перехідного процесу, с	3040	3040	1020

Таблиця Г.15 – Результати порівняльного аналізу (авторський доробок [419])

Метод визначення	Ймовірність помилки визначення оптимальних параметрів <i>n</i> _{TK} і <i>n</i> _{CB} , %				
	Визначення опт	имального пара-	Визначення опт	имального пара-	
	метра n_{TK}		метра n_{TK} метра n_{CB}		a n _{CB}
	Помилка пер-	Помилка дру-	Помилка пер-	Помилка дру-	
	шого роду	гого роду	шого роду	гого роду	
Класичний (метод допускового контролю)	1,85	1,12	2,38	1,76	
Нейромережевий	0,63	0,24	0,74	0,24	

Таблиця Г.16 – Показники якості по *п*_{CB} налаштовувальної моделі (на основі нейрон-

ної мережі NEWFF) з сигнальним регулятором (авторський доробок [420])

Тип регулятора	Максимальне відхилення, об/хв	Час перехідного процесу	Число коливань
Штатний	1380	10,1	1
Адаптивний	1000	7,5	1

Таблиця Г.17 – Поліпшення показників якості по *n*_{CB} налаштовувальної моделі (на основі

нейронної мережі NEWFF) з сигнальним регулятором (авторський доробок [420)

Поліпшення, %	26,37	26,51	27,17
Ділянка перехідного процесу, с	020	020	020

Таблиця Г.18 – Показники якості по *п*_{CB} налаштовувальної моделі (на основі нейрон-

ної мережі NEWFF) з сигнальним регулятором (авторський доробок [420])

Тип регулятора	Максимальне відхилення, об/хв	Час перехідного процесу	Число коливань
Штатний	350	10,8	0
Адаптивний	230	7,7	1

Таблиця Г.19 – Поліпшення показників якості по n_{CB} налаштовувальної моделі (на ос-

нові нейронної мережі NEWFF) з сигнальним регулятором (авторський доробок [420])

Поліпшення, %	29,14	31,32	33,03
Ділянка перехідного процесу, с	3045	3045	1020

Таблиця Г.20 – Результати порівняльного аналізу (авторський доробок [420])

Метод визначення	Абсолютна похибка, %				
	Частота обертів ро- Частота обертів ро-		Інтегратор регуля-	Інтегратор регуля-	
	тора вільної тур-	тора турбокомпре-	тора дозатора	тора вільної тур-	
	біни	copa		біни	
Класичний (МНК)	2,29	2,31	2,33	2,39	
Нейромережевий	0,75	0,76	0,74	0,78	

Таблиця Г.21 – Результати порівняльного аналізу (авторський доробок [420])

Метод визначення	Абсолютна похибка, %				
	Частота обертів ро-	Частота обертів ро-	Інтегратор регуля-	Інтегратор регуля-	
	тора вільної тур-	тора турбокомпре-	тора дозатора	тора вільної тур-	
	біни	copa		біни	
Класичний (МНК)	3,46	3,52	3,59	3,67	
Нейромережевий	1,18	1,23	1,27	1,32	

Таблиця Г.22 – Етапи алгоритму навчання нейронної мережі, розробленого на ос-

нові методу Нелдера-Міда [422]

Етап	Опис
1	Формування набору початкових симплексів, які мають координати точок $m (n \cdot m = 4 \cdot n)$ (кі-
	лькість вагових коефіцієнтів, визначена тим, що вихід нейронної мережі з урахуванням
	архітектури нейронної мережі відображає реакцію на значення від окремої синаптичної
	ваги).
2	Прирівнювання до нуля значення всіх синаптичних ваг у точці <i>m</i> + 1.
3	Варіювання знаку синаптичних ваг всієї множини їх можливих значень у точках симплексів.
4	Обчислення значень критерію $I(\mathbf{W}) = \int_{0}^{L} \varepsilon^{2}(t, \mathbf{W}) dt$ у кожному симплексі для всіх точок; у разі
	позначається як I_{ij} , де $i = 1, 2,$ номер симплекса, $j = 1, 2,$ точка i -го симплекса.
5	Визначення \hat{I} – характеристичного числа симплексу – як $\hat{I} = \min(I_{ij})$. Далі розглядаються
	лише ті симплекси, для яких $\frac{\hat{I}}{\min(\hat{I})} \le \mu$, $\mu \ge 1$.
6	Виконання основних операцій методу Нелдера-Міда [422] з відібраними симплексами: «со- ртування», «відображення», «розтяг», «стиск», «усічення», «перевірка виконання критерію закінчення пошуку».
7	Порівняння результатів роботи алгоритму, під якими розуміється пошук точок із наймен- шими критеріями <i>I</i> , в кожному симплексу. Шляхом знаходження евклідової відстані між цими точками визначається околиця локальних екстремумів, формується їх набір і серед нього вибирається точка з найменшим значенням критерію <i>I</i> . Її значення синаптичних ваг і вважаються оптимальними.

Таблиця Г.23 – Показники якості по *n*_{CB} налаштовувальної моделі (на основі нейронної

мережі прямого поширення) з сигнальним регулятором (авторський доробок [421])

Тип регулятора	Максимальне відхилення, об/хв	Час перехідного процесу	Число коливань
Штатний	2200	10,5	2
Адаптивний	1320	4,3	1

Таблиця Г.24 – Поліпшення показників якості по *n*_{CB} налаштовувальної моделі (на

основі нейронної мережі прямого поширення) з сигнальним регулятором (авторський

доробок [421])

Поліпшення, %	28,35	60,92	61,37
Ділянка перехідного процесу, с	4050	5060	5060

Таблиця Г.25 – Показники якості по *n*_{CB} налаштовувальної моделі (на основі нейронної мережі прямого поширення) з сигнальним регулятором (авторський доробок [421])

Тип регулятора	Максимальне відхилення, об/хв	Час перехідного процесу	Число коливань
Штатний	380	10,8	2
Адаптивний	230	3,9	3

Таблиця Г.26 – Поліпшення показників якості по *n*_{CB} налаштовувальної моделі (на основі нейронної мережі прямого поширення) з сигнальним регулятором (авторський

доробок [421])

Поліпшення, %	47,24	64,29	—
Ділянка перехідного процесу, с	5060	5060	5060

Таблиця Г.27 – Результати порівняльного аналізу (авторський доробок [421])

Метод визначення	Ймовірність помилки визначення оптимальних параметрів <i>n_{TK}</i> і				
	$n_{CB}, \%$				
	Визначення оптимального па-		Визначення оптимального па-		
	раметра <i>п</i> _{ТК}		раметра <i>пCB</i>		
	Помилка пер-	Помилка дру-	Помилка пер-	Помилка дру-	
	шого роду	гого роду	шого роду	гого роду	
Класичний (метод допускового контролю)	2,19	1,21	2,12	1,92	
Нейромережевий	0,61	0,32	0,69	0,34	

467




додаток д.

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 5

Таблиця Д.1 – Основні передумови застосування апарату нечіткої логіки та нейро-

нечітких мереж (авторський доробок)

Передумова	Опис
Нечіткість вхідних па-	Параметри ГТД вертольотів, такі як, частота обертів ротора турбокомпресора, температура
раметрів	газів перед турбіною компресора, частота обертів ротора вільної турбіни тощо, можуть бути
	нечіткими та змінюватися в ході роботи. Використання нечіткої логіки дозволяє ефективно
	моделювати цю нечіткість і пристосовувати систему до змін в умовах експлуатації.
Адаптація до змінних	ГТД вертольотів можуть працювати в різних режимах (наприклад, під час зміни наванта-
умов експлуатації	ження або швидкості обертання ротора турбокомпресора та/або вільної турбіни). Нейро-не-
	чіткі мережі можуть вивчати та адаптуватися до змін в умовах роботи, що робить їх ефекти-
	вними для систем автоматичного управління, що мають динамічний характер.
Робота в умовах неод-	АПУ ГТД вертольотів часто стикаються з неоднозначністю та невизначеністю у зв'язку з
нозначності	різними факторами, такими як знос, забруднення палива, інші аномалії. Використання нечі-
	ткої логіки дозволяє ефективно управляти такими умовами та приймати рішення при нечіт-
	ких або неоднозначних вхідних даних.
Моделювання склад-	ГТД вертольотів мають складні взаємозв'язки між різними параметрами. Нейро-нечіткі ме-
них залежностей між	режі можуть ефективно моделювати ці складні залежності та автоматично вивчати їх з да-
параметрами	них, що спрощує розробку управляючих систем.
Адаптивність до змін	Нейро-нечіткі мережі можуть адаптуватися до змін в режимах роботи ГТД вертольотів, оп-
в режимах роботи	тимізуючи параметри управління для досягнення кращої продуктивності та ефективності.
Висновок	Застосування нечіткої логіки та нейро-нечітких двигунами мереж у АПУ ГТД вертольотів
	допомагає покращити стійкість, ефективність та адаптивність цих систем до різних умов
	експлуатації.





