

Міністерство освіти і науки України
Харківський національний університет імені В. Н. Каразіна

Кваліфікаційна наукова праця
на правах рукопису

ШЕВЧЕНКО ДМИТРО ОЛЕКСАНДРОВИЧ

УДК 004.9:62-044.7

ДИСЕРТАЦІЯ

**ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ТЕХНІЧНОГО
ДІАГНОСТУВАННЯ ЕЛЕМЕНТІВ ДИНАМІЧНИХ
СИСТЕМ НА ОСНОВІ ДАНИХ МОНІТОРИНГУ**

Спеціальність 122 Комп'ютерні науки

Галузь знань 12 Інформаційні технології

Подається на здобуття ступеня доктора філософії

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

_____ **Д. О. Шевченко**

Науковий керівник: **Стрілець Вікторія Євгенівна** кандидат технічних наук,
доцент

Харків – 2026

АНОТАЦІЯ

Шевченко Д. О. Інформаційна технологія технічного діагностування елементів динамічних систем на основі даних моніторингу. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття ступеня доктора філософії за спеціальністю 122 Комп'ютерні науки (Галузь знань 12 Інформаційні технології). – Харківський національний університет імені В. Н. Каразіна, Міністерство освіти і науки України, Харків, 2026.

Дисертаційна робота присвячена розробці багаторівневої інформаційної технології технічного діагностування динамічних систем та їх елементів на основі даних моніторингу. Актуальність дослідження обумовлена тим, що непередбачувані відмови динамічних технічних систем призводять до значних економічних втрат та безпекових ризиків, а існуючі методи діагностування характеризуються фрагментарністю, гомогенністю ансамблевих підходів, відсутністю уніфікованих методів формування часових представлень для різнорідних компонентів та недостатньою спеціалізацією компонентів багаторівневих технологій. Метою роботи є підвищення якості та забезпечення стійкості технічного діагностування елементів динамічних систем в умовах складності операційних режимів шляхом розробки багаторівневої інформаційної технології за рахунок інтеграції комплементарних підходів машинного навчання з ансамблюванням діагностичних рішень.

Зміст дисертації. У вступі обґрунтовано актуальність теми, сформульовано мету та задачі дослідження, визначено об'єкт і предмет дослідження, розкрито наукову новизну та практичну цінність роботи.

У розділі 1 проведено аналіз існуючих математичних моделей, методів та технологій технічного діагностування динамічних систем на основі даних моніторингу. Дослідження охопило методи попередньої обробки даних, визначення стану технічних систем (класифікація, виявлення аномалій, кластеризація), зменшення розмірності, прогнозування залишкового ресурсу

та багаторівневі інтегровані технології з ансамблевими методами. Виявлені не вирішені проблеми мають системний характер та взаємно підсилюють одна одну, що обґрунтувало задачі дослідження та необхідність розробки нової багаторівневої інформаційної технології.

У **розділі 2** на основі визначених фундаментальних принципів – комплементарності діагностичних підходів, багаторівневої організації, модульності, ансамблювання, поєднання прогнозування та класифікації, використання часових представлень – розроблено інформаційну технологію та побудовано модель її функціонування, що структурує процес діагностування у три рівні. На рівні попередньої обробки та підготовки даних розроблено метод комплексної обробки даних моніторингу та формування диференційованих часових представлень для різномірних компонентів технології. На рівні діагностування стану об'єкта розроблено п'ять методів, організованих у дві паралельні гілки: метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання; метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням; метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою декількох режимів функціонування; метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі; метод класифікації стану на основі гібридної нейронної мережі. На рівні прийняття інтегрованого рішення розроблено метод ансамблювання діагностичних рішень з підтримкою трьох стратегій голосування та автоматизованим систематичним підбором конфігурації. Двоетапний процес налаштування технології забезпечує адаптацію до специфіки конкретного об'єкта діагностування.

У **розділі 3** виконано математичну формалізацію інформаційної технології та всіх її компонентів. Для методу попередньої обробки специфіковано послідовність операцій та два методи формування часових представлень: метод ковзного вікна і метод часових вікон з агрегацією статистик. Для п'яти методів рівня діагностування визначено механізми

формування діагностичних рішень та обчислення їх достовірності. Специфіковано метод ансамблювання з трьома стратегіями голосування: бінарне, зважене за достовірністю та гібридне. Формалізовано інтегроване функціонування технології та двоетапний процес її налаштування з автоматизованим підбором конфігурації ансамблювання.

У **розділі 4** виконано експериментальну перевірку розробленої інформаційної технології на даних моделювання деградації турбовентиляторних двигунів набору C-MAPSS NASA. Використано підмножини FD001 з одним операційним режимом та FD004 з шістьма операційними режимами і двома механізмами деградації. Систематичне дослідження п'яти методів рівня діагностування виявило залежність якості неконтрольованих компонент від складності операційних сценаріїв та високу стійкість методів на основі нейронних мереж. Дослідження методу ансамблювання встановило залежність оптимальної конфігурації від складності даних та підтвердило зростання цінності ансамблювання зі складністю. Технологія діагностування досягла F1-міри 94.12% на FD001 та 92.31% на FD004 зі зниженням лише 1.81%, що підтверджує стійкість до множинних операційних режимів. Порівняльний аналіз з 15 підходами до бінарної класифікації стану підтвердив найвищу F1-міру на складних багаторежимних даних та найменше зниження якості при ускладненні операційних умов. Оцінка обчислювальних ресурсів підтвердила придатність технології для практичного застосування з піковим споживанням пам'яті до 1,4 ГБ та часом опрацювання одного зразка до 41 мс. Порівняння з 27 підходами до прогнозування залишкового ресурсу підтвердило найвищу стійкість із різницею RMSE між підмножинами 1.59 циклів, що у 4.1 рази менше за найближчий конкурент, при конкурентній якості на FD004.

У **висновках** підведено підсумки проведених досліджень. Розроблена багаторівнева інформаційна технологія з інтеграцією комплементарних підходів машинного навчання та ансамблюванням забезпечує високу точність діагностування критичних станів із найвищою стійкістю до множинних

операційних режимів та конкурентоспроможну точність прогнозування залишкового ресурсу. Практична значущість результатів полягає у можливості їх використання при створенні систем прогностичного обслуговування турбовентиляторних двигунів, промислових турбін, підшипників, редукторів та іншого критичного обладнання в авіаційній, енергетичній та обробній промисловості.

Ключові слова: технічне діагностування, багаторівнева інформаційна технологія, машинне навчання, глибоке навчання, штучний інтелект, ансамблювання діагностичних рішень, прогнозування залишкового ресурсу, класифікація стану, виявлення аномалій, алгоритм нечіткої кластеризації, автокодувальники, рекурентні нейронні мережі, LSTM, гібридна нейронна мережа, оптимізація моделі.

ABSTRACT

Shevchenko D. O. Information technology for technical diagnosis of dynamic system elements based on monitoring data. – Qualification scholarly paper: a manuscript.

The dissertation submitted for obtaining the Doctor of Philosophy degree in Information Technology: Speciality 122 Computer science. V. N Karazin Kharkiv National University, Ministry of Education and Science of Ukraine, Kharkiv, 2026.

The dissertation is devoted to the development of a multilevel information technology for technical diagnosis of dynamic systems and their elements based on monitoring data. The relevance of the study is determined by the fact that unpredictable failures of dynamic technical systems lead to significant economic losses and safety risks, while existing diagnostic methods are characterized by fragmentation, homogeneity of ensemble approaches, the lack of unified methods for constructing temporal representations for heterogeneous components, and insufficient specialization of components within multilevel technologies. The objective of this work is to enhance the accuracy and ensure the robustness of technical diagnosis of dynamic system elements under complex operational regimes by developing a multilevel information technology through the integration of complementary machine learning approaches with ensemble-based aggregation of diagnostic decisions.

Content of the dissertation. The **introduction** substantiates the relevance of the topic, formulates the aim and objectives of the study, defines the object and subject of the research, and elucidates the scientific novelty and practical value of the work.

Chapter 1 presents an analysis of existing mathematical models, methods, and technologies for technical diagnosis of dynamic systems based on monitoring data. The study encompassed methods of data preprocessing, technical system state determination (classification, anomaly detection, clustering), dimensionality reduction, remaining useful life prediction, and multilevel integrated technologies

with ensemble methods. The identified unresolved problems are of a systemic nature and mutually reinforce one another, which substantiated the research objectives and the necessity of developing a novel multilevel information technology.

Chapter 2 describes the information technology developed on the basis of defined fundamental principles – complementarity of diagnostic approaches, multi-level organization, modularity, ensemble, combination of forecasting and classification, use of time representations, together with a model of its functioning that structures the diagnostic process into three levels. At the data preprocessing and preparation level, a method of comprehensive monitoring data processing and formation of differentiated temporal representations for heterogeneous technology components has been developed. At the object state diagnosis level, five methods have been developed and organized into two parallel branches: a state classification method based on the ensemble of supervised and unsupervised classical machine learning methods; an anomaly detection and dimensionality reduction method based on autoencoders with differentiated training; a fuzzy state clustering method based on an agent-oriented approach supporting multiple operating modes; a remaining useful life prediction method based on a recurrent neural network; and a state classification method based on a hybrid neural network. At the integrated decision-making level, a method of diagnostic decision ensembling has been developed, supporting three voting strategies with automated systematic configuration selection. A two-stage technology tuning process ensures adaptation to the specifics of a particular diagnostic object.

Chapter 3 presents the mathematical formalization of the information technology and all its components. For the preprocessing method, the sequence of operations and two methods of temporal representation construction have been specified: the sliding window method and the time window method with statistical aggregation. For the five methods at the diagnosis level, the mechanisms for generating diagnostic decisions and computing their confidence have been defined. The ensembling method with three voting strategies has been specified: binary, confidence-weighted, and hybrid. The integrated functioning of the technology and

the two-stage tuning process with automated ensemble configuration selection have been formalized.

Chapter 4 presents the experimental verification of the developed information technology using degradation simulation data of turbofan engines from the NASA C-MAPSS dataset. The FD001 subset with a single operational regime and the FD004 subset with six operational regimes and two degradation mechanisms were utilized. A systematic investigation of the five diagnosis-level methods revealed a dependence of unsupervised component quality on the complexity of operational scenarios and high robustness of neural network-based methods. The investigation of the ensembling method established a dependence of the optimal configuration on data complexity and confirmed the increasing value of ensembling with growing complexity. The diagnostic technology achieved an F1-score of 94.12% on FD001 and 92.31% on FD004, with a decrease of only 1.81%, confirming robustness to multiple operational regimes. A comparative analysis with 15 approaches to binary state classification confirmed the highest F1-score on complex multi-regime data and the smallest quality decrease under increasingly complex operational conditions. Computational resource evaluation confirmed the technology's suitability for practical deployment, with peak memory consumption not exceeding 1.4 GB and per-sample processing time not exceeding 41 ms. A comparison with 27 approaches to remaining useful life prediction confirmed the highest robustness, with an RMSE difference between subsets of 1.59 cycles, which is 4.1 times less than the nearest competitor, while maintaining competitive performance on FD004.

The **conclusions** summarize the findings of the conducted research. The developed multilevel information technology, integrating complementary machine learning approaches with ensemble-based aggregation, ensures high accuracy in diagnosing critical states with the highest robustness to multiple operational regimes and competitive accuracy in remaining useful life prediction. The practical significance of the results lies in their applicability to the development of predictive

maintenance systems for turbofan engines, industrial turbines, bearings, gearboxes, and other critical equipment in the aviation, energy, and manufacturing industries.

Keywords: technical diagnosis, multilevel information technology, machine learning, deep learning, artificial intelligence, diagnostic decision ensembling, remaining useful life prediction, state classification, anomaly detection, fuzzy clustering algorithm, autoencoders, recurrent neural networks, LSTM, hybrid neural network, model optimization.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у наукових фахових виданнях, що входять до міжнародних наукометричних баз Scopus та Web of Science

1. Donets V.V., Strilets V.Y., Ugryumov M.L., **Shevchenko D.O.**, Prokopovych S.V., Chagovets L.O. Methodology of the countries' economic development data analysis. *System Research and Information Technologies*. 2023. No. 4. P. 21–36. Scopus, Q4. DOI: 10.20535/SRIT.2308-8893.2023.4.02. ISSN: 1681-6048
2. Donets V., **Shevchenko D.**, Holikov M., Strilets V., Shmatkov S. Application of a data stratification approach in computer medical monitoring systems. *Eastern-European Journal of Enterprise Technologies*. 2024. Vol. 2, no. 9 (128). P. 6–16. Scopus, Q3. DOI: 10.15587/1729-4061.2024.298805. ISSN: 1729-3774

Статті у наукових фахових виданнях України

3. Лихач О., Угрюмов М., **Шевченко Д.**, Шматков С. Методи виявлення викидів в пробних вибірках при управлінні процесами в системах за станом. *Вісник Харківського національного університету імені В. Н. Каразіна серія «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління»*. 2022. Вип. 53. С. 21-40. DOI: 10.26565/2304-6201-2022-53-03.

(Особистий внесок здобувача: розробка класифікації методів виявлення аномалій, аналіз метрик оцінювання, створення практичної реалізації методів виявлення аномалій, їх тестування та формування висновків, відповідні частини наведені в роботі.

Особистий внесок Лихач О.: аналіз існуючих методів виявлення аномалій включаючи традиційні та глибокого навчання, визначення переваг та недоліків кожного, відповідна частина наведена в роботі.

Особистий внесок Угрюмов М.: постановка проблеми дослідження, перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування.

Особистий внесок Шматков С.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

4. Донець В., Стрілець В., **Шевченко Д.**, Шматков С. Агентно-орієнтований метод кластеризації даних оптового дистриб'ютора. *Вісник Харківського національного університету імені В. Н. Каразіна серія «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління»*. 2022. Вип. 55. С. 6-18. DOI: 10.26565/2304-6201-2022-55-01.

(Особистий внесок здобувача: попередня обробка даних з використанням методів роботи з асиметрією, нормалізації, виявлення аномалій, агрегування даних та аналіз даних з їх візуалізацією, результати наведені у відповідній частині роботи.

Особистий внесок Донець В.: впровадження розробленого методу мультиагентної нечіткої кластеризації на даних оптового дистриб'ютора, відповідні результати наведені в практичній частині роботи

Особистий внесок Стрілець В.: підготовка набору даних для тестування, перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування. Відповідні результатом є матеріалами публікації.

Особистий внесок Шматков С.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

5. **Shevchenko D.**, Ugryumov M., Artiukh S. Monitoring data aggregation of dynamic systems using information technologies. *Innovative technologies and scientific solutions for industries*. 2023. No. 1 (23). P. 123–131. DOI: 10.30837/ITSSI.2023.23.123.

(Особистий внесок здобувача: аналіз проблемної області, опис стандартного та варіаційного автокодувальників, розробка архітектур

автокодувальників, реалізація та практична перевірка архітектур, формування висновків.

Особистий внесок Mykhaylo Ugruytov: постановка проблеми дослідження, перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування.

Особистий внесок Serhiy Artiukh: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

6. Бондаренко К., Стрілець В., **Шевченко Д.** Прогнозування економічних показників за допомогою моделі LSTM. *Вісник Харківського національного університету імені В. Н. Каразіна серія «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління».* 2024. Вип. 64. С. 13-24. DOI: 10.26565/2304-6201-2024-64-02.

(Особистий внесок здобувача: побудова і оцінка моделі LSTM, порівняння і аналіз результатів моделей, формування висновків, результати наведені у відповідній частині роботи.

Особистий внесок Бондаренко К.: підготовка та аналіз набору даних, побудова і оцінка моделі ARIMA, результати наведені у відповідній частині роботи.

Особистий внесок Стрілець В.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

7. **Шевченко Д.О.,** Стрілець В.Є. Багаторівнева інформаційна технологія діагностування технічних систем на основі даних моніторингу. *Вісник НТУ «ХП».* Серія: Інформатика та моделювання. 2026. Вип. 1 (15). С.134-154. DOI: 10.20998/2411-0558.2026.01.09.

(Особистий внесок здобувача: постановка проблеми, розробка і опис багаторівневої інформаційної технології та її компонентів, реалізація та практична перевірка технології, проведення порівняльного аналізу та формування висновків.

Особистий внесок Стрілець В. Є.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування.)

Наукові праці, які засвідчують апробацію матеріалів дисертації

8. Бакуменко Н.С., Донець В.В., Шевченко Д.О., Одинець О.О., Угрюмов М.Л. Методи кластеризації даних на основі інформаційних критеріїв. *Збірник наукових праць міжнародної науково-технічної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2021)»*. Харків: ХНУ ім. В.Н. Каразіна, квіт. 2021, С. 20—23.

9. Шевченко Д.О., Лихач О.Ю., Угрюмов М.Л. Методи виявлення викидів в системах автоматизованого збору даних. *Збірник наукових праць міжнародної науково-технічної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2022)»*. Харків: ХНУ ім. В.Н. Каразіна, листоп. 2022. С. 204—209.

10. Shevchenko D.O., Ugrumov M.L., Kholmohortseva I. S. Anomaly detection methods in data processing using computational intelligence methods. *Academic and Scientific Challenges in the 21st Century: CLIL in Action*. Харків: ХНУ ім. В.Н. Каразіна, 2023, р. 342.

11. Шевченко Д.О., Стрілець В.Є. Зменшення розмірності даних моніторингу в динамічних системах. *Збірник наукових праць міжнародної науково-технічної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2023)»*. Харків: ХНУ ім. В.Н. Каразіна, 2023. С. 162—166.

12. Shevchenko D., Strilets V., Dobriak V. Recurrent Neural Networks for Multivariate Time Series Prediction in Technical Diagnostics Tasks. *IEEE 15th International Conference on Dependable Systems, Services and Technologies, DESSERT'2025*, Athens, Greece, Dec. 2025, 13 p.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ	17
ВСТУП.....	18
РОЗДІЛ 1. АНАЛІЗ МАТЕМАТИЧНИХ МОДЕЛЕЙ, МЕТОДІВ ТА ТЕХНОЛОГІЙ ТЕХНІЧНОГО ДІАГНОСТУВАННЯ.....	28
1.1 Технічне діагностування та роль даних моніторингу	28
1.2 Методи попередньої обробки даних моніторингу.....	31
1.3 Методи визначення стану технічних систем та їх елементів	33
1.3.1 Методи класифікації.....	33
1.3.2 Методи виявлення аномалій.....	34
1.3.3 Методи кластеризації	35
1.4 Методи зменшення розмірності даних моніторингу.....	36
1.5 Методи прогнозування залишкового ресурсу	38
1.6 Багаторівневі технології та ансамблеві методи технічного діагностування	40
1.6.1 Ансамблеві методи.....	40
1.6.2 Багаторівневі технології.....	41
1.7 Узагальнення результатів аналізу.....	42
Висновки до розділу 1	45
РОЗДІЛ 2. РОЗРОБКА ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ТЕХНІЧНОГО ДІАГНОСТУВАННЯ	46
2.1. Багаторівнева інформаційна технологія технічного діагностування та її компоненти	46
2.2. Рівень попередньої обробки та підготовки даних	49
2.3. Рівень діагностування стану об'єкта	53
2.3.1. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання.....	55
2.3.2. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням	58
2.3.3. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування.....	60

	15
2.3.4. Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі.....	62
2.3.5. Метод класифікації стану на основі гібридної нейронної мережі ..	64
2.4. Рівень прийняття інтегрованого рішення.....	65
2.5. Налаштування інформаційної технології та її компонентів	67
Висновки до розділу 2	68
РОЗДІЛ 3. МАТЕМАТИЧНА ФОРМАЛІЗАЦІЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ДІАГНОСТУВАННЯ ТА ЇЇ КОМПОНЕНТІВ.....	
	70
3.1. Формалізація методу попередньої обробки та підготовки даних.....	70
3.2. Формалізація методів рівня діагностування стану об'єкта.....	74
3.2.1. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання.....	74
3.2.2. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням	77
3.2.3. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування.....	80
3.2.4. Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі.....	85
3.2.5. Метод класифікації стану на основі гібридної нейронної мережі ..	89
3.3. Формалізація методу ансамблювання діагностичних рішень.....	93
3.4. Формалізація інтегрованого функціонування інформаційної технології діагностування	96
3.5. Формалізація процесу налаштування інформаційної технології.....	98
3.5.1. Метрики оцінки якості діагностування.....	99
3.5.2. Перший етап. Налаштування методів рівня діагностування стану об'єкта	101
3.5.3. Другий етап. Налаштування методу ансамблювання діагностичних рішень	103
Висновки до розділу 3	104
РОЗДІЛ 4. ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ДІАГНОСТУВАННЯ НА ДАНИХ ТУРБОВЕНТИЛЯТОРНИХ ДВИГУНІВ.....	
	106
4.1. Експериментальні дані та їх підготовка	106

	16
4.1.1. Вибір та характеристика експериментального набору даних.....	106
4.1.2. Підготовка даних для експериментів	109
4.2. Експерименти з методами рівня діагностування стану об'єкта	114
4.2.1. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання.....	114
4.2.2. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням	117
4.2.3. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування.....	121
4.2.4. Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі.....	123
4.2.5. Метод класифікації стану на основі гібридної нейронної мережі	126
4.3. Експерименти з методом ансамблювання діагностичних рішень	130
4.4. Оцінка інформаційної технології технічного діагностування.....	134
4.5. Порівняльний аналіз з існуючими підходами технічного діагностування	140
4.6. Оцінка обчислювальних ресурсів інформаційної технології	143
Висновки до розділу 4	146
ВИСНОВКИ.....	148
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	152
Додаток А. СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ.....	171
Додаток Б. ОПТИМІЗОВАНА КОНФІГУРАЦІЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ДЛЯ РОБОТИ НА ПІДМНОЖИНАХ FD001 ТА FD004....	171

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

- CNN – Convolutional Neural Networks, згорткові нейронні мережі
- Data-driven – підхід, заснований на даних
- GRU – Gated Recurrent Units, рекурентні блоки з керованими вентилями, тип рекурентних нейронних мереж
- Industry 4.0 – Індустрія 4.0, концепція цифрової трансформації промисловості, що базується на інтеграції кіберфізичних систем, IoT та аналізу великих даних для інтелектуалізації виробничих процесів
- IoT – Internet of Things, Інтернет речей, що являє собою мережу фізичних пристроїв, обладнання та датчиків, які збирають та обмінюються даними для моніторингу та управління технічними системами
- LSTM – Long Short-Term Memory, довга короткострокова пам'ять, тип рекурентних нейронних мереж
- PdM – Predictive Maintenance, прогнозне технічне обслуговування, що є стратегією обслуговування обладнання на основі прогнозування технічного стану та ймовірності відмов
- PHM – Prognostics and Health Management, прогностика та управління станом, що є системним підходом до моніторингу, діагностики та прогнозування технічного стану складних систем з метою підвищення їх надійності та безпеки
- RUL – Remaining Useful Life, залишковий ресурс, що визначає прогнозований час або кількість робочих циклів до настання відмови технічної системи чи обладнання

ВСТУП

Обґрунтування вибору теми дослідження. Динамічні технічні системи, такі як турбовентиляторні двигуни, промислові підшипники, редуктори, вітрові турбіни та гідравлічні системи, є критичними компонентами сучасної промислової інфраструктури [1]. Непередбачувані відмови таких систем призводять до значних економічних втрат, простоїв виробництва та потенційних ризиків для безпеки [2, 3]. У зв'язку з цим технічне діагностування стану та прогнозування залишкового ресурсу динамічних систем набуває особливого значення для забезпечення надійності, безпеки та економічної ефективності промислових процесів [4].

Традиційні підходи до технічного обслуговування базувалися на фізичних моделях деградації або планових графіках, що потребували глибокого розуміння механізмів руйнування, точного визначення параметрів моделей та не враховували реальний стан обладнання [2, 5]. Такі методи є трудомісткими та характеризуються суб'єктивністю оцінок та низькою налаштованістю до нових типів дефектів і змінних операційних режимів [6].

Розвиток технологій Індустрії 4.0, Інтернету речей (IoT) та систем диспетчерського контролю і збору даних (SCADA) суттєво розширив можливості збору великих обсягів даних моніторингу технічних систем у реальному часі [7, 8]. Це створило передумови для переходу до методів технічного діагностування на основі даних моніторингу, що використовують математичні моделі і методи машинного навчання та глибокого навчання для аналізу багатовимірних часових рядів, виявлення аномалій, класифікації станів систем та прогнозування залишкового ресурсу [9–11].

Проте аналіз сучасного стану досліджень у галузі технічного діагностування виявляє низку невирішених проблем [1]. По-перше, переважна більшість розроблених методів є фрагментарними та направленними на вирішення однієї задачі, що призводить до неповноти діагностичного висновку. Наприклад методи класифікації визначають поточний стан системи,

але не виявляють невідомі типи несправностей [11]. Методи виявлення аномалій виявляють відхилення, але не класифікують їх типи [12], а методи прогнозування залишкового ресурсу (RUL) орієнтовані виключно на регресію без поєднання з класифікацією стану [13, 14]. Така фрагментарність призводить до неповноти діагностичного висновку та втрати можливостей взаємного збагачення результатів різних підходів.

По-друге, відсутні уніфіковані підходи до попередньої обробки даних та формування часових представлень для різнорідних компонентів технологій діагностування [15]. Класичні методи машинного навчання потребують агрегованих статистик, рекурентні нейронні мережі працюють з послідовностями, згорткові мережі аналізують багатовимірні ознаки, проте систематичні підходи до узгодженого формування диференційованих представлень відсутні [16].

По-третє, існуючі багаторівневі та ансамблеві підходи характеризуються гомогенністю та відсутністю механізмів систематичного підбору конфігурації для конкретного типу об'єктів діагностування [17–19]. Практично відсутні методи побудови гетерогенних ансамблів, що комбінують класичне машинне навчання та глибоке навчання, контрольовані та неконтрольовані підходи з ансамблюванням діагностичних рішень.

По-четверте, спостерігається недостатня спеціалізація компонентів у багаторівневих технологіях, де одні компоненти використовуються для різних підзадач з конфліктними вимогами [20, 21].

Теоретичним і практичним дослідженням у галузі технічного діагностування динамічних систем та прогностичного обслуговування (PHM, Prognostics and Health Management) приділяється значна увага вітчизняними та зарубіжними вченими [1, 2, 4, 9, 11, 22–31]. Розвиток цих напрямків пов'язаний із дослідженнями у сферах методів машинного навчання, обробки сигналів, теорії прийняття рішень та інтелектуальних систем діагностування. Актуальність проблеми підтверджується активними дослідницькими

програмами провідних наукових установ та впровадженням технологій прогностичного обслуговування у промислових компаніях [2, 3, 32].

Тому, з'являється потреба у розробці багаторівневої інформаційної технології, що інтегрує комплементарні підходи машинного навчання з ансамблюванням діагностичних рішень, що визначає актуальність роботи.

Зв'язок роботи з науковими програмами, планами, темами. Тематика дисертаційної роботи пов'язана з дослідженнями:

– Участь у НДР «Моделювання інформаційних процесів у складних і розподілених системах» за 2021 – 2023 рр. (ДР № 0121U109183), у якості виконавця.

Мета і задачі дослідження. Метою дисертаційної роботи є підвищення якості та забезпечення стійкості технічного діагностування елементів динамічних систем в умовах складності операційних режимів шляхом розробки багаторівневої інформаційної технології за рахунок інтеграції комплементарних підходів машинного навчання з ансамблюванням діагностичних рішень.

Для досягнення поставленої мети був визначений наступний ряд задач:

1. Провести аналіз існуючих методів, математичних моделей та технологій технічного діагностування об'єктів на основі даних моніторингу, виявити та обґрунтувати невирішені проблеми.

2. Розробити метод попередньої обробки та підготовки даних, що включає обробку пропущених значень, нормалізацію та трансформацію даних, вибір і інженерію ознак та формування диференційованих часових представлень.

3. Розробити метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання.

4. Розробити метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням.

5. Розробити метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування.

6. Розробити метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі.

7. Розробити метод класифікації стану на основі гібридної нейронної мережі.

8. Розробити метод ансамблювання діагностичних рішень із автоматизованим систематичним підбором конфігурації.

9. Розробити багаторівневу інформаційну технологію технічного діагностування динамічних систем та їх елементів, що інтегрує комплементарні підходи машинного навчання з ансамблюванням рішень.

10. Провести експериментальну перевірку розробленої інформаційної технології на даних моніторингу, здійснити порівняльний аналіз з існуючими підходами та оцінити якість діагностування запропонованих методів та розробленої технології.

Об'єкт дослідження – процеси діагностування технічних систем та їх елементів на основі даних моніторингу під час експлуатації.

Предмет дослідження – математичні моделі, методи та інформаційна технологія обробки даних моніторингу стану технічних систем та їх елементів при діагностуванні.

Методи дослідження полягають у використанні принципів та методів системного аналізу, математичного та імітаційного моделювання, теорії штучного інтелекту та теорії інтелектуальних систем, а також застосування методів математичної статистики та теорії ймовірностей, методів лінійної алгебри та багатовимірного аналізу, методів теорії нечітких множин, методів машинного навчання та теорії штучних нейронних мереж, методів математичної оптимізації, методів теорії прийняття рішень, методів аналізу часових рядів, методів експериментального дослідження та порівняльного аналізу.

Наукова новизна отриманих результатів полягає в наступному.

1. **Вперше** запропоновано багаторівневу інформаційну технологію технічного діагностування динамічних систем та їх елементів, яка поєднує комплементарні підходи машинного навчання з ансамблюванням діагностичних рішень, що підвищує точність і забезпечує стійкість діагностування.

2. **Удосконалено** метод попередньої обробки та підготовки даних шляхом комплексної обробки даних та розробки підходу до формування диференційованих часових представлень, що забезпечує узгоджену обробку даних для різнорідних компонентів технології діагностування.

3. **Удосконалено** метод класифікації стану об'єктів на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання, що дозволяє поєднати переваги контрольованого навчання з можливостями неконтрольованих методів щодо виявлення нових типів аномалій.

4. **Дістав подальшого розвитку** метод нечіткої кластеризації стану об'єктів на основі агентно-орієнтованого підходу шляхом розробки та застосування декількох режимів функціонування.

Особистий внесок здобувача. Дисертаційне дослідження було виконане здобувачем самостійно, всі сформульовані в роботі положення, висновки та рекомендації були обґрунтовані особистими дослідженнями автора. Окремі положення були аргументовані з використанням робіт інших науковців, що мають відповідні посилання в тексті роботи. В індивідуальних наукових роботах використані лише авторські напрацювання та ідеї.

У процесі підготовки дисертаційної роботи автором використовувались системи штучного інтелекту (ШІ-асистенти) як допоміжний інструмент для: (1) підтримки процесу програмної реалізації розробленої інформаційної технології, методів, налагодження та документування коду; (2) генерації, редагування, покращення та структурування тексту дисертаційної роботи на основі авторських рішень, математичних моделей, методів та результатів

експериментів; (3) створення анотацій та перекладу текстів; (4) документування результатів, отриманих з інформаційної технології. Всі рішення, інформаційна технологія, математичні моделі, методи, алгоритми, методологія експериментів, інтерпретація результатів та наукові висновки розроблені автором особисто. Здобувач несе повну відповідальність за наукову достовірність, оригінальність та якість представлених результатів.

Автор дисертації активно брав участь у наукових дискусіях та написанні наукових статей, що були опубліковані за темою дисертації. Також автор доповідав результати досліджень на міжнародних наукових конференціях.

В роботі [33] було показано результати застосування розроблених методів попередньої обробки даних, зменшення розмірності, мультиагентної нечіткої кластеризації та класифікації на основі штучної нейронної мережі на даних економічного розвитку країн. Автору належить огляд методів попередньої обробки даних (обробка асиметрії, нормалізація, виявлення аномалій шляхом поєднання ізоляційного лісу та Z-оцінки, агрегування даних), виявлення аномалій, зменшення розмірності та їх практичне застосування для підготовки даних до застосування методології, а також написання відповідної частини тексту. В роботі [34] було показано розробку та впровадження методології стратифікації даних в комп'ютерній системі медичного моніторингу з застосуванням методів попередньої обробки даних, виявлення аномалій, зменшення розмірності та методу мультиагентної нечіткої кластеризації. Автору належить розробка методів попередньої обробки даних, виявлення аномалій шляхом поєднання ізоляційного лісу та Z-оцінки, методу зменшення розмірності та виявлення аномалій на основі автокодувальників, а також написання тексту роботи. В роботі [35] розглянуто методи виявлення аномалій (викидів) в пробних вибірках при управлінні процесами в системах за станом. Автору належить розробка класифікації методів виявлення аномалій, аналіз метрик оцінювання, створення практичної реалізації методів виявлення аномалій, їх тестування та формування висновків, а також написання відповідної частини тексту. Робота [36] присвячена застосуванню

розробленого агентно-орієнтованого методу мультиагентної нечіткої кластеризації на даних оптового дистриб'ютора. Автору належить попередня обробка даних з використанням методів роботи з асиметрією, нормалізації, виявлення аномалій, агрегування даних та аналіз даних з їх візуалізацією, а також написання відповідної частини тексту. Робота [37] присвячена застосуванню автокодувальників для агрегування даних моніторингу динамічних систем. Автору належить аналіз проблемної області, опис стандартного та варіаційного автокодувальників, розробка архітектур автокодувальників, реалізація та практична перевірка архітектур, формування висновків та написання тексту роботи. В роботі [38] розглянуто прогнозування економічних показників з використанням моделі LSTM. Автору належить побудова і оцінка моделі LSTM, порівняння і аналіз результатів моделей, формування висновків та написання відповідної частини тексту. В роботі [39] представлено багаторівневу інформаційну технологію діагностування технічних систем на основі даних моніторингу, що узагальнює розроблені методи попередньої обробки, виявлення аномалій, зменшення розмірності, класифікації, кластеризації, прогнозування залишкового ресурсу та ансамблювання діагностичних рішень. Автору належить постановка проблеми, розробка та опис багаторівневої інформаційної технології та її компонентів, реалізація та експериментальна перевірка технології на еталонних наборах даних NASA C-MAPSS, проведення порівняльного аналізу з існуючими аналогами та формування висновків, а також написання тексту роботи. В наукових працях [40–43] автор відповідав за всі частини робіт, починаючи з теоретичних основ і закінчуючи практичною реалізацією запропонованих методів і моделей, проведенням експериментальних досліджень та доповідями на конференціях. В роботі [44] розглянуто застосування рекурентних нейронних мереж для прогнозування залишкового ресурсу турбовентиляторних двигунів на основі багатовимірних даних сенсорів. Автору належить розробка та реалізація спеціалізованих архітектур LSTM та GRU, систематичне порівняння архітектур, дослідження впливу

функцій втрат для навчання в умовах промислових даних, експериментальна перевірка та аналізом обчислювальної продуктивності, візуальний аналіз результатів та визначення оптимальних конфігурацій розгортання для практичних систем моніторингу технічного стану, а також написання тексту роботи. Результатом усіх зазначених наукових робіт стало написання матеріалів дисертаційної роботи.

Практичне значення отриманих результатів.

Розроблені методи, математичні моделі та багаторівнева інформаційна технологія можуть бути використані при створенні систем технічного діагностування та прогностичного обслуговування для турбовентиляторних двигунів, промислових турбін, підшипників, редукторів та іншого критичного обладнання в авіаційній, енергетичній та обробній промисловості.

Результати дослідження можуть бути впроваджені у промислові системи прогнозованого технічного обслуговування (PdM/PHM) для автоматизації моніторингу стану обладнання та раннього виявлення деградації, що дозволяє знизити кількість незапланованих простоїв та оптимізувати витрати на технічне обслуговування.

Багаторівнева технологія з інтеграцією комплементарних підходів забезпечує повноту діагностичного висновку через одночасне вирішення задач класифікації стану та прогнозування залишкового ресурсу, що надає операторам комплексну інформацію для прийняття рішень щодо технічного обслуговування обладнання.

Апробація результатів дисертації.

Основні теоретичні положення, висновки і пропозиції, які містяться в дисертації, обговорювалися та були схвалені на засіданнях кафедри комп'ютерних систем та робототехніки Харківського національного університету імені В.Н. Каразіна. Ключові положення дослідження оприлюднені у доповідях на науково-технічних конференціях всеукраїнського та міжнародного рівнів (2021–2025 роки).

- Н.С. Бакуменко, В.В. Донець, Д.О. Шевченко, О.О. Одинець, М.Л. Угрюмов. Методи кластеризації даних на основі інформаційних критеріїв // Збірник наукових праць міжнародної науково-технічної конференції (м. Харків, 21-23 квітня 2021 року). – Харків: ХНУ ім. В.Н. Каразіна, 2021. – С.20-23.
- Д.О. Шевченко, О. Ю. Лихач, М.Л. Угрюмов. Методи виявлення викидів в системах автоматизованного збору даних // Збірник наукових праць міжнародної науково-технічної конференції (м. Харків, 23-25 листопада 2022 року). – Харків: ХНУ ім. В.Н. Каразіна, 2022.
- D.O. Shevchenko, M. L. Ugryumov, I. S. Kholmohortseva. Anomaly detection methods in data processing using computational intelligence methods // Збірник наукових праць XII Всеукраїнської міжнародної наукової конференції з міжнародною участю “Academic and Scientific Challenges in the 21st Century: CLIL in Action”. – Харків: ХНУ ім. В.Н. Каразіна, 2023. – 342 с.
- Д.О. Шевченко, В.Є. Стрілець. Зменшення розмірності даних моніторингу в динамічних системах. // Збірник наукових праць 9-ої Міжнародної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2023)». – Харків: ХНУ ім. В.Н. Каразіна, 2023.
- D. Shevchenko, V. Strilets, V. Dobriak. Recurrent Neural Networks for Multivariate Time Series Prediction in Technical Diagnostics Tasks. In IEEE 15th International Conference on Dependable Systems, Services and Technologies, DESSERT'2025. 19-21 December, 2025, Athens, Greece.

Публікації.

Теоретичні положення, результати тестування і висновки дисертації викладені у 12 наукових працях, з яких 2 у наукових фахових виданнях, що входять до міжнародних наукометричних баз [33, 34] та 5 у наукових фахових виданнях України [35–39] та 5 тез наукових доповідей [40–44].

Структура та обсяг дисертації.

Дисертаційна робота складається з вступу, чотирьох розділів, висновків, списку використаних джерел і двох додатків. Загальний обсяг дисертації

становить 183 сторінки: у тому числі анотації на 8 сторінках, зміст на 3 сторінках, основний текст на 135 сторінках, список використаних джерел із 150 найменувань на 19 сторінках та два додатка на 13 сторінках. Робота містить 30 таблиць, 9 рисунків.

РОЗДІЛ 1.

АНАЛІЗ МАТЕМАТИЧНИХ МОДЕЛЕЙ, МЕТОДІВ ТА ТЕХНОЛОГІЙ ТЕХНІЧНОГО ДІАГНОСТУВАННЯ

1.1 Технічне діагностування та роль даних моніторингу

Прогнозування та управління технічним станом (Prognostics and Health Management, PHM) є комплексним методологічним рішенням для управління станом технічних систем та їх елементів шляхом підвищення надійності, ремонтпридатності, безпеки та економічної ефективності промислових систем [1]. Ключовим фактором реалізації стратегії прогнозного технічного обслуговування (Predictive Maintenance, PdM) [4] є прогнозування залишкового ресурсу (Remaining Useful Life, RUL) та діагностування стану об'єктів.

Динамічні технічні системи та їх елементи характеризуються складною природою деградаційних процесів, що ускладнює їх моніторинг та діагностування. Зокрема, вітрові турбіни демонструють постійні зміни швидкості обертання під час запуску, зупинки та при змінах вітрових умов, що призводить до варіацій швидкості ротора та ускладнює процес моніторингу [6]. Аналогічно, гідравлічні системи є прикладом складних нелінійних систем, де діагностика стала особливо важливою завдяки досягненням у аналізі великих даних та застосуванню машинного навчання [7]. Головною особливістю сучасних технічних систем є їх багаторежимність та нестационарність. Одним з найважливіших аспектів є критичність системи, але їй часто надається низький пріоритет при оцінці стану [8].

Відмови промислового обладнання класифікуються за такими характеристиками, як поступова деградація та раптові відмови. Поступова деградація визначається поступовим накопиченням пошкоджень протягом тривалого часу експлуатації, що дозволяє застосовувати методи прогнозування залишкового ресурсу. В свою чергу, раптові відмови виникають без очевидних попередніх ознак деградації. Моніторинг та прогнозування стану може суттєво

підвищити ефективність технічного обслуговування та забезпечити раннє повідомлення про відмову [10]. Робота [3] показує, що якість виробленої продукції є важливим параметром для виявлення можливих дефектів у машинах. Тому повинна бути врахована разом з кількістю відпрацьованих годин під час технічного діагностування.

Багатофакторна природа деградації обумовлена комплексною взаємодією різних механізмів руйнування. У вітрових турбінах деградація може бути спричинена кількома типами механізмів, які включають механічне зношування, процеси, корозію та комбіновані ефекти змінних навантажень [45]. Ця багатофакторність ускладнює процес діагностування та потребує застосування комплексних підходів до аналізу стану об'єктів.

Результатами моніторингу стану динамічних технічних систем та їх елементів є багатовимірні часові ряди, представлені як набори вимірів від множини сенсорів, отриманих у певні проміжки часу. Такі часові ряди є дискретними моделями для моніторингу стану об'єктів, які зазвичай містять параметричні невизначеності, є нестационарними та зашумленими. Розвиток технологій Індустрії 4.0 (Industry 4.0) та Інтернету речей (Internet of Things, IoT) суттєво розширив можливості збору даних моніторингу технічних систем та їх елементів. Більшість вітрових ферм наразі використовують системи диспетчерського контролю та збору даних (Supervisory Control and Data Acquisition, SCADA) для збору, реєстрації та зберігання операційних даних вітрових турбін [45]. Сучасні дослідження також використовують дані зібрані через IoT сенсори для діагностування таких станів, як дефекти підшипників, перекиє валу, дисбаланс ротора та ослаблення паса [46]. Застосування даних від декількох сенсорів дає можливості для прогнозування стану компонентів, але збільшення кількості сенсорів і типів відмов ускладнює процес класифікації дефектів [7]. Також, багатовимірні сенсорні дані дозволяють застосовувати метод оцінки багатозмінного стану (Multi-Variables State Estimate Technique, MSET) для ефективного моніторингу стану промислового

обладнання [10]. На основі аналізу, виділяються такі вимоги до технологій технічного діагностування, як:

– *раннє виявлення аномалій*, що характеризує здатність технології діагностування виявляти відхилення від нормального стану на ранніх стадіях деградації. Це є критичною вимогою для запобігання відмовам та зменшення витрат на ремонт [9];

– *прогнозування RUL* є критичним фактором для реалізації стратегії PdM [4]. Це дозволяє планувати заходи технічного обслуговування, оптимізувати графіки простоїв та є частиною обслуговування на основі стану (Condition-Based Maintenance, CBM), що економічно ефективною стратегією [5];

– *стійкість до шумів та невизначеності*. Промислові дані моніторингу часто характеризуються високим рівнем шуму, наявністю викидів та пропущених значень. Технології діагностування повинні бути стійкими до цих факторів [4];

– *адаптивність до змін операційних режимів*. Динамічні системи експлуатуються за різних операційних умов, що вимагає здатності технологій та методів діагностування адаптуватись до змінних режимів роботи [6].

Отже технічне діагностування – це комплексний процес визначення стану системи, виявлення аномалій, класифікації типів несправностей та прогнозування залишкового ресурсу (Remaining Useful Life, RUL) на основі аналізу багатовимірних часових рядів даних моніторингу [1, 4]. Головними перевагами використання інформаційних технологій діагностування на основі даних є раннє виявлення аномалій на початкових стадіях деградації [9], прогнозування залишкового ресурсу для планування технічного обслуговування [4, 5], класифікація типів несправностей для прийняття обґрунтованих рішень [11], стійкість до шумів та невизначеності промислових даних [4], а також адаптивність до змін операційних режимів роботи систем [6].

Традиційні підходи технічного діагностування базуються на фізичних моделях деградації, що потребує глибокого розуміння механізмів руйнування та точного визначення параметрів, що призводить до зменшення стійкості та здатності до узагальнення [21]. Методи на основі даних набули широкого поширення завдяки наявності великих обсягів даних моніторингу та розвитку машинного навчання. Попри високу точність, вони обмежені якістю та кількістю даних та схильні до перенавчання [4, 29]. Гібридні підходи ефективно вирішують недоліки обох типів моделей [29] за рахунок поєднання фізичних моделей з методами на основі даних. Використання моделювання для генерації синтетичних даних з адаптацією домену дозволяє знизити помилку передбачення з понад 12% до приблизно 5% [47, 48].

Розвиток технологій та методів технічного діагностування відображає перехід від традиційних статистичних підходів до методів машинного навчання [11]. Зі зростанням складності промислових процесів штучний інтелект постає, як потужний інструмент для виявлення дефектів та діагностування [9]. Задача технічного діагностування на основі даних моніторингу може бути визначена, як вирішення взаємопов'язаних задач, таких як: попередня обробка даних; класифікація стану системи; виявлення аномалій; кластеризація станів; зменшення розмірності даних; прогнозування залишкового ресурсу; ансамблювання діагностичних рішень [15, 16].

1.2 Методи попередньої обробки даних моніторингу

Попередня обробка даних моніторингу є важливим етапом побудови технологій технічного діагностування, оскільки якість вхідних даних безпосередньо впливає на якість роботи всіх методів діагностування об'єктів [15, 49, 50]. У промислових умовах дані моніторингу характеризуються значними проблемами якості, які необхідно усунути до застосування методів діагностування.

– *Пропущені значення та викиди.* Переривання роботи сенсорів створюють прогалини у часових рядах, що суттєво знижує точність методів

прогнозування [51]. Для усунення пропусків застосовуються стратегії від простого заповнення середніми значеннями та лінійної інтерполяції до сучасних підходів на основі LSTM-моделей [51]. Викиди можуть бути наслідком справжніх аномалій або помилок вимірювання [12]. Для їх виявлення використовуються статистичні методи у одновимірних випадках та дерева ізоляції для багатовимірних даних [12, 52, 53].

– *Шум та висока розмірність.* Високочастотний шум маскує тренди деградації, що вимагає застосування ковзної медіанної фільтрації або широких згорткових шарів [54, 55]. Сучасні системи моніторингу генерують багатовимірні дані з десятків сенсорів [56, 57], що призводить до зниження якості прогнозування, збільшує обчислювальну складність та ризик перенавчання.

– *Незбалансованість даних.* Значне переважання даних нормальної роботи над аварійними станами призводить до зміщення моделей [58], що потребує спеціальних підходів до формування навчальної вибірки.

Оскільки сенсори вимірюють величини різної фізичної природи з різними діапазонами значень, то нормалізація параметрів є обов'язковою [55, 59]. Основними методами є мін-макс нормалізація до визначеного діапазону [55], стандартизація з центруванням відносно нуля [60], нормалізація на основі медіани та інтервалу між квантилями [53]. Параметри нормалізації обчислюються на навчальній вибірці та застосовуються до тестових даних для відповідності обчислень [50]. Зважаючи на те, що методи машинного навчання працюють краще на даних нормального розподілу виникає потреба до приведення асиметричних до нормального розподілів. Для цього застосовується перетворення Бокса-Кокса, що автоматично визначає оптимальний параметр трансформації, та логарифмічне перетворення для даних з експотенційним характером [50].

Зважаючи на високу розмірність даних та можливу кореляцію ознак використовується інженерія та вибір ознак, що дозволяє зменшити розмірність і прибрати корелюючі ознаки. Вибір ознак здійснюється через кореляційний

аналіз для виявлення параметрів з монотонною поведінкою відносно цільового значення [55] та методи важливості ознак у деревах рішень для визначення параметрів за їх внеском у передбачення [61]. Інженерія ознак дозволяє створити інформативні представлення, що явно відображають деградаційні процеси [16, 58, 62]. Основні підходи включають: статистичні характеристики ковзних вікон для фіксації локальних трендів [16, 63]; арифметичні комбінації параметрів для виявлення залежностей [61]; диференційні ознаки для фіксації швидкості зміни параметрів як індикатора деградації [60].

Дані моніторингу представлені в табличній формі, яка має бути підготовлена до використання методами машинного навчання у вигляді часових представлень [16, 64]. Основними підходами до підготовки даних є метод ковзного вікна, що формує послідовності фіксованої довжини з історією значень параметрів [57, 59, 63] та часова агрегація, що створює статистичні узагальнення у вікнах різного масштабу, формуючи багатовимірне представлення часової динаміки [56, 63].

1.3 Методи визначення стану технічних систем та їх елементів

Визначення стану об'єкту діагностування є ключовою задачею технічного діагностування, яка дозволяє своєчасно виявляти відхилення від нормального режиму роботи та прогнозувати можливі відмови. У сучасній літературі розглядаються три основні підходи: (1) методи класифікації, (2) методи виявлення аномалій та (3) методи кластеризації.

1.3.1 Методи класифікації

Методи класифікації відносяться до контрольованого машинного навчання і вимагають розміченого набору даних. У технічному діагностуванні застосовуються як традиційні, так і методи на основі глибокого навчання, які різняться підходами до діагностування стану.

До традиційних методів класифікації належать дерева рішень, випадковий ліс, метод опорних векторів (SVM), метод k-найближчих сусідів та

інші. У роботі [65] метод SVM досягає високої точності для діагностування підшипників, а у роботі [66] з оптимізацією через алгоритм оптимізації роєм – ще кращих результатів. Випадковий ліс демонструє високу стійкість до шумів та можливість роботи з багатовимірними даними [67].

В свою чергу методи глибокого навчання здатні діагностувати стан з мінімальною обробкою даних, усуваючи необхідність інженерії ознак [30]. Це особливо важливо при роботі з багатовимірними часовими рядами даних моніторингу. Згорткові нейронні мережі (CNN) виявляють локальні закономірності деградації з інваріантністю до часових зсувів [63]. Рекурентні мережі LSTM та GRU захоплюють довгострокові часові залежності, де стан визначається історією зміни параметрів [54]. Гібридні архітектури CNN-LSTM поєднують виявлення локальних ознак з моделюванням часової динаміки, досягаючи найкращих результатів [54].

Незважаючи на показники якості методів класифікації існують проблеми, які ускладнюють діагностування стану. Такими є незбалансованість класів, коли дані справного стану домінують [68, 69], потреба у великих обсягах розмічених даних [9] та перенавчання на специфічних режимах з поганим узагальненням [70].

1.3.2 Методи виявлення аномалій

На відміну від методів класифікації, які потребують розмічених даних про несправності, методи виявлення аномалій фокусуються виключно на моделюванні нормальної поведінки системи. Відхилення від цієї моделі інтерпретуються як потенційні аномалії. Найпростішим підходом є статистичні методи, що базуються на припущенні про певний розподіл нормальних даних [67]. Однак вони мають обмеження для багатовимірних часових рядів, де складні взаємозв'язки між параметрами не описуються простими статистичними моделями.

Для подолання обмежень статистичних методів при роботі з багатовимірними даними використовуються методи на основі відстаней, такі

як метод найближчих сусідів та локальний фактор викиду, що аналізують локальну щільність даних [71, 72]. Подальшим розвитком цього напрямку є ліс ізоляції, що базується на принципі ізоляції аномалій від основної маси даних [12, 52]. У роботі [12] метод виявив значну частку аномалій при передачі лише мінімальної кількості даних.

Найбільш перспективними для складних технічних систем є методи на основі реконструкції, що моделюють дані через їх стиснене представлення. Зокрема, автокодувальники досягають високої якості у виявленні аномалій без ручної інженерії ознак [20]. Розширенням цього підходу є варіаційні автокодувальники, що моделюють ймовірнісний розподіл у латентному просторі [73, 74]. Гібридний підхід поєднання варіаційного автокодувальника та генеративної мережі демонструє покращене раннє виявлення несправностей [74]. У роботі [21] варіаційний автокодувальник використовується для визначення справного стану через порівняння відхилень від визначеного розподілу. До основних проблем можна віднести, те що є складності у визначенні порогів аномальності з балансом між помилками першого і другого роду [67, 75] та адаптація до нових типів аномалій.

1.3.3 Методи кластеризації

Третім підходом до визначення стану є методи кластеризації, які виявляють групи схожих станів без попередньої розмітки. Це дозволяє ідентифікувати різні режими роботи, стадії деградації або типи несправностей у ситуаціях, коли експертна розмітка відсутня або неповна.

Найпоширенішим методом є К-середніх, що мінімізує суму квадратів відстаней до центрів кластерів. У роботі [76] комбінація К-середніх з глибокою Q-мережею досягла майже повної точності у класифікації 11 типів несправностей. Ієрархічна кластеризація будує дерево вкладених кластерів для аналізу на різних рівнях деталізації [77]. DBSCAN виявляє кластери довільної форми, проте потребує ретельного налаштування параметрів.

Важливим розширенням традиційних методів є нечітка кластеризація, яка дозволяє часткову належність до кількох кластерів. Це особливо важливо для моделювання перехідних станів деградації. Зокрема, нечіткий метод с-середніх (FCM, Fuzzy c-means) мінімізує зважену суму відстаней з вагами визначеними степенями належності [78]. Гібридні алгоритми FCM з імітацією відпалу та генетичним алгоритмом долають чутливість до початкових центрів [79].

Для роботи з багатовимірними даними ефективною є кластеризація у просторі зменшеної розмірності, яка уникає проблем з стратифікацією на базі багатьох ознак. Зокрема, кластеризація у латентному просторі автокодувальника виявляє нелінійні структури, як описано в [80]. Альтернативним підходом є самоорганізовані карти (SOM), які забезпечують зменшення розмірності та кластеризацію у єдиній структурі [81].

Проте методи кластеризації мають низку обмежень: визначення оптимальної кількості кластерів без експертних знань; інтерпретація кластерів у контексті реальних станів [82]; адаптація до змінних операційних режимів, де кластеризація може виявляти режими роботи замість станів деградації.

1.4 Методи зменшення розмірності даних моніторингу

Дані моніторингу динамічних систем часто характеризуються високою розмірністю. Наприклад для турбовентиляторних двигунів реєструється понад 20 параметрів, а для промислових установок це число може сягати сотень показників. Висока розмірність призводить до надлишковості інформації, значних обчислювальних витрат та ризику перенавчання через високу розмірність. Методи зменшення розмірності дозволяють виділити найбільш інформативні ознаки та покращити якість методів діагностування об'єктів.

Серед класичних підходів до зменшення розмірності найбільшого поширення набули методи, які базуються на лінійних перетвореннях даних. Метод головних компонент (PCA) здійснює ортогональне перетворення вхідних змінних у новий простір незалежних компонент, які упорядковані за

величиною пояснюваної дисперсії. У роботі [83] PCA успішно застосовано разом з відбором ознак на основі інформаційного приросту для діагностики фотоелектричних систем, а дослідження [80] демонструє ефективність PCA з автокодувальником для зменшення розмірності даних у периферійних обчислювальних пристроях, де збереження інформативності при суттєвому зменшенні обсягу є критичним.

Альтернативним лінійним підходом, що враховує інформацію про класову структуру даних, є лінійний дискримінантний аналіз (LDA), який спрямований на максимізацію роздільності між класами при мінімізації внутрішньокласової дисперсії. Дослідження [84] використовує LDA для діагностики несправностей підшипників, а робота [85] показала вищу точність FDA порівняно з PCA для діагностики коробок передач, що пояснюється безпосередньою оптимізацією роздільності класів. Основними перевагами лінійних методів є простота реалізації, низька обчислювальна складність та інтерпретованість результатів. Проте вони припускають лінійну структуру даних і не здатні виявляти складні нелінійні залежності, які властиві процесам деградації у технічних системах.

Для вирішення обмежень лінійних підходів у задачах діагностування застосовуються методи нелінійного зменшення розмірності, які здатні виявляти та зберігати складну структуру даних. Зокрема, метод UMAP здатен зберігати локальну і глобальну структуру даних. Дослідження [86] демонструє застосування UMAP для виявлення несправностей у морських дизельних двигунах, де нелінійне зменшення розмірності дозволило виявляти аномалії на два такти раніше порівняно з традиційними методами.

Стрімкий розвиток технологій глибокого навчання призвів до появи нового класу методів зменшення розмірності на основі нейронних мереж. Автокодувальники стали домінуючим підходом у сучасних технологіях діагностування. Дослідження [20] демонструє метод моніторингу обертових машин, де автокодувальник безпосередньо виділяє значущі ознаки з необроблених вібраційних сигналів. Робота [82] показала, що покращена

нейронна мережа HELM перевершила автокодувальники для гідравлічних систем. Подальшим удосконаленням традиційних автокодувальників є варіаційні автокодувальники (VAE). Вони моделюють розподіл даних у латентному просторі явним чином через вірогідності. Дослідження [21] використовує VAE для виявлення несправностей підшипників та визначає стан елементів через відхилення від еталонного розподілу. Модифікація архітектури у вигляді β -VAE вводить додатковий параметр β для контролю балансу між реконструкцією та структуруванням латентного простору. Роботи [87, 88] демонструють застосування β -VAE для зменшення розмірності та виявлення аномалій досягаючи високих метрик.

Аналіз впливу методів зменшення розмірності на якість діагностування показує неоднозначність їх застосування. Огляд [89] підкреслює критичність зменшення розмірності та виділяє, що необроблені багатовимірні дані призводять до погіршеної продуктивності. Зменшення розмірності впливає на якість діагностування через кілька механізмів: усунення шуму та надлишкової інформації, прискорення обробки [80, 86] та забезпечення можливості візуалізації багатовимірних залежностей [90]. Водночас надмірне зменшення призводить до втрати значущої інформації для діагностування.

1.5 Методи прогнозування залишкового ресурсу

Прогнозування RUL є одною з основних задач у РНМ технологіях [1]. На відміну від методів діагностування стану, методи прогнозування RUL орієнтовані на передбачення часу до відмови, що дозволяє покращити стратегії технічного обслуговування [5].

У науковій літературі виділяють три основні категорії методів прогнозування RUL [1, 29].

1. *Методи на основі фізичних процесів* базуються на математичному описі процесів деградації з використанням диференціальних рівнянь та фізичних законів, проте основним їх обмеженням є складність точного

визначення параметрів для багатокomпонентних систем та необхідність детальної інформації про механізми деградації [29].

2. *Data-driven методи* використовують історичні дані моніторингу для навчання статистичних моделей або методів машинного навчання [4, 55]. Вони істотно залежать від якості та повноти наявних даних, хоча і не потребують явного знання фізичних процесів. У контексті Industry 4.0 саме data-driven підходи набули значного поширення завдяки доступності великих обсягів даних з IoT-систем [2].

3. *Гібридні методи* поєднують переваги попередніх методів і поєднують фізичні знання з можливостями машинного навчання, демонструючи вищу стійкість і інтерпретованість [29].

Зважаючи на відсутність експертних знань технічних систем, в роботі розглядаються data-driven методи. Серед класичних методів машинного навчання для прогнозування RUL найбільшого розповсюдження набули методи опорних векторів та випадкові ліси [91]. Метод опорних векторів демонструє високу точність за умови якісних даних, а випадковий ліс забезпечує стійкість до шумів та оцінку важливості ознак [64]. Проте основним обмеженням традиційних методів є необхідність ручного виділення ознак, що може призводити до втрати важливої часової інформації [91]. Тому з'являється потреба у застосуванні методів на основі глибокого навчання.

Рекурентні нейронні мережі (RNN) стали домінуючим підходом завдяки здатності автоматично виділяти ознаки та виявляти часові залежності у послідовностях даних [30, 92]. Зокрема, архітектура LSTM вирішує проблему зникаючого градієнта базових RNN завдяки механізму комірок пам'яті [91]. Численні дослідження підтверджують перевагу LSTM, що демонструють точні прогнози з мінімальним рівнем шуму [55, 59]. GRU є спрощеною альтернативою з меншою кількістю параметрів, що забезпечує швидше навчання при порівнянній точності [13, 92]. Багатошарові та двонаправлені архітектури дозволяють моделювати ієрархічні залежності різних масштабів [93, 94]. Подальший розвиток методів прогнозування RUL пов'язаний з появою

гібридних архітектур глибокого навчання. CNN-LSTM архітектури інтегрують згорткові та рекурентні мережі. Згорткові мережі виділяють локальні просторові ознаки, тоді як LSTM захоплюють глобальну часову динаміку [60, 95]. Важливим напрямком удосконалення стало впровадження механізмів уваги, які дозволяють фокусуватися на важливих частинах послідовностей та досягати високих результатів [93, 96]. Механізми уваги не лише підвищують точність прогнозування, але й покращують інтерпретованість моделей [97].

Важливим аспектом побудови технологій прогнозування є вибір функції втрат. Середньоквадратична помилка є найпоширенішою функцією втрат, проте вона є чутливою до викидів. Функція Хьюбера вирішує цю проблему за рахунок поєднання середньоквадратичної та абсолютної помилок, що забезпечує стійкість [59]. Особливого значення набувають асиметричні функції втрат, які відображають практичну нерівноцінність помилок, тому що переоцінка RUL є критичним для технічних систем [98, 99].

1.6 Багаторівневі технології та ансамблеві методи технічного діагностування

1.6.1 Ансамблеві методи

Одним з напрямків інтеграції діагностичних рішень є ансамблеві методи машинного навчання, які працюють на основі поєднання рішень множини базових моделей для підвищення якості та стійкості діагностування. Систематичний огляд [17] узагальнює 209 публікацій з 87 журналів та виділяє три основні типи ансамблів, які застосовуються у технічному діагностуванні: (1) навчання моделей на різних підмножинах даних з усередненням результатів; (2) послідовне навчання з фокусом на виправлення помилок попередніх моделей; (3) та ієрархічна інтеграція через мета-модель, що комбінує виходи базових моделей. Серед конкретних реалізацій цих підходів випадковий ліс демонструє високу ефективність у задачах PdM [100], алгоритми AdaBoost та XGBoost широко застосовуються для класифікації

несправностей, а ієрархічні ансамблі [101] забезпечують підвищення якості прогнозування RUL.

Одним із напрямків розвитку ансамблевих підходів є перехід від гомогенних до гетерогенних ансамблів. Робота [18] показує зростаючий тренд до гетерогенних ансамблів, які комбінують традиційні методи машинного навчання з підходами глибокого навчання. Поєднання контрольованих та неконтрольованих методів представляє ще один напрямок, проте систематичні підходи до такої інтеграції залишаються недостатньо розробленими.

Важливим аспектом практичного застосування ансамблевих методів є вибір стратегії ансамблювання діагностичних рішень. Серед основних стратегій [17] можна виділити наступні: мажоритарне голосування, зважена інтеграція з урахуванням мір впевненості та зважене голосування на основі якості моделей. Аналіз результатів застосування цих стратегій [17] показує, що вибір оптимальної стратегії інтеграції суттєво залежить від специфіки задачі та характеристик даних. Проте автоматизований систематичний підбір стратегії та ваг компонентів ансамблевих методів залишається малодослідженим, що ускладнює налаштування методів до різних об'єктів діагностування.

1.6.2 Багаторівневі технології

На відміну від ансамблевих методів, багаторівневі технології діагностування організовують процес діагностування у вигляді послідовності або ієрархії етапів, де кожен рівень виконує окрему підзадачу, а результати передаються на наступні рівні для подальшого аналізу. Найпростіші багаторівневі архітектури реалізують двох етапну обробку, де спочатку відбувається фільтрація аномальних станів, а потім виконується детальна класифікація типів несправностей. Більш складні ієрархічні архітектури враховують структуру категорій діагностичних висновків. Зокрема, метод VMACNN [102] пропонує розгалужену структуру згорткової мережі для ієрархічної діагностики підшипників через множину вихідних шарів різних

рівнів деталізації. Підхід ієрархічної класифікації [103] розвиває цю ідею, розділяючи задачу класифікації на множину підзадач меншої складності, що дозволяє технології одночасно діагностувати множинні несправності у технічних системах.

Окрему категорію багаторівневих технологій становлять багатоетапні методи прогнозування, які базуються на концепції різних стадій деградації обладнання. Дослідження [104] демонструє використання алгоритмів виявлення точок зміни для автоматичної сегментації даних деградації з подальшим застосуванням специфічних методів для кожної стадії. Аналогічний підхід [97] пропонує диференційоване використання нейронних мереж залежно від стану системи поєднуючи LSTM для деградованих систем та гібридну CNN-LSTM для справних систем. Гібридні методи [105] реалізують ще один тип багаторівневої обробки, де дані деградації спочатку розділяються на трендові та нетрендові компоненти за допомогою варіаційної декомпозиції на основі моди. Після чого трендові компоненти прогнозуються ARIMA моделями, а нетрендові – LSTM. Наостанок, результати комбінуються для фінального прогнозу залишкового ресурсу.

В свою чергу паралельні багаторівневі технології виконують обробку одночасно на декількох незалежних гілках. Інтегрована структура [50] для оцінки залишкового ресурсу реалізує чотири паралельні фази обробки даних та демонструє, що ефективна попередня обробка та оптимізація гіперпараметрів можуть суттєво покращити точність та стійкість прогнозування.

1.7 Узагальнення результатів аналізу

Аналіз існуючих методів, математичних моделей та технологій технічного діагностування дозволив систематизувати невирішені проблеми, що обґрунтовують визначені задачі дослідження.

Перша група проблем пов'язана з ізольованістю та одноцільовою спрямованістю існуючих методів діагностування. Аналіз літератури [4, 30,

106] засвідчив, що сучасні дослідження концентруються на окремих аспектах діагностування без розгляду можливостей їх інтеграції. Зокрема, у підрозділі 1.3 показано, що контрольовані методи класифікації стикаються з проблемами незбалансованості класів та нездатністю виявляти принципово нові типи несправностей незважаючи на високу точність при наявності розмічених даних. Водночас неконтрольовані методи виявлення аномалій здатні ідентифікувати невідомі відхилення, хоча характеризуються нижчою точністю та складністю визначення порогів аномальності. Аналіз методів прогнозування залишкового ресурсу (підрозділ 1.5) виявив їх ізольованість від інших задач РНМ. Спеціалізовані архітектури нейронних мереж демонструють погіршення точності понад 80% при переході між операційними режимами [50, 107], потребують окремого навчання для кожного режиму та великих обсягів розмічених даних, які важко отримати в реальних умовах експлуатації [108]. Відсутність технологій, що одночасно вирішують взаємопов'язані задачі класифікації, виявлення аномалій, кластеризації та прогнозування RUL з інтеграцією результатів, унеможлиблює формування повного діагностичного висновку та взаємну верифікацію результатів різних підходів.

Друга група проблем стосується недостатньої розробленості методів попередньої обробки даних моніторингу. Як встановлено у підрозділі 1.2, різномірні компоненти багаторівневих технологій висувають різні вимоги до формату вхідних даних. Методи класичного машинного навчання ефективно працюють з агрегованими статистичними характеристиками часових вікон, тоді як рекурентні нейронні мережі потребують послідовностей для виділення часових закономірностей [15, 109]. Існуючі підходи реалізують окремі етапи обробки ізольовано [32, 50, 109] і не формують уніфікований метод попередньої обробки та підготовки даних. Зазначені обмеження обґрунтовують потребу у розробці методу, що забезпечує основні етапи попередньої обробки даних та узгоджене формування диференційованих часових представлень.

Третя група проблем охоплює обмеження існуючих ансамблевих методів та багаторівневих технологій. Аналіз проведений у підрозділі 1.6 виявив, що більшість ансамблів є гомогенними, що обмежує покращення якості діагностування за рахунок комбінування комплементарних підходів. Підходи до побудови гетерогенних ансамблів, що інтегрують класичне машинне навчання з глибоким навчанням, контрольовані методи з неконтрольованими, залишаються малодослідженими. Додатковим обмеженням є потреба в ручному налаштуванні конфігурації технологій діагностування в залежності від типу об'єкта діагностування, що ускладнює практичне використання таких технологій.

Четверта група проблем характеризує загальні обмеження багаторівневих систем діагностування. Аналіз проведений у підрозділах 1.4 та 1.6 засвідчив відсутність спеціалізації компонентів для різних підзадач. Типовим прикладом є використання єдиного автокодувальника одночасно для виявлення аномалій та зменшення розмірності, хоча ці задачі висувають конфліктні вимоги. Перша потребує навчання виключно на нормальних даних з максимізацією помилки реконструкції на аномаліях [20, 21], тоді як друга вимагає навчання на повному наборі даних з мінімізацією помилки для всіх зразків. Додатковим обмеженням є переважання послідовної організації діагностування у багаторівневих технологіях, де помилки ранніх рівнів накопичуються та поширюються на наступні етапи. Паралельна організація процесу діагностування з незалежною обробкою компонентів та подальшим ансамблюванням результатів досліджені недостатньо. Більшість багаторівневих технологій орієнтовані на вирішення єдиної кінцевої задачі. Різні компоненти функціонують як етапи для вирішення цієї задачі, а не як паралельне виконання комплементарних видів аналізу.

Виявлені проблеми мають системний характер та взаємно підсилюють одна одну, що обґрунтовує визначені задачі дослідження та необхідність розробки багаторівневої інформаційної технології технічного діагностування. Така технологія має інтегрувати комплементарні підходи машинного навчання

та задачі, такі як класифікація, виявлення аномалій, кластеризацію та прогнозування залишкового ресурсу формуючи фінальне діагностичне рішення за допомогою ансамблювання для підвищення якості та забезпечення стійкості діагностування технічних динамічних систем та їх елементів.

Висновки до розділу 1

У першому розділі проведено критичний аналіз сучасних математичних моделей, методів та технологій технічного діагностування динамічних систем на основі даних моніторингу. Дослідження охопило методи попередньої обробки даних, методи визначення стану (класифікація, виявлення аномалій, кластеризація), методи зменшення розмірності, методи прогнозування залишкового ресурсу та багаторівневі інтегровані технології з ансамблевими методами.

На основі проведеного аналізу систематизовано чотири групи невирішених проблем: фрагментарність існуючих методів діагностування, що розробляються ізольовано без можливості інтеграції результатів; недостатня розробленість уніфікованих підходів до формування диференційованих часових представлень для різнорідних компонентів технологій; гомогенність ансамблевих методів та відсутність автоматизованого підбору конфігурації для конкретних об'єктів діагностування; недостатня спеціалізація компонентів багаторівневих технологій, де одні елементи використовуються для задач з конфліктними вимогами.