Таблиця Д.2 – Діагностична матриця ГТД вертольотів (авторський доробок на ос-

Ресса	грують / верто	ся на	Визначаються аналітично Термогазолинаміцні показники							ан	Ію						
oopry	всрто	льоту				терм	огазод.	инамич	ні пока	зники	T	r		ВИТ	рат	CT	$\mathbf{B}\mathbf{y}$
Δn_{TK}	ΔT^*_{Γ}	Δn_{CB}	$\Delta T^*_{\rm ex}$	$\Delta P^*_{\rm ex}$	ΔT_{K}^{*}	ΔP_{K}^{*}	ΔP_{Γ}^{*}	ΔT^*_{TK}	ΔP_{TK}^*	ΔT_{CB}^{*}	ΔP_{CB}^{*}	ΔT_{C}^{*}	ΔP_{C}^{*}	ΔG_{B}	ΔG_T		
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Етал	он
3,92	0,69	1,76	4,77	4,76	5,44	8,09	-8,09	-10,99	-7,67	-5,35	4,76	5,5	-8,22	-8,22	4,76	π_{K}^{*} (1%)	
4,64	0,92	2,1	5,02	4,76	5,27	7,53	-7,54	-10,93	-7,58	-5,24	4,76	5,46	-7,89	-7,9	4,76	$\pi_{K}^{*}(3\%)$	
5,26	1,46	6,94	7,45	6,95	5,1	12,45	-4,76	-10,85	-7,14	-3,12	4,76	5,29	-6,87	-7,28	4,76	$\pi_{K}^{*}(5\%)$	d
4,29	0,66	1,29	4,71	4,76	5,68	-9,13	-9,14	-11,32	8,19	0,68	5,45	-6,98	-6,98	-9,35	6,26	η_{κ} (1%)	eco
4,85	0,82	0,67	4,82	4,76	5,99	-10,69	-10,7	-11,94	9,16	1,32	5,3	-7,76	-7,77	-9,52	6,92	η_{κ} (3%)	duy
4,97	1,16	-2,29	5,22	8,3	6,33	-16,32	-14,72	-12,59	10,97	1,88	4,93	-8,17	-8,18	-10,07	7,17	η_{κ} (5%)	voy
4,01	1,42	1,72	-5,46	4,76	5,46	8,87	8,88	-11,67	-8,68	1,12	-2,24	0,22	1,02	1,16	1,9	$\eta_{_{MK}}$ (1 %)	4
3,82	3,03	1,94	-7,02	4,76	5,35	9,85	9,86	-12,94	-10,52	1,56	-4,75	0,8	1,74	3	3,76	η_{MK} (3%)	
2,51	4,48	8,28	-10,94	8,26	4,43	13,72	14,73	-13,88	-11,35	2,09	-5,96	1,17	1,98	3,37	4,71	$\eta_{\scriptscriptstyle MK}~(5\%)$	
3,36	0,52	1,64	4,59	4,76	5,5	-8,22	-8,22	-10,93	7,6	5,32	-2,89	0,37	1,23	1,73	4,52	σ_{Γ} (1%)	Бŧ
3,87	0,38	1,73	4,47	4,76	5,46	-7,89	-7,9	-10,72	7,3	4,73	-7,92	2,12	1,95	1,76	4,52	σ_{Γ} (3%)	IHK
4,34	0,07	2,25	2,12	7,47	5,4	-3,84	-4,62	-10,5	7,0	3,59	-11,31	2,97	2,26	3,19	4,52	σ_{Γ} (5%)	dou
4,75	0,8	1,48	4,88	4,76	5,59	-8,87	-8,88	-11,3	-8,16	-3,15	-5,53	-7,17	-7,18	-9,27	6,17	F_{KC} (1%)	pa 3
6,06	1,78	1,19	5,2	4,76	5,73	-9,88	-9,89	-11,87	-9,01	-4,18	-5,53	-8,38	-8,36	-9,27	6,67	$F_{KC}(3\%)$	ame
7,09	3,02	0	7,03	0	10,12	-13,64	-13,15	-12,11	-10,2	-5,01	-5,71	-11,29	-16,3	-9,35	7,69	F_{KC} (5%)	K
3,92	0,59	1,59	-2,78	4,76	5,53	6,59	-6,59	-9,27	5,92	0,28	-5,14	5,97	5,97	-9,76	-5,14	$\eta_{_{TK}}(1\%)$	
4,1	1,04	1,8	-4,65	4,76	5,72	8,38	-8,39	-11,02	7,74	0,92	-5,51	6,55	6,56	-9,25	-5,51	η_{TK} (3%)	pa
4,8	4,09	3,1	-7,36	9,11	5,88	12,23	-12,72	-14,67	9,57	1,67	-5,51	7,49	7,49	-9,22	-5,91	η_{TK} (5%)	Sco
-3,54	0,48	-1,42	2,29	3,81	4,41	5,25	5,25	7,41	4,71	-0,74	0,66	1,29	4,71	4,36	5,68	A _{TK} (1%)	лре
-2,24	0,22	-1,02	1,16	1,9	2,21	2,61	2,61	3,71	2,31	-0,23	0,82	1,67	4,82	4,36	5,99	A _{TK} (3%)	MO:
-1,78	-0,56	0,05	0,1	0,63	0,21	1,59	0,71	0,27	0,59	-0,06	1,42	1,72	5,46	4,36	6,46	A _{TK} (5%)	Ia k
4,1	0,59	1,59	2,78	4,76	-5,66	7,17	7,18	-9,27	-6,23	0,35	4,76	5,35	9,85	9,86	-12,94	$\pi^*_{\tau\kappa}$ (1%)	00ii
4.0	0.59	1.59	2.78	4.76	-5.93	8.38	8.39	-9.27	-6.88	0.46	4.76	5.5	8.22	8.22	-10.93	$\pi_{\pi_{TV}}^{*}(3\%)$	Typ
3.89	0.62	3.61	-1.64	8.62	-7.17	10.29	11.70	-9.71	-7.16	0.68	4.76	5.66	7.89	7.9	-10.72	$\pi_{\pi_{TV}}^{*}(5\%)$	
-4.75	0.81	1.74	3.01	4.76	5.45	-6.98	-6.98	-9.35	6.26	-3.25	4.88	4.76	5.59	8.87	8.88	π^{*}_{CP} (1%)	
-6.24	1.24	2.02	3.44	4.76	5.3	-7.76	-7.77	-9.52	6.92	-2.87	5.2	4.76	5.73	9.88	9.89	π [*] _m (3%)	
-7.78	3.22	4.62	4.1	9.63	4.53	-9.59	-9.61	-9.77	7.59	-2.08	7.78	4.76	6.53	16.59	16.59	π [*] _{en} (5%)	Ia
-2.89	0.37	1.23	1.73	4.76	-5.71	6.29	6.3	-9.35	5.69	-1.74	1.04	-1.8	4.65	4.76	5.72	η _{xcn} (1%)	26ii
_7.92	2.12	1.95	1,76	4 76	-5 34	4 34	4 34	-10.39	6 38	-2.68	0.48	-1.42	2 29	3.81	4 4 1	n _{ren} (3%)	Tyl
-10.2	6.09	3 29	4.08	33	-4 54	1,51	2 65	-10.7	8.12	_3 35	0.22	-1.02	1.16	19	2 21	n (5%)	На
4.1	0,59	1 59	2.78	4 76	-5.53	_7.17	_7.18	_9.27	6.17	5.68	5.73	8.05	8.06	_9.5	7 19	π^*_{2CB} (1%)	Sim
4.1	0,59	1,59	2,70	4.76	_5 53	_8 38	_8.36	_9.27	6.67	5.98	5,66	7 17	7.18	_9.27	6.23	π [*] (3%)	Ц
4.35	_1.84	5.87	5.12	5.87	-5.03	-12.54	_11 72	_9.93	7.12	6.21	1.93	5 38	6 39	_9.07	5.48	π^* (5%)	
4,55	-1,04	5,67	5,12	5,67	-5,05	-12,34	-11,72	-7,75	7,12	0,21	4,75	5,50	0,37	-2,07	5,40	π _{ΣCB} < · · · ·	
-5,31	0,97	1,86	3,19	4,76	-5,39	6,33	6,33	-9,41	-6,12	-3,84	4,35	4,76	-5,03	5,87	5,87	σ_c (1%)	істрій
-7,92	1,76	2,34	3,97	4,76	-5,14	5,97	5,97	-9,76	-6,58	-2,17	3,05	4,76	-5,51	6,42	6,43	σ _c (3%)	ıңий при
-9,05	5,78	6,42	4,01	6,43	-4,11	1,63	4,73	-10,17	-7,51	-1,31	2,78	4,76	-5,53	7,59	6,59	σ _c (5%)	Вихід

нові [436, 437])

Таблиця Д.3 – Формування бази нечітких правил на базі діагностичної матриці (ав-

Реєс борту	груютн у верто	ься на ольоту	Визначаються аналітично Термогазодинамічні показники Показники						тан	гогу							
Δητκ	ΔT_{n}^{*}	Λn_{CB}	ΛT^*	ΛP^*	$\Delta T_{}^{*}$	$\Delta P_{}^{*}$	ΛP_n^*	ΔT_{min}^*	ΔP_{m}^*	ΔT^*_{aa}	ΔP_{m}^{*}	ΔT_{π}^{*}	ΔP_{π}^{*}	ΔG_n	ΔG_{r}	0	Ą.
1	2	3	4	^{ex} 5	6	7	8	9	10	11	12	13	14	15	16	17	18
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	Етал	он
+			+	+	+	+								+	+	$\pi^*_{\scriptscriptstyle K} \ (1 \ \%)$	
+			+	+	+	+								+	+	$\pi^*_{\kappa}~(3\%)$	
\otimes			+	+	\otimes	\otimes								\otimes	+	$\pi^*_{\scriptscriptstyle K}$ (5%)	
+			+	+	+	+								+	+	$\eta_{\kappa}(1\%)$	doo
\otimes			+	+	\otimes	\otimes								\otimes	+	$\eta_{\kappa}(3\%)$	шре
\otimes			+	+	\otimes	\otimes								\otimes	+	$\eta_{\scriptscriptstyle K}(5\%)$	Хом
+			+	+	+	+								+	+	$\eta_{\scriptscriptstyle MK}~(1\%)$	Γ
\otimes			+	+	\otimes	\otimes								\otimes	+	$\eta_{\scriptscriptstyle M\!K}(3\%)$	
\otimes			+	+	\otimes	\otimes								\otimes	+	$\eta_{\scriptscriptstyle MK}~(5\%)$	
+	+		+	+	+	+	+							+	+	$\sigma_{\scriptscriptstyle \Gamma}$ (1%)	I
+	\otimes		+	+	+	+	+							+	+	σ_{Γ} (3%)	SHIHB
+	\otimes		+	+	+	+	\otimes							\otimes	\otimes	$\sigma_{\scriptscriptstyle \Gamma} {}^{(5\%)}$	srop
+	+		+	+	+	+	+							+	+	F_{KC} (1%)	spa 3
+	\otimes		+	+	+	+	+							\otimes	\otimes	$F_{KC}(3\%)$	CaMe
+	\otimes		+	+	+	+	\otimes							\otimes	\otimes	F_{KC} (5%)	Ч
+	+		+	+	+	+	+	+	+					+	+	$\eta_{\scriptscriptstyle TK}(1\%)$	
+	+		+	+	+	+	+	+	+					\otimes	+	$\eta_{\scriptscriptstyle TK}(3\%)$	а
+	\otimes		+	+	+	+	+	\otimes	\otimes					\otimes	\otimes	$\eta_{\scriptscriptstyle TK}(5\%)$	doo
+	+		+	+	+	+	+	+	+					+	+	A_{TK} (1%)	шbе
+	+		+	+	+	+	+	+	+					\otimes	+	A_{TK} (3%)	KOM
+	\otimes		+	+	+	+	+	\otimes	\otimes					\otimes	\otimes	$A_{_{TK}}(5\%)$	іна
+	+		+	+	+	+	+	+	+					+	+	$\pi^*_{\scriptscriptstyle TK}$ (1%)	yp6
+	+		+	+	+	+	+	+	+					\otimes	+	$\pi^{*}_{_{TK}}$ (3%)	Γ
+	\otimes		+	+	+	+	+	\otimes	\otimes					\otimes	\otimes	$\pi^{*}_{_{TK}}$ (5%)	
+	+	+	+	+	+	+	+	+	+	+	+			+	+	$\pi^{*}_{_{CB}}$ (1%)	
+	+	+	+	+	+	+	+	+	+	+	+			\otimes	+	$\pi^*_{\scriptscriptstyle CB}$ (3%)	
+	\otimes	\otimes	+	+	+	+	+	\otimes	\otimes	\otimes	\otimes			\otimes	\otimes	$\pi^*_{\scriptscriptstyle CB}$ (5%)	На
+	+	+	+	+	+	+	+	+	+	+	+			+	+	$\eta_{\scriptscriptstyle \Sigma CB}$ (1%)	pói
+	+	+	+	+	+	+	+	+	+	+	+			\otimes	+	$\eta_{\scriptscriptstyle \Sigma CB}$ (3%)	a Ty
+	\otimes	\otimes	+	+	+	+	+	\otimes	\otimes	\otimes	\otimes			\otimes	\otimes	$\eta_{\scriptscriptstyle \Sigma CB}$ (5%)	льн
+	+	+	+	+	+	+	+	+	+	+	+			+	+	$\pi^{*}_{\Sigma CB}$ (1%)	Bi
+	+	+	+	+	+	+	+	+	+	+	+			\otimes	+	$\pi^{*}_{\Sigma CB}$ (3%)	
+	\otimes	\otimes	+	+	+	+	+	\otimes	\otimes	\otimes	\otimes			\otimes	\otimes	$\pi^{*}_{\Sigma CB}$ (5%)	
+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	σ_{c} (1%)	стрій
+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	σ_{c} (3%)	ний при
+	\otimes	⊗	+	+	+	+	+	⊗	⊗	⊗	⊗	⊗	⊗	8	⊗	σ_{c} (5%)	Вихід