Виявлені проблеми обґрунтовують необхідність розробки багаторівневої інформаційної технології технічного діагностування динамічних систем та їх елементів, що інтегрує комплементарні підходи машинного навчання з ансамблюванням діагностичних рішень для підвищення якості та забезпечення стійкості діагностування.

РОЗДІЛ 2.

РОЗРОБКА ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ТЕХНІЧНОГО ДІАГНОСТУВАННЯ

2.1. Багаторівнева інформаційна технологія технічного діагностування та її компоненти

Виходячи з аналізу існуючих математичних моделей, методів та технологій технічного діагностування представленого в розділі 1, було виявлено низку недоліків існуючих підходів та невирішених проблем. Для їх вирішення розроблено багаторівневу інформаційну технологію технічного діагностування динамічних систем та їх елементів на основі даних моніторингу. Ця технологія базується на шести фундаментальних принципах, що визначають особливості її побудови та функціонування. Розглянемо детальніше кожен з цих принципів.

1. *Комплементарність діагностичних підходів* [17, 18, 82, 106]. Замість використання одного методу діагностування застосовується сукупність методів, які доповнюють слабкі сторони один одного. Поєднання контрольованих та неконтрольованих методів машинного навчання дозволяє використовувати як наявну експертну інформацію про стани системи, так і виявляти приховані закономірності деградації без попередньої розмітки даних.

2. *Багаторівнева організація* [102–104]. Процес діагностування розбивається на послідовність взаємопов'язаних рівнів. Таке структурування дозволяє розглядати кожен рівень як окрему глобальну підзадачу, в межах якої можуть застосовуватись різні методи та їх комбінації залежно від специфіки системи.

3. *Модульність* [106, 110, 111]. Кожен рівень системи реалізовано як окремий модуль з чітко визначеними вхідними та вихідними даними. Модульна архітектура забезпечує можливість заміни або удосконалення окремих компонентів без перебудови всієї системи, що особливо важливо для адаптації технології до діагностування різних типів динамічних систем.

4. *Ансамблювання* [17, 100, 101]. Фінальне діагностичне рішення формується шляхом інтеграції рішень усіх методів діагностування системи з використанням механізму ансамблювання для підвищення стійкості технології в умовах різних операційних режимів.

5. *Поєднання прогнозування та класифікації* [4, 19, 97]. Інформаційна технологія об'єднує в єдину систему як задачі класифікації поточного стану систем, так і задачі прогнозування майбутнього стану. Це дозволяє отримувати комплексну діагностичну інформацію для прийняття рішень щодо технічного обслуговування та планування експлуатації системи.

6. *Використання часових представлень* [15, 16, 54, 63]. Оскільки дані моніторингу динамічних систем мають природу часових рядів, технологія передбачає формування спеціальних часових представлень на етапі попередньої обробки. Це дозволяє аналізувати не тільки миттєві значення параметрів, а й їх динаміку, тренди та взаємозв'язки в часі, що є критично важливим для виявлення процесів деградації.

Реалізація зазначених принципів покладена в основу моделі функціонування багаторівневої інформаційної технології діагностування, яку представлено на рис. 2.1 у вигляді діаграми активностей (UML Activity Diagram). Для забезпечення прозорості логіки функціонування процеси в моделі розподілені за трьома функціональними областями, що відповідають послідовним рівням обробки та перетворення інформації:

1. Рівень попередньої обробки та підготовки даних – забезпечує підготовку даних моніторингу, їх трансформацію та формування у структуровані представлення, такі як агреговані часові вікна та багатовимірні часові ряди.

2. Рівень діагностування стану системи – реалізує паралельне застосування методів машинного навчання для багатоаспектної оцінки поточного та майбутнього технічного стану об'єкта. На цьому рівні здійснюється класифікація поточного стану, виявлення аномалій, зменшення розмірності ознак, кластеризація та прогнозування залишкового ресурсу.

3. Рівень прийняття інтегрованого рішення – здійснює ансамблювання результатів, отриманих від різних аналітичних модулів, та синтез інтегрованого висновку. Результатом функціонування моделі є показники, що включають оцінку технічного стану об'єкта (бінарна мітка), рівень достовірності прийнятого рішення та значення прогнозованого залишкового ресурсу.

Таке представлення дозволяє наочно продемонструвати паралельність обчислювальних потоків, логічний зв'язок між методами обробки даних різної природи, діагностування та прийняття рішення. Додатково, модель показує ієрархічну структуру розробленої технології.

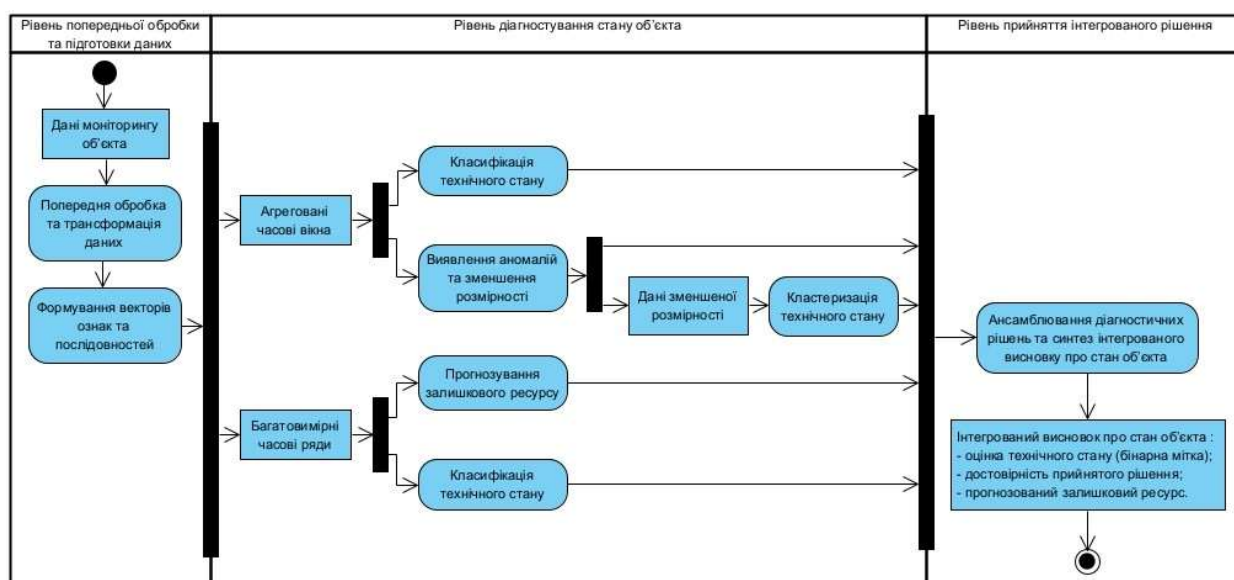


Рис. 2.1 – Модель функціонування багаторівневої інформаційної технології діагностування

Кожна з наведених функціональних операцій моделі базується на застосуванні конкретних методів та математичних моделей. Подальша деталізація інформаційної технології передбачає детальний розгляд кожного з рівнів інформаційної технології та розроблених методів, що реалізують визначені функціональні операції на кожному рівні.

2.2. Рівень попередньої обробки та підготовки даних

Рівень попередньої обробки та підготовки даних є важливим компонентом розробленої інформаційної технології діагностування, оскільки якість вхідних даних безпосередньо впливає на якість роботи всіх наступних рівнів технології. Цей рівень призначено для трансформації даних моніторингу у форму, яка використовується для аналізу методами машинного навчання. Також слід зауважити, виходячи з проведеного аналізу в розділі 1, що приведення до коректної форми не є достатнім для того, щоб методи працювали якісно. Тому перед цим додається обробка даних зважаючи на загальні практики обробки даних при роботі з методами машинного навчання.

Як перший рівень технології діагностування, він отримує на вхід вихідні дані моніторингу у вигляді табличних даних, що визначають багатовимірні часові ряди параметрів динамічних систем та їх елементів. Вихідні дані цього рівня передаються на рівень діагностування стану об'єкта.

Для виконання визначених функціональних операцій, що визначені на рис. 2.1 та у цьому розділі, було розроблено метод попередньої обробки та підготовки даних.

Метод попередньої обробки та підготовки даних. В попередніх роботах було закладено теоретичні та практичні основи окремих етапів обробки та підготовки даних моніторингу. Зокрема, у працях [33, 36, 37] представлено методи обробки пропущених значень, нормалізації даних, перевірки асиметрії та методи трансформації даних. В роботах також висвітлюється практичне значення цих методів та їх вплив на якість отриманих результатів.

Розроблений метод попередньої обробки та підготовки даних поєднує ці напрацювання та розвиває їх шляхом комплексної обробки даних та розробки підходу до формування диференційованих часових представлень для аналізу багатовимірних часових рядів. Це забезпечує узгоджену обробку даних для різномірних компонентів інформаційної технології діагностування, що працюють на різних представленнях даних. Діаграма активності

запропонованого методу представлено на рис. 2.2. Вона ілюструє інтеграцію попередніх напрацювань у єдиний процес підготовки даних.

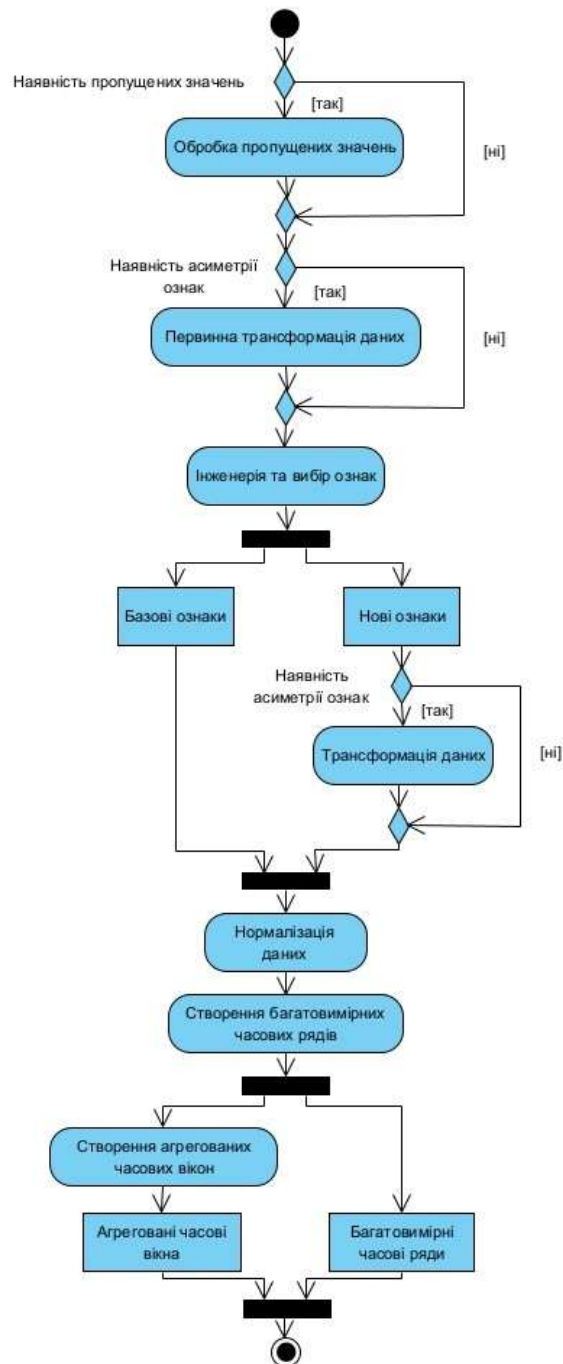


Рис. 2.2 – Діаграма активності методу попередньої обробки та підготовки даних

Першим кроком методу є перевірка на наявність пропущених значень та їх усунення, оскільки у системах моніторингу часто виникають ситуації, коли окремі значення параметрів не фіксуються через збої у роботі сенсорів або

проблеми передачі даних. Пропущені значення унеможливають застосування більшості методів машинного навчання, що вимагає їх обробки. При наявності пропущених значень, метод обробляє їх в залежності від характеру та обсягу відсутньої інформації. Використовуються наступні операції обробки: видалення записів, заповнення значеннями (середнім, медіаною), інтерполяція на основі сусідніх значень. Для часових рядів технічних систем найбільш природним підходом є інтерполяція, що дозволяє враховувати плавність зміни параметрів у часі.

Багато методів машинного навчання базуються на припущенні про нормальність розподілу даних. В свою чергу, реальні дані моніторингу часто демонструють значну асиметрію, що негативно впливає на якість діагностування. Тому, наступним кроком методу є перевірка на наявність асиметрії ознак та їх трансформація. При наявності асиметрії, дані трансформуються до нормального розподілу за допомогою Бокса-Кокса, що є універсальним методом, що включає сімейство степеневих трансформацій з автоматичним налаштуванням.

Трансформовані дані передаються на виконання операції інженерії та вибору ознак. Це робиться через те, що часто в даних не всі ознаки є інформативними, або декілька з них сильно корелюють між собою і створення одної, яка корелює більше, є корисним. Інженерія ознак визначається вручну та виконується за рахунок використання арифметичних комбінацій. В свою чергу вибір ознак виконується в автоматичному режимі та використовує декілька підходів в залежності від конфігурації. Перший – це використання коефіцієнта кореляції Пірсона і порівняння його до порогового значення. Іншим підходом є використання випадкового лісу, а саме його тренування та використання коефіцієнтів важливості для відбору ознак.

При створенні нових ознак, з тих, що відповідають нормальному розподілу, не гарантується відповідність новостворених ознак до нормального розподілу. Тому виконується додаткова перевірка на наявність асиметрії та трансформація нових ознак, що є аналогічною операцією до вже розглянутої.

Використання двох операцій трансформації даних до та після інженерії ознак обґрунтовується зменшенням впливу кумулятивної асиметрії при створенні нових ознак.

Останнім кроком попередньої обробки даних є нормалізація. Дані моніторингу зазвичай включають параметри, виміряні у різних фізичних величинах та діапазонах значень. Без нормалізації параметри з більшими абсолютними значеннями будуть домінувати при обчисленні відстаней та інших метрик, що призведе до некоректної роботи методів машинного навчання. В методі передбачено три основні методи нормалізації: мін-макс масштабування (1), яке здійснює лінійне перетворення даних до визначеного діапазону, проте є чутливим до викидів; стандартизація (2), що корисна для алгоритмів, що припускають нормальний розподіл даних; та стійке масштабування (3), що забезпечує стійкість до викидів.

Після попередньої обробки даних, розпочинається підготовка даних для різномірних методів інформаційної технології шляхом створення диференційованих часових представлень. Для цього використовуються наступні методи:

1. *Метод ковзного вікна* застосовується для методів, що працюють з послідовними даними. Даний метод полягає у розбитті довгих часових рядів на фрагменти фіксованої довжини з кроком зсуву. Результатом є набір послідовностей фіксованої довжини в якому повністю зберігається часова динаміка параметрів.

2. *Метод часових вікон з агрегацією статистик* застосовується для методів, що оперують векторними представленнями фіксованої розмірності. Вектор ознак формується шляхом об'єднання статистичних показників, розрахованих на інтервалах рівної тривалості для кожного параметра. Такий підхід дає змогу врахувати як середні значення параметрів у різні моменти часу, так і їхню варіативність, що сприяє виявленню трендів у зміні стану системи.

Згідно з рис. 2.2 на вихід методу попередньої обробки та підготовки даних подаються: (1) багатовимірні часові ряди, які створюються методом ковзного вікна; та (2) агреговані часові вікна створені з використанням методу часових вікон з агрегацією статистик.

2.3. Рівень діагностування стану об'єкта

Рівень діагностування стану об'єкта є центральним рівнем розробленої багаторівневої інформаційної технології, на якому здійснюється безпосередня оцінка технічного стану динамічної системи та її елементів. Згідно з моделлю функціонування технології (рис. 2.1), цей рівень отримує на вхід результати роботи рівня попередньої обробки та підготовки даних. Вихідними даними рівня є множина діагностичних рішень, які передаються на рівень прийняття інтегрованого рішення для ансамблювання.

Відповідно до принципу комплементарності діагностичних підходів, на цьому рівні реалізовано паралельне виконання п'яти функціональних операцій, що вирішують взаємопов'язані, але різні за своєю природою задачі діагностування. Кожна операція спеціалізована на окремій підзадачі та використовує відповідне часове представлення даних, що забезпечує повноту діагностичного аналізу.

Паралельна обробка на рівні діагностування організована у вигляді двох гілок відповідно до типу вхідних даних (рис. 2.1). Перша гілка оперує агрегованими часовими вікнами та включає три функціональні операції.

1. *Класифікація технічного стану.* Реалізує бінарну класифікацію поточного стану об'єкта на основі агрегованих статистичних характеристик часових вікон.

2. *Виявлення аномалій та зменшення розмірності.* Виконує дві взаємопов'язані задачі: ідентифікацію відхилень від нормальної поведінки системи та перехід до компактного представлення даних у просторі меншої розмірності. Результатом операції є діагностичне рішення про наявність

аномалій та дані зменшеної розмірності, що передаються на наступну операцію.

3. *Кластеризація технічного стану.* Виконується у просторі зменшеної розмірності, отриманому від попередньої операції, що дозволяє уникнути проблем кластеризації у просторі з великою кількістю ознак. Кластеризація забезпечує виявлення груп схожих станів об'єкта, що є важливим для ідентифікації перехідних стадій деградації та різних режимів роботи системи.

Друга гілка оперує багатовимірними часовими рядами, що зберігають повну часову динаміку параметрів, та включає дві функціональні операції.

1. *Прогнозування залишкового ресурсу.* Вирішує задачу регресії шляхом оцінки кількості робочих циклів до прогнозованої відмови на основі аналізу послідовностей багатовимірних часових рядів. На відміну від операцій класифікації, що визначають поточний стан, прогнозування залишкового ресурсу надає кількісну оцінку майбутнього стану об'єкта. Додатково формується діагностичне рішення про бінарний стан.

2. *Класифікація технічного стану.* Реалізує бінарну класифікацію стану безпосередньо на послідовностях багатовимірних часових рядів. На відміну від першої операції класифікації, що працює з агрегованими статистиками, дана операція аналізує повну часову структуру даних, що дозволяє виявляти складні часові закономірності деградації.

Така організація рівня діагностування забезпечує реалізацію принципу поєднання прогнозування та класифікації, оскільки об'єднує в єдиному рівні як задачі оцінки поточного стану (класифікація, виявлення аномалій, кластеризація), так і задачу прогнозування майбутнього стану (прогнозування залишкового ресурсу). Більшість операцій виконуються незалежно одна від одної, що забезпечує паралельність обчислювальних потоків та зменшує ризик накопичення помилок, характерний для послідовних багаторівневих технологій. Виключенням є залежність між операціями виявлення аномалій та зменшення розмірності і кластеризації технічного стану, де друга використовує дані зменшеної розмірності, отримані від першої. Результатом роботи кожної

функціональної операції є діагностичне рішення, що передається на рівень прийняття інтегрованого рішення.

Для реалізації визначених функціональних операцій рівня діагностування було розроблено відповідні методи, що детально розглядаються у наступних підрозділах.

2.3.1. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання

Для виконання функціональної операції класифікації технічного стану на основі агрегованих часових вікон (рис. 2.1) розроблено метод класифікації стану, який використовує ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання. Теоретичні та практичні основи неконтрольованої компоненти методу було закладено у роботах [33, 35], де представлено підходи до виявлення аномалій на основі ізоляційного лісу та Z-оцінки, їх комбінування та синтез оцінки аномальності. Розроблений метод інтегрує зазначені напрацювання з контрольованою компонентою та ансамблюванням діагностичних рішень обох компонент.

Ключовою ідеєю методу є поєднання двох парадигм машинного навчання в єдиному ансамблі. Як було встановлено у підрозділі 1.3, контрольовані методи класифікації ефективно розпізнають відомі типи деградації при наявності розмічених навчальних даних, проте нездатні виявляти типи відхилень, що не були представлені у навчальній вибірці. Неконтрольовані методи виявлення аномалій не потребують розмічених даних та здатні виявляти невідомі відхилення, однак характеризуються нижчою точністю та складністю визначення порогів аномальності. Їх поєднання дозволяє компенсувати обмеження кожного з підходів та реалізувати принцип комплементарності діагностичних підходів, визначений у підрозділі 2.1.

Діаграма активності розробленого методу представлена на рис. 2.3. Згідно з діаграмою, метод передбачає паралельну обробку вхідних агрегованих

часових вікон у двох незалежних гілках контрольованого та неконтрольованого аналізу з подальшим синтезом та прийняттям рішень.




Рис. 2.3 – Діаграма активності методу класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання

Контрольована гілка аналізу реалізована на основі методу випадкового лісу [67], який виконує бінарну класифікацію стану об'єкта. Вибір випадкового лісу як базового класифікатора обумовлено його перевагами для задачі технічного діагностування, такими як: природна стійкість до шуму та викидів у даних завдяки агрегації прогнозів множини дерев рішень; здатність формувати оцінку ймовірності належності до класу, що є необхідним для

подальшого ансамблювання рішень; ефективна робота з багатовимірними даними без значної чутливості до масштабу ознак. Результатом роботи контрольованої компоненти є ймовірність деградованого стану для кожного вхідного спостереження, що визначається часткою дерев, які проголосували за відповідний клас.

Неконтрольована гілка аналізу базується на комбінації двох методів виявлення аномалій [33, 35], що використовують різні принципи виявлення відхилень від нормальної поведінки системи та її елементів. Як показано на рис. 2.3, обидва методи працюють паралельно в межах неконтрольованої гілки, обробляючи одні й ті самі вхідні дані.

Першим методом є ізоляційний ліс [12, 52], що аналізує структурні властивості даних у багатовимірному просторі ознак. Метод базується на принципі, що аномальні спостереження є рідкісними та суттєво відокремленими від основного масиву даних, що робить їх легко ізольованими через випадкові розділення простору ознак. Для кожного спостереження формується оцінка аномальності на основі середньої глибини ізоляції в ансамблі дерев, де менша глибина ізоляції відповідає вищому ступеню аномальності.

Другим методом є Z-оцінка – статистичний підхід, що оцінює відхилення значень окремих параметрів від їх статистичних норм у одиницях стандартного відхилення. Параметри розподілу обчислюються на навчальній вибірці, а спостереження вважається аномальним, якщо стандартизоване відхилення хоча б одного з параметрів перевищує встановлений поріг.

Комбінація ізоляційного лісу та Z-оцінки забезпечує чутливість до різних типів аномалій. Ізоляційний ліс виявляє глобальні структурні відхилення у багатовимірному просторі ознак, тоді як Z-оцінка ідентифікує локальні статистичні відхилення окремих параметрів. Результати обох методів об'єднуються в операції синтезу оцінки аномальності, що формує єдину ймовірність аномального стану для неконтрольованої гілки.

Після завершення паралельної обробки в обох гілках виконується ансамблювання результатів та формування інтегрованого висновку (рис. 2.3). На цьому етапі результати контрольованого та неконтрольованого аналізу поєднуються для формування бінарного діагностичного рішення про стан об'єкта. Метод також передбачає можливість повного виключення однієї з компонент, що дозволяє йому функціонувати виключно на основі контрольованого або неконтрольованого аналізу залежно від наявних даних та специфіки об'єкта діагностування.

Результатом роботи методу є інтегрований висновок про стан об'єкта, що включає бінарне діагностичне рішення та достовірність прийнятого рішення. Ці результати передаються на рівень прийняття інтегрованого рішення для подальшого ансамблювання з результатами інших методів діагностування відповідно до моделі функціонування технології (рис. 2.1).

2.3.2. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням

Для виконання функціональної операції виявлення аномалій та зменшення розмірності (рис. 2.1) розроблено метод, що використовує автокодувальники з диференційованим навчанням. Загальні відомості про автокодувальник та переваги його використання було представлено у роботах [34, 37].

Як зазначено у підрозділі 1.7, використання єдиного автокодувальника для одночасного виявлення аномалій та зменшення розмірності призводить до конфлікту вимог. Виявлення аномалій потребує навчання виключно на даних справного стану з максимізацією помилки реконструкції на аномальних спостереженнях, тоді як зменшення розмірності вимагає навчання на повному наборі даних для формування латентного простору, що відображає весь спектр станів об'єкта. Розроблений метод вирішує цю проблему шляхом використання двох автокодувальників з однаковою архітектурою, але різними стратегіями

навчання, що забезпечує спеціалізацію кожного на конкретній задачі без взаємних компромісів якості.

Перший автокодувальник спеціалізований на виявленні аномалій та навчається виключно на спостереженнях, що відповідають справному стану об'єкта. Під час навчання нейронна мережа виявляє закономірності та взаємозалежності параметрів, характерні для нормального функціонування та формує здатність стискати їх у латентне представлення з подальшим відновленням. Оскільки спостереження з деградованим станом не були представлені у навчальній вибірці, автокодувальник не здатен якісно реконструювати такі спостереження, що проявляється у значному зростанні помилки реконструкції. На відміну від контрольованих методів класифікації, даний підхід не потребує розмічених аномальних зразків та здатен виявляти відхилення від нормальної поведінки незалежно від конкретного механізму деградації. Діагностичне рішення про наявність аномалії формується на основі порівняння помилки реконструкції з пороговим значенням, а достовірність прийнятого рішення визначається на основі відхилення від цього порогу.

Другий автокодувальник призначений для зменшення розмірності даних та навчається на повному наборі спостережень, що включає як справні, так і деградовані стани. Мета полягає у формуванні латентного простору, що відображає весь спектр можливих станів об'єкта. У вузькому горлі автокодувальника формується компактне представлення вхідних даних, де процес навчання забезпечує збереження найбільш інформативних характеристик, необхідних для якісної реконструкції.

Обидва автокодувальники працюють паралельно та незалежно, обробляючи одні й ті самі вхідні агреговані часові вікна. Диференційоване навчання дозволяє незалежно тренувати кожен автокодувальник відповідно до специфіки задачі.

Результатом роботи методу є два типи інформації: (1) діагностичне рішення про стан об'єкта із зазначенням достовірності прийнятого рішення, що передається на рівень прийняття інтегрованого рішення для ансамблювання з

результатами інших методів діагностування (рис. 2.1); та (2) дані зменшеної розмірності у вигляді латентного представлення, що передаються на операцію кластеризації технічного стану.

2.3.3. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування

Для виконання функціональної операції кластеризації технічного стану (рис. 2.1) розроблено метод нечіткої кластеризації стану, що використовує агентно-орієнтований підхід для визначення кількості кластерів та підтримує декілька режимів функціонування. Теоретичні та практичні основи нечіткої кластеризації С-середніх, агентно-орієнтованого алгоритму визначення кількості кластерів, функцій належності та їх математична формалізація були детально представлені у роботах [33, 34, 36, 40].

На вхід метод отримує латентне представлення зменшеної розмірності, сформоване методом виявлення аномалій та зменшення розмірності, що забезпечує роботу з найбільш інформативними характеристиками даних та усуває проблеми кластеризації у просторах високої розмірності.

Базовим алгоритмом методу є нечітка кластеризація С-середніх [78], вибір якої обумовлено здатністю відображати перехідну природу станів деградації через часткову належність спостережень до кластерів та стійкістю до шуму у даних моніторингу. Для автоматичного визначення кількості кластерів застосовується агентно-орієнтована модифікація [33, 36], де елементи вхідної вибірки представляються як агенти-елементи, а кластери – як агенти-кластери. Агенти-елементи обирають найближчі агенти-кластери за обраною функцією належності та приєднуються до них, а агенти-кластери адаптують свої параметри відповідно до характеристик приєднаних елементів. Така взаємодія реалізує ітераційний процес, що прибирає необхідність попереднього задання кількості кластерів.

Якість кластеризації залежить від вибору функції належності, що визначає спосіб обчислення ступенів належності спостережень до кластерів. У

методі передбачено декілька функцій належності на основі різних метрик відстані та інформаційних критеріїв.

Ключовою особливістю розробленого методу, що відрізняє його від базового методу кластеризації, є підтримка декількох режимів функціонування: неконтрольованого та напівконтрольованого. Гнучкість у виборі режиму забезпечує застосовність методу як за наявності, так і за відсутності маркованих навчальних даних, що є важливим з практичної точки зору, оскільки розмічені дані для технічних систем часто є обмеженими або відсутніми. Метод формує діагностичне рішення про стан об'єкта за рахунок аналізу належності нових спостережень до виявлених кластерів, а конкретний механізм формування цього рішення визначається обраним режимом функціонування.

У неконтрольованому режимі діагностичне рішення формується виключно на основі аналізу структури кластерів без використання зовнішніх міток про стан об'єкта. Під час навчання метод виявляє групи схожих станів та визначає їх характеристики. Для нового спостереження рішення про аномальність базується на аналізі ступеня належності до кластерів та відстані до їх центрів. Спостереження, що мають низьку належність або значну відстань від виявлених груп, класифікуються як аномальні. Перевагою неконтрольованого режиму є здатність виявляти спостереження, що не належать до жодної з відомих груп станів, що дозволяє ідентифікувати нові типи аномалій, не представлені у навчальних даних. Проте він не використовує наявну інформацію про стан об'єкта навіть за її наявності, що може обмежувати якість діагностування.

У напівконтрольованому режимі додатково використовується інформація про відомі стани об'єкта. На етапі навчання здійснюється маркування кластерів на основі розподілу міток станів серед їх елементів, що дозволяє кожному кластеру набути семантичного значення відносно стану об'єкта. Для нового спостереження діагностичне рішення формується на основі мітки кластера з найвищим ступенем належності. Напівконтрольований

режим може мати позитивний вплив на якість діагностування, оскільки використання інформації про стан дозволяє безпосередньо пов'язати результати кластеризації з діагностичними категоріями. Якість цього режиму залежить від складності даних та кількості операційних режимів роботи об'єкта. Напівконтрольований режим зазвичай забезпечує вищу точність діагностування за наявності чітко розділених кластерів, що відповідають різним станам.

Результатом роботи методу є діагностичне рішення про стан об'єкта, що включає бінарне рішення та достовірність прийнятого рішення. Ці результати передаються на рівень прийняття інтегрованого рішення для ансамблювання з результатами інших методів діагностування відповідно до моделі функціонування технології (рис. 2.1).

2.3.4. Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі

Для виконання функціональної операції прогнозування залишкового ресурсу (рис. 2.1) розроблено метод, що використовує рекурентну нейронну мережу для вирішення задачі регресії на багатовимірних часових рядах. Теоретичні основи рекурентних нейронних мереж, архітектури комірок LSTM та GRU, а також їх математична формалізація були представлені у попередніх роботах [38, 44]. У роботі [44] додатково подано повний опис архітектури нейронної мережі, її варіацій з використанням різних типів рекурентних комірок та особливостей навчання для задачі прогнозування залишкового ресурсу турбовентиляторних двигунів.

Ключовою ідеєю методу є вирішення задачі регресії залишкового ресурсу для одночасного отримання кількісної оцінки часу до відмови та бінарного діагностичного рішення про стан об'єкта. Числовий прогноз залишкового ресурсу використовується для планування технічного обслуговування, а шляхом порівняння з пороговим значенням трансформується у бінарне рішення для інтеграції діагностичних рішень

технології. Такий підхід забезпечує вищу інтерпретованість порівняно з методами класифікації, оскільки діагностичне рішення ґрунтується на кількості робочих циклів до прогнозованої відмови. Це реалізує принцип поєднання прогнозування та класифікації, визначений у підрозділі 2.1.

Вибір рекурентної нейронної мережі як базової архітектури обумовлено двома факторами. По-перше, рекурентні мережі здатні автоматично виділяти часові залежності безпосередньо з послідовностей даних без необхідності ручної інженерії ознак, що є обмеженням класичних методів машинного навчання для задач прогнозування залишкового ресурсу. По-друге, внутрішня пам'ять рекурентних мереж про попередні стани дозволяє моделювати процеси деградації, де поточний стан об'єкта визначається його історією експлуатації.

Як визначено у підрозділі 1.5, класичні рекурентні мережі обмежені проблемою зникаючого градієнта при навчанні на довгих послідовностях, що вирішується застосуванням спеціалізованих архітектур комірок LSTM та GRU, які підтримуються методом.

Важливим аспектом прогнозування залишкового ресурсу є нерівноцінність помилок прогнозу. Переоцінка залишкового ресурсу є значно критичнішою за недооцінку, оскільки може призвести до несвоєчасного технічного обслуговування та відмови об'єкта під час експлуатації. Для контролю цього метод підтримує декілька функцій втрат для навчання нейронної мережі, що відрізняються чутливістю до великих відхилень та характером штрафування помилок.

Результатом роботи методу є діагностичне рішення, що включає прогнозований залишковий ресурс, бінарне рішення про стан об'єкта та достовірність прийнятого рішення. Прогнозований залишковий ресурс передається на рівень прийняття інтегрованого рішення для включення до інтегрованого висновку, а бінарне рішення та достовірність – для ансамблювання з результатами інших методів діагностування відповідно до моделі функціонування технології (рис. 2.1).

2.3.5. Метод класифікації стану на основі гібридної нейронної мережі

Для виконання функціональної операції класифікації технічного стану на основі багатовимірних часових рядів (рис. 2.1) розроблено метод, що використовує гібридну нейронну мережу для бінарної класифікації стану об'єкта. На відміну від методу класифікації на основі ансамблювання контрольованих та неконтрольованих методів (підрозділ 2.3.1), що оперує агрегованими часовими вікнами, даний метод аналізує повну часову структуру даних у вигляді багатовимірних часових рядів, сформованих на рівні попередньої обробки та підготовки даних. Це дозволяє виявляти складні просторово-часові закономірності деградації, які не відображаються в агрегованих статистиках.

Ключовою ідеєю методу є поєднання згорткових та рекурентних нейронних мереж у єдиній гібридній архітектурі. Як визначено у підрозділах 1.3 та 1.5, така архітектура вирішує обмеження кожного з підходів окремо, забезпечуючи одночасне виділення локальних ознак та моделювання глобальної часової динаміки на їх основі.

Розроблена нейронна мережа реалізує послідовну обробку вхідних часових послідовностей через три функціональні блоки. Блок згорткових шарів забезпечує ієрархічне виділення локальних ознак та зменшення розмірності послідовності, далі блок рекурентних шарів моделює часову динаміку виділених ознак, аналізуючи довгострокові тренди та переходи між режимами функціонування об'єкта. Останнім етапом є блок повнозв'язних шарів, що виконує фінальну трансформацію у ймовірність деградованого стану.

Результатом роботи методу є діагностичне рішення, що включає бінарне рішення про стан об'єкта та достовірність прийнятого рішення. Ці результати передаються на рівень прийняття інтегрованого рішення для ансамблювання з результатами інших методів діагностування відповідно до моделі функціонування технології (рис. 2.1). Включення методу на основі гібридної нейронної мережі до ансамблю забезпечує реалізацію принципу

комплементарності діагностичних підходів, оскільки глибоке навчання на повних часових послідовностях формує альтернативну оцінку стану порівняно з методами, що працюють на агрегованих представленнях, та доповнює метод прогнозування залишкового ресурсу (підрозділ 2.3.4), який також оперує багатовимірними часовими рядами, але вирішує задачу регресії.

2.4. Рівень прийняття інтегрованого рішення

Рівень прийняття інтегрованого рішення є завершальним рівнем розробленої інформаційної технології діагностування, оскільки саме на цьому рівні формується фінальний діагностичний висновок на основі результатів усіх методів рівня діагностування стану об'єкта. Цей рівень призначено для інтеграції множини діагностичних рішень у єдиний висновок шляхом ансамблювання. Необхідність такої інтеграції обумовлена тим, що кожен метод діагностування спеціалізований на окремій підзадачі та характеризується різною чутливістю до типів відхилень та операційних режимів, тому використання результатів лише одного методу не забезпечує повноти та стійкості діагностування.

Згідно з моделлю функціонування технології (рис. 2.1), рівень отримує на вхід діагностичні рішення від п'яти функціональних операцій попереднього рівня та прогнозований залишковий ресурс. Результатом його функціонування є інтегрований висновок про стан об'єкта, що включає оцінку технічного стану, достовірність прийнятого рішення та прогнозований залишковий ресурс.

Для його реалізації було розроблено метод ансамблювання діагностичних рішень, що детально розглядається у наступному підрозділі.

Метод ансамблювання діагностичних рішень. Для реалізації функціональної операції ансамблювання діагностичних рішень та синтезу інтегрованого висновку (рис. 2.1) розроблено метод ансамблювання діагностичних рішень. Вхідні та вихідні дані методу збігаються з вхідними та вихідними даними рівня прийняття інтегрованого рішення. Метод забезпечує перехід від множини окремих діагностичних оцінок, сформованих методами

рівня діагностування стану об'єкта, до єдиного інтегрованого висновку, що характеризує технічний стан об'єкта з урахуванням усіх аспектів проведеного аналізу.

Для кожного методу діагностування визначається ваговий коефіцієнт, що відображає його відносну важливість у формуванні інтегрованого рішення. Вагові коефіцієнти задовольняють умову нормалізації, що забезпечує інтерпретацію результату ансамблювання як нормалізованої міри узгодженості рішень. Важливою особливістю є можливість встановлення нульового вагового коефіцієнта для окремих методів, що дозволяє виключати компоненти з низькою якістю діагностування з процесу ансамблювання без зміни загальної структури технології.

Метод підтримує три стратегії ансамблювання, що відрізняються способом використання інформації про достовірність прийнятих рішень окремими компонентами. Першою стратегією є бінарне голосування. Воно базується виключно на бінарних діагностичних рішеннях окремих методів без урахування достовірності. Перевагою бінарного голосування є простота та інтерпретованість.

Другою стратегією є зважене голосування за достовірністю. Ця стратегія використовує достовірність прийнятих рішень як додаткові множники для зважування внеску кожного методу. Рішення з високою достовірністю мають пропорційно більший вплив на фінальний результат. Така стратегія є особливо корисною у ситуаціях суперечливих рішень, де окремі методи формують протилежні висновки з різною достовірністю.

Третьою стратегією є гібридне голосування. Ця стратегія поєднує переваги обох попередніх підходів та додатково враховує достовірність методів, які визначили стан об'єкта як справний. Перевагою гібридної стратегії є найбільш збалансоване використання всієї діагностичної інформації та підвищена стійкість до конфліктних ситуацій.

На основі обраної стратегії формується інтегрований висновок, що включає бінарне рішення про стан об'єкта, достовірність прийнятого рішення

та прогнозований залишковий ресурс. Математична формалізація розроблених стратегій ансамблювання та механізму формування достовірності наведена у розділі 3.

2.5. Налаштування інформаційної технології та її компонентів

Розроблена багаторівнева інформаційна технологія є параметризованою, оскільки кожен з її методів має множину параметрів, значення яких впливають на якість діагностування та визначаються характеристиками конкретного об'єкта діагностування. Сукупність значень параметрів усіх методів формує конфігурацію інформаційної технології. Процес налаштування полягає у визначенні конфігурації, що забезпечує найвищу якість діагностування для заданого об'єкта.

Налаштування інформаційної технології здійснюється у два етапи. На першому етапі виконується налаштування методів рівня діагностування стану об'єкта. Параметри кожного методу визначаються шляхом навчання на навчальній вибірці з оцінкою якості на перевіірочній вибірці. Для методів, що підтримують декілька варіантів структурних параметрів (тип архітектури, функція втрат, режим функціонування тощо), виконується систематичне порівняння варіантів за обраними метриками якості на перевіірочних даних. Результатом першого етапу є набір налаштованих методів з визначеними параметрами.

На другому етапі виконується налаштування методу ансамблювання діагностичних рішень. Після того як усі методи рівня діагностування налаштовані та зафіксовані, визначаються параметри методу ансамблювання діагностичних рішень: стратегія ансамблювання та вагові коефіцієнти компонентів. Підбір цих параметрів виконується автоматизовано шляхом систематичного перебору можливих комбінацій стратегій та ваг з оцінкою якості інтегрованого рішення на перевіірочній вибірці. Автоматизація підбору конфігурації ансамблювання усуває потребу в ручному налаштуванні та забезпечує адаптацію технології до специфіки об'єкта діагностування.

Таким чином, двоетапний процес налаштування забезпечує послідовне визначення параметрів від окремих методів до інтеграції їх результатів. Конкретні метрики якості, параметри пошуку та деталі реалізації систематичного підбору конфігурації наведено у розділі 3.

Висновки до розділу 2

У другому розділі розроблено багаторівневу інформаційну технологію технічного діагностування динамічних систем та їх елементів на основі даних моніторингу. Визначено шість фундаментальних принципів побудови технології: комплементарність діагностичних підходів, багаторівнева організація, модульність, ансамблювання, поєднання прогнозування та класифікації, використання часових представлень. На їх основі створено інформаційну технологію та побудовано модель її функціонування, що структурує процес діагностування у три послідовні рівні обробки та перетворення інформації.

На рівні попередньої обробки та підготовки даних розроблено метод, що забезпечує комплексну обробку даних моніторингу та формування диференційованих часових представлень для різномірних компонентів технології, що вирішує проблему узгодженої підготовки даних для методів з різними вимогами до формату вхідних даних.

На рівні діагностування стану об'єкта розроблено п'ять методів, організованих у дві паралельні гілки відповідно до типу вхідних даних. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання забезпечує поєднання переваг обох парадигм для компенсації їх обмежень. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням усуває конфлікт вимог між цими задачами шляхом спеціалізації компонентів. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу забезпечує автоматичне визначення кількості кластерів та підтримку декількох режимів функціонування. Метод

прогнозування залишкового ресурсу на основі рекурентної нейронної мережі реалізує одночасне отримання кількісної оцінки часу до відмови та бінарного діагностичного рішення. Метод класифікації стану на основі гібридної нейронної мережі забезпечує аналіз просторово-часових закономірностей деградації на повних часових послідовностях.

На рівні прийняття інтегрованого рішення розроблено метод ансамблювання діагностичних рішень з підтримкою трьох стратегій голосування та можливістю виключення неефективних компонентів. Також визначено двоетапний процес налаштування технології з автоматизованим підбором конфігурації ансамблювання, що забезпечує адаптацію до специфіки конкретного об'єкта діагностування.

Розроблена технологія та її методи створюють основу для математичної формалізації розробленої багаторівневої інформаційної технології діагностування та її компонентів, що розглядаються у наступному розділі.

РОЗДІЛ 3.

МАТЕМАТИЧНА ФОРМАЛІЗАЦІЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ДІАГНОСТУВАННЯ ТА ЇЇ КОМПОНЕНТІВ

3.1. Формалізація методу попередньої обробки та підготовки даних

Даний підрозділ присвячено математичній формалізації методу попередньої обробки та підготовки даних. Як визначено у підрозділі 2.2, рівень попередньої обробки та підготовки даних є першим рівнем розробленої інформаційної технології діагностування та забезпечує трансформацію вихідних даних моніторингу у часові представлення, що використовуються на рівні діагностування стану об'єкта. Відповідно до діаграми активності методу (рис. 2.2), обробку організовано як послідовність операцій: обробка пропущених значень, трансформація розподілів, інженерія та вибір ознак, додаткова трансформація розподілів, нормалізація параметрів та формування диференційованих часових представлень.

Нехай вихідні дані моніторингу представлені матрицею $X = \{x_{ij}\}$ розмірності $n \times m$, де n – кількість спостережень, m – кількість параметрів. Першою операцією методу є *обробка пропущених значень*. Якщо частка пропусків у спостереженні перевищує 0.3, таке спостереження видаляється. Для малої кількості пропусків застосовується заповнення медіаною для асиметричних розподілів або середнім для нормальних розподілів, а для часових рядів – лінійна інтерполяція на основі сусідніх значень.

Наступною операцією є *трансформація розподілів* для приведення даних до нормального розподілу. Для оцінки асиметрії обчислюється коефіцієнт:

$$A_s = \mu_3 / \sigma^3, \quad (3.1)$$

де μ_3 – центральний момент третього порядку; σ – стандартне відхилення параметра. При виявленні значної асиметрії ($|A_s| > 1$) застосовується перетворення Бокса-Кокса [112].

Після трансформації розподілів виконується *інженерія ознак*, що полягає у створенні додаткових характеристик на основі арифметичних комбінацій існуючих параметрів. Метою є формування ознак з вищою кореляцією до цільової змінної, що відображають фізичні процеси в системі, що діагностується. Даний етап виконується вручну шляхом додавання відповідного модуля для кожного набору даних.

Далі виконується *вибір ознак* для зменшення розмірності та усунення надлишкових параметрів. Реалізовано два підходи. Перший – кореляційний аналіз для усунення мультиколінеарності через коефіцієнт кореляції Пірсона:

$$\rho_{ij} = \text{cov}(f_i, f_j) / (\sigma_i \times \sigma_j), \quad (3.2)$$

де $\text{cov}(f_i, f_j)$ – коваріація між ознаками; σ_i і σ_j – стандартні відхилення ознак. Якщо $|\rho_{ij}| > 0.95$, то одна з ознак видаляється.

Другий підхід – аналіз важливості ознак на основі випадкового лісу, де ліс тренується на наборі даних, а отримані коефіцієнти важливості використовуються для відбору інформативних ознак.

Оскільки відповідність новостворених ознак нормальному розподілу не гарантується, після інженерії та вибору ознак виконується *додаткова трансформація розподілів*, аналогічна до описаної вище (3.1). Застосування двох операцій трансформації до та після інженерії ознак обґрунтовується зменшенням впливу кумулятивної асиметрії при створенні нових ознак.

Наступною операцією є *нормалізація параметрів* для забезпечення інваріантності до масштабу вимірювань. Реалізовано три методи нормалізації:

1. Мін-макс масштабування до діапазону $[0, 1]$:

$$x'_{ij} = (x_{ij} - x_j^{\min}) / (x_j^{\max} - x_j^{\min}), \quad (3.3)$$

де x_j^{\min} , x_j^{\max} – мінімальне та максимальне значення j -го параметра у навчальній вибірці.

2. Стандартизація:

$$x'_{ij} = (x_{ij} - \mu_j) / \sigma_j, \quad (3.4)$$

де μ_j , σ_j – середнє значення та стандартне відхилення j -го параметра.

3. Стійке масштабування на основі міжквартильного розмаху:

$$x'_{ij} = (x_{ij} - \text{median}_j) / \text{IQR}_j, \quad (3.5)$$

де median_j – медіана j -го параметра; IQR_j – міжквартильний розмах.

Параметри нормалізації визначаються виключно на навчальній вибірці та зберігаються для застосування на етапі експлуатації.

Завершальною операцією методу є *формування диференційованих часових представлень* для різнорідних методів рівня діагностування стану об'єкта (підрозділ 2.3). Реалізовано два підходи залежно від вимог методів до формату вхідних даних.

1. *Метод ковзного вікна*. Він застосовується для формування багатовимірних часових рядів, що використовуються методом прогнозування залишкового ресурсу на основі рекурентної нейронної мережі (підрозділ 2.3.4) та методом класифікації стану на основі гібридної нейронної мережі (підрозділ 2.3.5). Нехай часовий ряд представлено послідовністю векторів спостережень $X = \{x_t \mid t=1, \dots, L\}$, де $x_t \in \mathbb{R}^m$ – вектор параметрів у момент t ; m – кількість параметрів; L – загальна кількість часових кроків. Метод формує набір підпослідовностей фіксованої довжини w з кроком зсуву s . i -те вікно визначається як:

$$S_i = [x_{1+is}, x_{2+is}, \dots, x_{w+is}], \quad i = 0, 1, \dots, N-1, \quad (3.6)$$

де S_i – i -те ковзне вікно; w – розмір вікна; s – крок зсуву між послідовними вікнами; i – індекс вікна.

Кількість вікон обчислюється як:

$$N = \frac{L-w}{s} + 1, \quad (3.7)$$

де L – загальна кількість часових кроків; w – розмір вікна; s – крок зсуву між послідовними вікнами. Результатом є тривимірний масив $N \times w \times m$, що зберігає повну часову динаміку параметрів.

2. *Метод часових вікон з агрегацією статистик.* Він застосовується для формування агрегованих часових вікон, що використовуються методом класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів (підрозділ 2.3.1) та методом виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням (підрозділ 2.3.2). Нехай часовий ряд $X = \{x_t \mid t=1, \dots, L\}$, де $x_t \in \mathbb{R}^m$ – вектор параметрів у момент t ділиться на n_w послідовних вікон без перекриття. Для кожного вікна $k = 1, \dots, n$ та кожного параметра $j = 1, \dots, m$ обчислюються середнє значення μ_{kj} та стандартне відхилення σ_{kj} . Вектор ознак для одного зразка формується послідовною конкатенацією статистик по вікнах:

$$F = [\mu_1, \sigma_1, \mu_2, \sigma_2, \dots, \mu_n, \sigma_n], \quad (3.8)$$

де μ_k – вектор середніх значень всіх параметрів у k -му вікні; σ_k – вектор стандартних відхилень всіх параметрів у k -му вікні. Таким чином результатом є $F \in \mathbb{R}^d$, де $d = n \times m \times 2$. Статистики μ_k відображають типову поведінку параметрів, а σ_k – їхню варіативність у межах вікна, що забезпечує здатність захоплювати часову прогресію деградації на різних етапах експлуатації. Для кожного часового представлення формується мітка класу на основі залишкового ресурсу.

Таким чином, результатом роботи методу попередньої обробки та підготовки даних є два типи часових представлень відповідно до моделі функціонування технології (рис. 2.1): (1) багатовимірні часові ряди розмірності $N \times w \times m$, створені методом ковзного вікна, що використовуються методами другої гілки рівня діагностування стану об'єкта (підрозділи 2.3.4, 2.3.5); та (2) агреговані часові вікна розмірності $n \times m \times 2$, створені методом часових вікон з агрегацією статистик, що використовуються методами першої гілки (підрозділи 2.3.1, 2.3.2). Диференційоване формування часових представлень забезпечує кожному методу рівня діагностування коректний формат вхідних даних.

3.2. Формалізація методів рівня діагностування стану об'єкта

3.2.1. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання

Даний підрозділ присвячено математичній формалізації методу класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання, розробленого у підрозділі 2.3.1. Метод виконує бінарну класифікацію технічного стану об'єкта на основі агрегованих часових вікон, сформованих методом часових вікон з агрегацією статистик (формула 3.8). Відповідно до діаграми активності методу (рис. 2.3), обробку організовано як паралельне виконання контрольованої та неконтрольованої гілок аналізу з подальшим ансамблюванням результатів та формуванням діагностичного рішення.

Нехай кожне спостереження $X_i \in R^d$ представляє вектор ознак агрегованого часового вікна, де d – розмірність простору ознак відповідно до формули (3.8).

Контрольовану гілку аналізу реалізовано на основі випадкового лісу. Ансамбль складається з T дерев рішень, кожне з яких формує бінарне рішення $h_t(X_i) \in \{0, 1\}$ для спостереження X_i .

Ймовірність деградованого стану обчислюється усередненням рішень дерев:

$$P_{RF}(X_i) = \frac{1}{T} \times \sum_{t=1}^T h_t(X_i), \quad (3.9)$$

де T – кількість дерев у ансамблі; $h_t(X_i)$ – рішення t -го дерева. Бінарне рішення контрольованої компоненти формується порівнянням ймовірності P_{RF} з пороговим значенням θ . Спостереження класифікується як таке, що відповідає деградованому стану, якщо $P_{RF}(X_i) > \theta$. Значення P_{RF} , близьке до 0 або 1, свідчить про високу узгодженість прогнозів дерев та, відповідно високу достовірність рішення.

Неконтрольовану гілку аналізу сформовано як комбінацію ізоляційного лісу та методу Z-оцінки, що працюють паралельно в межах неконтрольованої гілки (рис. 2.3). Ізоляційний ліс аналізує структурні властивості даних у багатовимірному просторі ознак шляхом побудови ансамблю бінарних дерев із рекурсивним випадковим розділенням простору. Для кожного спостереження X_i обчислюється середня глибина шляху ізоляції $h(X_i)$ в ансамблі дерев. Оцінка аномальності нормалізується до діапазону $[0, 1]$:

$$P_IF(X_i) = 2^{-\frac{h(X_i)}{c(n)}}, \quad (3.10)$$

де $h(X_i)$ – середня глибина шляху ізоляції спостереження; $c(n)$ – нормалізуючий коефіцієнт, що залежить від кількості спостережень n у навчальній вибірці. Значення P_IF близьке до 1 визначає високу ймовірність аномалії, близьке до 0 – нормальне спостереження.

Метод Z-оцінки оцінює відхилення значень параметрів від їх статистичних норм у одиницях стандартного відхилення. Для кожної j -ої ознаки спостереження X_i обчислюється стандартизоване відхилення:

$$Z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j}, \quad (3.11)$$

де x_{ij} – значення j -ої ознаки для i -го спостереження; μ_j та σ_j - середнє значення та стандартне відхилення j -ої ознаки на навчальній вибірці. Спостереження вважається аномальним, якщо $|Z_{ij}| > \theta$ для хоча б однієї ознаки.

Для синтезу оцінки аномальності неконтрольованої гілки (рис. 2.3) результати ізоляційного лісу та Z-оцінки об'єднуються. Нехай $Z_{\max}(X_i)$ – максимальна абсолютна Z-оцінка серед усіх ознак спостереження, тоді інтегральна оцінка аномальності неконтрольованої компоненти визначається як:

$$P_U(X_i) = P_IF(X_i) \times \frac{1}{1 + e^{-Z_{\max}(X_i)}}, \quad (3.12)$$

де $P_{IF}(X_i)$ – оцінка аномальності від ізоляційного лісу згідно з формулою (3.10); $Z_{\max}(X_i)$ – максимальна абсолютна Z-оцінка серед усіх ознак. Другий множник є сигмоїдальною функцією активації, що приводить значення до діапазону $[0, 1]$.

Формула 3.12 реалізує мультиплікативну інтеграцію двох незалежних оцінок, де сигмоїдальна функція забезпечує плавне зростання внеску статистичної компоненти при збільшенні відхилення, а множення на P_{IF} посилює сигнал для спостережень, що є одночасно структурно та статистично аномальними.

Інтегрована оцінка стану об'єкта формується зваженою комбінацією результатів контрольованої та неконтрольованої гілок аналізу:

$$P_A(X_i) = w_s \times P_{RF}(X_i) + w_u \times P_U(X_i), \quad (3.13)$$

де w_s та w_u – вагові коефіцієнти контрольованої та неконтрольованої компонент відповідно; $P_{RF}(X_i)$ – ймовірність деградованого стану згідно з (3.9); $P_U(X_i)$ – інтегральна оцінка неконтрольованої компоненти згідно з (3.12). Спостереження класифікується як таке, що відповідає деградованому стану, якщо $P_A(X_i) > \theta$. Встановлення $w_s = 0$ або $w_u = 0$ забезпечує можливість функціонування методу виключно на основі однієї з компонент відповідно до підрозділу 2.3.1.

Достовірність прийнятого рішення визначається як міра віддаленості інтегрованої оцінки від порогу невизначеності:

$$C(X_i) = \max(P_A(X_i), 1 - P_A(X_i)). \quad (3.14)$$

Значення $C(X_i) \in [0.5, 1]$, де 0.5 відповідає максимальній невизначеності, а 1 – повній достовірності рішення.

Результатом роботи методу є діагностичне рішення для кожного спостереження X_i , що включає: (1) бінарне рішення про стан об'єкта на основі $P_A(X_i)$; (2) достовірність прийнятого рішення $C(X_i)$ згідно з формулою (3.14).

3.2.2. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням

Даний підрозділ присвячено математичній формалізації методу виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням, розробленого у підрозділі 2.3.2. Метод виконує дві взаємопов'язані задачі: ідентифікацію відхилень від нормальної поведінки системи через аналіз помилки реконструкції та формування компактного латентного представлення даних зменшеної розмірності. Відповідно до моделі функціонування технології (рис. 2.1), метод отримує на вхід агреговані часові вікна, сформовані методом часових вікон з агрегацією статистик (формула 3.8).

Нехай кожне спостереження $X_i \in \mathbb{R}^d$ представляє вектор ознак агрегованого часового вікна, де d – розмірність простору ознак відповідно до формули (3.8). Математична модель автокодувальника описується композицією функцій кодувальника і декодера:

$$\hat{x} = \text{Decoder}(\text{Encoder}(x)) = \text{Decoder}(z), \quad (3.15)$$

де $x \in \mathbb{R}^d$ – вхідний вектор ознак; $\hat{x} \in \mathbb{R}^d$ – реконструйований вектор; $z \in \mathbb{R}^1$ – латентне представлення у вузькому горлі; $1 \ll d$ – розмірність латентного простору.

Запропонована архітектура, яка представлена на рис. 3.1, включає три повнозв'язних шари у кодувальнику з поступовим зменшенням розмірності, вузьке горло з шаром відновлення, та симетричні три шари у декодері з поступовим збільшенням розмірності до вихідної. Як функція активації використовується ReLU, що забезпечує нелінійність перетворень без проблеми зникаючого градієнта [113]. Для регуляризації застосовується шар Dropout після кожного прихованого шару [114] та нормалізація пакетів [115].




Рис. 3.1 – Архітектура автокодувальника

Ключовою особливістю методу є використання двох незалежних автокодувальників з ідентичною архітектурою, але різними стратегіями навчання. Як обґрунтовано у підрозділі 2.3.2, для якісного виявлення аномалій нейронна мережа повинна бути натренована виключно на даних справного стану, тоді як для якісного зменшення розмірності – на повному наборі даних, щоб латентний простір відображав весь спектр станів системи. Використання єдиного автокодувальника призводить до неоптимального компромісу, тоді як диференційоване навчання дозволяє оптимізувати кожен компонент незалежно. Автокодувальники працюють паралельно, обробляючи одні й ті самі вхідні дані та формуючи комплементарні діагностичні характеристики.

Перший автокодувальник (AE_1) реалізує виявлення аномалій через порушення здатності до реконструкції. Навчання здійснюється виключно на множині спостережень справного стану системи. Функція втрат визначається як середньоквадратична помилка реконструкції:

$$MSE(x, \hat{x}) = \frac{1}{N} \times \sum_{i=1}^N (x_i - \hat{x}_i)^2, \quad (3.16)$$

де N – кількість спостережень; \hat{x}_i – реконструкція спостереження x_i . У процесі навчання параметри мережі оптимізуються для мінімізації MSE, внаслідок чого автокодувальник формує здатність ефективно стискати та відтворювати

характеристики справного функціонування. Оскільки спостереження деградованого стану не були представлені у навчальній вибірці, автокодувальник не здатен ефективно реконструювати незнайомі патерни, що проявляється у значному зростанні помилки реконструкції. Пороговий критерій виявлення аномалій θ визначається на основі статистичного аналізу розподілу помилок реконструкції для справних даних навчальної вибірки за правилом k сигм:

$$\theta = \mu_{\text{train}} + k \times \sigma_{\text{train}}, \quad (3.17)$$

де μ_{train} та σ_{train} – середнє значення та стандартне відхилення помилок реконструкції на навчальній вибірці; k – множник чутливості, що налаштовується на етапі перевірки. Спостереження класифікується як аномальне, якщо його помилка реконструкції перевищує θ . Достовірність прийнятого рішення визначається як нормалізоване відхилення помилки реконструкції від порогу:

$$C(x_i) = \min\left(\frac{|MSE(x_i, \hat{x}_i) - \theta|}{\theta}, 1\right), \quad (3.18)$$

де $MSE(x_i, \hat{x}_i)$ – помилка реконструкції спостереження згідно з формулою (3.16); θ – пороговий критерій згідно з формулою (3.17). Нормалізація відносно порогу забезпечує інтерпретацію достовірності як частки відхилення від критичного рівня. Обмеження значення одиницею гарантує $C \in [0, 1]$.

Другий автокодувальник (AE₂) виконує зменшення розмірності даних шляхом навчання на повній множині спостережень, що включає як справні, так і деградовані стани системи. Функція втрат аналогічна до формули (3.16), але обчислюється по повній вибірці. Навчання на повних даних забезпечує формування збалансованого латентного простору, у якому різні стани системи займають різні області, що дозволяє методу нечіткої кластеризації стану (підрозділ 2.3.3) ефективно групувати схожі стани.

Для спостереження x латентне представлення зменшеної розмірності формується як вихід кодувальника AE₂:

$$z(x) = \text{Encoder}_2(x), \quad (3.19)$$

де $z \in \mathbb{R}^d$ – латентне представлення у вузькому горлі. Розмірність вузького горла l є важливим гіперпараметром, що визначає баланс між ступенем компресії даних та якістю збереження інформації. Теоретично оптимальна розмірність визначається власною розмірністю даних – мінімальною кількістю параметрів, необхідних для адекватного опису варіативності спостережень. Для технічних систем з множинними сенсорами власна розмірність зазвичай значно менша за кількість вихідних ознак завдяки кореляціям між параметрами.

Результатом роботи методу є два типи діагностичної інформації для кожного спостереження:

1. Від AE_1 – діагностичне рішення про наявність аномалії та достовірність прийнятого рішення.
2. Від AE_2 – латентне представлення зменшеної розмірності $z \in \mathbb{R}^l$, обчислене за формулою 3.19.

Діагностичне рішення та достовірність від AE_1 передаються на рівень прийняття інтегрованого рішення для ансамблювання з результатами інших методів діагностування відповідно до моделі функціонування технології (рис. 2.1). Латентне представлення від AE_2 передається методу нечіткої кластеризації стану (підрозділ 2.3.3) для групування схожих станів та виявлення типових ознак деградації. Таким чином, диференційоване навчання двох автокодувальників забезпечує одночасне виявлення аномалій через аналіз помилки реконструкції та формування інформативного компактного представлення для подальшої кластеризації без компромісів у якості кожної з цих задач.

3.2.3. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування

Даний підрозділ присвячено математичній формалізації методу нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою

вибору режиму функціонування, розробленого у підрозділі 2.3.3. Метод виконує кластеризацію у просторі латентних ознак зменшеної розмірності та формує діагностичне рішення на основі належності спостережень до виявлених кластерів. Відповідно до моделі функціонування технології (рис. 2.1), метод отримує на вхід латентне представлення, сформоване другим автокодувальником АЕ₂ методу виявлення аномалій та зменшення розмірності (формула 3.19).

Нехай $Z = \{z_i \mid i=1, \dots, N\}$ є множиною спостережень у просторі латентних ознак, де $z_i \in R^1$ – латентне представлення i -го спостереження, отримане від автокодувальника АЕ₂, 1 – розмірність латентного простору. Задача кластеризації полягає у розподілі множини Z на K груп (кластерів) $C = \{C_j \mid j=1, \dots, K\}$, що відображають різні режими функціонування та стани деградації об'єкта діагностування.

Базовим алгоритмом методу є нечітка кластеризація C -середніх [78], що реалізує концепцію часткової належності, коли кожне спостереження характеризується вектором ступенів належності до всіх кластерів $u_i = [u_{i1}, u_{i2}, \dots, u_{iK}]$, де $u_{ij} \in [0, 1]$ є ступенем належності i -го спостереження до j -го кластера з обмеженням нормалізації. Як обґрунтовано у підрозділі 2.3.3, вибір нечіткої кластеризації обумовлено здатністю відображати перехідну природу станів деградації через часткову належність та стійкістю до шуму у даних моніторингу. На відміну від чітких методів, де кожне спостереження належить виключно одному кластеру, нечітка кластеризація дозволяє відображати перехідні стани об'єкта через проміжні значення належності до кількох груп.

Ступінь належності i -го спостереження до j -го кластера обчислюється на основі відстані до центрів всіх кластерів:

$$u_{ij} = 1 / \sum_{k=1}^K \left(\frac{d(z_i, c_j)}{d(z_i, c_k)} \right)^{\frac{2}{m-1}}, \quad (3.20)$$

де $d(z_i, c_j)$ – відстань між спостереженням z_i та центром кластера c_j згідно з обраною метрикою; m – параметр нечіткості, що контролює ступінь розмитості

меж між кластерами. Центр j -го кластера визначається як зважене середнє всіх спостережень з урахуванням їх ступенів належності:

$$c_j = \frac{\sum_{i=1}^N (u_{ij}^m \times z_i)}{\sum_{i=1}^N u_{ij}^m}. \quad (3.21)$$

Оптимізація розподілу спостережень за кластерами здійснюється ітераційним алгоритмом з послідовним оновленням матриці належності за формулою (3.20) та центрів кластерів за формулою (3.21) до досягнення збіжності.

Якість кластеризації залежить від вибору метрики $d(z_i, c_j)$ для оцінки відстані між спостереженнями та центрами кластерів. Як визначено у підрозділі 2.3.3, у методі передбачено підтримку декількох функцій належності на основі різних метрик відстані та інформаційних критеріїв: відстані Манхеттена [116], відстані Махаланобіса [117], дивергенції Кульбака-Лейблера [118] та крос-ентропії [119].

Класичний метод нечіткої кластеризації потребує апріорного визначення кількості кластерів K , що є складною задачею для об'єктів з невідомою кількістю режимів функціонування та типів деградації. Для автоматичного визначення оптимальної кількості кластерів застосовано агентно-орієнтовану модифікацію [33, 36], де елементи вхідної вибірки представляються як агенти-елементи, а кластери – як агенти-кластери. Агенти-елементи обирають найближчі агенти-кластери за обраною функцією належності та приєднуються до них, а агенти-кластери адаптують свої параметри відповідно до характеристик приєднаних елементів.

Для кожного агента-кластера визначається функція втрат як середня міра внутрішньо-кластерної відстані:

$$cl_loss(P_j) = \frac{1}{|P_j|} \sum_{i=1}^{|P_j|} d(z_i, c_j), \quad (3.22)$$

де P_j – множина індексів спостережень, віднесених до j -го кластера; $|P_j|$ – кількість елементів у кластері. Загальна функція втрат для оцінки поточної якості кластеризації визначається як:

$$\text{loss}(Z_t) = \frac{1}{K_t} \sum_{j=1}^{K_t} \text{cl_loss}(P_j), \quad (3.23)$$

де K_t – поточна кількість кластерів на ітерації t . Мінімізація функції (3.23) є критерієм оптимальності кластеризації.

Алгоритм агентно-орієнтованої нечіткої кластеризації:

1. Визначити початкову кількість агентів-кластерів та встановити обмеження на кількість елементів у кожному кластері. Обрати центри кластерів серед елементів вхідної вибірки.

2. За обраною між-елементною відстанню визначити набір найближчих елементів до кожного з кластерів. Отримані центр та найближчі елементи є агентом-кластером.

3. Обчислити значення належності до кожного з кластерів за формулою 3.20 та обчислити нові центри кластерів за формулою (3.21).

4. За обраною між-елементною відстанню визначити набір найближчих елементів до кожного з кластерів.

5. Для кожного кластера за формулою (3.22) обчислити значення функції втрат.

6. Оцінити поточну якість кластеризації за формулою (3.23). У випадку режиму роботи алгоритму в автопошуку оптимальної кількості кластерів та збільшенні значення функції втрат зупинити алгоритм.

7. Провести відбір агентів-кластерів та відкинути агент-кластер з найбільшим значенням функції втрат.

8. Повернутися до етапу 2, за умови, що цільова кількість кластерів не досягнута.

Алгоритм забезпечує автоматичне визначення кількості кластерів без необхідності експертного визначення, а механізм селекції через функцію втрат гарантує збереження лише значущих кластерів.

Ключовою особливістю методу, як визначено у підрозділі 2.3.3, є підтримка двох режимів формування діагностичного рішення: неконтрольованого та напівконтрольованого.

У неконтрольованому режимі діагностичне рішення формується виключно на основі аналізу структури кластерів без використання зовнішніх міток про стан об'єкта. Для нового спостереження z обчислюється вектор ступенів належності згідно з формулою (3.20) та визначаються два діагностичні показники. Максимальний ступінь належності:

$$u_{max}(z) = \max_j(u_{ij}(z)), \quad (3.24)$$

та мінімальна відстань до центрів кластерів

$$d_{min}(z) = \min_j(d(z, c_j)). \quad (3.25)$$

Спостереження класифікується як аномальне, якщо $u_{max}(z) < \theta_u$ або $d_{min}(z) > \theta_d$, де θ_u та θ_d – порогові значення, що визначаються на основі статистичного аналізу навчальної вибірки.

У напівконтрольованому режимі додатково використовується інформація про відомі стани об'єкта. На етапі навчання здійснюється маркування кластерів на основі мажоритарного правила. Для кожного кластера C_j обчислюється частка деградованих спостережень серед його елементів та кластеру присвоюється відповідна мітка. Для нового спостереження визначається кластер з максимальним ступенем належності:

$$j^*(z) = \operatorname{argmax}_j u_j(z), \quad (3.26)$$

а діагностичне рішення формується на основі мітки відповідного кластера.

Достовірність прийнятого рішення в обох режимах визначається максимальним ступенем належності до кластерів:

$$C(z) = u_{max}(z), \quad (3.27)$$

де $u_{max}(z)$ – максимальний ступінь належності згідно з формулою (3.24). Значення $C(z) \in [0, 1]$, де значення близьке до 1 свідчить про високу достовірність прийнятого рішення.

Результатом роботи методу є діагностичне рішення для кожного спостереження, що включає: (1) бінарне рішення про стан об'єкта; (2) достовірність прийнятого рішення згідно з формулою (3.27).

3.2.4. Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі

Даний підрозділ присвячено математичній формалізації методу прогнозування залишкового ресурсу на основі рекурентної нейронної мережі, розробленого у підрозділі 2.3.4. Метод виконує регресійну задачу оцінки кількості робочих циклів до прогнозованої відмови об'єкта діагностування на основі аналізу часових характеристик даних моніторингу. Відповідно до моделі функціонування технології (рис. 2.1), метод отримує на вхід багатовимірні часові ряди, сформовані методом ковзного вікна (формула 3.6).

Нехай $X = \{X_i \mid i=1, \dots, N\}$ є множиною багатовимірних часових послідовностей, де $X_i \in \mathbb{R}^{w \times m}$ – послідовність спостережень для i -го вікна, w – довжина вікна відповідно до формули (3.6), m – кількість ознак після попередньої обробки (підрозділ 3.1). Задача прогнозування залишкового ресурсу полягає у побудові функції f , що відображає вхідну послідовність у прогнозоване значення залишкового ресурсу $\hat{y} \in \mathbb{R}_+$ (кількість циклів до відмови). Цільова змінна $y \in \mathbb{R}_+$ визначається як кількість робочих циклів від моменту останнього часового кроку послідовності до моменту відмови об'єкта.