торський доробок на основі [436, 437])

N⁰		Атрибути і їх значення	Pe	зультат
1	anano	$(\Delta T_2 = Z) \land (\Delta P_4 = Z) \land (\Delta F_c = MP)$	то	$Y_1 = \pi_K^*$
2	лкщо	$(\Delta n = Z) \land (\Delta T_2 = Z) \land (\Delta F_C = MN) \land (\Delta G_T = MP)$	10	$Y_2 = \eta_K$
3		$(\Delta n = LN) \land (\Delta T_2 = Z) \land (\Delta P_2 = LP) \land (\Delta R = LP)$		$Y_3 = \eta_{MK}$
4		$(\Delta n = LN) \land (\Delta G_B = Z) \land (\Delta P_2 = Z) \land (\Delta R = Z)$		$Y_4 = \sigma_{\Gamma}$
5		$\left(\Delta n = MP\right) \land \left(\Delta G_B = Z\right) \land \left(\Delta T_2 = Z\right) \land \left(\Delta R = MP\right)$		$Y_5 = F_{KC}$
6		$(\Delta T_2 = Z) \land (\Delta P_2 = Z) \land (\Delta T_4 = Z) \land (\Delta G_T = Z)$		$Y_6 = \eta_{TK}$
7	anino	$(\Delta n = MN) \land (\Delta T_4 = LN) \land (\Delta G_T = LN) \land (\Delta R = LN)$	то	$Y_7 = A_{TK}$
8	лкщо	$\left(\Delta P_4 = Z\right) \land \left(\Delta P_2 = Z\right) \land \left(\Delta G_T = MN\right)$	10	$Y_8 = \pi^*_{TK}$
9		$\left(\Delta T_4 = Z\right) \land \left(\Delta P_4 = Z\right) \land \left(\Delta R = Z\right)$		$Y_9 = \pi_{CB}^*$
10		$(\Delta n = MP) \land (\Delta G_{B} = Z) \land (\Delta G_{T} = Z) \land (\Delta R = Z)$		$Y_{10} = \eta_{\Sigma CB}$
11		$(\Delta P_2 = MN) \land (\Delta P_4 = Z) \land (\Delta G_T = MP) \land (\Delta F_C = MN)$		$Y_{11} = \pi^*_{\Sigma CB}$
12		$(\Delta P_2 = MN) \land (\Delta P_4 = MN) \land (\Delta F_C = LN) \land (\Delta G_T = MN)$		$Y_{12} = \sigma_C$

Таблиця Д.4 – База нечітких експертних правил (авторський доробок на основі [436, 437])



Рисунок Д.2 – Структура нечіткої нейронної мережі Ванга-Менделя [444–446]

Таблиця Д.5 – Фрагмент даних для бази нечітких експертних правил (авторський до-

Перша вхідна змінна, Т _К	Друга вхідна змінна, P_{Γ}	Третя вхідна змінна, <i>Р</i> _{СВ}	Вихідна змінна, $\pi_{\scriptscriptstyle K}^*$
1,000	1,000	1,000	9,400
0,973	0,817	0,898	9,306
0,984	0,884	0,933	9,307
0,966	0,767	0,854	9,305
0,975	0,812	0,893	9,306
0,953	0,693	0,808	9,304
0,974	0,821	0,895	9,306
0,975	0,819	0,891	9,306
0,966	0,774	0,849	9,305
0,951	0,769	0,804	9,304
0,951	0,691	0,805	9,304
0,973	0,813	0,892	9,306
0,967	0,761	0,852	9,305
0,962	0,765	0,856	9,305
0,963	0,773	0,851	9,305
0,975	0,815	0,889	9,306
0,974	0,814	0,892	9,306
0,952	0,685	0,809	9,304
0,968	0,762	0,858	9,305
0,952	0,688	0,803	9,304
0,976	0,816	0,887	9,306
0,986	0,879	0,935	9,307
0,985	0,875	0,938	9,307
0,965	0,763	0,849	9,305
0,975	0.819	0,896	9,306

робок [446])

Таблиця Д.6 – Значення параметрів дзвоноподібної функції належності, а також ваг нечітких правил, до та після навчання ГННМ (авторський доробок [240] на основі [447])

Параметри	Значення						
	До навчання ГННМ						
b	0,10	0,10	0,10				
С	0,25	0,50	0,75				
W	1,0	1,0	1,0				
	Після навчання ГН	ΉM					
b	0,12	0,11	0,13				
С	0,29	0,53	0,76				
W	0,999	0,997	0,998				



Рисунок Д.3 – Структура системи нечіткого виведення (авторський доробок [240])



Рисунок Д.4 – Координуюча частина нейро-нечіткого регулятора у структурній схемі багатопараметричної АПУ ГТД вертольотів (авторський доробок [240] на основі [447])



Рисунок Д.5 – Система нечіткого логічного висновку (авторський доробок [240], на основі [447])

Таблиця Д.7 – Результати порівняльного аналізу розв'язання задачі управління ГТД вертольотів (авторський доробок [240])

Номер	Архітектура нейронної мережі	Навчалы	на вибірка	Тестова вибірка		
		Номер по-	Відсоток	Номер по-	Відсоток	
		милки	помилки	милки	помилки	
1	Багатошаровий персептрон	10	2,05	45	9,23	
2	Нейронна мережа Хопфілда	10	2,05	38	7,79	
3	Нейронна мережа Хеммінга	10	2,05	30	6,15	
4	Гібридні інтелектуальні системи [447]	10	2,05	18	3,69	
5	Реконфігурована модифікована закрита бортова	10	2,05	11	2,23	
	АПУ ГТД вертольотів					

Таблиця Д.8 – Результати визначення похибок 1-го і 2-го роду (авторський доробок [240])

	Error pi	Error probability in determining the optimal parameters n_{TK} , T_{Γ}^* , n_{CB} and G_T %							
	Парам	етр <i>п</i> _{ТК}	Параметр T_{Γ}^*		Параметр <i>пСВ</i>		Параметр G_T		
Архітектура нейронної мережі	Помилка першого роду	Помилка другого роду	Помилка першого роду	Помилка другого роду	Помилка першого роду	Помилка другого роду	Помилка першого роду	Помилка другого роду	
Багатошаровий персептрон	1,13	1,08	1,14	1,06	1,10	1,05	1,17	1,12	
Нейронна мережа Хопфілда	1,02	0,98	1,00	0,87	1,01	0,88	1,03	0,99	
Нейронна мережа Хеммінга	0,97	0,86	0,94	0,83	0,96	0,85	0,94	0,82	
Гібридні інтелектуальні системи [447]	0,75	0,64	0,76	0,65	0,74	0,63	0,74	0,65	
Реконфігурована модифікована за- крита бортова АПУ ГТД вертольотів	0,38	0,18	0,35	0,16	0,36	0,17	0,35	0,15	

Назва	Опис
Оптимізація ефективності та ресурсу	Моделювання дозволяє вивчити та оптимізувати динаміку перехідних
	процесів у ГТД вертольотів. Це важливо для досягнення максимальної
	ефективності та продовження терміну служби двигунів.
Аналіз та управління перехідними режи-	Математичні моделі дозволяють аналізувати та управляти перехід-
мами	ними процесами в реальному часі. Це важливо для забезпечення стабі-
	льності та ефективності роботи ГТЛ вертольотів при зміні режимів
	експлуатації.
Прогнозування та уникнення аварійних си-	Моделювання дозволяє прогнозувати можливі аварійні ситуації під
туацій	час перехідних процесів та розробляти ефективні заходи для їх попе-
	редження чи швидкого реагування.
Розробка та вдосконалення систем управ-	Результати математичного моделювання служать основою для розро-
ління	бки та оптимізації АПУ ГТД вертольотів під час перехідних процесів.
Економія палива	Математичне моделювання дозволяє визначити оптимальні режими
	роботи для зменшення витрат палива під час перехідних процесів, що
	є критичним для ефективного використання ресурсів.
Вдосконалення динамічних характеристик	Моделювання перехідних процесів дозволяє вдосконалити динамічні
	характеристики ГТД вертольотів, забезпечуючи швидший відгук на
	зміни обтічних умов чи навантаження.
Висновок	Моделювання витрати палива ГТД вертольотів за допомогою мате-
	матичних моделей на основі дослідження перехідних процесів є не-
	від'ємним етапом в розвитку та вдосконаленні сучасних технологій
	ГТД вертольотів.

рингу витрати палива ГТД вертольотів (авторський доробок)



Рисунок Д.6 – П'ятишарова нейронна мережа, що використовує систему нечіткого висновку Sugeno з прямим поширенням сигналу [450–452]

Таблиця Д.10 – Матриця експертних знань для моделювання витрати палива ГТД
вертольотів (авторський доробок [450–452])

Номер		Якщо <вхід>		То	Вага пра-
правила	витрата повітря в камері згоряння	питома потужність дви- гуна	відношення витрати па- лива та повітря у камері згоряння	<вихід>	вила
1	0,985	0,995	0,990	1	1
2	0,975	0,995	0,985	1	1
3	0,965	0,995	0,980	1	1
4	0,940	0,980	0,975	2	1
5	0,930	0,980	0,970	2	1
6	0,920	0,980	0,965	2	1
7	0,895	0,960	0,960	3	1
8	0,875	0,960	0,955	3	1
9	0,855	0,960	0,950	3	1



Рисунок Д.7 – Тип поверхонь нечіткого виведення для різних типів функцій належності [451]

Таблиця Д.11 – Помилка навчання нейро-нечіткої мережі, отримана з різними функ-

ціями належності (авторський доробок [451])

Кількість функцій належності	Помилка навчання	Час виконання, секунд
1	0,000129	5,46
2	0,000367	48,92
3	0,000492	1566,08

Таблиця Д.12 – Вплив кількості затриманих входів на показники ефективності

ทองหวังรงหลุ่มอาการเกิด	(авторський доробок [451])
розв лзуванот зада н	(авторовкий доробок [451])

Кількість затриманих входів	Помилка навчання	Час навчання, секунд
1	0,000326	3,18
2	0,000129	8,44
3	0,000156	17,56
4	0,000286	49,35
5	0,000422	77,93
6	0,000575	185,72



Рисунок Д.8 – Універсальна структура нейро-нечіткої системи (авторський доробок [451])

Таблиця Д.13 – Порівняння отриманих значень витрати палива авіаційного двигуна ТВЗ-117 з паспортними характеристиками та результатами роботи [453]

Режим роботи дви-	Потужність на	Витрата палива, г/к.с.			
гуна	вихідному валу,	Обчислені	Отримані у [453]		
	к.с.	00 menem	Indenoprin	Orphinally [455]	
Надзвичайний	2200	232	230	263	
Злітний	2000	235	236	272	
Номінальний	1700	249	248	295	
I крейсерський	1500	260	258	307	
II крейсерський	1200	280	278	330	

Таблиця Д.14 – Результати порівняльного аналізу ефективності методів (авторський доробок [451])

Методи	Accuracy	F1-міра	Повнота
ANFIS	0,992	0,905	0,976
Random Forest	0,862	0,754	0,811
ExtraTree	0,975	0,907	0,977
MLP	0,723	0,698	0,634



Рисунок Д.9 – Порівняння отриманих значень витрати палива авіаційного двигуна ТВЗ-117 з паспортними характеристиками та результатами, отриманими в [453]

Таблиця Д.15 – Результати визначення похибок 1-го і 2-го роду (авторський доробок [451])

Архітектура нейронної мережі	Імовірність помилки при визнач	Імовірність помилки при визначенні оптимального значення ви-			
	трати	палива			
	Помилка першого роду	Помилка другого роду			
ANFIS (розроблено)	0,76	0,47			
Багатошаровий персептрон	1,04	0,63			
РБФ мережа	1,05	0,66			
Нейронна мережа Хопфілда	1,38	0,82			
Нейронна мережа Елмана	1,77	1,01			
Нейронна мережа Джордана	1,96	1,12			
Нейронна мережа Хеммінга	2,13	1,25			
LSTM-комірка	2,69	1,43			
Нейронна мережа Кохонена	3,17	1,84			
Адаптивна резонансна мережа	3,93	2,36			

Режим роботи двигуна	Абсолютна похибка витрати палива, г/к.с.				
	Результати, отримані за допомогою пас-	Результати, отримані відповідно до дос-			
	портних даних	ліджень у [453]			
Надзвичайний	2	31			
Злітний	1	37			
Номінальний	1	46			
I крейсерський	2	47			
II крейсерський	2	50			

Таблиця Д.16 – Результати порівняльного аналізу (авторський доробок [451])

Таблиця Д.17 – Фрагмент навчальної вибірки (на прикладі авіаційного двигуна ТВЗ-117)

(авторський доробок [454])

Haven	Термогазодинамічні параметри					
помер	n _{TK}	T_H	P_H	k	σ_{ex}	М
1	0,929	0,997	0,993	1,000	1,000	1,000
2	0,933	0,995	0,995	1,000	0,999	1,000
3	0,952	0,992	0,990	1,000	0,997	1,000
4	0,988	0,998	0984	1,000	1,000	1,000
5	0,991	0,991	0,988	1,000	0,998	1,000
256	0,973	0,984	0,992	1,000	0,995	1,000

Таблиця Д.18 – Результати навчання тришарового персептрону різними алгорит-

мами навчання (авторський доробок [454])

Алгоритм навчання	СКВ	Кількість епох на-	Кількість нейронів у
		вчання	прихованому шарі
Back propagation	0,06852	120	4
Quick propagation	0,08371	140	6
Conjugate gradient	0,09982	140	8
Quasi-Newton	0,10125	150	8
Lewenberg-Marquardt	0,36202	150	10
Delta bar delta	0,41755	160	10

Таблиця Д.19 – Опис вхідних і вихідних змінних (авторський доробок [454])

Назва	Діапазон зміни	Терм	Тип функції належності
Вхідна змінна 0,750,86		Низький (Low) Нище середнього (Below average) Середній (Average)	Двостороння функція Гауса
	Вище середнього (Above average) Високий (High)		
Вихідна змінна	0,750,86	Низький (Low) Нище середнього (Below average) Середній (Average) Вище середнього (Above average) Високий (High)	Двостороння функція Гауса

	Ефективність ансамблю нейронних		СКВ	
Архітектура нейронної мережі	Розрахунок	Визначення ро- бочого стану	Розрахунок	Визначення ро- бочого стану
	ККД	двигуна	ККД	двигуна
Ансамбль нейронних мереж з				
лінгвістичною змінною форми:				
Двостороння функція Гауса	99,62	99,35	0,068	0,075
Трапецієдальна	95,38	93,89	0,069	0,077
Трикутна	95,15	93,29	0,068	0,084
П'ятишаровий персептрон	94,32	94,17	1,056	1,078
Нейронна мережа Елмана	93,88	93,75	1,238	1,245
Нейронна мережа Хемінга	93,44	93,18	1,567	1,575
РБФ мережа	93,00	92,85	2,067	2,089
Нейронна мережа Хопфілда	92,53	92,32	2,187	2,217
Нейронна мережа Кохонена	90,62	90,59	2,354	2,482
Адаптивна резонансна мережа	84,18	82,68	4,969	5,011

Таблиця Д.20 – Результати порівняльного аналізу (авторський доробок [454])

Таблиця Д.21 – Результати порівняльного аналізу (авторський доробок [454])

	Ймовірність помилки, %				
	Розраху	нок ККД	Визначення робоч	Визначення робочого стану двигуна	
Архпектура неиронног мережі	Помилка пер-	Помилка дру-	Помилка пер-	Помилка дру-	
	шого роду	гого роду	шого роду	гого роду	
Ансамбль нейронних мереж з					
лінгвістичною змінною форми:					
Двостороння функція Гауса	0,68	0,35	0,67	0,35	
Трапецієдальна	0,84	0,44	0,82	0,46	
Трикутна	1,05	0,57	1,09	0,58	
П'ятишаровий персептрон	1,29	0,66	1,34	0,70	
Нейронна мережа Елмана	1,42	0,84	1,65	0,86	
Нейронна мережа Хемінга	1,63	0,99	1,77	1,04	
РБФ мережа	2,21	1,17	2,29	1,20	
Нейронна мережа Хопфілда	2,34	1,55	2,46	1,63	
Нейронна мережа Кохонена	2,51	1,76	2,63	1,83	
Адаптивна резонансна мережа	4,05	2,18	4,24	2,32	

Таблиця Д.22 – Результати порівняльного аналізу (авторський доробок [454])

	Ймовірність помилки, %				
	Розраху	нок ККД	Визначення робоч	Визначення робочого стану двигуна	
Архпектура неиронног мережі	Помилка пер-	Помилка дру-	Помилка пер-	Помилка дру-	
	шого роду	гого роду	шого роду	гого роду	
Ансамбль нейронних мереж з					
лінгвістичною змінною форми:					
Двостороння функція Гауса	0,84	0,42	0,82	0,42	
Трапецієдальна	1,03	0,53	1,01	0,56	
Трикутна	1,29	0,69	1,34	0,70	
П'ятишаровий персептрон	1,59	0,80	1,65	0,85	
Нейронна мережа Елмана	1,75	1,02	2,03	1,04	
Нейронна мережа Хемінга	2,01	1,20	2,18	1,26	
РБФ мережа	2,72	1,42	2,82	1,45	
Нейронна мережа Хопфілда	2,88	1,88	3,03	1,97	
Нейронна мережа Кохонена	3,09	2,13	3,24	2,21	
Адаптивна резонансна мережа	4,98	2,64	5,22	2,81	

Таблиця Д.23 – Вплив коефіцієнта навчання на результуючу похибку (авторський

доробок [457])

Коефіцієнт швидкості навчання	Кінцеве стандартне відхилення
0,4	1,722
1,5	1,471
3,6	1,471
5,0	1,723

Таблиця Д.24 – Вплив кількості нейронів у шарі нормалізації на результуючу поми-

лку (авторський доробок [457])

Кількість нейронів у шарі нормалізації	Кінцеве стандартне відхилення
5	6,360
10	3,138
15	1,004
20	0,126
25	0,126
50	0,126

Таблиця Д.25 – Вплив довжини лінії затримки на результуючу похибку (авторський

доробок [457])

Довжина лінії затримки	Кінцеве стандартне відхилення
0,5	3,349
1,5	4,354
25,1	7,512
50,1	6,029

Таблиця Д.26 – Вплив кількості пройдених епох на результуючу похибку (авторсь-

кий доробок [457])

Пройдені епохи навчання	Кінцеве стандартне відхилення
0	10,0
1000	0,239
2500	0,239
5000	0,239
10000	0,239

Таблиця Д.27 – Опис складових рис. 5.34 (авторський доробок)