Для вирішення задачі прогнозування залишкового ресурсу розроблено дві архітектури рекурентних нейронних мереж на основі блоків LSTM та GRU. Як було обґрунтовано у підрозділі 2.3.4, рекурентні архітектури здатні моделювати довгострокові залежності у процесах деградації завдяки

механізмам воріт, що контролюють потоки інформації та забезпечують стабільність градієнтів при навчанні на довгих послідовностях [120].

Розроблена архітектура на основі LSTM (рис. 3.2) використовує багатошарову конфігурацію з L послідовно з'єднаних шарів LSTM, що дозволяє формувати ієрархічні представлення часових залежностей. Між шарами застосовується регуляризація Dropout [114] для запобігання перенавчанню. Прогноз залишкового ресурсу формується на основі фінального прихованого стану останнього шару LSTM через повнозв'язний регресійний шар, що математично визначається як:

$$\hat{y} = W_{out} \times h_w^L + b_{out}, \quad (3.28)$$

де \hat{y} – прогноз залишкового ресурсу, $W_{out} \in \mathbb{R}^{1 \times h}$ – матриця ваг регресійного шару, $h_w^L \in \mathbb{R}^h$ – прихований стан останнього L -го шару на останньому W -му часовому кроці послідовності, $b_{out} \in \mathbb{R}$ – зміщення регресійного шару, h – розмірність прихованого шару.




Рис. 3.2 – Архітектура нейронної мережі на основі LSTM

Розмірність даних на кожному етапі обробки нейронною мережею показано як мітки над стрілками, де: $batch_size$ відображає розмір вхідного пакета; seq_len – розмір послідовності, на якій відбувається навчання та прогнозування; $input_dim$ – кількість змінних (багатовимірні часові ряди); $hidden_size$ – розмір прихованого шару.

Розроблена архітектура на основі GRU (рис. 3.3) має аналогічну структуру з L послідовно з'єднаних шарів GRU, Dropout регуляризацією та лінійним регресійним шаром для формування прогнозу згідно з виразом (3.28). Основна відмінність між архітектурами полягає у структурі рекурентних комірок. В роботі [44] подано експериментальне порівняння між LSTM та GRU на основі метрик якості прогнозування залишкового ресурсу (RMSE, MAE, R^2) та обчислювальних витрат для конкретного набору даних.




Рис. 3.3 – Архітектура нейронної мережі на основі GRU

Навчання рекурентної нейронної мережі для прогнозування залишкового ресурсу здійснюється методом зворотного поширення помилки у часі [121] з використанням функції втрат, що забезпечує обчислення градієнтів

відносно параметрів мережі через всю часову послідовність. Як було обґрунтовано у підрозділі 2.3.4, стандартна функція середньоквадратичної похибки у випадку даних моніторингу з наявністю викидів може призводити до нестабільності градієнтів внаслідок надмірної чутливості до аномальних спостережень.

У розробленому методі застосовано функцію втрат Хьюбера як стійку альтернативу, що поєднує переваги квадратичних втрат L2 для малих помилок та абсолютних втрат L1 для великих відхилень [122]:

$$L(y, \hat{y}) = \begin{cases} \frac{(y-\hat{y})^2}{2\beta}, & \text{якщо } |y - \hat{y}| < \beta, \\ |y - \hat{y}| - \frac{\beta}{2}, & \text{в іншому випадку,} \end{cases} \quad (3.29)$$

де y – істинне значення залишкового ресурсу, \hat{y} – прогнозоване значення залишкового ресурсу, $\beta > 0$ – пороговий параметр, що контролює перехід між квадратичною та лінійною поведінкою. При малих помилках функція Хьюбера забезпечує швидку збіжність та стабільність градієнтів, поводячись як квадратична функція L2. При великих відхиленнях функція переходить до лінійної поведінки L1, що зменшує чутливість до викидів та запобігає домінуванню окремих аномальних спостережень у процесі навчання. Використання такої функції забезпечує більш стабільне навчання рекурентних мереж на даних моніторингу, де природна варіативність операційних режимів та похибки сенсорів створюють нерегулярні відхилення у траєкторіях деградації.

Метод прогнозування залишкового ресурсу виконує подвійну функцію в інформаційній технології діагностування. Він формує числовий прогноз залишкового ресурсу для планування обслуговування та приймає бінарне діагностичне рішення для інтеграції з іншими методами через механізм ансамблювання (підрозділ 2.4.1). Числовий прогноз \hat{y} представляє оцінку кількості робочих циклів до прогнозованої відмови та передається на рівень прийняття інтегрованого рішення для включення до інтегрованого висновку відповідно до моделі функціонування технології (рис. 2.1).

Бінарне діагностичне рішення формується на основі порогового аналізу прогнозованого значення залишкового ресурсу. Якщо прогноз \hat{y} опускається нижче критичного порога θ , метод класифікує стан як деградований, інакше – як справний. Значення порогу підбирається на основі балансу між раннім виявленням деградації та мінімізацією хибних спрацювань.

Достовірність прийнятого рішення C визначається на основі відстані прогнозу залишкового ресурсу від порогового значення:

$$C(\hat{y}) = \begin{cases} 1 - \frac{\hat{y}}{\theta}, & \text{якщо } Y(X) = 1 \\ \min(1, \frac{\hat{y} - \theta}{\theta}), & \text{в іншому випадку} \end{cases} \quad (3.30)$$

де $Y(X)$ – бінарне діагностичне рішення, \hat{y} – прогноз залишкового ресурсу, θ – пороговий залишковий ресурс. Для деградованого стану достовірність зростає при зменшенні залишкового ресурсу, для справного стану достовірність зростає при збільшенні відстані від порогу. Обчислені значення обмежуються діапазоном $[0.5, 1]$, що забезпечує мінімальну базову достовірність 0.5.

Результатом роботи методу є діагностичне рішення для кожного спостереження X_i , що включає: (1) числовий прогноз залишкового ресурсу \hat{y} на основі формули (3.28); (2) бінарне рішення про стан об'єкта на основі порогового аналізу; (3) достовірність прийнятого рішення згідно з формулою (3.30).

3.2.5. Метод класифікації стану на основі гібридної нейронної мережі

Даний підрозділ присвячено математичній формалізації методу класифікації стану на основі гібридної нейронної мережі, розробленого у підрозділі 2.3.5. Метод виконує бінарну класифікацію технічного стану об'єкта діагностування через поєднання згорткових та рекурентних нейронних мереж. Відповідно до моделі функціонування технології (рис. 2.1), метод отримує на вхід багатовимірні часові ряди, сформовані методом ковзного вікна (формула 3.6).

Нехай $X = \{X_i \mid i=1, \dots, N\}$ є множиною багатовимірних часових послідовностей, де $X_i \in \mathbb{R}^{w \times m}$ – послідовність спостережень для i -го вікна, w – довжина вікна відповідно до формули (3.6), m – кількість ознак після попередньої обробки (підрозділ 3.1). Задача бінарної класифікації стану полягає у побудові функції f , що відображає вхідну послідовність у ймовірність належності до класу деградованого стану $\hat{y} \in [0, 1]$.

Як було обґрунтовано у підрозділі 2.3.5, гібридна архітектура мережі CNN-LSTM (рис. 3.4) поєднує переваги згорткових мереж для виявлення локальних патернів та рекурентних мереж для моделювання часової динаміки, забезпечуючи автоматичне виділення складних нелінійних ознак деградації без експертної інженерії ознак.

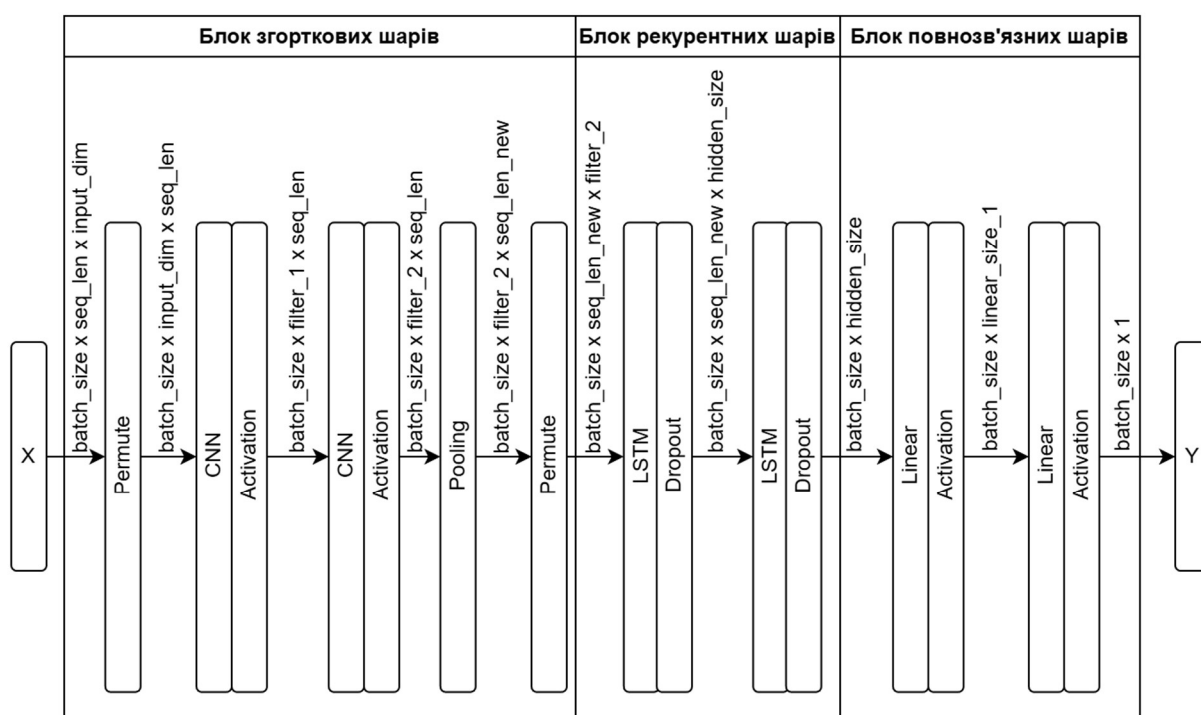


Рис. 3.4 – Архітектура гібридної нейронної мережі CNN-LSTM

Розроблена архітектура нейронної мережі використовує двошарову конфігурацію згорткових шарів з операцією максимального об'єднання для виділення локальних ознак, двошарову конфігурацію LSTM для моделювання часової динаміки та двошарову конфігурацію повнозв'язних шарів для

формування класифікаційного рішення. Між шарами LSTM застосовується регуляризація Dropout [114] для запобігання перенавчанню.

Розмірність даних на кожному етапі обробки нейронною мережею показано у вигляді міток над стрілками, де: `batch_size` відображає розмір вхідного пакета; `seq_len`, `seq_len_new` – розміри послідовностей до та після операції об'єднання; `input_dim` – кількість ознак; `filter_1`, `filter_2` – кількість каналів першого та другого згорткових шарів; `hidden_size` – розмір прихованого шару рекурентних шарів; `linear_size_1` – розмір першого повнозв'язного шару. На рис. 3.4 визначені типи шарів нейронної мережі: `Permute` – шари перестановки осей тензора для узгодження розмірностей даних між згортковими та рекурентними блоками; `CNN` – шари одновимірної згортки; `Activation` – функції активації; `Pooling` – шари стиснення ознак для зменшення розмірності та стабілізації виходу мережі; `LSTM` – шари довгострокової короткочасної пам'яті; `Dropout` – шари регуляризації; `Linear` – повнозв'язні шари.

Блок згорткових шарів обробляє вхідні послідовності X через послідовність одновимірних згорткових операцій з нелінійними активаціями та операцією максимального об'єднання, формуючи послідовність високорівневих ознак:

$$h_{\text{CNN}}(X) = \text{CNN_block}(X), h_{\text{CNN}} \in \mathbb{R}^{W' \times F}, \quad (3.31)$$

де `CNN_block(X)` – композиція двох згорткових шарів з ReLU активаціями та операцією максимального об'єднання; W' – зменшена довжина послідовності після об'єднання; F – кількість каналів після згорткових шарів. Нашаровування двох згорткових шарів забезпечує ієрархічне виділення ознак, де перший шар виявляє прості локальні особливості, а другий формує складніші абстрактні представлення.

Блок рекурентних шарів виконує моделювання часової динаміки виявлених ознак через двошарову конфігурацію LSTM з регуляризацією

Dropout між шарами. Фінальний прихований стан верхнього шару LSTM містить компактне представлення всієї інформації про вхідну послідовність:

$$h_{LSTM}(h_{CNN}) = \text{LSTM_block}(h_{CNN}), h_{LSTM} \in R^h, \quad (3.32)$$

де LSTM_block – композиція двох шарів LSTM з регуляризацією між шарами; h – розмірність прихованого шару LSTM. Використання двох шарів LSTM дозволяє формувати ієрархічні часові представлення, де нижній шар виявляє короткострокові патерни у еволюції локальних ознак від згорткового блоку, а верхній шар синтезує довгострокові тренди та глобальну динаміку стану об'єкта.

Блок повнозв'язних шарів виконує фінальну трансформацію високорівневого представлення від блоку LSTM до класифікаційного рішення через проміжний повнозв'язний шар та вихідний шар з сигмоїдною активацією для отримання ймовірності деградації:

$$\hat{y} = \sigma(W_{\text{out}} \times h_{LSTM} + b_{\text{out}}), \quad (3.33)$$

де $W_{\text{out}} \in R^{1 \times h}$ – матриця ваг вихідного шару; $b_{\text{out}} \in R$ – зміщення вихідного шару, σ – сигмоїдна функція активації. Сигмоїдна функція відображає довільне дійсне число у діапазон $[0,1]$, що дозволяє інтерпретувати вихід мережі як ймовірність належності спостереження до класу деградованого стану.

Навчання гібридної нейронної мережі здійснюється методом зворотного поширення помилки у часі з використанням функції втрат бінарної крос-ентропії, що вимірює розбіжність між прогнозованими ймовірностями та справжніми мітками станів:

$$L_{\text{BCE}}(y, \hat{y}) = - \left(\frac{1}{N} \right) \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1-y_i) \log(1-\hat{y}_i)], \quad (3.34)$$

де y – вектор справжніх міток класів; \hat{y} – вектор прогнозованих ймовірностей; N – кількість спостережень. Функція крос-ентропії штрафує помилки асиметрично через логарифмічну шкалу, що забезпечує швидку збіжність для

правильних впевнених прогнозів та великі градієнти для корекції помилкових класифікацій.

Бінарне діагностичне рішення про наявність деградації формується шляхом порогового аналізу прогнозованої ймовірності. Якщо прогноз \hat{y} перевищує пороговий рівень θ , метод класифікує стан як деградований, інакше – як справний. Значення порогу підбирається на основі балансу між чутливістю та точністю класифікатора. Достовірність прийнятого діагностичного рішення визначається як:

$$C = \max(\hat{y}, 1 - \hat{y}), \quad (3.35)$$

де \hat{y} – прогнозована ймовірність деградованого стану. Високі значення ймовірності або низькі значення відповідають високій достовірності класифікації як деградованого або справного стану відповідно. Проміжні значення поблизу порогу відповідають низькій достовірності, що вказує на невизначеність або перехідний стан об'єкта.

Результатом роботи методу є діагностичне рішення для кожного спостереження X_i , що включає: (1) бінарне рішення про стан об'єкта на основі порогового аналізу; (2) достовірність прийнятого рішення згідно з формулою (3.35).

3.3. Формалізація методу ансамблювання діагностичних рішень

Даний підрозділ присвячено математичній формалізації методу ансамблювання діагностичних рішень, розробленого у підрозділі 2.4. Метод забезпечує перехід від множини окремих діагностичних рішень, сформованих методами рівня діагностування стану об'єкта (підрозділ 2.3), до інтегрованого висновку, що характеризує технічний стан об'єкта з урахуванням усіх аспектів проведеного аналізу. Відповідно до моделі функціонування технології (рис. 2.1), метод отримує на вхід діагностичні рішення від п'яти методів рівня діагностування та прогнозований залишковий ресурс від методу прогнозування залишкового ресурсу (підрозділ 3.2.3).

Нехай кожен метод діагностування $i \in \{1, 2, 3, 4, 5\}$ формує бінарне діагностичне рішення A_i та достовірність прийнятого рішення C_i відповідно до підрозділів 3.2.1–3.2.4. Нехай $w = (w_1, w_2, w_3, w_4, w_5)$ є вектором вагових коефіцієнтів для п'яти методів діагностування, де $w_i \in [0,1]$ відображає важливість i -го методу у формуванні інтегрованого рішення. Вагові коефіцієнти задовольняють умову нормалізації, що забезпечує інтерпретацію зваженого діагностичного показника як нормалізованої міри узгодженості рішень окремих методів. Можливість встановлення $w_i = 0$ дозволяє виключати методи з низькою якістю діагностування з процесу ансамблювання без зміни загальної структури технології. Тоді кожен метод формує діагностичне рішення A_i та достовірність прийнятого рішення C_i .

Для інтеграції діагностичних рішень від п'яти методів розроблено три стратегії ансамблювання, що відрізняються способом використання інформації про достовірність прийнятих рішень окремих методів:

1. *Бінарне голосування*. Воно базується виключно на бінарних рішеннях окремих рівнів без урахування достовірності:

$$S_b = \sum_{i=1}^5 w_i \times A_i. \quad (3.36)$$

2. *Зважене голосування за впевненістю*. Ця стратегія використовує достовірність прийнятих рішень окремих методів як множники для зважування їх внеску:

$$S_c = \sum_{i=1}^5 w_i \times A_i \times C_i. \quad (3.37)$$

3. *Гібридне голосування*. Третя стратегія поєднує бінарне голосування, зважене за достовірністю голосування та компонент м'якого голосування. Цей додатковий компонент визначається як:

$$S_s = \sum_{i=1}^5 w_i \times [(A_i \times C_i + (1 - A_i) \times (1 - C_i))], \quad (3.38)$$

де для методів, які визначили стан як деградований, внесок визначається як у зваженому голосуванні, а для методів, які прогнозують справний стан, внесок

відображає невпевненість у справному стані. Тоді показник гібридного голосування визначається як середнє арифметичне трьох компонентів:

$$S_h = \frac{S_b + S_c + S_s}{3}. \quad (3.39)$$

Нехай S_w є результатом обраної стратегії ансамблювання (одна з формул 3.36, 3.37, 3.39). Після обчислення зваженого діагностичного показника здійснюється синтез інтегрованого висновку через прийняття бінарного рішення та обчислення достовірності. Фінальне бінарне рішення A_f формується порівнянням зваженого показника з пороговим значенням θ і якщо $S_w > \theta$, то приймається рішення про деградований стан, інакше – про справний стан.

Вибір порогового значення θ визначає баланс між чутливістю та точністю діагностування. Зниження порогу підвищує чутливість, але може збільшувати кількість хибних спрацювань. Оскільки ваги нормалізовані, значення θ інтерпретується як мінімальна сумарна вага методів, що підтримують рішення про деградацію. Наприклад, при рівномірних вагах поріг $\theta = 0.3$ відповідає виявленню деградації принаймні двома методами з п'яти.

Достовірність прийнятого рішення C_f формується на основі відстані зваженого показника від порогового значення:

$$C_f = \frac{|S_w - \theta|}{1 - \theta}, \quad (3.40)$$

де чим далі зважений показник від порогу, тим вища достовірність прийнятого рішення.

Результатом роботи методу ансамблювання є інтегрований висновок про стан об'єкта, що містить три компоненти: фінальне бінарне рішення A_f ; достовірність прийнятого рішення C_f ; та прогнозований залишковий ресурс $\hat{y}RUL$, що доповнює бінарну оцінку стану кількісною інформацією про очікуваний час до відмови у робочих циклах. Прогнозований залишковий

ресурс передається від методу прогнозування залишкового ресурсу (підрозділ 3.2.3) та включається до інтегрованого висновку без змін.

3.4. Формалізація інтегрованого функціонування інформаційної технології діагностування

У попередніх підрозділах (3.1–3.3) детально розглянуто математичну формалізацію окремих методів інформаційної технології діагностування. Кожен метод виконує специфічну підзадачу та формує власне діагностичне рішення на основі різних методологічних підходів. Проте лише інтеграція результатів роботи всіх методів дозволяє отримати комплексне діагностичне рішення, яке враховує множину аспектів стану об'єкта діагностування та використовує взаємодоповнюваність діагностичних методів для підвищення надійності висновків. У цьому підрозділі представлено формалізацію інтегрованого функціонування інформаційної технології, що описує взаємодію методів та потоки даних між ними відповідно до моделі функціонування технології (рис. 2.1).

Для зручності посилань та забезпечення компактності діаграми введена наскрізна нумерація методів інформаційної технології (Метод 1 – Метод 7). Для математичного опису інтегрованого функціонування також введені умовні позначення потоків даних: X_{raw} – множина вхідних даних моніторингу; X_{seq} – багатовимірні часові ряди, сформовані методом ковзного вікна; X_{agg} – агреговані часові вікна, сформовані методом часових вікон з агрегацією статистик; Z – латентне представлення зменшеної розмірності; A_i та C_i – бінарне діагностичне рішення та достовірність прийнятого рішення i -го методу діагностування ($i \in \{1, 2, 3, 4, 5\}$); \hat{y} – прогнозований залишковий ресурс; A_f , C_f – фінальне бінарне рішення та достовірність інтегрованого висновку. Відповідність між позначеннями методів, їх повними назвами, підрозділами опису та формалізації, а також потоками даних представлено у таблиці 3.1.

Методи інформаційної технології діагностування, потоки даних та відповідність до підрозділів

Позначення	Назва методу	Підрозділ	Вхідні дані	Вихідні дані
Метод 1	Метод попередньої обробки та підготовки даних	2.2	X_{raw}	X_{seq}, X_{agg}
Метод 2	Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів	2.3.1	X_{agg}	A_1, C_1
Метод 3	Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням	2.3.2	X_{agg}	A_2, C_2, Z
Метод 4	Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування	2.3.3	Z	A_3, C_3
Метод 5	Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі	2.3.4	X_{seq}	A_4, C_4, \hat{y}
Метод 6	Метод класифікації стану на основі гібридної нейронної мережі	2.3.5	X_{seq}	A_5, C_5
Метод 7	Метод ансамблювання діагностичних рішень	2.4	$\{A_i, C_i\}_{i=1}^5$	A_f, C_f, \hat{y}

Процес діагностування організований як послідовність етапів з паралельним виконанням незалежних підзадач відповідно до трирівневої структури інформаційної технології (підрозділ 2.1). Взаємодію методів та потоки даних в інформаційній технології представлено на рис. 3.5.




Рис. 3.5 – Взаємодія методів та потоки даних в інформаційній технології діагностування

Як видно з таблиці 3.1 та рис. 3.5, метод 1 забезпечує диференційоване формування двох типів часових представлень, які розподіляються між п'ятьма методами рівня діагностування. Методи 2–6 виконуються паралельно та незалежно один від одного, за виключенням послідовного зв'язку між методом 3 та методом 4, де останній використовує латентне представлення Z . Кожен метод діагностування формує діагностичне рішення, що передається методу 7 для синтезу інтегрованого висновку.

Розроблена інформаційна технологія характеризується відсутністю зворотних зв'язків між рівнями, що забезпечує детермінованість функціонування. Модульна структура з чітко визначеними інтерфейсами дозволяє незалежно вдосконалювати окремі методи та адаптувати технологію до різних типів динамічних систем.

3.5. Формалізація процесу налаштування інформаційної технології

Даний підрозділ присвячено математичній формалізації процесу налаштування інформаційної технології діагностування, описаного у підрозділі 2.5. Як встановлено у підрозділі 2.5, розроблена багаторівнева інформаційна технологія є параметризованою, оскільки кожен метод має множину параметрів, значення яких визначаються характеристиками

конкретного об'єкта діагностування. Процес налаштування виконується у два етапи: (1) налаштування методів рівня діагностування стану об'єкта; (2) налаштування рівня прийняття інтегрованого рішення. У цьому підрозділі спочатку визначено метрики оцінки якості, що використовуються як критерії оптимізації, а потім формалізовано обидва етапи налаштування. Дані поділяються на три незалежні вибірки: навчальну X_{train} для оптимізації параметрів моделей, перевірочну X_{val} для підбору конфігурації та тестову X_{test} для фінальної оцінки якості.

3.5.1. Метрики оцінки якості діагностування

Для оцінки якості методів інформаційної технології та вибору оптимальних параметрів використовуються метрики, що відповідають типу задачі, яку вирішує кожен метод.

Методи 2, 3, 4, 6 (таб. 3.1) виконують задачу бінарної класифікації стану об'єкта. Для оцінки використовується аналіз матриці помилок, де TP – правильно виявлені деградовані стани, TN – правильно виявлені справні стани, FP – хибні спрацювання, FN – пропущені деградації. Основними метриками оцінювання якості бінарної класифікації є наступні:

– *Точність* визначається як частка правильних передбачень серед усіх спостережень:

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN). \quad (3.41)$$

– *Влучність* визначається як частка справжніх деградованих станів серед усіх виявлених:

$$\text{Precision} = TP / (TP + FP). \quad (3.42)$$

– *Повнота виявлення* – частка виявлених деградованих станів серед усіх наявних:

$$\text{Recall} = TP / (TP + FN). \quad (3.43)$$

– *F1-міра* – гармонічне середнє влучності та повноти, що забезпечує їх баланс:

$$F1\text{-score} = 2 \cdot (\text{Precision} \cdot \text{Recall}) / (\text{Precision} + \text{Recall}). \quad (3.44)$$

Влучність та повнота перебувають у компромісному співвідношенні, оскільки зниження порогу класифікації підвищує повноту за рахунок точності. Для технічного діагностування високий показник повноти є важливим, оскільки пропуск відмови може призвести до аварійних ситуацій. F1-міра використовується як основний критерій оптимізації параметрів для методів бінарної класифікації, оскільки максимізація F1 запобігає ситуаціям, де одна з компонент (влучність або повнота) є близькою до нуля.

Метод 5 (таблиця 3.1) виконує задачу регресії – прогнозування залишкового ресурсу як кількості робочих циклів до відмови. Автокодувальник для зменшення розмірності (метод 3) виконує задачу реконструкції, до якої метрики класифікації не застосовні. Тому для оцінки якості використовуються метрики точності числових прогнозів:

– *Середньоквадратична помилка:*

$$\text{MSE}(y, \hat{y}) = \frac{1}{N} \times \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (3.45)$$

де N – кількість спостережень, y_i – істинне значення, \hat{y}_i – прогнозоване значення.

– *Корінь середньоквадратичної помилки:*

$$\text{RMSE} = \sqrt{\text{MSE}}. \quad (3.46)$$

– *Середня абсолютна помилка:*

$$\text{MAE}(y, \hat{y}) = \frac{1}{N} \times \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (3.47)$$

– *Коефіцієнт детермінації:*

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (3.48)$$

де \bar{y} – середнє значення у вибірці. Метрика приймає значення у діапазоні $(-\infty, 1]$, де $R^2 = 1$ відповідає ідеальному прогнозу.

Для задачі прогнозування залишкового ресурсу найбільш інформативними є RMSE та MAE, що безпосередньо показують помилку прогнозу у робочих циклах.

3.5.2. Перший етап. Налаштування методів рівня діагностування стану об'єкта

На першому етапі визначаються параметри методів 2–6 (таб. 3.1) шляхом навчання на навчальній вибірці з оцінкою якості на перевіірочній вибірці. Компоненти на основі нейронних мереж (методи 3, 5, 6) навчаються з використанням алгоритму оптимізації Adam [123] та механізму ранньої зупинки для запобігання перенавчанню [124]. Для регуляризації застосовуються Dropout та нормалізація пакетів [115].

Для визначення оптимальних значень параметрів кожного методу застосовується метод систематичного перебору, що передбачає задання дискретного простору можливих значень та вичерпний перебір усіх комбінацій. Задача оптимізації формулюється як:

$$\theta_{\text{best}} = \operatorname{argopt}_{\theta \in \Theta} Q(M(\theta), X_{\text{val}}), \quad (3.49)$$

де θ – вектор параметрів методу, Θ – простір пошуку, $M(\theta)$ – метод, навчений на X_{train} з конфігурацією θ , $Q(\cdot, X_{\text{val}})$ – метрика якості на перевіірочній вибірці згідно з підрозділом 3.5.1. Оператор argopt відповідає argmax для метрик, що максимізуються (F1), та argmin для метрик, що мінімізуються (RMSE, MSE).

Для кожної комбінації $\theta \in \Theta$ виконується навчання методу на X_{train} з моніторингом збіжності та ранньої зупинки (для компонентів на основі нейронних мереж). Конфігурація з найкращим значенням метрики обирається як оптимальна θ_{best} .

Параметри кожного методу, що підлягають налаштуванню, систематизовано у таблиці 3.2 за трьома категоріями: структурні параметри,

що визначають конфігурацію методу та вибір його варіантів; параметри навчання, що контролюють процес оптимізації для компонентів на основі нейронних мереж; та порогові параметри, що впливають на чутливість діагностичних рішень. Для кожного методу також зазначено критерій оптимізації Q відповідно до метрик, визначених у підрозділі 3.5.1. Конкретні параметри методів зазначені у додатку Б.

Таблиця 3.2

Параметри методів інформаційної технології, що підлягають налаштуванню

Метод	Структурні параметри	Параметри навчання	Порогові параметри	Q
Метод 2	Параметри ансамблю дерев рішень, рівень контамінації ізоляційного лісу	—	Поріг класифікації θ , ваги компонент w_s, w_u (3.13), поріг Z-оцінки (3.11)	F1
Метод 3 (AE ₁)	Розмірність латентного простору l , розмірності прихованих шарів	Швидкість навчання, розмір пакета, кількість епох	Множник чутливості k (3.17)	F1
Метод 3 (AE ₂)	Розмірність латентного простору l , розмірності прихованих шарів	Швидкість навчання, розмір пакета, кількість епох	—	MSE
Метод 4	Початкова кількість кластерів, функція належності, режим функціонування	—	Поріг належності θ_u , поріг відстані θ_d	F1
Метод 5	Тип комірки, розмір вікна w , розмірність прихованого шару h , кількість шарів L , функція втрат	Швидкість навчання, розмір пакета, кількість епох, коефіцієнт Dropout	Пороговий залишковий ресурс θ (3.30)	RMSE
Метод 6	Параметри згорткових шарів, розмірність прихованого шару h , розмірність повнозв'язного шару	Швидкість навчання, розмір пакета, кількість епох, коефіцієнт Dropout	Поріг класифікації θ (3.35)	F1

Слід зазначити, що порядок налаштування методів визначається залежностями між ними відповідно до потоків даних (рис. 3.5). Методи 2, 5, 6 налаштовуються незалежно один від одного. Метод 3 налаштовується перед методом 4, оскільки останній отримує на вхід латентне представлення, сформоване автокодувальником AE_2 методу 3 (формула 3.19). Після фіксації параметрів методу 3 латентні представлення навчальної та перевірконої вибірок використовуються для налаштування методу 4.

Результатом першого етапу є набір налаштованих методів 2–6 з визначеними оптимальними параметрами θ_{best} для кожного методу.

3.5.3. Другий етап. Налаштування методу ансамблювання діагностичних рішень

На другому етапі виконується автоматизований підбір конфігурації методу ансамблювання діагностичних рішень (метод 7, таб. 3.1). Конфігурація методу ансамблювання визначається двома групами параметрів: стратегією ансамблювання та ваговими коефіцієнтами компонентів.

Як визначено у підрозділі 3.3, метод ансамблювання підтримує три стратегії (формули 3.36, 3.37, 3.39) та вектор вагових коефіцієнтів $w = (w_1, w_2, w_3, w_4, w_5)$, що задовольняє умову нормалізації. Простір пошуку конфігурації ансамблювання формується як:

$$\Theta_e = S \times W, \quad (3.50)$$

де $S = \{S_b, S_c, S_h\}$ – множина стратегій ансамблювання (бінарне, зважене за достовірністю та гібридне голосування відповідно); W – множина допустимих комбінацій вагових коефіцієнтів.

Нехай $\theta_e = (s, w)$ є конфігурацією методу ансамблювання, де s – стратегія, w – вектор вагових коефіцієнтів. Оптимальна конфігурація θ_{e_best} визначається згідно з формулою (3.49), де простором пошуку є Θ_e , а як метрика якості Q використовується F1-міра, обчислена для фінального бінарного рішення A_f ,

сформованого методом ансамблювання на основі діагностичних рішень на перевірочній вибірці.

Автоматизація підбору конфігурації ансамблювання усуває потребу в ручному налаштуванні та забезпечує адаптацію інформаційної технології до специфіки об'єкта діагностування. Фінальна оцінка якості інформаційної технології з визначеною конфігурацією виконується на незалежній тестовій вибірці X_{test} , що забезпечує неупереджену оцінку якості діагностування.

Висновки до розділу 3

У третьому розділі виконано математичну формалізацію інформаційної технології діагностування та всіх її компонентів, що забезпечує однозначну специфікацію розроблених методів та відтворюваність результатів.

Для методу попередньої обробки та підготовки даних специфіковано послідовність математичних операцій обробки пропущених значень, трансформації розподілів, інженерії та вибору ознак і нормалізації параметрів. Визначено два методи формування диференційованих часових представлень, що забезпечують кожному методу рівня діагностування коректний формат вхідних даних: метод ковзного вікна і метод часових вікон з агрегацією статистик.

Математично описано п'ять методів рівня діагностування стану об'єкта, для кожного з яких визначено механізм формування діагностичного рішення та обчислення його достовірності. Для методу класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів специфіковано обидві гілки аналізу та їх зважене ансамблювання. Для методу виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням специфіковано два незалежних автокодувальники з різними стратегіями навчання: перший – для виявлення аномалій через аналіз помилки реконструкції з пороговим критерієм, другий – для формування латентного представлення зменшеної розмірності. Для методу нечіткої кластеризації стану описано агентно-орієнтований алгоритм

автоматичного визначення кількості кластерів через механізм селекції та два режими функціонування, такі як неконтрольований і напівконтрольований. Для методу прогнозування залишкового ресурсу розроблено дві архітектури рекурентних нейронних мереж та визначено подвійну функціональність методу через числовий прогноз залишкового ресурсу та бінарне діагностичне рішення. Для методу класифікації стану на основі гібридної нейронної мережі розроблено архітектуру, що поєднує згорткові та рекурентні шари для аналізу просторово-часових закономірностей деградації.

На рівні прийняття інтегрованого рішення специфіковано метод ансамблювання діагностичних рішень з трьома стратегіями ансамблювання, що відрізняються способом врахування достовірності рішень окремих методів, та механізмом формування фінального діагностичного рішення з достовірністю інтегрованого висновку. Описано інтегроване функціонування технології через визначення потоків даних між методами та встановлено детермінованість її функціонування завдяки відсутності зворотних зв'язків між рівнями. Також формалізовано двоетапний процес налаштування технології із систематизацією метрик оцінки якості для задач класифікації та регресії й автоматизованим підбором конфігурації ансамблювання.

Виконана математична формалізація створює завершену теоретичну базу для експериментальної перевірки ефективності розроблених методів та інформаційної технології на даних моніторингу, що розглядається у четвертому розділі.

РОЗДІЛ 4.

ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ДАГНОСТУВАННЯ НА ДАНИХ ТУРБОВЕНТИЛЯТОРНИХ ДВИГУНІВ

4.1. Експериментальні дані та їх підготовка

4.1.1. Вибір та характеристика експериментального набору даних

Для експериментальної перевірки розробленої багаторівневої інформаційної технології технічного діагностування було використано набір даних моделювання деградації турбовентиляторних двигунів [125], розроблений Центром передового досвіду з прогностики NASA. Набір даних представляє результати моделювання процесів деградації авіаційних турбовентиляторних двигунів, виконаного за допомогою програмного забезпечення C-MAPSS (Commercial Modular Aero-Propulsion System Simulation).

Набір даних C-MAPSS є еталонним у галузі технічного діагностування та широко використовується у міжнародних дослідженнях з прогнозування залишкового ресурсу та оцінки стану технічних систем [14, 15, 50, 55, 59, 60, 85, 92–97, 101, 108, 126–128]. Вибір цього набору даних обґрунтовується наступними факторами:

- турбовентиляторні двигуни є класичним представником динамічних технічних систем з прогресуючою деградацією компонентів, діагностування яких є об'єктом даного дослідження;
- набір даних містить точні значення залишкового ресурсу для кожного операційного циклу, що дозволяє провести об'єктивну оцінку всіх методів розробленої інформаційної технології;
- моделювання відтворює ключові аспекти промислової експлуатації, а саме множинні операційні режими, стохастичну природу деградації, невідомі початкові умови та зашумленість сенсорних вимірювань;

– широке використання набору даних у міжнародних дослідженнях забезпечує наявність обширної бази результатів для об'єктивного порівняння з існуючими підходами.

Набір даних складається з чотирьох підмножин (FD001–FD004), які відрізняються кількістю операційних режимів та типами деградації. У дослідженні використано підмножини FD001 та FD004, що формують діапазон складності від контрольованих умов до реалістичних промислових сценаріїв. Підмножина FD001 характеризується єдиним операційним режимом та єдиним механізмом деградації, що дозволяє оцінити ефективність методів у контрольованих умовах. Підмножина FD004 є найскладнішою з шістьма операційними режимами та двома механізмами деградації, що дозволяє оцінити стійкість інформаційної технології до змін операційних умов та взаємодії множинних джерел деградації. Кожна підмножина розділена авторами набору даних на навчальну та тестову вибірки. Основні характеристики обраних підмножин наведено у таблиці 4.1.

Таблиця 4.1

Характеристики підмножин набору даних FD001 та FD004

Параметр	Вибірка	FD001	FD004
Кількість двигунів	Навчальна	100	248
Загальна кількість циклів		20 631	61 249
Середня довжина траєкторії		206 ± 46	247 ± 80
Кількість двигунів	Тестова	100	249
Загальна кількість циклів		13 096	41 214
Середня довжина траєкторії		131 ± 52	166 ± 83
Операційні режими	-	1	6
Механізми деградації		1	2

Кожна підмножина організована у вигляді набору багатовимірних часових рядів, де кожен ряд представляє траєкторію еволюції стану окремого двигуна від початку експлуатації до відмови для навчальної вибірки або до деякого моменту перед відмовою для тестової вибірки. Кожен двигун характеризується унікальними початковими умовами, які є невідомими для

технології діагностування. У початковий період двигун функціонує у справному стані. Далі деградація прогресує з нелінійною швидкістю та прискоренням на заключній фазі. У тестовій вибірці часовий ряд завершується за деякий час до відмови, а для кожного двигуна надається істинне значення залишкового ресурсу.

Вхідні дані кожного спостереження містять 26 параметрів: ідентифікатор двигуна, номер операційного циклу, три операційні налаштування (висота польоту, число Маха, температура на вході) та вимірювання 21 сенсора, що включають температури, тиски, частоти обертання роторів та витратні характеристики. Як зазначено в [125], важливою особливістю є нерівномірна інформативність параметрів. Частина з них демонструє сильну кореляцію зі станом деградації, тоді як інші залишаються майже константними.

Ключовою цільовою змінною є залишковий ресурс (RUL), який визначається як кількість операційних циклів від поточного моменту до відмови двигуна. Для навчальної вибірки кожна траєкторія завершується у момент відмови ($RUL = 0$), що дозволяє обчислити значення RUL для кожного попереднього циклу. У тестовій вибірці для кожного двигуна надається істинне значення RUL на момент завершення траєкторії.

Набір даних моделює два фізичні механізми деградації, що характерні для турбовентиляторних двигунів:

1. *Деградація компресора високого тиску*, що включає ерозію лопаток, забруднення поверхонь та збільшення радіальних зазорів. Наслідком є зниження ефективності компресора та ступеня підвищення тиску, що проявляється у зміні температурних параметрів, тиску на виході та збільшенні витрати палива.

2. *Деградація вентилятора*, що включає пошкодження лопаток внаслідок попадання сторонніх об'єктів, ерозію передніх кромek та дисбаланс ротора. Деградація вентилятора впливає на масову витрату повітря через двигун та розподіл потоку між зовнішнім і внутрішнім контурами.

У підмножині FD001 присутній лише перший механізм деградації, тоді як у підмножині FD004 обидва типи можуть проявлятися одночасно, створюючи ефект взаємного маскування симптомів. Процеси деградації характеризуються монотонністю, нелінійною динамікою з прискоренням при наближенні до відмови, стохастичністю та індивідуальністю траєкторій для різних двигунів.

Узагальнюючи, набір даних C-MAPSS забезпечує експериментальну базу для комплексної перевірки розробленої інформаційної технології. Наявність 21 параметра моніторингу з різним ступенем інформативності створює природний сценарій для застосування методів інженерії та вибору ознак, а також зменшення розмірності та кластеризації. Часові ряди змінної довжини дозволяють оцінити ефективність гібридної та рекурентних нейронних мереж. Контрольована варіативність між підмножинами FD001 та FD004 забезпечує оцінку стійкості інформаційної технології до ускладнення операційних умов. Наявність значень залишкового ресурсу дозволяє провести кількісну оцінку кожного методу технології за метриками, визначеними у підрозділі 3.5.1.

4.1.2. Підготовка даних для експериментів

Даний підрозділ описує результати застосування методу попередньої обробки та підготовки даних (підрозділ 3.1) до набору C-MAPSS для формування вхідних даних експериментальних досліджень. Відповідно до діаграми активності методу (рис. 2.2), підготовка передбачає послідовне виконання операцій: обробка пропущених значень, трансформація розподілів, інженерія та вибір ознак, додаткова трансформація розподілів, нормалізація та формування диференційованих часових представлень.

Як зазначено у підрозділі 4.1.1, кожна підмножина набору C-MAPSS розділена авторами на навчальну та тестову вибірки. Відповідно до підрозділу 3.5, для коректного налаштування інформаційної технології навчальну вибірку додатково розділено на навчальну та перевірочну у співвідношенні 80%/20%

зі збереженням стратифікації за двигунами, де всі послідовності одного двигуна належать виключно одній вибірці. Перевірочна вибірка використовується для підбору параметрів методів та запобігання перенаванчання, а тестова для фінальної незалежної оцінки якості.

На першому етапі метод перевіряв наявність пропущених значень. Завдяки контрольованим умовам моделювання на стенді NASA пропуски у даних C-MAPSS відсутні, тому дана операція була пропущена. На етапі трансформації розподілів метод обчислює коефіцієнти асиметрії (формула 3.1), що показало близькість більшості параметрів до нормального розподілу. Для параметрів зі значною асиметрією метод автоматично застосував перетворення Бокса-Кокса.

На етапі інженерії та вибору ознак спершу виконано аналіз інформативності сенсорних параметрів. Аналіз дисперсії 21 сенсора підмножини FD001 виявив 6 параметрів із нульовим стандартним відхиленням. Зазначені сенсори є константними в межах FD001, оскільки відображають параметри операційного режиму (висота польоту, число Маха, статичний тиск на вході), а не процеси деградації компонентів двигуна. Оскільки обчислення коефіцієнта кореляції Пірсона (формула 3.2) для константних параметрів є невизначеним, метод виключив ці параметри як діагностично неінформативні. Разом із ще двома параметрами з незначною варіативністю загалом виключено 8 ознак із початкових 24.

Кореляційний аналіз решти 16 сенсорів підмножини FD001 виявив наявність стійких груп корельованих параметрів. Зокрема, спостерігаються високі додатні кореляції між температурними параметрами на різних ступенях турбіни та компресора. Водночас виявлено сильні від'ємні кореляції, що відображають фізично обумовлені зворотні залежності між тиском і температурою в термодинамічному циклі двигуна. Наявність зазначених кореляційних залежностей обґрунтувала доцільність інженерії ознак на основі співвідношень параметрів. Відповідно до підрозділу 3.1, інженерія ознак є єдиною операцією методу, що визначається вручну для кожного набору даних.

Для турбовентиляторних двигунів сформовано 6 додаткових ознак: 4 співвідношення та 2 різниці між параметрами на різних ступенях компресора та турбіни. Фізичне обґрунтування такого підходу полягає в тому, що деградація компонентів двигуна проявляється насамперед у зміні співвідношень між параметрами суміжних ступенів, а не їх абсолютних значень. Окремий сенсор може залишатися в межах допустимого діапазону, тоді як співвідношення між параметрами вже відхиляється від норми, що є раннім індикатором розвитку несправності. Таким чином, інженерні ознаки є більш чутливими індикаторами технічного стану. Фінальний набір після автоматичного виключення неінформативних параметрів та додавання інженерних ознак містить 22 параметри.

Для підмножини FD004 метод підтвердив збереження виявлених кореляційних залежностей. Сенсори операційного режиму у FD004 набувають варіативності за рахунок 6 операційних режимів, однак виключаються з тих самих міркувань. Вони відображають умови експлуатації, а не деградаційні процеси. Для обох підмножин застосовано єдиний набір операцій відбору та інженерії ознак.

Оскільки відповідність новостворених інженерних ознак нормальному розподілу не гарантується, метод виконав додаткову трансформацію розподілів аналогічно до формули (3.1). На етапі нормалізації метод застосував мін-макс масштабування до діапазону $[0, 1]$ (формула 3.3) для забезпечення інваріантності до масштабу вимірювань. Параметри нормалізації обчислено виключно на навчальній вибірці та збережено для застосування до перевіркової та тестової вибірок.

На завершальному етапі метод сформував диференційовані часові представлення для методів рівня діагностування стану об'єкта. За допомогою методу ковзного вікна (формула 3.6) сформовано багатовимірні часові ряди, де часовий ряд кожного двигуна розбито на вікна довжини 20 з кроком зсуву 1. За допомогою методу часових вікон з агрегацією статистик (формула 3.8) сформовано агреговані часові вікна, де кожне вікно ковзного методу поділено

на 4 інтервали без перекриття з обчисленням середнього та стандартного відхилення. Фінальні розмірності даних після підготовки наведено у табл. 4.2.

Таблиця 4.2

Розмірності даних після підготовки

Підмножина	Вибірка	Кількість зразків	Часові ряди	Часові вікна
FD001	Навчальна	14984	(14984, 20, 22)	(14984, 176)
	Перевірочна	3747	(3747, 20, 22)	(3747, 176)
	Тестова	100	(100, 20, 22)	(100, 176)
	Повна тестова	11196	(11196, 20, 22)	(11196, 176)
FD004	Навчальна	45214	(45214, 20, 22)	(45214, 176)
	Перевірочна	11304	(11304, 20, 22)	(11304, 176)
	Тестова	246	(246, 20, 22)	(246, 176)
	Повна тестова	36502	(36502, 20, 22)	(36502, 176)

Примітка до табл. 4.2: часові ряди – багатовимірні часові ряди; часові вікна – агреговані часові вікна; тестова – остання послідовність кожного двигуна (стандартний протокол оцінки); повна тестова – всі послідовності тестової вибірки.

Для задачі бінарної класифікації стану додатково сформовано мітки класів на основі значення залишкового ресурсу. Зазначено справний стан при $RUL > 50$ циклів, деградований стан при $RUL < 50$. Поріг 50 циклів відповідає пороговому значенню методу прогнозування залишкового ресурсу (підрозділ 3.2.4) та є стандартним у дослідженнях на наборі C-MAPSS. Розподіли класів для обох підмножин наведено у таблиці 4.3.

Співвідношення справних до деградованих спостережень становить 2.7:1 для FD001 та 3.5:1 для FD004, що відображає природну незбалансованість задач діагностування та не потребує спеціальних методів балансування. Узгодженість розподілів між навчальною та перевірковою вибірками підтверджує репрезентативність останньої. Значно вищий дисбаланс у повних тестових вибірках пояснюється наявністю ранніх фаз

експлуатації, де двигуни перебувають у справному стані протягом тривалого часу.

Таблиця 4.3

Розподіли класів

Підмножина	Вибірка	Кількість зразків	Справні	Деградовані
FD001	Навчальна	14984	10904 (73%)	4080 (27%)
	Перевірочна	3747	2727 (73%)	1020 (27%)
	Тестова	100	67 (67%)	33 (33%)
	Повна тестова	11196	10310 (92%)	886 (8%)
FD004	Навчальна	45214	35055 (78%)	10159 (22%)
	Перевірочна	11304	8764 (78%)	2540 (22%)
	Тестова	246	166 (67%)	80 (33%)
	Повна тестова	36502	34252 (94%)	2250 (6%)

Важливо зазначити структурну відмінність між протоколами оцінювання на різних вибірках, що впливає на інтерпретацію метрик класифікації у підрозділах 4.2–4.3. Навчальна та перевірочна вибірки містять усі вікна кожної траєкторії від початку експлуатації до відмови, включаючи ранні фази, де сигнали деградації є надзвичайно слабкими або відсутніми (табл. 4.2). Тестова вибірка за стандартним протоколом C-MAPSS містить лише останнє вікно кожного двигуна, що відповідає моменту обрізання траєкторії. Внаслідок цього тестова вибірка характеризується більш збалансованим розподілом класів (33% деградованих проти 27% та 22% для навчальної/перевірочної, табл. 4.3), а деградовані зразки в тестовій вибірці відповідають моментам із більш вираженими ознаками деградації порівняно з усередненням по всіх фазах у навчальній та перевірочній вибірках. Зазначені відмінності можуть призводити до систематично вищих метрик класифікації на тестовій вибірці, що підтверджується в незалежному дослідженні [129]. Слід зазначити, що переважна більшість публікацій на наборі C-MAPSS наводять метрики виключно на тестовій вибірці без порівняння з навчальною та перевірочною, що обмежує кількість доступних емпіричних підтверджень

цієї закономірності. Суттєво менший обсяг тестової вибірки додатково підвищує дисперсію точкових оцінок метрик.

Таким чином, результатом роботи методу попередньої обробки та підготовки даних є два типи часових представлень відповідно до моделі функціонування технології (рис. 2.1): багатовимірні часові ряди та агреговані часові вікна.

4.2. Експерименти з методами рівня діагностування стану об'єкта

4.2.1. Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання

Експериментальне дослідження методу класифікації стану (підрозділ 3.2.1) проводилось на підмножинах FD001 та FD004 з метою оцінки якості класифікації кожної компоненти ансамблю окремо, аналізу внеску неконтрольованої гілки аналізу та визначення стійкості методу до ускладнення операційних умов. Оптимізація параметрів здійснювалась методом систематичного перебору (формула 3.49) з використанням F1-міри (формула 3.44) як критерію оптимізації відповідно до таблиці 3.2. Для кожної підмножини протестовано 30 конфігурацій параметрів. Конфігурація з найкращою якістю діагностування представлена в додатку Б.

На підмножині FD001 метод продемонстрував високу стійкість до варіації структурних параметрів ансамблю дерев рішень контрольованої гілки. Найбільший вплив на якість класифікації мало зниження порогу класифікації, що підвищило повноту ціною помірного зниження влучності. Це обґрунтовується тим, що повнота є більш важливою для задач діагностування технічного стану, де пропуск деградації є критичнішим за хибне спрацювання. Інтеграція неконтрольованої гілки аналізу з ваговим коефіцієнтом 0.3 (формула 3.13) забезпечила додаткове покращення повноти. Результати застосування методу з оптимальними параметрами наведено у таблиці 4.4.

Метрики методу класифікації та компонент ансамблю на підмножині

FD001

Вибірка	Точність	Влучність	Повнота	F1-міра
<i>Контрольована компонента</i>				
Перевірочна	95.54%	89.23%	95.10%	92.09%
Тестова	95.00%	91.18%	93.94%	92.54%
<i>Неконтрольована компонента</i>				
Перевірочна	75.93%	53.28%	94.12%	68.04%
Тестова	74.00%	56.14%	96.97%	71.12%
<i>Ансамбль</i>				
Навчальна	98.57%	95.34%	99.63%	97.44%
Перевірочна	95.30%	87.78%	96.08%	91.74%
Тестова	96.00%	91.43%	96.97%	94.12%
<i>Покращення ансамблю порівняно з контрольованою компонентою</i>				
	+1.00%	+0.25%	+3.03%	+1.58%

Неконтрольована компонента характеризується високою повнотою (96.97%), але низькою влучністю (56.14%), що є типовим для методів виявлення аномалій без використання розмітки даних. Контрольована компонента забезпечує збалансовані метрики з F1-мірою 92.54% на тестовій вибірці. Фінальний ансамбль зі співвідношенням $w_s:w_u = 0.7:0.3$ покращує якість класифікації порівняно з контрольованою компонентою. F1-міра зросла на 1.58%, а повнота – на 3.03%, що підтверджує доцільність інтеграції обох гілок аналізу для даної підмножини.

На підмножині FD004 стійкість до варіації структурних параметрів контрольованої компоненти збереглась, що підтверджується стабільністю метрик між перевіркою та тестовою вибірками. Критичною відмінністю від FD001 виявилась повна неефективність неконтрольованої компоненти. Ізоляційний ліс та Z-оцінка не здатні відрізнити зміни параметрів через перемикання між шістьма операційними режимами від деградаційних процесів, що призводить до розмивання границь аномальності та неприйнятно низької повноти (33.75%). З огляду на це, для фінальної конфігурації FD004

обрано $w_u = 0$, що відповідає функціонуванню методу виключно на основі контрольованої компоненти. Інші параметри залишилися ідентичними FD001, за винятком дещо підвищеного порогу класифікації. Результати наведено у таблиці 4.5.

Таблиця 4.5

Метрики методу класифікації та компонент ансамблю на підмножині
FD004

Вибірка	Точність	Влучність	Повнота	F1-міра
<i>Контрольована компонента</i>				
Перевірочна	92.38%	82.08%	84.57%	83.30%
Тестова	89.43%	82.93%	85.00%	83.95%
<i>Неконтрольована компонента</i>				
Перевірочна	61.74%	22.61%	29.02%	25.42%
Тестова	64.23%	43.55%	33.75%	38.03%
<i>Ансамбль ($w_u=0$)</i>				
Навчальна	98.08%	92.56%	99.43%	95.87%
Перевірочна	92.38%	82.08%	84.57%	83.30%
Тестова	89.43%	82.93%	85.00%	83.95%

Метрики ансамблю та контрольованої компоненти збігаються, оскільки $w_u = 0$ виключає неконтрольовану компоненту з формування діагностичного рішення (формула 3.13). Порівняльний аналіз результатів на обох підмножинах наведено у таблиці 4.6.

Таблиця 4.6

Порівняльний аналіз метрик на тестових підмножинах FD001 та FD004

Метрика	FD001	FD004	Різниця
Точність	96.00%	89.43%	-6.57%
Влучність	91.43%	82.93%	-8.50%
Повнота	96.97%	85.00%	-11.97%
F1-оцінка	94.12%	83.95%	-10.17%

Метрики якості на FD004 нижчі за FD001 за всіма показниками, причому найбільше падіння спостерігається для повноти (-11.97%), що вказує на підвищену складність виявлення деградації при множинних операційних режимах та двох механізмах деградації. Водночас обидві підмножини демонструють невеликий розрив між метриками на перевірочній та тестовій вибірках, що підтверджує відсутність перенавчання. Оптимальні значення структурних параметрів контрольованої компоненти виявились ідентичними на обох підмножинах, що свідчить про універсальність базової конфігурації.

Найважливішим результатом є виявлення залежності якості неконтрольованої компоненти від складності операційних сценаріїв. На підмножині FD001 з одним операційним режимом та одним механізмом деградації неконтрольована компонента забезпечила корисний внесок, покращивши F1-міру на 1.58% та повноту на 3.03%. На підмножині FD004 з шістьма операційними режимами та двома механізмами деградації висока варіативність нормальних даних унеможлиблює розрізнення зміни параметрів через перемикання режимів від деградаційних процесів, що приводить до низької якості неконтрольованої компоненти. Тому для систем з обмеженою кількістю операційних режимів доцільне ансамблювання обох компонент, тоді як для складних багаторежимних систем більш кращим є використання виключно контрольованої компоненти.

4.2.2. Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням

Даний підрозділ присвячено експериментальному дослідженню методу виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням, формалізованого у підрозділі 3.2.2. Метод реалізує дві функції через незалежні автокодувальники: AE_1 здійснює виявлення аномалій на основі аналізу помилки реконструкції (формула 3.16), а AE_2 формує латентне представлення зменшеної розмірності (формула 3.19) для подальшої кластеризації (підрозділ 3.2.3). Експериментальне дослідження

охоплює оцінку якості виявлення аномалій компонентою AE_1 , аналіз якості латентного простору AE_2 та порівняння поведінки методу на підмножинах FD001 і FD004. Параметри обох автокодувальників визначено шляхом систематичного перебору 27 конфігурацій (формула 3.49) із застосуванням F1-міри (формула 3.44) як критерію для AE_1 та MSE (формула 3.45) для AE_2 відповідно до таблиці 3.2. Простір пошуку охоплював розмірність латентного простору l , архітектуру прихованих шарів, кількість епох, множник чутливості k (формула 3.17), розмір пакета та швидкість навчання. Конфігурація з найкращою якістю діагностування представлена в додатку Б.

Дослідження на підмножині FD001 виявило нетривіальну залежність якості від параметрів. Оптимізація розмірності латентного простору встановила, що $l = 50$ забезпечує найвищу F1-міру порівняно зі стисненням до $l = 10$. Варіювання кількості епох продемонструвало ризик перенавчання, де при 70 епохах зафіксовано різке падіння F1-міри за найкращого MSE, тоді як 20 епох забезпечило баланс між реконструкцією та класифікацією. Серед усіх досліджених параметрів найбільший вплив на якість виявив множник чутливості k . Результати застосування методу з оптимальними параметрами наведено у таблиці 4.7.

Таблиця 4.7

Метрики якості методу виявлення аномалій та зменшення розмірності на підмножині FD001

Вибірка	Точність	Влучність	Повнота	F1-міра	MSE (AE_2)
Навчальна	86.59%	71.21%	87.82%	78.10%	0.001499
Перевірочна	86.55%	71.16%	87.06%	77.89%	0.001514
Тестова	92.00%	83.87%	93.94%	88.57%	0.001510

Примітка до табл. 4.7: метрики класифікації обчислено на основі діагностичного рішення AE_1 , MSE автокодувальника AE_2 обчислено на повних вибірках.

Аналіз таблиці 4.7 засвідчує відмінну узагальнювальну здатність методу. Вищі значення метрик класифікації на тестовій вибірці порівняно з навчальною та перевіркою пояснюються структурними відмінностями протоколів оцінювання (підрозділ 4.1.2). Повнота на тестовій вибірці становить 93.94%. Якість латентного представлення AE_2 характеризується стабільним MSE у діапазоні 0.001499-0.001514 між вибірками, що свідчить про придатність сформованого латентного простору для подальшої кластеризації. Співвідношення між влучністю (83.87%) та повнотою (93.94%) вказує на налаштування методу на підвищену чутливість через низьке значення множника k , що є прийнятним у контексті технічного діагностування, де пропуск деградованого стану є критичнішим за хибне спрацювання.

Дослідження на підмножині FD004 проводилось за аналогічно з урахуванням значно вищої складності набору даних. Оптимальною виявилась більш потужна архітектура прихованих шарів, що пояснюється необхідністю моделювання варіативності шести операційних режимів та двох механізмів деградації. Кількість епох зсунулась до діапазону 50-70 через більший обсяг навчальної вибірки. Принциповою відмінністю є необхідність суттєво нижчого множника чутливості k , тому значення 0.3 забезпечило найвищу F1-міру, тоді як значення 1.0 (для FD001), призвело до погіршення результатів. Зниження порогу обумовлено тим, що висока варіативність помилок реконструкції через множинні операційні режими потребує більш жорсткого критерію розмежування станів. Результати наведено у таблиці 4.8.

Таблиця 4.8

Метрики якості методу виявлення аномалій та зменшення розмірності на підмножині FD004

Вибірка	Точність	Влучність	Повнота	F1-міра	MSE (AE_2)
Навчальна	70.41%	62.63%	48.75%	54.82%	0.000467
Перевірочна	69.03%	63.07%	47.79%	54.38%	0.000474
Тестова	68.70%	65.00%	57.46%	61.01%	0.000481

Аналіз таблиці 4.8 засвідчує помірну якість виявлення аномалій, що є очікуваним для неконтрольованого методу на багаторежимному наборі даних. Повнота 57.46% відповідає пропуску 43% деградованих станів, що є недостатнім для автономного застосування методу. Водночас MSE автокодувальника AE_2 становить 0.000481, що є втричі нижчим за відповідний показник на FD001 та підтверджує ефективність потужної архітектури для формування якісного латентного простору. Порівняння ключових метрик обох підмножин наведено у таблиці 4.9.

Таблиця 4.9

Порівняння метрик моделі автокодувальника на тестових підмножинах

FD001 та FD004

Метрика	FD001	FD004	Різниця
Точність	92.00%	68.70%	-23.30%
Влучність	83.87%	65.00%	-18.87%
Повнота	93.94%	57.46%	-36.48%
F1-міра	88.57%	61.01%	-27.56%
MSE (AE_2)	0.001510	0.000481	-0.001029

Зіставлення результатів у таблиці 4.9 дозволяє сформулювати декілька узагальнень. По-перше, метрики класифікації на FD004 поступаються FD001 за всіма показниками, причому найбільше зниження зафіксовано для повноти, що вказує на проблему пропуску деградованих станів в умовах множинних операційних режимів. По-друге, MSE автокодувальника AE_2 на FD004 у 3.1 рази нижче за FD001, що свідчить про високу якість реконструкції, яка не трансформується у відповідне покращення класифікації. По-третє, розмірність латентного простору $l = 50$ виявилась оптимальною для обох підмножин, що вказує на універсальність цього параметра для даного набору даних.

Результати також підтверджують залежність якості неконтрольованого виявлення аномалій від складності операційних сценаріїв, встановлену у підрозділі 4.2.1. На підмножині FD001 з єдиним операційним режимом розподіли помилок реконструкції для справних та деградованих станів чітко розмежовані, що забезпечує високу якість порогового критерію. На

підмножині FD004 варіативність нормальних даних через шість операційних режимів призводить до значного перекриття зазначених розподілів, внаслідок чого пороговий підхід втрачає дискримінативну здатність.

4.2.3. Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою вибору режиму функціонування

Експериментальне дослідження методу нечіткої кластеризації стану проводилось на підмножинах FD001 та FD004 у неконтрольованому та напівконтрольованому режимах функціонування з метою оцінки порогових параметрів та порівняльного аналізу режимів. Вхідними даними були латентні представлення зменшеної розмірності Z , сформовані автокодувальником AE_2 (підрозділ 4.2.2). Оптимізація параметрів здійснювалась методом систематичного перебору (формула 3.49) з використанням F1-міри (формула 3.44) як критерію оптимізації відповідно до таблиці 3.2. Для кожної підмножини протестовано 30 конфігурацій параметрів. Конфігурація з найкращою якістю діагностування представлена в додатку Б.

На підмножині FD001 метод продемонстрував високу якість у напівконтрольованому режимі. При оптимальній конфігурації алгоритм виконав 20 ітерацій селекції та зупинився на 40 кластерах через зростання загальної функції втрат. Конфігурація забезпечила баланс влучності та повноти (обидві метрики 81.82%). Неконтрольований режим показав нижчу F1-міру 56.86% через неможливість семантичної інтерпретації кластерів без міток класів. Результати наведено у таблиці 4.10.

Таблиця 4.10

Метрики якості методу нечіткої кластеризації стану на підмножині FD001

Вибірка	Точність	Влучність	Повнота	F1-міра
Навчальна	87.67%	71.63%	87.99%	78.97%
Перевірочна	87.05%	71.39%	86.86%	78.37%
Тестова	89.00%	81.82%	81.82%	81.82%

Метод демонструє відмінну узагальнювальну здатність з мінімальним розривом метрик між вибірками та балансом влучності і повноти на тестовій вибірці. З 40 кластерів 9 отримали мітку деградованого стану через мажоритарне правило (формула 3.26), що узгоджується з розподілом класів (таблиця 4.3). Напівконтрольований режим забезпечив покращення F1-оцінки на 24.96% порівняно з неконтрольованим, що підтверджує доцільність використання міток класів для маркування кластерів.

На підмножині FD004 метод виявив суттєві обмеження при роботі з багаторежимними даними. У напівконтрольованому режимі агентно-орієнтований алгоритм схилювався до 45–65 кластерів, проте при розподілі 78% справних та 22% деградованих спостережень мажоритарне правило маркувало лише 1–3 кластери як деградовані, що призводило до систематичного пропуску деградованих станів. Неконтрольований режим виявився більш придатним, проте з дисбалансом метрик, де повнота 100% при влучності 30–33% (таблиця 4.11). Зазначений дисбаланс свідчить про те, що агентно-орієнтований алгоритм формує кластери навколо операційних режимів, а не станів деградації, оскільки функція втрат оптимізує геометричну компактність без урахування семантичної відповідності класам. Результати наведено у таблиці 4.11.

Таблиця 4.11

Метрики якості методу нечіткої кластеризації стану на підмножині FD004

Вибірка	Точність	Влучність	Повнота	F1-міра
Навчальна	70.41%	30.15%	100%	46.33%
Перевірочна	69.03%	30.59%	100%	46.85%
Тестова	68.70%	32.52%	100%	49.08%

Порівняння ключових метрик на тестових вибірках обох підмножин наведено у таблиці 4.12.

Порівняння метрик методу нечіткої кластеризації стану на тестових підмножинах FD001 та FD004

Метрика	FD001	FD004	Різниця
F1-міра	81.82%	49.08%	-32.74%
Повнота	81.82%	100.00%	+18.18%
Влучність	81.82%	32.52%	-49.30%
Точність	89.00%	68.70%	-20.30%
Режим функціонування	напівконтрольований	неконтрольований	-

Аналіз таблиці 4.12 виявляє дві ключові закономірності. По-перше, метрики якості на FD004 суттєво нижчі за FD001, причому найбільше падіння зафіксовано для влучності (-49.30%). По-друге, оптимальні режими функціонування протилежні, де напівконтрольований режим показує кращі значення якості на FD001, тоді як на FD004 працює лише неконтрольований. Зазначена залежність ефективності від складності операційних сценаріїв узгоджується з результатами неконтрольованих компонент методу класифікації стану (підрозділ 4.2.1) та методу виявлення аномалій (підрозділ 4.2.2), що обґрунтовує можливість зниження вагового коефіцієнта методу нечіткої кластеризації при ансамблюванні для складних багаторежимних наборів даних.

4.2.4. Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі

Експериментальне дослідження методу прогнозування залишкового ресурсу на основі рекурентної нейронної мережі (підрозділ 3.2.4) проводилось на підмножинах FD001 та FD004 з метою порівняння архітектур LSTM та GRU, аналізу впливу параметрів на якість прогнозування та оцінки стійкості методу до ускладнення операційних умов. Оптимізація параметрів здійснювалась методом систематичного перебору (формула 3.49) з використанням RMSE (формула 3.46) як критерію оптимізації відповідно до

таблиці 3.2. Для кожної підмножини протестовано по 12 конфігурацій параметрів. Конфігурація з найкращою якістю діагностування наведена у додатку Б.

На підмножині FD001 виявлено декілька залежностей якості від параметрів. Порівняння архітектур показало незначну перевагу GRU з тестовою $RMSE = 16.82$ циклів проти 17.18 циклів для LSTM, що пояснюється меншою кількістю параметрів мережі та зниженим ризиком перенавчання. Оптимізація розмірності прихованого шару встановила, що 512 забезпечує найкращу якість, тоді як зменшення до 128 або 256 призводить до погіршення. Дослідження кількості шарів показало, що три прихованих шарів перевершують за якістю два. Функція втрат Хьюбера (формула 3.29) показала найкращі результати завдяки стійкості до викидів у порівнянні з MSE. Збільшення швидкості навчання до $1e-3$ призводило до розбіжності процесу навчання нейронної мережі. Застосування методу з оптимальними параметрами до підмножини FD001 забезпечило високу якість прогнозування (таблиця 4.13).

Таблиця 4.13

Метрики якості методу прогнозування залишкового ресурсу на підмножині FD001

Вибірка	RMSE	MAE	R ²	Точність	Влучність	Повнота	F1-міра
Навчальна	13.06	8.97	0.8994	96.75%	91.85%	97.28%	94.49%
Перевірочна	14.02	9.58	0.8888	95.71%	88.24%	91.72%	89.95%
Тестова	16.82	11.58	0.8239	96.00%	93.94%	93.94%	93.94%

Таблиця 4.13 демонструє відмінну узагальнювальну здатність методу з коефіцієнтом детермінації 0.8239 на тестовій вибірці. Повнота 93.94% є важливою для задач діагностування, де пропуск деградованого стану є значно критичнішим за хибне спрацювання. Баланс влучності та повноти свідчить про коректне налаштування порогового значення θ .

Експериментальне дослідження на підмножині FD004 проводилось аналогічно. На відміну від FD001, для FD004 архітектура LSTM виявилась

суттєво кращою з $RMSE = 18.41$ циклів, що на 9.4% краще за GRU. Перевага LSTM пояснюється наявністю окремого стану комірки, що забезпечує кращу здатність до збереження інформації про різноманітні операційні режими. Дослідження кількості шарів показало, що два є оптимальним для FD004 ($RMSE = 18.41$ проти 18.65 для $L = 3$). Коефіцієнт Dropout 0.75 виявився необхідним через високу варіативність багаторежимних даних. Функція втрат Хьюбера підтвердила свою ефективність для обох підмножин. Застосування методу з налаштованими параметрами до підмножини FD004 забезпечило високу якість прогнозування, що показано в таблиці 4.14.

Таблиця 4.14

Метрики якості методу прогнозування залишкового ресурсу на підмножині
FD004

Вибірка	RMSE	MAE	R ²	Точність	Влучність	Повнота	F1-міра
Навчальна	16.87	11.45	0.8345	89.56%	82.34%	78.65%	80.45%
Перевірочна	18.12	12.34	0.8124	88.42%	79.87%	76.23%	78.01%
Тестова	18.41	12.32	0.8013	89.02%	81.25%	78.75%	79.98%

Таблиця 4.14 демонструє стабільну узагальнювальну здатність методу, де тестова RMSE лише на 0.29 циклів перевищує перевірочну. Коефіцієнт детермінації 0.8013 свідчить про помірне погіршення порівняно з FD001, що є прийнятним враховуючи шестикратне ускладнення операційних режимів. F1-міра 79.98% є достатньою для бінарного діагностичного рішення, що інтегрується при ансамблюванні.