Складова	Опис
а	графік перехідного процесу по частоті обертання вільної турбіни під час роботи двигуна в польотному
	режимі з лінійним ПД-регулятором контуру підтримки частоти обертання вільної турбіни
б	графік перехідного процесу за частотою обертання вільної турбіни при роботі лінійного ПД-регулятора
	та ПД-регулятора зі зменшеним пропорційним коефіцієнтом підсилення (1 – лінійний ПД-регулятор; 2
	– ПД-регулятор зі зменшеним $k_{\mathcal{I}}$)
В	графік перехідного процесу за частотою обертання вільної турбіни під час робо-ти лінійного ПД-регу-
	лятора та квадратичного регулятора (1 – лінійний ПД-регулятор; 2 – квадратичний регулятор)
Г	графік перехідного процесу за частотою обертання вільної турбіни при роботі лінійного ПД-регулятора
	та ПД-регулятора зі змінним коефіцієнтом посилення (1 – лінійний ПД-регулятор; 2 – ПД-регулятор зі
	змінним коефіцієнтом підсилення)
Д	графік перехідного процесу за частотою обертання вільної турбіни при роботі лінійного ПД-регулятора
	та нечіткого П-регулятора (1 – лінійний ПД-регулятор; 2 – нечіткий логічний П-регулятор)

e	графік перехідного процесу за частотою обертання вільної турбіни при роботі лінійного ПД-регулятора
	та нечіткого П-регулятора з коригуючою диференціальною ланкою (1 – лінійний ПД-регулятор; 2 – не-
	чіткий логічний П-регулятор з коригуючою диференціальною ланкою)
ж	графік перехідного процесу за частотою обертання вільної турбіни під час роботи лінійного ПД-регуля-
ж	графік перехідного процесу за частотою обертання вільної турбіни під час роботи лінійного ПД-регулятора та нейронної мережі (1 – лінійний ПД-регулятор; 2 – ПІД-регулятор, розроблений на основі нейро-



Рисунок Д.10 – Графік зниження точності під час тестування: 1 – навчальна вибірка,

2-тестова вибірка (авторський доробок [458])

додаток ж.

ГРАФІЧНІ ТА ТАБЛИЧНІ МАТЕРІАЛИ ДО РОЗДІЛУ 6

Таблиця Ж.1 – Технічні характеристики мікроконтролерів (авторський доробок [479, 481])

Параметр	Raspberry Pi NanoPi M1 Plus	Intel Neural Compute Stick 2	
	(процесор – Allwinner H3)	(процесор – Intel Atom Z3735F)	
Тактова частота	1,2 ГГц	1,33 ГГц	
Максимальний час виконання команди додавання	0,833 нс	0,7519 нс	
Максимальний час виконання команди множення	8,33 нс	0,7519 нс	
Максимальний час виконання команди ділення	16,67 нс	0,7519 нс	
Розрядність	32/64	32/64	
Об'єм внутрішнього ОЗП	1 Гб	2 Гб	

Таблиця Ж.2 – Порівняльний аналіз різних способів розв'язання задачі відновлення інформації (на прикладі авіаційного двигуна ТВЗ-117) (авторський доробок [481])

Моделі	Час обчислення, мкс	Об'ємо займаної	Похи	бка обчислен	ня, %
		пам'яті, байт	n _{TK}	$T^*_{\scriptscriptstyle \Gamma}$	n _{CB}
Кусково-лінійна	46,3	3192	3,677	2,829	6,266
Поліноміальна	51,4	486	1,118	1,515	2,539
Нейромережева	3,6	394	0,719	0,762	0,725



Рисунок Ж.1 – Головна компонента множини \mathbf{X}^n на двовимірній площині (чорні точки – $F_2(V)$, білі точки – X) (авторський доробок [486] на основі [487])



Рисунок Ж.2 – Множина ознак в одній з двовимірних площин: б – множина помилок для площини (а) (чорні точки – **Y**⁰, білі точки – **Y**¹) (авторський доробок [486] на основі [487])



Рисунок Ж.3 – Схема особливостей навчання АНМ: а – допустима узагальнююча здатність; б – перенавчання [487]



Рисунок Ж.4 – Віртуальна установка в програмному комплексі LabVIEW, що моделює систему з трьома датчиками (авторський доробок [486])



Рисунок Ж.5 – Удосконалена функціональна схема відновлення втраченої інформації (авторський доробок [486] на основі [483, 484])

Таблиця Ж.3 – Результати відновлення інформації АНМ у разі відмови датчика T_{Γ}^{*} (ав-

торський доробок [486])

Структура АНМ Похибка відновлення парам		параметрів дв	аметрів двигуна, %	
	G_T	n_{TK}	n_{CB}	T_{Γ}
4–3–4 у складі запропонованої вдосконаленої функціональної схеми (рис. 6.18)	0,31	0,28	0,39	0,31
5–4–5 у складі базової функціональної схеми, розробленої професором Сергієм Жернаковим [483, 484]	0,33	0,31	0,24	0,42

Таблиця Ж.4 – Результати відновлення інформації АНМ у разі подвійних (кратних) відмов датчиків (авторський доробок [486])

Структура АНМ	Похибка відновлення параметрів двигуна, %			
	G_T	n_{TK}	n_{CB}	T_{Γ}
4–3–4 у складі запропонованої вдосконаленої функціональної схеми (рис. 6.18)	0,42	0,39	0,50	0,43
5–4–5 у складі базової функціональної схеми, розробленої професором Сергієм Жернаковим [483, 484]	0,56	0,45	0,44	0,58

Таблиця Ж.5 – Алгоритм виявлення та локалізації відмови каналу двоканального да-

$WSSR_1$	$WSSR_2$	Ситуація	На вихід надходить
≤ 2	≤ 2	Обидва канали справні	Відфільтроване (по Калману) вимірювання каналу з
			найменшим WSSR
≤ 2	≥ 2	Відмова другого каналу	Відфільтроване (по Калману) вимірювання першого ка-
			налу
≥ 2	≤ 2	Відмова першого каналу	Відфільтроване (по Калману) вимірювання другого ка-
			налу
≥ 2	≥2	Обидва канали відмовили	Модельне значення переміщення поршня х

тчика [501-505]

Таблиця Ж.6 – Функціональні можливості банківських фільтрів Калмана

Випадок 1		Випадок 2	
Без виявлення н	есправностей або з ними фільтри Кал-	При відмові одного датчика чи механізму тільки один	
мана зберігають	сигнали індикатора низького рівня, по-	фільтр із правильною гіпотезою генерує сигнал індика-	
казуючи відсутні	ість правильності, і генерують точні оці-	тора несправності та точні оцінки параметрів в робочих	
нки в робочих ме	ежах	межах	
Висновки	1. Сигнали індикатора несправностей в	имагають додаткової обробки для виявлення несправнос-	
	тей. Процес може завершитися інтеграц	ією банку фільтрів Калмана з логікою ізоляції несправнос-	
	тей.		
	2. Логіка ізоляції несправностей визначе	на порогами виявлення та правилами рішення, як показано	
	сигнали індикатора несправностей на порушення встанов-		
	лених порогів. Якщо необхідні правила виявлення несправностей виконуються, то логіка ізоляці		
	несправностей оголошує несправність.		
	3. Ізоляція несправностей досягається, якщо помилка оголошена для всіх сигналів індикатора не-		
справностей, за винятком сигналу, що відповідає вірній гіпотезі про несправність. Розвиток			
ізоляції несправностей залежить від конкретного застосування.			



Рисунок Ж.6 – Модифікована схема навчання нейромережевої моделі ГТД вертольоту з інтегрованими фільтрами банку Калмана (авторський доробок [494])



Рисунок Ж.7 – Структура модифікованої рекурентної нейронної мережі для діагностики та парування відмов вимірювальних каналів у АПУ ГТД вертольотів (авторський доробок [496])

			• •		••• /	(>
Таблиня Ж /	– Метоли	визначения т	Cenmillin	nerviigi	NU391111 (систематизовано	arton	OM)
Tuomin m.	тегоди			perysin	ризаци	cheremannoballo	ubrope	5141)

	L ₁ регуляризація	L ₂ регуляризація		
Опис	Є сумою абсолютних значень всіх парамет-	Є сумою квадратів всіх параметрів моделі.		
	рів моделі.			
Математичний вираз	$RegTerm_{L1} = \lambda \cdot \sum_{i=1}^{N} \theta_i $	$RegTerm_{L2} = \lambda \cdot \sum_{i=1}^{N} \theta_i^2$		
Змінні	λ – коефіцієнт регуляризації, θ_i – параметри моделі, N – кількість параметрів			
Висновок	Вибір між L ₁ і L ₂ регуляризацією залежить від специфіки завдання та властивостей даних			
	регуляризація може призвести до розріджених моделей, корисних для відбору ознак, тоді як			
	L ₂ регуляризація сприяє згладжуванню парам	етрів моделі та запобігання більшим вагам.		

Таблиця Ж.8 – Результати обчислення помилок першого і другого роду (авторський доробок [512])

Метод ідентифікації на основі багатови-	Ймовірність помилки в ідентифікації параметрів						
мірного фільтра Калмана	<i>n_{TK}</i>		n _{CB}		$T^*_{arGamma}$		
	Помилка	Помилка	Помилка	Помилка	Помилка	Помилка	
	першого	другого	першого	другого	першого	другого	
	роду	роду	роду	роду	роду	роду	
Без використання нейронних мереж [494]	0,84	0,63	0,85	0,64	0,79	0,58	
3 використанням РБФ-мережі [495]	0,62	0,38	0,63	0,41	0,56	0,33	
З використанням модифікованої рекурент- ної нейронної мережі	0,49	0,23	0,50	0,24	0,45	0,20	

Таблиця Ж.9 – Основні етапи доведення теореми «Про структурну реконфігурацію

АПУ ГТД вертольотів»

Етап	Опис
Визначення	Приймається, що САУ ГТД вертольотів має початкову структуру, що включає датчики темпера-
структурної ре-	тури та інші справні датчики. При виявленні відмови датчика частоти обертів ротора турбокомп-
конфігурації	ресора, система переходить до альтернативної структури, яка використовує інші доступні датчики
	та елементи керування.
Аналіз стійко-	Застосовується теорія управління та спостережуваності для переконання, що нова структура сис-
сті	теми забезпечує стійкість САУ ГТД вертольотів. Датчики температури, атмосферного тиску, час-
	тоти обертів вільної турбіни та положення напрямних апаратів турбокомпресора повинні бути ви-
	користані для отримання важливих параметрів системи.
Керування по-	Електронний регулятор двигуна (h) та бортовий алгоритм F, які враховують нові вхідні дані від
дачею палива	замінених датчиків, повинні бути налаштовані для ефективного керування подачею палива, щоб
	уникнути перевищення обертів ротора турбокомпресора.
Проведення	Використовуючи математичні і нейромережеві моделі ГТД вертольотів та їх САУ, здійснюються си-
експериментів	муляції та експерименти для підтвердження ефективності нової структури при виявленні відмови.