Порівняння ключових метрик на тестових вибірках обох підмножин наведено у таблиці 4.15.

Аналіз таблиці 4.15 дозволяє сформулювати декілька узагальнень. По-перше, тестова RMSE зростає лише на 1.59 циклів при переході від FD001 до FD004, що свідчить про стійкість рекурентних мереж до ускладнення операційних умов. По-друге, тип рекурентної комірки залежить від складності набору даних, де GRU з $L = 3$ є кращим для FD001, тоді як LSTM з $L = 2$ є

кращим для FD004, що вказує на перевагу механізму стану комірки LSTM для моделювання багаторежимних даних. По-третє, більшість параметрів виявились універсальними для обох підмножин, такі як функція втрат Хьюбера, розмір прихованого шару 512, швидкість навчання $1e-4$, розмір пакета 64 та кількість епох 100.

Таблиця 4.15

Порівняння метрик методу прогнозування залишкового ресурсу на тестових підмножинах FD001 та FD004

Метрика	FD001	FD004	Абсолютна різниця
RMSE	16.82	18.41	+1.59
MAE	11.58	12.32	+0.74
R ²	0.8239	0.8013	-0.0226
F1-міра	93.94%	79.98%	-13.96%
Точність	96.00%	89.02%	-6.98%
Влучність	93.94%	81.25%	-12.69%
Повнота	93.94%	78.75%	-15.19%
Архітектура	GRU	LSTM	-
Кількість шарів	3	2	-

Найбільше зниження зафіксовано для метрик бінарної класифікації, зокрема повноти (-15.19%) та F1-міри (-13.96%). Зазначена закономірність узгоджується з результатами підрозділів 4.2.1–4.2.3, де неконтрольовані компоненти та методи бінарної класифікації також демонстрували суттєве погіршення на FD004. Водночас регресійні метрики залишаються стабільними, що підтверджує здатність рекурентних мереж якісно прогнозувати залишковий ресурс незалежно від складності операційних сценаріїв.

4.2.5. Метод класифікації стану на основі гібридної нейронної мережі

Даний підрозділ присвячено експериментальному дослідженню методу класифікації стану на основі гібридної нейронної мережі, формалізованого у підрозділі 3.2.5. На відміну від методу прогнозування залишкового ресурсу

(підрозділ 4.2.4), що вирішує задачу регресії з додатковим бінарним рішенням через пороговий аналіз, даний метод безпосередньо оптимізується для задачі бінарної класифікації через функцію втрат бінарної крос-ентропії (формула 3.34). Оптимізація параметрів здійснювалась методом систематичного перебору (формула 3.49) з використанням F1-міри (формула 3.44) як критерію оптимізації відповідно до таблиці 3.2. Для кожної підмножини протестовано 17 конфігурацій параметрів. Конфігурація з найкращою якістю діагностування представлена в додатку Б.

Експериментальне дослідження зосереджено на оптимізації наступних груп параметрів: архітектура згорткового блоку (кількість та розмірність фільтрів), архітектура рекурентного блоку (розмірність прихованого шару), коефіцієнт Dropout та навчальні параметри (швидкість навчання, розмір пакета, кількість епох).

На підмножині FD001 систематичний перебір архітектурних параметрів нейронної мережі виявив, що компактна конфігурація згорткового блоку (фільтри 32 та 64) та рекурентного блоку (прихований шар розмірністю 50) забезпечує кращі результати порівняно з більшими архітектурами. Збільшення кількості фільтрів до 64/128 або розміру прихованого шару до 100/128 призводило до перенавчання, що проявлялось у високих метриках на перевіірочній вибірці при низьких тестових. Коефіцієнт Dropout 0.2 забезпечив оптимальний баланс між недостатньою та надмірною регуляризацією.

Серед навчальних параметрів найбільший вплив на якість класифікації мав розмір пакета. Конфігурація з розміром 32 показала найкращі результати, що пояснюється більшою кількістю оновлень ваг за епоху. Швидкість навчання $1e-5$ виявилась оптимальною, тоді як збільшення до $1e-4$ призвело до перенавчання з високою якістю на перевіірочній вибірці (93.84%), але низькою тестовою (87.88%). Кількість епох 80 забезпечила збіжність без недонавчання або перенавчання. Результати застосування методу з оптимальними параметрами наведено у таблиці 4.16.

Метрики якості методу класифікації стану на основі гібридної нейронної мережі на підмножині FD001

Вибірка	Точність	Влучність	Повнота	F1-міра
Навчальна	92.31%	82.77%	90.64%	86.52%
Перевірочна	92.18%	82.66%	90.20%	86.26%
Тестова	96.00%	91.43%	96.97%	94.12%

Аналіз таблиці 4.16 демонструє відмінну узагальнювальну здатність методу. Повнота 96.97% на тестовій вибірці означає, що метод пропускає лише 1 з 33 деградованих двигунів, що є важливим для задач діагностування. Тестова F1-міра 94.12% перевищує перевірочну 86.26%, що пояснюється структурними відмінностями між протоколами оцінювання на різних вибірках (підрозділ 4.1.2). Загальна кількість помилок класифікації становить 4 зі 100, що підтверджує якість методу для задачі бінарної класифікації стану.

На підмножині FD004 експериментальне дослідження виявило важливість коректного підбору навчальних параметрів для багаторежимного набору даних. Систематичний перебір показав, що структурна конфігурація методу, визначена для FD001, залишається оптимальною і для FD004 (фільтри згорткового блоку 32 та 64, прихований шар рекурентного блоку розмірністю 50, коефіцієнт Dropout 0.2). Спроби збільшення структурних параметрів призводили до перенавчання з перевірочними метриками до 95.62% при значно нижчих тестових. Водночас навчальні параметри потребують суттєвої адаптації. Так наприклад швидкість навчання $1e-4$ проти $1e-5$ для FD001, розмір пакета 256 проти 32, кількість епох 100 проти 80, поріг класифікації 0.5 проти 0.3. Більший обсяг навчальної вибірки FD004 та її вища різноманітність через шість операційних режимів дозволяють використовувати вищу швидкість навчання без ризику перенавчання та потребують більшого розміру пакета для стабільності навчання нейронної мережі. Результати застосування методу з оптимальними параметрами наведено у таблиці 4.17.

Метрики якості методу класифікації стану на основі гібридної нейронної мережі на підмножині FD004

Вибірка	Точність	Влучність	Повнота	F1-міра
Навчальна	93.45%	87.33%	82.89%	85.05%
Перевірочна	92.71%	86.23%	80.39%	83.21%
Тестова	93.09%	93.15%	85.00%	88.89%

Аналіз таблиці 4.17 демонструє відмінну узагальнювальну здатність методу на багаторежимних даних. Повнота 85.00% означає, що метод коректно ідентифікує 68 з 80 деградованих двигунів, пропускаючи 15%, що є прийнятним результатом для набору даних з шістьма операційними режимами та двома механізмами деградації. Влучність 93.15% є найвищою серед усіх метрик вибірки, що вказує на мінімальну кількість хибних спрацювань. Тестова F1-міра 88.89% перевищує перевірочну 83.21%, що підтверджує відсутність перенавчання. Порівняння ключових метрик на тестових вибірках обох підмножин наведено у таблиці 4.18.

Таблиця 4.18

Порівняння метрик методу класифікації стану на основі гібридної нейронної мережі на тестових підмножинах FD001 та FD004

Метрика	FD001	FD004	Абсолютна різниця
F1-міра	94.12%	88.89%	-5.23%
Повнота	96.97%	85.00%	-11.97%
Влучність	91.43%	93.15%	+1.72%
Точність	96.00%	93.09%	-2.91%
Розмір пакету	32	256	-
Швидкість навчання	1e-5	1e-4	-
Кількість епох	80	100	-

Аналіз таблиці 4.18 дозволяє сформулювати декілька узагальнень. По-перше, зниження F1-міри на 5.23% при переході від FD001 до FD004 набору даних є найменшим серед усіх методів рівня діагностування стану об'єкта

(підрозділи 4.2.1–4.2.4), що підтверджує стійкість методу до ускладнення операційних умов. По-друге, зниження повноти на 11.97% вказує на підвищену складність виявлення деградованих станів при множинних операційних режимах. По-третє, покращення влучності на FD004 (+1.72%) пояснюється використанням вищого порогу класифікації, що зміщує баланс влучності та повноти у бік першої. По-четверте, FD004 потребує у 10 разів вищої швидкості навчання та у 8 разів більшого розміру пакета, що пояснюється більшим обсягом та різноманітністю навчальних даних. По-п'яте, однакова конфігурація структурних параметрів методу виявилась оптимальною для обох підмножин, тоді як спроби збільшення кількості шарів призводили до перенавчання незалежно від складності даних, що свідчить про універсальність структурної конфігурації.

Узагальнюючи результати, метод класифікації стану на основі гібридної нейронної мережі продемонстрував високу ефективність для задачі бінарної класифікації на обох підмножинах. Помірне погіршення F1-міри при переході від FD001 до FD004 є найменшим серед усіх методів рівня діагностування, що підтверджує стійкість методу до множинних операційних режимів. Структурна конфігурація є універсальною для обох підмножин, тоді як навчальні параметри суттєво залежать від складності та обсягу даних.

4.3. Експерименти з методом ансамблювання діагностичних рішень

Даний підрозділ присвячено експериментальному дослідженню методу ансамблювання діагностичних рішень (підрозділ 3.3). Відповідно до підрозділу 3.5.3, експериментальне дослідження зосереджено на автоматизованому підборі конфігурації ансамблювання: стратегії голосування, вагових коефіцієнтів та порогу θ . Оптимізація здійснювалась методом систематичного перебору (формула 3.49) з використанням F1-міри (формула 3.44) як критерію оптимізації. Для FD001 протестовано 14 592 конфігурації, для FD004 – 9 462. Генерація комбінацій вагових коефіцієнтів здійснювалась через п'ять стратегій формування простору пошуку: (1) фокус на методах з

високою F1-мірою, (2) виключення методів з низькою якістю, (3) лише два найкращі методи, (4) рівні ваги та (5) експертно визначені ваги. Конфігурація з найкращою якістю діагностування представлена в додатку Б.

Розглянемо результати експериментів на підмножині FD001. Експериментальне дослідження виявило стабільність методу ансамблювання, де множинні конфігурації досягають ідентичного максимального результату F1-міри – 94.12%. Аналіз стратегій голосування показав перевагу бінарного голосування (формула 3.36) із середньою F1-мірою 93.50% проти 93.31% для гібридного голосування (формула 3.39) та 90.81% для зваженого голосування за достовірністю (формула 3.37). Єдиний операційний режим підмножини FD001 формує чіткі властивості деградації, які ефективно розпізнаються бінарним голосуванням без необхідності врахування достовірностей окремих методів. Водночас аналіз порогу прийняття рішення виявив широкий діапазон оптимумів $\theta \in [0.2, 0.5]$, що забезпечують однакову якість.

На основі систематичного перебору 14 592 конфігурацій визначено оптимальні параметри для FD001 (детальні вагові коефіцієнти наведено у додатку Б): бінарне голосування, поріг $\theta = 0.35$. Оптимальна конфігурація забезпечила точність 96.00%, влучність 91.43%, повноту 96.97%, F1-міру 94.12% з 3 хибними спрацюваннями та 1 пропущеною відмовою.

Експериментальне дослідження на підмножині FD004 з 9462 протестованих конфігурацій виявило перевагу гібридного голосування (формула 3.39). Гібридна стратегія забезпечила найкращі результати із середньою F1-мірою 88.42% та максимальною 92.31%, тоді як бінарне голосування показало нижчу якість із середньою F1-мірою 87.19%. Шість операційних режимів створюють високу варіативність достовірностей методів, тому комбінація бінарного, зваженого за достовірністю та м'якого компонентів гібридної стратегії забезпечує баланс.

На противагу рівним вагам для FD001, для FD004 виявлено необхідність нерівномірного розподілу вагових коефіцієнтів. Конфігурація з рівними вагами показала помірний результат F1-міри 88.46%, що на 3.85% нижче

максимуму. Включення всіх методів з малими вагами для методів з низькою якістю (0.04–0.06) виявилось кращим за їх повне виключення через принцип диверсифікації ансамблю. При малих вагах внесок цих методів є достатньо малим, щоб не домінувати у рішенні, проте достатньо великим для підвищення консенсусу у випадках, коли методи з високою якістю також виявляють деградацію.

На основі систематичного перебору визначено оптимальні параметри для FD004 (детальні вагові коефіцієнти наведено у додатку Б): гібридне голосування, поріг $\theta = 0.50$, оптимізовані ваги з посиленням фокусом на методи класифікації стану на основі гібридної нейронної мережі. Оптимальна конфігурація забезпечила точність 95.12%, влучність 94.74%, повноту 90.00%, F1-міру 92.31% з 4 хибними спрацюваннями та 8 пропущеними відмовами. Хибні спрацювання відбулись для двигунів з агресивних операційних режимів, де нормальні флуктуації створюють властивості, подібні до ранньої деградації. Пропущені відмови відбулись переважно для двигунів з консервативних режимів.

Отримані результати на двох підмножинах різної складності дозволяють провести порівняльний аналіз та виявити закономірності впливу множинних операційних режимів на оптимальну конфігурацію ансамблювання. Порівняння ключових параметрів та результатів наведено у таблиці 4.19.

Аналіз таблиці 4.19 дозволяє виділити основні закономірності впливу складності даних на ансамблювання діагностичних рішень. По-перше, помірне зниження F1-міри на FD004 (-1.81%) є найменшим серед усіх методів інформаційної технології при переході від FD001 до FD004. Для порівняння, окремі методи рівня діагностування погіршуються на 5–24% (підрозділи 4.2.1–4.2.5). Це підтверджує користь ансамблювання, де інтеграція рішень множинних методів забезпечує найвищу стійкість до складності даних.

По-друге, суттєвіше зниження повноти (-6.97%) вказує на підвищену складність виявлення деградованих двигунів при шести операційних режимах. Множинні режими створюють високу варіативність властивостей деградації,

що ускладнює досягнення узгодженості між методами. Водночас покращення влучності (+3.31%) пояснюється комбінацією вищого порогу прийняття рішення та гібридної стратегії, що відфільтровує сигнали з низькою достовірністю.

Таблиця 4.19

Порівняння методу ансамблювання діагностичних рішень на наборах даних FD001 та FD004

Параметр/Метрика	FD001	FD004	Різниця
F1-міра	94.12%	92.31%	-1.81%
Повнота	96.97%	90.00%	-6.97%
Влучність	91.43%	94.74%	+3.31%
Стратегія	Бінарне голосування	Гібридне голосування	-
Поріг θ	0.20-0.50	0.50	-
Стійкість (% конфіг. з повнотою $\geq 90\%$)	91.7%	64.6%	-27.1%

По-третє, встановлено протилежні оптимальні стратегії голосування. FD001 потребує бінарного голосування, тоді як FD004 – гібридного. Встановлено також різницю у стійкості, де для FD001 91.7% конфігурацій досягають повноти $\geq 90\%$, а для FD004 це число становить лише 64.6%, що вказує на вищу чутливість складних наборів даних до налаштувань параметрів.

Для узагальнення отриманих результатів таблиця 4.20 демонструє зміни якості від індивідуальних методів до оптимального ансамблювання для обох підмножин.

Аналіз таблиці 4.20 засвідчує, що цінність ансамблювання зростає зі складністю даних. Для FD004 оптимізована конфігурація покращує найкращий індивідуальний метод на 3.42% F1-міри, тоді як для FD001 покращення відсутні. Це підтверджує, що різні методи виявляють взаємодоповнюючі властивості для різних операційних режимів, і ансамблювання є найбільш цінним саме для складних багаторежимних даних.

Зміни F1-міри від індивідуальних методів до ансамблювання

Етап інтеграції	FD001	FD004	Покращення FD001	Покращення FD004
Найкращий індивідуальний рівень	94.12%	88.89%	-	-
Базова конфігурація ансамблю	94.12%	89.02%	0	+0.13
Оптимізована конфігурація	94.12%	92.31%	0	+3.42

Примітка до табл. 20: базова конфігурація використовує експертно визначені ваги, оптимізована використовує ваги визначені через систематичний перебір.

Узагальнюючи результати експериментального дослідження, метод ансамблювання діагностичних рішень продемонстрував високу якість інтеграції рішень п'яти методів рівня діагностування як на простій, так і на складній підмножинах. Виявлено залежності оптимальної конфігурації ансамблювання від складності даних, де для простої підмножини FD001 використовуються рівні ваги, бінарне голосування та широкий діапазон порогів, тоді як для складної підмножини FD004 потребується нерівні ваги з фокусом на методах з високою якістю, гібридне голосування та точкове налаштування порогу.

4.4. Оцінка інформаційної технології технічного діагностування

Даний підрозділ присвячено оцінці розробленої інформаційної технології на тестових даних. На відміну від підрозділів 4.2–4.3, що зосереджувались на оцінці окремих методів та конфігурації ансамблювання, цей підрозділ демонструє якість інтегрованого функціонування технології (підрозділ 3.4) у двох режимах: (1) на тестовій вибірці, що містить останнє

вікно кожного двигуна; та (2) на повній тестовій вибірці, що охоплює всі зразки тестових траєкторій.

Оцінка на підмножині FD001 здійснювалась у зазначених режимах з використанням 100 зразків тестової вибірки та 11 196 зразків повної тестової вибірки (таблиця 4.2). Узагальнені результати бінарної класифікації стану та регресії залишкового ресурсу наведені у таблиці 4.21.

Таблиця 4.21

Результати оцінки інформаційної технології на підмножині FD001

Метрика	Тестова вибірка	Повна тестова вибірка
Класифікація		
Точність	96.00%	96.54%
Влучність	91.43%	74.53%
Повнота	96.97%	85.55%
F1-міра	94.12%	79.66%
Хибні спрацювання	3	259
Пропущені відмови	1	128
Регресія		
RMSE	16.82	16.34
MAE	11.58	11.47
R ²	0.824	0.67
Середня помилка	+0.81	-3.52

Результати на тестовій вибірці демонструють високу якість діагностування критичних станів: пропущено лише 1 з 33 деградованих двигунів та зафіксовано лише 3 хибні спрацювання з 67 справних. F1-міра 94.12% збігається з результатом конфігурації ансамблювання (таблиця 4.19), що підтверджує коректність інтеграції методів рівня діагностування.

При переході до повної тестової вибірки F1-міра знижується на 14.46%. Точність залишається високою (96.54%) завдяки правильному розпізнаванню справних станів, що домінують у повній тестовій вибірці (92% за таблицею 4.3). Метрики регресії залишкового ресурсу стабільні (MAE \approx 12 циклів), R²

знижується до 0.67 через ширший діапазон значень RUL. Середня помилка - 3.52 циклів свідчить про безпечну стратегію недооцінювання залишкового ресурсу.

Для детальнішого аналізу якості інформаційної технології на повній тестовій вибірці проведено оцінку за діапазонами залишкового ресурсу, результати якої наведені у таблиці 4.22.

Таблиця 4.22

Метрики класифікації за діапазонами RUL для FD001 (повна тестова вибірка)

Діапазон RUL	Кількість зразків	Точність	Влучність	Повнота	F1-міра
Дуже рання (RUL \geq 100)	8,069	99.78%	0.00%	0.00%	0.00%
Рання ($80 \leq$ RUL < 100)	1,092	96.43%	0.00%	0.00%	0.00%
Середня ($50 \leq$ RUL < 80)	1,182	81.47%	7.34%	48.48%	12.75%
Пізня ($20 \leq$ RUL < 50)	746	85.12%	100.00%	85.12%	91.96%
Критична (RUL < 20)	107	100.00%	100.00%	100.00%	100.00%

Примітка до табл. 22: пороговий підхід формування міток (підрозділ 4.1.2) визначає відсутність деградованих вікон у діапазонах RUL \geq 80, тому F1-міра = 0% є очікуваним результатом для цих діапазонів.

Аналіз таблиці 4.22 виявляє монотонне зростання якості діагностування зі зменшенням залишкового ресурсу, що відповідає фізичній природі деградації. Середня стадія ($50 \leq$ RUL < 80) характеризується низькими значеннями метрик через складність розмежування станів у зоні порогу RUL (50). На пізній стадії F1-міра = 91.96% при влучності 100%, що забезпечує відсутність хибних спрацювань та високу надійність для планового обслуговування. На критичній стадії (RUL < 20) F1-міра = 100%, що

підтверджує абсолютну надійність діагностування станів, близьких до відмови.

Для оцінки стійкості розробленої інформаційної технології до ускладнення операційних умов проведено аналогічне дослідження на підмножині FD004. Узагальнені результати наведені у таблиці 4.23.

Таблиця 4.23

Результати оцінки інформаційної технології на підмножині FD004

Метрика	Тестова вибірка	Повна тестова вибірка
Класифікація		
Точність	95.12%	96.09%
Влучність	94.74%	70.65%
Повнота	90.00%	62.49%
F1-міра	92.31%	66.32%
Хибні спрацювання	4	584
Пропущені відмови	8	844
Регресія		
RMSE	18.41	16.38
MAE	12.32	10.04
R ²	0.801	0.537
Середня помилка	-3.58	-5.72

При переході до повної тестової вибірки F1-міра знижується на 25.99% через високу варіативність параметрів на ранніх стадіях деградації за наявності шести операційних режимів. Детальний аналіз за діапазонами залишкового ресурсу для FD004 наведений у таблиці 4.24.

Порівняння з таблицею 4.22 виявляє вплив багаторежимності на різних стадіях деградації (рис. 4.1). На середній стадії F1-міра = 10.02% проти 12.75% для FD001. На пізній стадії F1-міра = 73.25% проти 91.96%, проте влучність залишається 100% для обох підмножин, що означає відсутність хибних спрацювань. На критичній стадії F1-міра = 98.02%, що підтверджує надійність

інформаційної технології для прийняття рішень про негайне обслуговування незалежно від складності операційних умов.

Таблиця 4.24

Метрики класифікації за діапазонами RUL для FD004 (повна тестова вибірка)

Діапазон RUL	Кількість зразків	Точність	Влучність	Повнота	F1-міра
Дуже рання (RUL \geq 100)	28,920	99.51%	0.00%	0.00%	0.00%
Рання ($80 \leq$ RUL < 100)	2,584	97.45%	0.00%	0.00%	0.00%
Середня ($50 \leq$ RUL < 80)	2,828	84.76%	6.02%	30.00%	10.02%
Пізня ($20 \leq$ RUL < 50)	1,836	57.79%	100.00%	57.79%	73.25%
Критична (RUL < 20)	334	96.11%	100.00%	96.11%	98.02%

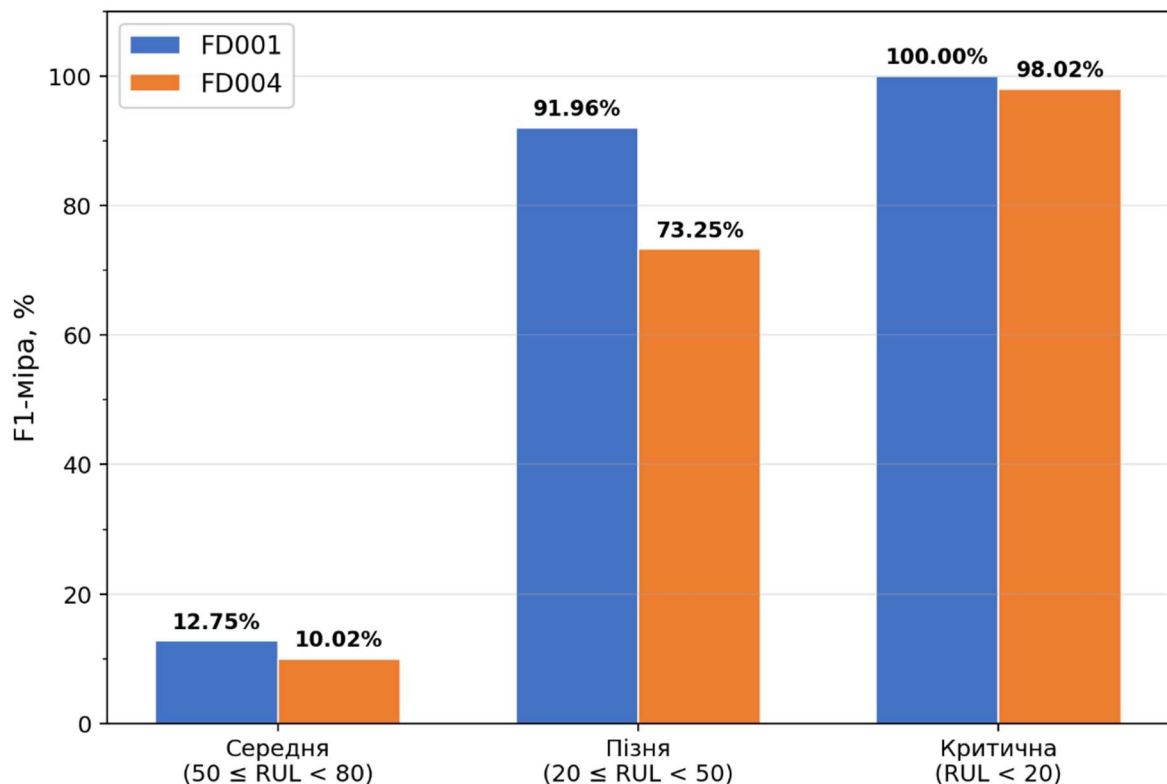


Рис. 4.1. – Порівняння F1-міри за діапазонами залишкового ресурсу для підмножин FD001 та FD004 (повна тестова вибірка)

Оцінка розробленої багаторівневої інформаційної технології технічного діагностування на підмножинах FD001 та FD004 у двох режимах дозволяє сформулювати наступні висновки:

1. *Висока якість для критичних станів.* Інформаційна технологія демонструє F1-міру $> 92\%$ для діагностування станів, близьких до відмови (тестова вибірка). Повнота 90–97% мінімізує пропущені відмови, влучність 91–95% мінімізує зайві витрати на обслуговування.

2. *Стійкість до багаторежимності.* Перехід від одного операційного режиму до шести при одночасному збільшенні кількості механізмів деградації призводить до зниження F1-міри на тестовій вибірці лише на 1.81%, що є найменшим серед усіх методів інформаційної технології (підрозділи 4.2.1–4.2.5) та підтверджує вплив ансамблювання (підрозділ 4.3).

3. *Монотонне покращення від ранніх до критичних стадій.* Аналіз за діапазонами RUL виявляє закономірність, що відповідає фізиці деградації, де якість діагностування зростає зі зменшенням залишкового ресурсу. На критичній стадії ($RUL < 20$) F1-міра становить 100% для FD001 та 98.02% для FD004.

4. *Стабільність прогнозування залишкового ресурсу.* Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі забезпечує $MAE \approx 12$ циклів для обох підмножин. Від'ємна середня помилка (-3.52 та -5.72 циклів) відповідає безпечній стратегії недооцінювання залишкового ресурсу.

5. *Очікуване зниження метрик на повній тестовій вибірці.* У повній тестовій вибірці домінують справні стани, де симптоми деградації фізично відсутні або надзвичайно слабкі, що обумовлює зниження F1-міри на повній тестовій вибірці через складність розпізнавання слабких симптомів. Для практичних застосувань визначальною є якість на пізніх та критичних стадіях. Інформаційна технологія демонструє F1-міра $> 92\%$ на тестовій вибірці та F1-міра $\geq 98\%$ на критичних стадіях для обох підмножин.

4.5. Порівняльний аналіз з існуючими підходами технічного діагностування

Даний підрозділ присвячено порівнянню розробленої багаторівневої інформаційної технології технічного діагностування з існуючими підходами за двома задачами: бінарна класифікація стану та прогнозування залишкового ресурсу. Порівняння здійснюється на підмножинах FD001 та FD004, що забезпечує оцінку як абсолютної якості, так і стійкості підходів до ускладнення операційних умов. Для інформаційної технології використано результати комплексної оцінки (підрозділ 4.4), а саме F1-міру фінального бінарного рішення для задачі класифікації та RMSE методу прогнозування залишкового ресурсу (метод 5, таблиця 3.1) для задачі регресії.

Результати порівняльного аналізу за задачею бінарної класифікації стану наведено у таблиці 4.25.

Таблиця 4.25

Порівняння підходів до бінарної класифікації стану на підмножинах FD001 та FD004

Підхід	FD001 F1-міра (%)	FD004 F1-міра (%)	Різниця (%)
CNN-LSTM [97]	89.7	-	-
ММoE-GRU [130]	57.21	60.55	+3.34
Decision Tree	74.2	63.4	-10.8
Time Net [131]	94.02	72.76	-21.26
ММoE-BiGRU [130]	79.66	76.53	-3.13
ROCKET [130]	89.19	78.11	-11.08
Support Vector Machine	87.1	79.8	-7.3
SB-BiGRU [130]	67.66	80.32	+12.66
Gradient Boosting	91.2	83.1	-8.1
Random Forest	92.54	83.95	-8.59
LSTM [129]	94.0	85.0	-9.0
Vanilla Transformer [131]	96.24	87.81	-8.43
Linear [132]	92.0	89.1	-2.9
CNN-LSTM [131]	94.24	90.83	-3.41
Запропонована ІТ	94.12	92.31	-1.81

Примітка до табл. 4.25: підходи без посилань представляють експерименти, проведені у рамках дослідження.

Аналіз таблиці 4.25 свідчить, що більшість існуючих підходів зазнають суттєвого зниження F1-міри при переході від FD001 до FD004. Значення різниці змінюються від -21.26% (Time Net) до +12.66% (SB-BiGRU), що відображає різну чутливість підходів до варіативності операційних умов.

Окремі підходи перевищують запропоновану інформаційну технологію на підмножині FD001: Vanilla Transformer досягає 96.24%, CNN-LSTM – 94.24%. Водночас на підмножині FD004, де шість операційних режимів та два механізми деградації створюють умови, наближені до реальної експлуатації, запропонована інформаційна технологія демонструє найвищу F1-міру 92.31% серед усіх досліджених підходів. Абсолютне значення різниці 1.81% є найменшим, що підтверджує найвищу стійкість до ускладнення операційних умов. Такий результат узгоджується з висновками підрозділу 4.3, де встановлено, що ансамблювання рішень п'яти методів рівня діагностування (підрозділ 2.3) забезпечує найменше зниження F1-міри серед усіх компонентів інформаційної технології.

Результати порівняльного аналізу за задачею прогнозування залишкового ресурсу наведено у таблиці 4.26.

Таблиця 4.26

Порівняння підходів до прогнозування залишкового ресурсу на підмножинах FD001 та FD004

Метод	FD001 RMSE	FD004 RMSE	Різниця
Decision Tree [133]	97.58	-	-
Support Vector Machine [133]	69.69	-	-
Linear Regression [134]	30.5	-	-
BLSTM + Dropout [134]	26.68	-	-
FCM-STL-TSBP [135]	22.99	-	-
BiLSTM [133]	18.71	-	-
LSTM [136]	27.74	30.32	+2.58
DBN [137]	18.48	30.02	+11.54
Gradient Boosting [137]	18.8	29.46	+10.66
MODBNE [137]	17.96	29.45	+11.49
LSTM-AON [138]	16.81	28.10	+11.29
LSTM + Attention [139]	14.45	27.08	+12.63
SKF [137]	19.24	26.76	+7.52
GA-CNN-LSTM [140]	15.92	26.32	+10.40
Transformer [141]	-	24.86	-

DCNN [137]	12.61	23.31	+10.70
RCNN-Abi-LSTM [142]	12.98	22.29	+9.31
Multi-attention-TCN [143]	13.25	21.69	+8.44
AGCNN [144]	-	21.50	-
GATA-TCN [145]	12.80	21.04	+8.24
TCMN [146]	-	21.03	-
GM-LSTM [147]	14.08	20.91	+6.83
GAN [141]	-	20.88	-
CNN-LSTM-SAM [60]	12.6	20.5	+7.9
CNN-Bi-LSTM-3DAttention [148]	13.12	20.24	+7.12
Att-LSTM [93]	13.95	20.21	+6.26
CNN-BGRU-SA [149]	13.88	19.39	+5.51
DA-TCN [150]	11.78	18.23	+6.45
Запропонована IT	16.82	<i>18.41</i>	+1.59

Аналіз таблиці 4.26 засвідчує, що всі підходи, для яких доступні результати на обох підмножинах, демонструють зростання RMSE при переході від FD001 до FD004. Різниця змінюється від +1.59 до +12.63 циклів, що свідчить про різний ступінь адаптованості підходів до багаторежимних умов.

На підмножині FD001 низку підходів характеризує нижча RMSE: DA-TCN досягає 11.78, DCNN – 12.61, CNN-LSTM-SAM – 12.6. Запропонована інформаційна технологія з RMSE 16.82 поступається зазначеним підходам на FD001, що є очікуваним, оскільки метод прогнозування залишкового ресурсу (підрозділ 3.2.4) розроблений для стабільної роботи на різних операційних сценаріях, а не для максимізації якості на окремій підмножині. На підмножині FD004 запропонована інформаційна технологія демонструє RMSE 18.41, що є другим найкращим результатом після DA-TCN (18.23). При цьому різниця між підмножинами для запропонованої інформаційної технології становить лише 1.59 циклів, тоді як для DA-TCN – 6.45, що у 4.1 рази більше.

Стійкість прогнозування залишкового ресурсу підтверджується порівнянням з іншими підходами, що демонструють конкурентну якість на FD004. CNN-BGRU-SA досягає RMSE 19.39 на FD004, проте різниця між підмножинами становить 5.51 циклів. Att-LSTM має RMSE 20.21 на FD004 з різницею 6.26 циклів. Таким чином, навіть підходи з помірною різницею

значно поступаються запропонованій інформаційній технології за стійкістю до зміни операційних умов.

Узагальнення результатів порівняльного аналізу за обома задачами дозволяє сформулювати наступні висновки.

За задачею бінарної класифікації стану запропонована інформаційна технологія забезпечує найвищу F1-міру на підмножині FD004 (92.31%) та найменше зниження якості при переході від FD001 до FD004 (1.81%). Це підтверджує ефективність ансамблювання діагностичних рішень п'яти методів рівня діагностування стану.

За задачею прогнозування залишкового ресурсу запропонована інформаційна технологія демонструє найвищу стійкість (різниця 1.59 циклів) при конкурентній якості на FD004 (RMSE 18.41). Різниця у стійкості порівняно з найближчим конкурентом DA-TCN (6.45 циклів) становить 4.1 рази, що свідчить про стабільність прогнозування незалежно від складності операційних сценаріїв.

Таким чином, порівняльний аналіз з підходами, опублікованими за останні 5–6 років, підтверджує досягнення поставленої мети дисертаційної роботи.

4.6. Оцінка обчислювальних ресурсів інформаційної технології

Даний підрозділ присвячено оцінці обчислювальних ресурсів, необхідних для функціонування розробленої інформаційної технології в режимі виконання діагностування. Усі вимірювання виконано виключно на процесорі AMD Ryzen 7800X3D. В якості даних для оцінки була використана повна тестова вибірка підмножини FD004 (табл. 4.2) та розмір пакета 256. Кожне вимірювання виконано з 10-15 повтореннями для забезпечення статистичної коректності результатів.