Таблиця Ж.10 – Додатковий математичний апарат для розширеного доведення тео-

реми (авторський доробок)

Назва	Опис
Розширений ана-	1. Використання функцій Ляпунова вищого порядку або з урахуванням нелінійних елементів
ліз Ляпунова	системи.
	2. Врахування динаміки внутрішніх зв'язків системи та їх взаємовплив на стійкість.
Аналіз чутливості	Вивчення чутливості системи до параметричних змінних та вибір оптимальних параметрів для
	максимізації стійкості
Метод Ляпунова-	Використання методів, які враховують нелінійність в системі та забезпечують стійкість за
Красовського	умови заданих критеріїв.
Аналіз впливу	Вивчення впливу можливих розладів та розробка стратегій управління для забезпечення стій-
розладу	кості в умовах непередбачуваних обставин.
Аналіз обмежень	Врахування обмежень управління та вихідних величин системи під час аналізу стійкості
Метод конструк-	Використання методів конструктивного аналізу для розробки побудовних процедур управління
тивного аналізу	та реконфігурації системи







Таблиця Ж.11 – Алгоритм зворотного поширення помилки (авторський доробок)





Рисунок Ж.9 – Графік навчання тришарового персептрону (авторський доробок)



Параметри ГТД вертольотів

Рисунок 6.10 – Структура бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів (авторський доробок на основі [124]): БДВ – база даних випробувань; НММ – нейромережеві модулі; БКЗ – база концептуальних знань; БЕЗ – база експертних знань; БНП – база нечітких правил; БЗП – база знань прецедентів; БДВ – база даних випробувань; СУБД і СУБЗ – системи управління базами даних і базами знань.



Рисунок Ж.11 – Класи розв'язуваних задач і основні модулі бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів (авторський доробок на основі [124])



Рисунок Ж.12 – Схема функціонування бортової нейромережевої експертної системи моніторингу технічного стану ГТД вертольотів (авторський доробок на основі [124])

Назва прикладної задачі	Застосована нейронна мережа	Accuracy	Precision	Recall	Loss	<i>F</i> -міра	uac, t_i
Ідентифікація багаторежи- мної моделі ГТД вертольо-	тришаровий персептрон архітектури 7–53–36	0,995	0,992	1,0	0,011	0,979	4,827
тів за параметрами, що ре- єструються на борту вер- тольоту	гібридна мережа NARX з радіально-базисним шаром	0,997	0,988	1,0	0,009	0,978	5,613
Ідентифікація багаторежи- мної моделі ГТД вертольо- тів за параметрами, що об- числюються за математич- ною моделию		0,994	0,984	1,0	0,012	0,976	5,824
Ідентифікація зворотної багаторежимної моделі ГТД вертольотів за пара- метрами, що обчислю- ються за математичною моделлю	РБФ-мережа з модифіко- ваних градієнтним алго- ритмом навчання архіте- ктури 6–12–1	0,994	0,989	1,0	0,010	0,974	5,827
Класифікація режимів ро- боти ГТД вертольотів	имів ро- гібридна нейронна ме- режа на основі АРТ-1 і ДАП		0,985	1,0	0,010	0,979	6,332
Ідентифікація динамічної моделі ГТД вертольотів	нейронна мережа Елмана з динамічною стек- пам'яттю	0,995	0,983	1,0	0,011	0,977	5,997
Контроль технічного стану ГТД вертольотів	модифікована LSTM- мережа	0,995	0,986	1,0	0,010	0,972	7,337
Діагностика дефектів в ос- новних вузлах проточної частини ГТД вертольотів	нейромережевий класифі- катор: RBF–персептрон– нейронна мережа Кохо- нена–гібридна мережа	0,995	0,993	1,0	0,009	0,972	8,364
Прогнозування динаміки зміни термогазодинаміч- них параметрів ГТД верто- льотів	GRNN-мережа архітек- тури 2–8–6–1	0,997	0,985	1,0	0,012	0,976	6,224
Ідентифікація можливих несправностей (дефектів) ГТД вертольотів за резуль- татами прогнозування	GRNN-мережа архітек- тури 2–8–6–1	0,996	0,982	1,0	0,011	0,974	6,224
Налагодження дозатора палива ГТД вертольотів	нейронна мережа пря- мого поширення архітек- тури 2–3–2	0,996	0,991	1,0	0,009	0,972	4,735
Тренд-аналізу параметрів ГТД вертольотів	нейронна мережа Джор- дана з динамічною стек- пам'яттю	0,999	0,989	1,0	0,010	0,977	5,992
Визначення та діагностика помпажу ГТД вертольотів на динамічних нейронах з рекурентними зв'яз-		0,995	0,983	1,0	0,011	0,979	4,091

Таблиця Ж.12	– Значення метрик	якості нейромереж	евих моделей (авторський	доробок)

Таблиця Ж.13 – Результати порівняння пропонованої метрики MAD з класичними

Метрика	Значення	Переваги	Недоліки			
Пропонована метрика	0,992	Враховує Accuracy, Recall, Preci-	Більш складна для інтерпретації,			
MAD		sion, F1-міру та час виконання ней-	ніж метрики, що базуються на се-			
		ронної мережі, а також напрямок,	редніх значеннях, а також є більш			
		величину помилки, масштаб даних,	чутливою до змін у масштабі да-			
		і є нечутливою до викидів.	них, ніж метрики, засновані на се-			
			редніх значеннях			
Accuracy	0,995	Простота обчислення	He враховує Recall та Precision			
Recall	1,0	Простота обчислення	Не враховує Precision та F1-міру			
Precision	0,987	Враховує Accuracy та Recall	Не враховує F1-міру			
F-міра	0,976	Враховує Accuracy, Recall та комп-	Більш складна у обчисленні, ніж			
		роміс між ними	Accuracy ta Recall			
Середній час	5,953	Враховує час виконання нейронної	He враховує Accuracy, Recall та F1-			
		мережі	міру			
PerCr	0,992	Враховує помилку нейронної ме-	Не враховує Accuracy, Recall, Pre-			
		peжi (Fault) та час виконання ней-	cision та F1-мipy			
		ронної мережі				
Коефіцієнт детерміна-	0,985	Простота обчислення	Не враховує нелінійну залежність			
ції			між змінними			
Середньоквадратична	0,126 (адапта-	Враховує як напрямок, так і вели-	Чутлива до викидів			
помилка	ція з 0,874)	чину помилки				
Середньоабсолютна по-	0,291 (адапта-	Нечутлива до викидів	Не враховує напряму помилки			
милка	ція з 0,709)					
Середня абсолютна по-	0,073 (адапта-	Враховує як напрямок, і величину	Чутлива до викидів			
милка відсоткового від-	ція з 0,927)	помилки, і навіть масштаб даних				
хилення						
Висновок	Пропонована метрика МАД враховує як напрямок, так і величину помилки, а також масштаб					
	даних, і ϵ нечутливою до викидів. Пропонована метрика <i>MAD</i> ϵ середнім значенням абсолю-					
	$\frac{1}{\Sigma}$					
	тного відхилення медіани $MAD = -\sum_{n i=1} y_i - y_i $, де $n - кількість спостережень, y_i - cпосте-$					
	<i>i</i> =1					
	режене значення для <i>i</i> -го прикладу, <i>y_i</i> – передбачене значення для <i>i</i> -го прикладу. Пропо-					
	нована метрика МАД враховує як напрямок, і величину помилки, оскільки вона обчислю-					
	ється як середнє значення абсолютних помилок. Вона також не чутлива до викидів, тому					
	що вона використовує медіану замість середнього обчислення помилки.					

метриками якості (авторський доробок)





Рисунок Ж.13 – Пропонований зовнішній вигляд модифікованої кабіни вертольоту Мі-8Т (авторський доробок)



Рисунок Ж.14 – Зовнішній вигляд експериментальної установки (авторський доробок)





ванням [525, 526])



бок з урахуванням [525, 526])

Рисунок Ж.16 – Структурна схема розподілу інформаційних потоків програмного засобу «MONITOR» (авторський доро-

501



Рисунок Ж.17 – Головне діалогове вікно інтерфейсу користувача програмного засобу «MONITOR» (авторський доро-

60K)





ДОДАТОК К

АКТИ, ДОВІДКИ ЩОДО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЇ

МІНІСТЕРСТВО ВНУТРІШНІХ СПРАВ УКРАЇНИ

ДЕПАРТАМЕНТ АВІАЦІЙНОЇ БЕЗПЕКИ

вул. Богомольця, 10, м. Київ, 01601 тел.: (044) 256-03-33, факс: (044) 253-64-04 сайт: www.mvs.gov.ua код згідно з ЄДРПОУ 00032684

Про результати наукових досліджень Владова С. I.

Департаментом авіаційної безпеки Міністерства внутрішніх справ України опрацьовано результати наукових досліджень Владова Сергія Ігоровича та повідомляється про таке.

Інтелектуальна система моделювання систем підтримки прийняття рішень за результатами комплексного моніторингу технічного стану авіаційних двигунів вертольотів сприятиме оптимізації процесів прийняття рішень екіпажами повітряних суден у нестандартних польотних ситуаціях.

Створення та впровадження моделей розвитку польотних ситуацій технічного стану авіаційного двигуна прискорить прийняття рішень у непередбачуваних польотних ситуаціях, які характеризуються великим обсягом неповної та невизначеної інформації, обмеженим часом та стресовим психофізіологічним станом пілота.

Обчислення та передбачення сценаріїв розвитку польотних ситуацій у випадку виникнення непередбачуваних обставин пов'язаних з технічним станом авіаційних двигунів може бути застосовано в інформаційних системам підтримки прийняття рішень єдиної системи авіаційної безпеки та цивільного захисту.

Директор

Сергій НАУМЕНКО

Дмитро Клименко 254 92 56



МВС УКРАЇНИ № 2038/42-2024 від 09.02.2024 (1379712) Підписав: Науменко Сергій Миколайович Сертифікат: 368DC35ECECB2DC10400000E39801002D3D0400 Дійсний: э 13.06.2023 09:24:46 по 13.06.2025 09:24:46 Кременчуцький льотний коледж ХНУВС МВС України
МВС УКРАЇНИ ВІЙСЬКОВА ЧАСТИНА 2269 НАЦІОНАЛЬНОЇ ГВАРДІЇ УКРАЇНИ

вул. Діброви 77/95, м. Олександрія, Кіровоградська область, 28000 тел.:(05235)7-10-85, факс:(05235)7-12-83, е-mail: 2269@ngu.gov.ua код ЄДРПОУ 14322859 ОЯ. 12. 2023 № 2550

АКТ

про впровадження результатів наукових досліджень Владова Сергія Ігоровича

Цим актом підтверджую, що результати наукових досліджень Владова С.І. використовуються у військовій частині 2269 Національної гвардії України у вигляді:

1. Нейромережевих моделей, алгоритмів та методик контролю, діагностики та прогнозування, що забезпечують вирішення широкого кола завдань щодо оцінки технічного стану авіаційних газотурбінних двигунів вертольотів на борту вертольоту.

2. Нейромережевих модулів обробки інформації, що входять до складу нейромережевої експертної системи контролю, діагностики та прогнозування технічного стану авіаційних газотурбінних двигунів вертольотів.

3. Нейромережевих алгоритмів відновлення інформації у разі відмови штатних датчиків у складі бортової апаратури управління та контролю авіаційних газотурбінних двигунів вертольотів.

Використання отриманих результатів дозволяє підвищити ефективність та якість результатів оперативного оцінювання технічного стану авіаційних газотурбінних двигунів вертольотів в режимі польоту вертольоту, а також підвищити безпеку польотів вертольотів цивільної і державної авіації України, авіації Повітряних Сил України.

За результатами проведеної апробації визначено, що підхід до моніторингу технічного стану авіаційних газотурбінних двигунів вертольотів, запропонований у наукових дослідженнях Владова С.І., і ґрунтований на застосуванні новітніх інформаційних технологій у польотних режимах, є перспективним для розробки відповідних автоматизованих інтелектуальних систем на підприємствах авіаційної промисловості.

Командир військової частини 2269 Національної гвардії України полковник

T'BAPALS

Руслан РОЗЕНБЕРГ



ТОВАРИСТВО З ОБМЕЖЕНОЮ ВІДПОВІДАЛЬНІСТЮ

«ЕЙР ТАУРУС»

вул. Шевченка, 64, м. Кременчук, Полтавська область, 39600, тел: +38(0536) 75-85-75, факс: +38(0536) 75-85-75 e-mail: officeairtaurus@gmail.com Код ЄДРПОУ 35874196

АКТ

про впровадження результатів дисертаційної роботи «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації» Владова Сергія Ігоровича

Комісія у складі директора Гришкова О.О., головного інженера організації з технічного обслуговування Путятіна Є.В., інженера з технічного обслуговування та ремонту авіаційного і радіоелектронного обладнання Калініна О.В., цим актом підтверджує, що результати дисертаційної роботи «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації» Владова С.І. використовуються у ТОВ «ЕЙР ТАУРУС» у вигляді:

 Алгоритмів і методів контролю та діагностики термогазодинамічних параметрів газотурбінних двигунів вертольотів у польотних режимах на основі розроблених автором нейро-нечіткої експертної системи, що грунтується на застосуванні у процесі контролю та діагностики математичної моделі двигуна, що реконфігурується.

2. Нейромережевих моделей, методів, алгоритмів та методик контролю, діагностики та прогнозування технічного стану газотурбінних двигунів вертольотів.

3. Нейромережевої експертної системи моніторингу технічного стану газотурбінних двигунів вертольотів у польотних режимах.

Використания отриманих результатів дозволяє:

 підвищити ефективність та якість результатів оперативного оцінювання технічного стану газотурбінних двигунів вертольотів у польотних режимах;

– підвищити безпеку польотів вертольотів цивільної та державної авіації України. Зважаючи на вищевикладене, комісія вважає, що запропонований у наукових дослідження Владов С.І. підхід до моніторингу технічного стану газотурбінних двигунів вертольотів у польотних режимах на основі застосування нових інформаційних технологій є перспективним для створення на підприємствах авіаційної промисловості відповідних автоматизованих інтелектуальних систем.

Голова комісії: Директор

Члени комісії: Головний інженер орсанізації з технічного обслуговування

Інженер з технічного обсытонтвання та ремонту авіаційного і радіоелектронного обладнання Олег ГРИШКОВ

Євген ПУТЯТІН

Олег КАЛІНІН



WYDZIAŁ MECHANICZNO-NOLOGICZNY POLITECHNIKI RZESZOWSKIEJ

ul. Kwiatkowskiego 4, 37-450 Stalowa Wola + 48 15 844 89 12

ACT

regarding implementation in the educational process Rzeszów University of Technology (Politechnika Rzeszowska im. Ignacego Łukasiewicza) of Serhii Vladov's dissertation "Methods and means of monitoring helicopter turboshaft engines based on neural network technologies during their operation"

The commission consists of:

chair - Andrzej Chmielowiec, Head of department of industrial processes computerization and robotization (dr);

members - Denys Baranovskyi, Professor of department of industrial processes computerization and robotization (dr hab. inż., professor); Maryna Bulakh, Assistant professor of department of industrial processes computerization and robotization (dr);

after considering the results of Serhii Vladov's dissertation "Methods and means of monitoring helicopter turboshaft engines based on neural network technologies during their operation" results, made a decision to implement them in the educational process Rzeszów University of Technology (Politechnika Rzeszowska im. Ignacego Łukasiewicza) when teaching professional academic disciplines, related to the artificial intelligence methods and means use, in particular, neural networks in the neural network's architectures and training algorithms form, which made it possible to increase the monitoring complex non-linear objects solving applied tasks accuracy and reliability by increasing the accuracy of processing large data sets.

Chair:

Head of department of industrial processes computerization and robotization E R O W N I K Zakładu Informatyzacji doctor i Robotyzacji Procesów Przemy Andrzej CHMIELOWIEC

Members:

Professor of department of industrial processes computerization and robotization doctor habilitatus inżynier, professor

Denys BARANOVSKYI

Assistant professor of department of industrial processes computerization and robotization, doctor

Maryna Bulakh Maryna BULAKH

dr Andrzej Chmielowiec







ACT

of implementation of Serhii Vladov's dissertation "Methods and means of monitoring helicopter turboshaft engines based on neural network technologies during their operation" results in Wyższa Szkoła Gospodarki w Bydgoszczy

This act certifies that the dissertation "Methods and means of monitoring helicopter turboshaft engines based on neural network technologies during their operation" results by the author Serhii Vladov have been implemented in the educational process of Wyższa Szkoła Gospodarki w Bydgoszczy in the study «Informatics» and «Information systems in industry» areas in the form of:

1. The neural network step-by-step creation method for solving applied problems, in which the neural network reduction and measures to increase the model's robustness are justified, indicates an effort to achieve maximum efficiency.

2. Methods of forming universal, homogeneous, and representative training and test datasets for solving applied problems on the data input array basis.

3. The RBF network's new architecture is a polymorphic RBF network, which differs from the traditional one in that due to a separate hidden layer for each independent variable and a different number of multidimensional radial basis functions in each group and the multiplication element using the radial elements summation instead, it allows eliminating its shortcomings and limitations.

4. A linear neural network based on dynamic neurons with recurrent connections with an adjustable smoothing parameter, which allows the first and second kind of errors not to exceed 0.64 and 0.82 %, respectively, makes it possible to predict the changes in dynamics in the complex dynamic objects and systems parameters.

The above-mentioned results use Serhii Vladov's dissertation "Methods and means of monitoring helicopter turboshaft engines based on neural network technologies during their operation" in the Wyższa Szkoła Gospodarki w Bydgoszczy educational process, contributing to the specialists training quality improvement in the study «Informatics» and «Information systems in industry» fields.

Social Sciences College Coordinator

Weronika Gradek



ЗАТВЕРДЖУЮ В.о. ректора Національного аерокосмічного університету ім М. Є. Жуковського «Харківський авіаційний інститут» Олексій ЛИТВИНОВ «________2024 р.

АКТ

щодо впровадження в освітній процес Національного аерокосмічного університету ім. М. Є. Жуковського «Харківський авіаційний інститут»

результатів дисертаційної роботи Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації»

Комісія у складі:

Голова: проректор з НПР, к.т.н., доц. Гуменний А.М.,

Члени: декан факультету літакобудування, к.т.н., доц. Крицький Д.М., завідувач кафедри проектування літаків та вертольотів, к.т.н., доц. Трубаєв С.В.

Розглянувши результати дисертаційної роботи Владова С.І., комісія прийняла рішення щодо впровадження її результатів в освітній процес Національного аерокосмічного університету ім. М. Є. Жуковського «Харківський авіаційний інститут» при провадженні освітньої діяльності за спеціальністю 272 «Авіаційний транспорт» за освітньо-професійними програмами «Технічне обслуговування та ремонт повітряних суден і авіадвигунів» першого (бакалаврського) і другого (магістерського) рівнів вищої освіти; «Інтелектуальні транспортні системи» першого (бакалаврського) і другого (магістерського) рівнів вищої освіти.

Результати дисертаційних досліджень Владова С.І. в області створення бортових інтелектуальних систем моніторингу і управління експлуатацією газотурбінних двигунів вертольотів із застосуванням методів і засобів штучного інтелекту створює умови для розвитку і вдосконаленню наукової і технікоекономічної бази України та сприяє становленню демократичної та правової держави шляхом підвищення ефективності використання вертольотів як в авіаційних підрозділах Міністерства внутрішніх справ України, так і в Збройних Силах України.

Голова комісії

Члени комісії

Андрій ГУМЕННИЙ Дмитро КРИЦЬКИЙ Сергій ТРУБАЄВ

ЗАТВЕРДЖУЮ В.о. директора Льогної вкадемії Паціонального віа піного університету С.М. Неділько (15 » « » 2023 p.

АКТ

щодо впровадження в освітній процес Льотної академії Національного авіаційного університету результатів дисертаційної роботи Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації»

Комісія у складі: голови — заступника директора академії з навчальної, науково-методичної та виховної роботи, к.т.н., доц. Сороки М.Ю.; членів декана факультету льотної експлуатації, д.т.н., проф. Дмітрієва О.М., завідувача кафедри конструкції повітряних суден, авіадвигунів та підтримання льотної придатності, к.т.н., проф. Сікірди Ю.В., розглянувши результати дисертаційної роботи Владова С.І. за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації», прийняла рішення щодо впровадження їх в освітній процес Льотної академії Національного авіаційного університету при викладанні практичних та лабораторних робіт з фахових навчальних дисциплін:

 – за спеціальністю 272 «Авіаційний транспорт», освітньо-професійна програма «Технічне обслуговування та ремонт повітряних суден і авіадвигунів» першого (бакалаврського) рівня вищої освіти,

 – за спеціальністю 272 «Авіаційний транспорт», освітньо-професійна програма «Авіаційний транспорт» другого (магістерського) рівня вищої освіти.

Отримані в дисертаційній роботі нові результати направлені на створення бортових інтелектуальних систем моніторингу і управління експлуатацією газотурбінних двигунів вертольотів із застосуванням методів і засобів штучного інтелекту – експертних систем, нейро-нечітких мереж, нейронних мереж тощо, що підтверджується близько 200 науковими публікаціями.

Голова комісії

Члени комісії

М.Ю. Сорока О.М. Дмітрієв Ю.В. Сікірда

Кременчуцький національний університет імені Михайла Остроградського Навчально-науковий інститут електричної інженерії та інформаційних технологій

ЗАТВЕРДЖУЮ Проректор КрНУ із науково-педагогічної роботи та методичної роботи ностін В. В. 12 2023 р.

АКТ

Комісія у складі голови: проректора КрНУ доц. Сергієнка С.А.; членів комісії: зав. каф. КІЕ проф. Перекреста А.Л., в.о. начальника навчальнометодичного відділу Васечко Л.О., асистента кафедри КІЕ Вадуріна К.О., фахівця Корецького В.В. склала цей акт про впровадження результатів дисертації «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації» автора Владова Сергія Ігоровича.

Склад впровадження:

 метод побудови нейромережевої моделі моніторингу, який за рахунок алгоритму формування однорідної і репрезентативної навчальної і тестової вибірок, дозволяє збільшити достовірність визначення технічного стану складних нелінійних об'єктів (на прикладі газотурбінних двигунів вертольотів);

 архітектури і алгоритми навчання нейронних мереж, що дозволило підвищити точність і достовірність розв'язку прикладних задач моніторингу складних нелінійних об'єктів (на прикладі газотурбінних двигунів вертольотів);

 нейромережеві модулі експертної системи для розв'язку прикладних задач моніторингу складних нелінійних об'єктів (на прикладі газотурбінних двигунів вертольотів).

Комісія встановила відповідність впроваджуваних розробок програмам практичних занять з фахових навчальних дисциплін при підготовці фахівців зі спеціальності 123 «Комп'ютерна інженерія», освітньо-професійна програма «Комп'ютерна інженерія» першого (бакалаврського) і другого (магістерського) рівнів вищої освіти.

Голова комісії Сергій СЕРГІЄНКО Члени комісії Андрій ПЕРЕКРЕСТ Вячеслав КОРЕЦЬКИЙ

Людмила ВАСЕЧКО

ዾ Кирило ВАДУРІН

ЗАТВЕРДЖУЮ Директор Кременчуцького льотного коледжу Харківського національного університету внутрішніх справ Руслан ЯКОВЛЄВ » 2023 p. АКТ

щодо впровадження в освітній процес Кременчуцького льотного коледжу Харківського національного університету внутрішніх справ результатів дисертаційної роботи Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації»

Комісія у складі: Голови комісії:	Першого заступника директора коледжу з безпеки польотів Пєшкова В.В.
Членів комісії:	Заступника директора коледжу – головного інженера інженерно- авіаційної служби Масла А.В.;
	Заступника директора коледжу з навчально-методичної та виховної роботи, канд. пед. наук, доцента Губачова О.І.;
	Професора циклової комісії аеронавігації
	канд. техн. наук, с.н.с. Тягнія В.Г.
	1 олови циклової комісці технічного обслуговування авіаційної техніки, канд. хім. наук, доц. Козловської Т.Ф.

розглянули результати дисертаційної роботи Владова С.І. «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації» та прийняла рішення щодо впровадження їх в освітній процес при викладанні практичних та лабораторних робіт з навчальних дисциплін: «Інформаційні системи контролю і діагностики технічного стану авіаційних двигунів», «Надійність і діагностика авіаційної техніки», «Основи теорії автоматичного регулювання», «Основи надійності авіаційної техніки», «Технічне обслуговування та ремонт авіаційної техніки» за спеціальністю 272 «Авіаційний транспорт», освітньо-професійна програма «Технічне обслуговування та ремонт повітряних суден і авіадвигунів першого (бакалаврського) рівня вищої освіти.

Отримані в дисертаційній роботі нові результати направлені на розробку і втілення в авіаційну галузь експертної системи інтелектуального моніторингу технічного стану газотурбінних двигунів вертольотів у польотних умовах, що надасть можливість підвищити безпеку польотів вертольотів цивільної та державної авіації України.

Голова комісії

Члени комісії

Вадим ПЄШКОВ Анатолій МАСЛО Олександр ГУБАЧОВ Володимир ТЯГНІЙ Тетяна КОЗЛОВСЬКА



АКТ

щодо впровадження в освітній процес Харківського національного університету радіоелектроніки результатів дисертації Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації»

Розглянувши на засіданні кафедри штучного інтелекту результати дисертації Владова С.І. за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації», було прийняте рішення щодо впровадження їх в освітній процес Харківського національного університету радіоелектроніки за спеціальністю 122 «Комп'ютерні науки» освітньо-професійна програма «Штучний інтелект» першого (бакалаврського) рівня вищої освіти й за освітньо-науковою програмою «Системи штучного інтелекту» другого (магістерського) рівня вищої освіти.

Відповідно до отриманих результатів наукових досліджень Владова С.І. в області створення бортових інтелектуальних систем моніторингу і управління експлуатацією газотурбінних двигунів вертольотів **i**3 застосуванням методів і засобів штучного інтелекту – експертних систем, нейро-нечітких мереж, нейронних мереж тощо, набули подальшого розвитку архітектури і алгоритми навчання нейронних мереж, що дозволило підвищити точність і достовірність розв'язку прикладних задач моніторингу технічного стану складних динамічних систем (класифікації, контролю, діагностики, прогнозування, тренд-аналізу тощо), зокрема, авіаційних двигунів вертольотів. Отримані прикладні результати можна використовувати як корисні практичні приклади застосування методів штучного інтелекту для багатьох дисциплін за наведеними вище освітніми програмами.

Завідувач кафедри штучного інтелекту доктор технічних наук, професор

Валентин ФІЛАТОВ

ЗАТВЕРДЖУЮ Проректор Харківського національного університету внутрішніх справ 1857109 доктор юридичних наук, професор, заслужений юрист України АРКІВСЬКИЙ АШОНАЛЬНИ HIBEPCUTE: ВНУТРІШНІХ Олександр МУЗИЧУК СПРАВ 2023 p. 08571

АКТ

впровадження результатів дисертаційної роботи Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації» в науково-дослідну діяльність Харківського національного університету внутрішніх справ

Комісія у складі:

1) декана факультету № 4, доктора юридичних наук, професора Марчука Миколи Івановича (голова);

2) завідувача кафедри протидії кіберзлочинності факультету № 4, кандидата технічних наук, професора Манжая Олександра Володимировича;

3) заступника начальника відділу організації наукової діяльності та захисту інтелектуальної власності — завідувача відділення організації наукової роботи, кандидата юридичних наук Надопти Людмили Сергіївни;

склала цей акт з приводу вивчення наукових положень, методів і методик, що відображені у дисертаційній роботі Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації», та впровадження в науководослідну діяльність Харківського національного університету внутрішніх справ.

Комісією проаналізовано основні результати дисертаційних досліджень, зокрема, наукові праці, в яких опубліковані теоретичні положення дисертаційної роботи «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації»:

1. Vladov S., Shmelov Y., Yakovliev R. Methodology for Control of Helicopters Aircraft Engines Technical State in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. Vol. 3137. 2022. P. 108–125. doi: 10.32782/cmis/3137-10 URL: https://ceur-ws.org/Vol-3137/paper10.pdf

2. Vladov S., Shmelov Y., Yakovliev R. Method for Forecasting of Helicopters Aircraft Engines Technical State in Flight Modes Using Neural Networks. CEUR Workshop Proceedings. Vol. 3171. 2022. P. 974–985. URL: https://ceur-ws.org/Vol-3171/paper70.pdf

3. Vladov S., Shmelov Y., Yakovliev R. Parameter Debugging (Regulation) Method of Helicopters Aircraft Engines in Flight Modes Using Neural Networks. *CEUR Workshop Proceedings*. Vol. 3179. 2022. P. 1–14. URL: https://ceurws.org/Vol-3179/Paper 1.pdf

4. *Vladov S.*, Shmelov Y., Yakovliev R., Petchenko M. Modified Neural Network Method for Trend Analysis of Helicopter Turboshaft Engine Parameters at Flight Modes. *CEUR Workshop Proceedings*. Vol. 3347. 2023. P. 11–29. URL: https://ceurws.org/Vol-3347/Paper 2.pdf

5. *Vladov S.*, Shmelov Y., Yakovliev R., Petchenko M. Neural Network Method for Detecting and Diagnostics Helicopters Turboshaft Engines Surge at Flight Modes. *CEUR Workshop Proceedings*. Vol. 3392. 2023. P. 86–105. doi: 10.32782/cmis/3392-8 URL: https://ceur-ws.org/Vol-3392/paper8.pdf

На основі проведеного аналізу комісія зробила висновок, що подані наукові праці Владова Сергія Ігоровича містять науково-обґрунтовані теоретичні положення, методи і методики, що дає підстави запровадити їх в науководослідну діяльність Харківського національного університету внутрішніх справ.

Також комісією встановлено, що наукові положення, методи і методики, викладені у наукових працях Владова Сергія Ігоровича, можуть бути використані при проведенні наукових досліджень за темою Харківського національного університету внутрішніх справ з державною реєстрацією «Теоретичні та прикладні аспекти розвитку авіаційної сфери».

Комісія дійшла висновку, що результати дисертаційної роботи Владова Сергія Ігоровича за темою «Методи та засоби моніторингу газотурбінних двигунів вертольотів на основі нейромережевих технологій під час їх експлуатації», викладених у вищенаведених наукових працях, слід вважати впровадженими в науково-дослідну діяльність Харківського національного університету внутрішніх справ.

Голова комісії:

Члени комісії:

Микола МАРЧУК

Олександр МАНЖАЙ

Людмила НАДОПТА