Використання оперативної пам'яті оцінювалось на різних етапах від ініціалізації середовища виконання до виконання діагностування. Зважаючи на те, що конфігурація методів відрізняється в залежності від підмножини, тому

було проведено перевірку для інформаційної технології налаштованої для підмножин FD001 і FD004. Результати наведено у таблиці 4.27.

Таблиця 4.27

Використання оперативної пам'яті інформаційної технології

Показник	FD001, МБ	FD004, МБ
Середовище виконання	595,1	596,9
Завантаження даних	360,4	348,2
Завантаження методів	199,0	236,7
Разом до виконання діагностування	1154,6	1181,8
Пікове споживання (послідовний режим)	1222,2	1270,4
Пікове споживання (паралельний режим)	1357,6	1412,7

Основний обсяг пам'яті займає середовище виконання, що включає інтерпретатор та бібліотеки. Різниця у 12,2 МБ між конфігураціями при завантаженні даних пояснюється тим, що методи попередньої обробки, навчені на різних підмножинах, формують дещо різні проміжні структури даних (нормалізовані масиви, агреговані часові вікна). Завантаження методів для FD004 потребує на 37,7 МБ більше, ніж для FD001. Це пояснюється тим, що методи, що використовуються для FD004 мають більшу кількість параметрів.

Сумарний обсяг пам'яті до початку діагностування становить ~1,2 ГБ для обох конфігурацій. Пікове споживання у паралельному режимі є вищим, ніж у послідовному, через одночасне зберігання вхідних та вихідних даних кількох методів. Загалом пікове споживання оперативної пам'яті не перевищує 1,4 ГБ.

Час опрацювання оцінювався за двома аспектами: (1) порівняння послідовного та паралельного режимів виконання функціональних операцій інформаційної технології та (2) порівняння пакетного та одиничного режимів обробки. Аналіз часу виконання окремих методів інформаційної технології встановив, що метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі є домінуючим, займаючи 91,4% загального часу для конфігурації FD001 та 86,0% для FD004. Це пояснюється послідовною

природою рекурентних обчислень, що обмежує можливості паралелізації. Порівняння режимів виконання інформаційної технології наведено у таблиці 4.28.

Таблиця 4.28

Порівняння режимів виконання інформаційної технології

Показник	FD001	FD004
<i>Послідовний режим</i>		
Час опрацювання вибірки, с	20,164	14,796
Пропускна здатність, зразків/с	1810	2467
Час на зразок (одиничний режим), мс	30,708	32,489
Час на зразок (пакетний режим), мс	0,562	0,416
<i>Паралельний режим</i>		
Час опрацювання вибірки, с	16,294	10,475
Пропускна здатність, зразків/с	2240	3485
Час на зразок (одиничний режим), мс	40,402	39,443
Час на зразок (пакетний режим), мс	0,447	0,304

Паралельний режим виконання інформаційної технології забезпечує прискорення в 1,24 рази для FD001 та 1,41 для FD004 порівняно з послідовним режимом. Помірне прискорення пояснюється тим, що у паралельному режимі всі методи рівня діагностування виконуються одночасно, проте метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі займає 86–91% загального часу, тому решта методів завершуються значно раніше та очікують на його завершення. Для FD004 прискорення є більшим, оскільки частка методу прогнозування залишкового ресурсу у загальному часі є меншою, що збільшує ефект від паралельного виконання решти методів.

Пакетна обробка забезпечує суттєве прискорення порівняно з одиничним режимом. У послідовному режимі прискорення становить 54,6 для конфігурації FD001 та 78,1 для FD004. Навіть у найповільнішому одиничному режимі час опрацювання одного зразка не перевищує 41 мс, що дозволяє обробляти щонайменше 24 зразки на секунду.

Слід зазначити, що одиничний режим при паралельному виконанні є повільнішим, ніж при послідовному. Це пояснюється накладними витратами

на створення та синхронізацію паралельних потоків, які при обробці лише одного зразка перевищують вигоду від паралелізації. Натомість при пакетній обробці ці витрати амортизуються на великій кількості зразків, тому паралельний режим стає швидшим за послідовний.

Висновки до розділу 4

У четвертому розділі проведено комплексне експериментальне дослідження розробленої багаторівневої інформаційної технології технічного діагностування на даних моделювання деградації турбовентиляторних двигунів набору C-MAPSS NASA. Обґрунтовано вибір підмножин FD001 та FD004, що формують діапазон складності від контрольованих умов з одним операційним режимом та одним механізмом деградації до реалістичних промислових сценаріїв із шістьма операційними режимами та двома механізмами деградації. Метод попередньої обробки та підготовки даних забезпечив формування 22 ознак після виключення неінформативних параметрів та додавання інженерних ознак, а також диференційованих часових представлень для всіх методів рівня діагностування.

Систематичне експериментальне дослідження п'яти методів рівня діагностування стану об'єкта з оптимізацією параметрів методом систематичного перебору виявило залежність якості неконтрольованих компонент від складності операційних сценаріїв. На підмножині FD001 неконтрольована компонента методу класифікації стану покращила F1-міру ансамблю на 1.58%, тоді як на підмножині FD004 множинні операційні режими унеможливили розрізнення зміни параметрів від деградаційних процесів, що призвело до встановлення нульового вагового коефіцієнта неконтрольованої компоненти. Аналогічну закономірність підтверджено для методу виявлення аномалій на основі автокодувальників (F1-міра 88.57% на FD001 проти 61.01% на FD004) та методу нечіткої кластеризації (81.82% проти 49.08%). Водночас методи на основі нейронних мереж продемонстрували значно вищу стійкість. Метод прогнозування залишкового ресурсу забезпечив

RMSE 16.82 та 18.41 циклів з F1-мірою бінарного рішення 93.94% та 79.98% відповідно, а метод класифікації на основі гібридної нейронної мережі – F1-міру 94.12% та 88.89% зі зниженням лише на 5.23%, що є найменшим серед усіх методів рівня діагностування.

Експериментальне дослідження методу ансамблювання діагностичних рішень на 14 592 конфігураціях для FD001 та 9 462 для FD004 встановило залежність оптимальної конфігурації від складності даних, де для FD001 оптимальним є бінарне голосування з рівними вагами, тоді як для FD004 – гібридне голосування з нерівномірним розподілом ваг та фокусом на методах з високою якістю. Покращення F1-міри відносно найкращого індивідуального методу становить 0.18% для FD001 та 3.42% для FD004, що підтверджує зростання цінності ансамблювання зі складністю даних.

Оцінка обчислювальних ресурсів інформаційної технології встановила, що пікове споживання оперативної пам'яті не перевищує 1,4 ГБ. Паралельний режим виконання забезпечує прискорення в 1,24–1,41 рази порівняно з послідовним, а пакетна обробка – в 54,6–78,1 разів порівняно з одиничним режимом. Навіть у найповільнішому одиничному режимі час опрацювання одного зразка не перевищує 41 мс. Домінуючим за часом виконання є метод прогнозування залишкового ресурсу, що займає 86–91% загального часу через послідовну природу рекурентних обчислень, що обмежує ефект від паралелізації.

Порівняльний аналіз із існуючими підходами підтвердив конкурентні переваги розробленої інформаційної технології. За задачею бінарної класифікації стану досягнуто найвищу F1-міру на підмножині FD004 (92.31%) серед 15 досліджених підходів та найменше зниження якості при переході між підмножинами (1.81%). За задачею прогнозування залишкового ресурсу інформаційна технологія демонструє найвищу стійкість серед 27 досліджених підходів з різницею RMSE між підмножинами лише 1.59 циклів, що у 4.1 рази менше за найближчий конкурент DA-TCN (6.45 циклів), при конкурентній якості на FD004 (RMSE 18.41).

ВИСНОВКИ

У дисертаційній роботі отримано теоретичні та практичні результати, спрямовані на підвищення якості та забезпечення стійкості технічного діагностування елементів динамічних систем в умовах складності операційних режимів. Основні результати полягають у наступному.

Проведено аналіз існуючих математичних моделей, методів та технологій технічного діагностування динамічних систем та їх елементів на основі даних моніторингу. Дослідження охопило методи попередньої обробки даних, методи визначення стану, методи зменшення розмірності, методи прогнозування залишкового ресурсу та багаторівневі інтегровані технології з ансамблевими методами. Систематизовано чотири групи невирішених проблем: фрагментарність існуючих методів діагностування; недостатня розробленість уніфікованих підходів до формування диференційованих часових представлень; гомогенність ансамблевих методів та відсутність автоматизованого підбору конфігурації; недостатня спеціалізація компонентів багаторівневих технологій. Виявлені проблеми обґрунтували необхідність розробки нової багаторівневої інформаційної технології.

Розроблено багаторівневу інформаційну технологію технічного діагностування динамічних систем та їх елементів на основі даних моніторингу. На основі шести фундаментальних принципів створено модель функціонування технології, що структурує процес діагностування у три послідовні рівні. На рівні попередньої обробки та підготовки даних розроблено метод, що забезпечує комплексну обробку даних моніторингу та формування диференційованих часових представлень для різнорідних компонентів технології. На рівні діагностування стану об'єкта розроблено п'ять методів, організованих у дві паралельні гілки: метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання; метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням;

метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу з підтримкою декількох режимів функціонування; метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі; метод класифікації стану на основі гібридної нейронної мережі. На рівні прийняття інтегрованого рішення розроблено метод ансамблювання діагностичних рішень з підтримкою трьох стратегій голосування та автоматизованим систематичним підбором конфігурації. Двоетапний процес налаштування технології забезпечує адаптацію до специфіки конкретного об'єкта діагностування.

Виконано математичну формалізацію інформаційної технології діагностування та всіх її компонентів, що забезпечує однозначну специфікацію розроблених методів та відтворюваність результатів. Для методу попередньої обробки специфіковано послідовність математичних операцій та два методи формування диференційованих часових представлень. Для п'яти методів рівня діагностування визначено механізми формування діагностичних рішень та обчислення їх достовірності. Специфіковано метод ансамблювання з трьома стратегіями голосування. Описано інтегроване функціонування технології та формалізовано двоетапний процес її налаштування з автоматизованим підбором конфігурації ансамблювання.

Проведено експериментальне дослідження розробленої інформаційної технології на даних моделювання деградації турбовентиляторних двигунів набору C-MAPSS NASA. Систематичне дослідження п'яти методів рівня діагностування з оптимізацією параметрів виявило залежність якості неконтрольованих компонент від складності операційних сценаріїв та високу стійкість методів на основі нейронних мереж. Дослідження методу ансамблювання встановило залежність оптимальної конфігурації від складності даних та підтвердило зростання цінності ансамблювання зі складністю. Комплексна оцінка інтегрованого функціонування технології підтвердила її ефективність для діагностування критичних станів та стійкість до ускладнення операційних умов. Оцінка обчислювальних ресурсів

підтвердила придатність технології для практичного застосування. Порівняльний аналіз з існуючими підходами підтвердив конкурентні переваги розробленої технології за задачами бінарної класифікації стану та прогнозування залишкового ресурсу, зокрема найвищу стійкість до зміни операційних умов.

Наукова новизна отриманих результатів полягає в наступному:

1. **Вперше** запропоновано багаторівневу інформаційну технологію технічного діагностування динамічних систем та їх елементів, яка поєднує комплементарні підходи машинного навчання з ансамблюванням діагностичних рішень, що підвищує точність і забезпечує стійкість діагностування.

2. **Удосконалено** метод попередньої обробки та підготовки даних шляхом комплексної обробки даних та розробки підходу до формування диференційованих часових представлень, що забезпечує узгоджену обробку даних для різнорідних компонентів технології діагностування.

3. **Удосконалено** метод класифікації стану об'єктів на основі ансамблювання контрольованих та неконтрольованих методів класичного машинного навчання, що дозволяє поєднати переваги контрольованого навчання з можливостями неконтрольованих методів щодо виявлення нових типів аномалій.

4. **Дістав подальшого розвитку** метод нечіткої кластеризації стану об'єктів на основі агентно-орієнтованого підходу шляхом розробки та застосування декількох режимів функціонування.

Практичне значення отриманих результатів полягає у тому, що розроблені методи, математичні моделі та багаторівнева інформаційна технологія можуть бути використані при створенні систем технічного діагностування та прогностичного обслуговування для турбовентиляторних двигунів, промислових турбін, підшипників, редукторів та іншого критичного обладнання в авіаційній, енергетичній та обробній промисловості. Багаторівнева технологія забезпечує повноту діагностичного висновку через

одночасне вирішення задач класифікації стану та прогнозування залишкового ресурсу, що надає операторам комплексну інформацію для прийняття рішень щодо технічного обслуговування. Модульна організація та автоматизований підбір конфігурації дозволяють адаптувати технологію до різних типів динамічних систем та операційних умов.

Подальші дослідження можуть зосередитися на інтеграції методів на основі механізмів уваги для покращення моделювання довгострокових залежностей; розробці онлайн-версії технології з послідовним навчанням для адаптації до нових умов без повного перенавчання; розширенні на багатокласову класифікацію з виділенням специфічних типів деградації; адаптації технології для інших типів динамічних систем.

Таким чином, усі задачі дослідження вирішені в повному обсязі. Сукупність отриманих наукових та практичних результатів дає змогу вважати поставлену мету дисертаційної роботи досягнутою.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

- [1] K. L. Tsui, N. Chen, Q. Zhou, Y. Hai, and W. Wang, “Prognostics and Health Management: A Review on Data Driven Approaches,” *Math. Probl. Eng.*, vol. 2015, pp. 1–17, 2015, doi: 10.1155/2015/793161.
- [2] Y. Ran, X. Zhou, P. Lin, Y. Wen, and R. Deng, “A Survey of Predictive Maintenance: Systems, Purposes and Approaches”, doi: 10.48550/arXiv.1912.07383.
- [3] C. Riccio, M. Menanno, I. Zennaro, and M. M. Savino, “A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters,” *Machines*, vol. 12, p. 443, 2024, doi: 10.3390/machines12070443.
- [4] M. Salinas-Camus, K. Goebel, and N. Eleftheroglou, “A comprehensive review and evaluation framework for data-driven prognostics: Uncertainty, robustness, interpretability, and feasibility,” *Mech. Syst. Signal Process.*, vol. 237, p. 113015, 2025, doi: 10.1016/j.ymsp.2025.113015.
- [5] D. An, N. Ho Kim, and J.-H. Choi, “Options for Prognostics Methods: A review of data-driven and physics- based prognostics,” presented at the Annual Conference of the PHM Society, 2013. doi: 10.36001/phmconf.2013.v5i1.2184.
- [6] Y. Wang *et al.*, “Overview of Condition Monitoring Technology for Variable-Speed Offshore Wind Turbines,” *Energies*, vol. 18, p. 1026, 2025, doi: 10.3390/en18051026.
- [7] C. Yildirim, A. M. Franco-Pereira, and R. E. Lillo, “Condition monitoring and multi-fault classification of hydraulic systems using multivariate functional data analysis,” *Heliyon*, vol. 11, p. e41251, 2025, doi: 10.1016/j.heliyon.2024.e41251.
- [8] A. Parida and P. Tretten, “Condition monitoring and diagnosis of modern dynamic complex systems using criticality aspect of key performance indicators,” *Int. J. COMADEM*, vol. 20, pp. 35–39, 2017.

- [9] M. Ahang, T. Charter, O. Ogunfowora, M. Khadivi, and H. Najjaran, “Intelligent Condition Monitoring of Industrial Plants: An Overview of Methodologies and Uncertainty Management Strategies.” doi: 10.48550/arXiv.2401.10266.
- [10] D. Long, H. Zheng, and F. Hong, “Condition Monitoring of Industrial Equipment Based on Multi-Variables State Estimate Technique,” *Appl. Sci.*, vol. 10, p. 5637, 2020, doi: 10.3390/app10165637.
- [11] L. Lei, W. Li, S. Zhang, C. Wu, and H. Yu, “Research Progress on Data-Driven Industrial Fault Diagnosis Methods,” *Sensors*, vol. 25, pp. 2952–2952, 2025, doi: 10.3390/s25092952.
- [12] W. S. Al Farizi, I. Hidayah, and M. N. Rizal, “Isolation Forest Based Anomaly Detection: A Systematic Literature Review”, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/9617498>
- [13] J. Li, Z. Wang, X. Liu, and Z. Feng, “Remaining Useful Life Prediction of Rolling Bearings Using GRU-DeepAR with Adaptive Failure Threshold,” *Sensors*, vol. 23, pp. 1144–1144, 2023, doi: 10.3390/s23031144.
- [14] F. Wang, A. Liu, C. Qu, R. Xiong, and L. Chen, “A Deep-Learning Method for Remaining Useful Life Prediction of Power Machinery via Dual-Attention Mechanism,” *Sensors*, vol. 25, p. 497, 2025, doi: 10.3390/s25020497.
- [15] M. L. Ndao, G. Youness, N. Niang, and G. Saporta, “Improving predictive maintenance: Evaluating the impact of preprocessing and model complexity on the effectiveness of eXplainable Artificial Intelligence methods,” *Eng. Appl. Artif. Intell.*, vol. 144, p. 110144, 2025, doi: 10.1016/j.engappai.2025.110144.
- [16] M. A. B. Syed, M. R. Hasan, N. I. Chowdhury, M. H. Rahman, and I. Ahmed, “A systematic review of time series algorithms and analytics in predictive maintenance,” *Decis. Anal. J.*, vol. 15, p. 100573, 2025, doi: 10.1016/j.dajour.2025.100573.
- [17] Z. Mian *et al.*, “A literature review of fault diagnosis based on ensemble learning,” *Eng. Appl. Artif. Intell.*, vol. 127, pp. 107357–107357, 2024, doi: 10.1016/j.engappai.2023.107357.

- [18] H. Su and J. Lee, “Machine Learning Approaches for Diagnostics and Prognostics of Industrial Systems Using Open Source Data from PHM Data Challenges,” *Int. J. Progn. Health Manag.*, vol. 15, 2024, doi: 10.36001/ijphm.2024.v15i2.3993.
- [19] Z. Xie, J. Chen, Y. Feng, K. Zhang, and Z. Zhou, “End to end multi-task learning with attention for multi-objective fault diagnosis under small sample,” *J. Manuf. Syst.*, vol. 62, pp. 301–316, 2022, doi: 10.1016/j.jmsy.2021.12.003.
- [20] S. Ahmad, K. Styp-Rekowski, S. Nedelkoski, and O. Kao, “Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines,” *ArXiv Cornell Univ.*, 2021, doi: 10.48550/arxiv.2101.11539.
- [21] M. Ahang, M. Abbasi, T. Charter, and H. Najjaran, “Condition Monitoring with Incomplete Data: An Integrated Variational Autoencoder and Distance Metric Framework,” presented at the 2024 IEEE 20th International Conference on Automation Science and Engineering (CASE), 2024. doi: 10.1109/case59546.2024.10711553.
- [22] В. Є. Стрілець, С. І. Шматков, М. Л. Угрюмов, Є. С. Меньяйлов, С. В. Черниш, and К. М. Угрюмова, *Методи машинного навчання у задачах системного аналізу і прийняття рішень*. Харківський національний університет імені В. Н. Каразіна, 2020. [Online]. Available: https://www.researchgate.net/publication/345100769_METODI_MASINNOG_O_NAVCANNA_U_ZADACAH_SISTEMNOGO_ANALIZU_I_PRIJNATTA_RISEN
- [23] V. P. Babak, S. V. Babak, and M. V. Myslovykh, *Diagnostic Systems For Energy Equipments*. Switzerland ISBN - 978-3-030-44442-6: Springer, 2020. doi: 10.1007/978-3-030-44443-3.
- [24] S. D. Leoshchenko, A. O. Oliinyk, S. A. Subbotin, and B. V. Morklyanyk, “SYNTHESIS OF NEURAL NETWORK MODELS FOR TECHNICAL DIAGNOSTICS OF NONLINEAR SYSTEMS,” *RIC*, no. 2, pp. 126–132, Jun. 2025, doi: 10.15588/1607-3274-2025-2-11.

- [25] O. Gubarevych, I. Melkonova, H. Melkonov, O. Melnyk, and M. Miroshnykova, "Synthesis of the structural diagram with algorithms of the units of the on-board diagnostic system of induction motors of vehicles," *Diagnostyka*, vol. 25, pp. 1–19, Jan. 2024, doi: 10.29354/diag/180309.
- [26] L. Dubchak *et al.*, "Adaptive Neuro-Fuzzy System for Detection of Wind Turbine Blade Defects," *Energies*, vol. 17, no. 24, p. 6456, Dec. 2024, doi: 10.3390/en17246456.
- [27] O. V. Sobko, R. A. Dydo, and O. V. Mazurets, "Method of neural network detection of defects based on the analysis of rotating machines vibrations," *Radio Electron. Comput. Sci. Control*, vol. 1, pp. 106–115, 2025, doi: 10.15588/1607-3274-2025-1-10.
- [28] O. O. Zalutska, O. V. Hladun, and O. V. Mazurets, "METHOD OF PREVENTING FAILURES OF ROTATING MACHINES BY VIBRATION ANALYSIS USING MACHINE LEARNING TECHNIQUES," *Radio Electron. Comput. Sci. Control*, no. 1, pp. 142–152, Apr. 2025, doi: 10.15588/1607-3274-2025-1-13.
- [29] S. Wang, L. Yan, S. Du, S. Li, and X. Chen, "Bearing prognostics and health management based on hybrid physical mechanism and data models: a systematic review," *Meas. Sci. Technol.*, vol. 36, p. 052002, 2025, doi: 10.1088/1361-6501/adcce4.
- [30] B. Rezaeianjouybari and Y. Shang, "Deep learning for prognostics and health management: State of the art, challenges, and opportunities," *Measurement*, vol. 163, p. 107929, 2020, doi: 10.1016/j.measurement.2020.107929.
- [31] N. G. Lo, J.-M. Flaus, and O. Adrot, "Review of Machine Learning Approaches In Fault Diagnosis applied to IoT Systems," presented at the 2019 International Conference on Control, Automation and Diagnosis (ICCAD), 2019. doi: 10.1109/iccad46983.2019.9037949.
- [32] I. Kabashkin and V. Susanin, "Unified Ecosystem for Data Sharing and AI-Driven Predictive Maintenance in Aviation," *Computers*, vol. 13, p. 318, 2024, doi: 10.3390/computers13120318.

- [33] V. V. Donets, V. Y. Strilets, M. L. Ugryumov, D. O. Shevchenko, S. V. Prokopovych, and L. O. Chagovets, “METHODOLOGY OF THE COUNTRIES’ ECONOMIC DEVELOPMENT DATA ANALYSIS,” *Syst. Res. Inf. Technol.*, no. 4, pp. 21–36, 2023, doi: 10.20535/SRIT.2308-8893.2023.4.02.
- [34] V. Donets, D. Shevchenko, M. Holikov, V. Strilets, and S. Shmatkov, “Application of a data stratification approach in computer medical monitoring systems,” *East.-Eur. J. Enterp. Technol.*, vol. 2, no. 9 (128), pp. 6–16, Apr. 2024, doi: 10.15587/1729-4061.2024.298805.
- [35] О. Лихач, М. Угрюмов, Д. Шевченко, and С. Шматков, “Методи виявлення викидів в пробних вибірках при управлінні процесами в системах за станом,” *Вісник Харківського Національного Університету Імені В Н Каразіна Серія «Математичне Моделювання Інформаційні Технології Автоматизовані Системи Управління»*, no. 53, pp. 21–40, Apr. 2022, doi: 10.26565/2304-6201-2022-53-03.
- [36] В. Донець, В. Стрілець, Д. Шевченко, and С. Шматков, “Агентно-орієнтований метод кластеризації даних оптового дистриб’ютора,” *Вісник Харківського Національного Університету Імені В Н Каразіна Серія «Математичне Моделювання Інформаційні Технології Автоматизовані Системи Управління»*, no. 55, pp. 6–18, Oct. 2022, doi: 10.26565/2304-6201-2022-55-01.
- [37] D. Shevchenko, M. Ugryumov, and S. Artiukh, “Monitoring data aggregation of dynamic systems using information technologies,” *Innov. Technol. Sci. Solut. Ind.*, no. 1 (23), pp. 123–131, 2023, doi: 10.30837/ITSSI.2023.23.123.
- [38] К. Бондаренко, В. Стрілець, and Д. Шевченко, “Прогнозування економічних показників за допомогою моделі LSTM,” *Вісник Харківського Національного Університету Імені В Н Каразіна Серія «Математичне Моделювання Інформаційні Технології Автоматизовані Системи Управління»*, no. 64, pp. 13–24, Nov. 2024, doi: 10.26565/2304-6201-2024-64-02.

- [39] Д. О. Шевченко and В. Є. Стрілець, “Багаторівнева інформаційна технологія діагностування технічних систем на основі даних моніторингу,” *Вісник НТУ ХПІ Серія Інформатика Та Моделювання*, no. 1 (15), pp. 134–154, 2026.
- [40] Н. С. Бакуменко, В. В. Донець, Д. О. Шевченко, О. О. Одинець, and М. Л. Угрюмов, “Методи кластеризації даних на основі інформаційних критеріїв,” presented at the *Збірник наукових праць міжнародної науково-технічної конференції «Комп’ютерне моделювання в наукоємних технологіях (КМНТ-2021)»*, Харків: ХНУ ім. В.Н. Каразіна, Apr. 2021, pp. 20–23.
- [41] Д. О. Шевченко, О. Ю. Лихач, and М. Л. Угрюмов, “Методи виявлення викидів в системах автоматизованого збору даних,” presented at the *Збірник наукових праць міжнародної науково-технічної конференції «Комп’ютерне моделювання в наукоємних технологіях (КМНТ-2022)»*, Харків: ХНУ ім. В.Н. Каразіна, Nov. 2022.
- [42] D. O. Shevchenko, M. L. Ugryumov, and I. S. Kholmohortseva, “Anomaly detection methods in data processing using computational intelligence methods,” presented at the *Academic and Scientific Challenges in the 21st Century: CLIL in Action*, Харків: ХНУ ім. В.Н. Каразіна, 2023, p. 342.
- [43] Д. О. Шевченко and В. Є. Стрілець, “Зменшення розмірності даних моніторингу в динамічних системах,” presented at the *Збірник наукових праць міжнародної науково-технічної конференції «Комп’ютерне моделювання в наукоємних технологіях (КМНТ-2021)»*, Харків: ХНУ ім. В.Н. Каразіна, 2023.
- [44] D. Shevchenko, V. Strilets, and V. Dobriak, “Recurrent Neural Networks for Multivariate Time Series Prediction in Technical Diagnostics Tasks,” presented at the *IEEE 15th International Conference on Dependable Systems, Services and Technologies, DESSERT’2025*, Athens, Greece, Dec. 2025.

- [45] M. Yan, S. C. Hui, N. Jiang, and N. Li, “A review on data-driven prognostics and health management for wind turbine systems,” *Eng. Appl. Artif. Intell.*, vol. 159, pp. 111484–111484, 2025, doi: 10.1016/j.engappai.2025.111484.
- [46] S.-H. Sung, S. Hong, H.-R. Choi, D.-M. Park, and S. Kim, “Enhancing Fault Diagnosis in IoT Sensor Data through Advanced Preprocessing Techniques,” *Electronics*, vol. 13, pp. 3289–3289, 2024, doi: 10.3390/electronics13163289.
- [47] Y. Wilhelm, P. Reimann, W. Gauchel, and B. Mitschang, “Overview on hybrid approaches to fault detection and diagnosis: Combining data-driven, physics-based and knowledge-based models,” *Procedia CIRP*, vol. 99, pp. 278–283, 2021, doi: 10.1016/j.procir.2021.03.041.
- [48] D.-Y. Ji, B. Wang, H. Inoue, and M. Kanemaru, “Motor Fault Detection with a Hybrid Physics-based and Data-Driven Method,” presented at the 2025 IEEE International Electric Machines & Drives Conference (IEMDC), 2025. doi: 10.1109/IEMDC60492.2025.11061000.
- [49] A. Aminzadeh *et al.*, “A Machine Learning Implementation to Predictive Maintenance and Monitoring of Industrial Compressors,” *Sensors*, vol. 25, pp. 1006–1006, 2025, doi: 10.3390/s25041006.
- [50] S. Son and K.-Y. Oh, “Integrated framework for estimating remaining useful lifetime through a deep neural network,” *Appl. Soft Comput.*, vol. 122, p. 108879, 2022, doi: 10.1016/j.asoc.2022.108879.
- [51] B. C. Mateus, M. Mendes, J. T. Farinha, and A. Martins, “Hybrid Deep Learning for Predictive Maintenance: LSTM, GRU, CNN, and Dense Models Applied to Transformer Failure Forecasting,” *Energies*, vol. 18, p. 5634, 2025, doi: 10.3390/en18215634.
- [52] J. Hofmockel and E. Sax, “Isolation Forest for Anomaly Detection in Raw Vehicle Sensor Data,” presented at the Proceedings of the 4th International Conference on Vehicle Technology and Intelligent Transport Systems, 2018. doi: 10.5220/0006758004110416.
- [53] P. S. Chirumamilla, A. S. Gadipe Sunitha, V. Thirupathi, C. R. Naidu, and A. L. Rao, “A Hybrid Approach for IoT Sensor Anomaly Detection with LSTM and

- Autoencoder-Based Preprocessing,” presented at the 2025 International Conference on Advances in Modern Age Technologies for Health and Engineering Science (AMATHE), 2025. doi: 10.1109/amathe65477.2025.11081356.
- [54] Z. He *et al.*, “Enhancing fault diagnosis with a hybrid attention mechanism and spatio-temporal feature mining model using small sample data,” *Struct. Health Monit.*, 2024, doi: 10.1177/14759217241290537.
- [55] O. Asif, S. A. Haider, S. R. Naqvi, J. F. W. Zaki, K.-S. Kwak, and S. M. R. Islam, “A Deep Learning Model for Remaining Useful Life Prediction of Aircraft Turbofan Engine on C-MAPSS Dataset,” *IEEE Access*, vol. 10, pp. 95425–95440, 2022, doi: 10.1109/ACCESS.2022.3203406.
- [56] S. Dai, S. Han, X. Bai, Z. Kang, and Y. Liu, “A Multivariate Spatiotemporal Feature Fusion Network for Wind Turbine Gearbox Condition Monitoring,” *Energies*, vol. 18, pp. 1273–1273, 2025, doi: 10.3390/en18051273.
- [57] N. Iftikhar, T. Baattrup-Andersen, F. E. Nordbjerg, and K. Jeppesen, “Outlier Detection in Sensor Data using Ensemble Learning,” *Procedia Comput. Sci.*, vol. 176, pp. 1160–1169, 2020, doi: 10.1016/j.procs.2020.09.112.
- [58] A. Cédola, R. Rossini, I. Bosi, and D. Conzon, “Feature Engineering and Machine Learning Modelling for Predictive Maintenance Based on Production and Stop Events.” [Online]. Available: <https://www.semanticscholar.org/paper/Feature-Engineering-and-Machine-Learning-Modelling-C%C3%A9dola-Rossini/ff0c26bd7e6e9143bec6cc67db839e932b2d2732>
- [59] A. G. SOLANKI, Z. LU, and M. M. MAGIGE, “Remaining useful life prediction of turbofan engines using long short-term memory networks,” *Int. J. Sci. Res. Arch.*, vol. 16, pp. 1240–1253, 2025, doi: 10.30574/ijrsra.2025.16.3.2704.
- [60] K. Ensarioğlu, T. İnkaya, and E. Emel, “Remaining Useful Life Estimation of Turbofan Engines with Deep Learning Using Change-Point Detection Based

- Labeling and Feature Engineering,” *Appl. Sci.*, vol. 13, pp. 11893–11893, 2023, doi: 10.3390/app132111893.
- [61] F. Makansi and K. Schmitz, *Feature Generation and Evaluation for Data-Based Condition Monitoring of a Hydraulic Press*. [Online]. Available: https://books.google.com.ua/books/about/Feature_Generation_and_Evaluation_for_Da.html?id=dGgd0AEACAAJ&redir_esc=y
- [62] L. Porcelli, “A Feature Engineering Approach for Business Impact-Oriented Failure Detection in Distributed Instant Payment Systems,” *ArXiv Cornell Univ.*, 2025, doi: 10.48550/arxiv.2510.21710.
- [63] C. Wang, G. Wang, T. Wang, X. Xiong, Z. Ouyang, and T. Gong, “Exploring the Processing Paradigm of Input Data for End-to-End Deep Learning in Tool Condition Monitoring,” *Sensors*, vol. 24, p. 5300, 2024, doi: 10.3390/s24165300.
- [64] T. Niu, Z. Xu, H. Luo, and Z. Zhou, “Hybrid Gaussian Process Regression with Temporal Feature Extraction for Partially Interpretable Remaining Useful Life Interval Prediction in Aeroengine Prognostics,” *ArXiv Cornell Univ.*, 2024, doi: 10.48550/arxiv.2411.15185.
- [65] T. Yilin, T. Inoue, S. Yabui, K. Katayama, and S. Tomimatsu, “Hybrid feature selection method for SVM classification and its application for fault diagnosis of wear and peeling in journal bearing with a little muddy water using long-term real data,” *J. Low Freq. Noise Vib. Act. Control*, vol. 42, pp. 231–252, 2022, doi: 10.1177/14613484221118997.
- [66] D. Maincer, Y. Benmahamed, M. Mansour, M. Alharthi, and S. S. M. Ghonein, “Fault Diagnosis in Robot Manipulators Using SVM and KNN,” *Intell. Autom. Soft Comput.*, vol. 35, pp. 1957–1969, 2023, doi: 10.32604/iasc.2023.029210.
- [67] M. A. Hanif, A. Wadood, R. W. Ahmad, S. A. Shah, and R. Khan, “Real-Time Anomaly Detection in IoT Sensor Data Using Statistical and Machine Learning Methods,” *Acad. Int. J. Soc. Sci.*, vol. 4, pp. 5203–3227, 2025, doi: 10.63056/acad.004.03.0784.

- [68] W. Zhang, X. Li, X. Jia, V. C. Li, Z. Luo, and X. Li, "Machinery fault diagnosis with imbalanced data using deep generative adversarial networks," *Measurement*, vol. 152, pp. 107377–107377, 2020, doi: 10.1016/j.measurement.2019.107377.
- [69] C. Deng, Z. Deng, S. Lu, M. He, J. Miao, and Y. Peng, "Fault Diagnosis Method for Imbalanced Data Based on Multi-Signal Fusion and Improved Deep Convolution Generative Adversarial Network," *Sensors*, vol. 23, pp. 2542–2542, 2023, doi: 10.3390/s23052542.
- [70] K. Yu, Y. Li, Q. Zhan, Y. Zhang, and B. Xing, "Intelligent Fault Diagnosis for Cross-Domain Few-Shot Learning of Rotating Equipment Based on Mixup Data Augmentation," *Machines*, vol. 13, pp. 807–807, 2025, doi: 10.3390/machines13090807.
- [71] A. Adesh, S. G. J. Shetty, and L. Xu, "Local outlier factor for anomaly detection in HPC systems," *J. Parallel Distrib. Comput.*, vol. 192, p. 104923, 2024, doi: 10.1016/j.jpdc.2024.104923.
- [72] D. Zou *et al.*, "Outlier detection and data filling based on KNN and LOF for power transformer operation data classification," *Energy Rep.*, vol. 9, pp. 698–711, 2023, doi: 10.1016/j.egy.2023.04.094.
- [73] J. Jakubowski, P. Stanisiz, S. Bobek, and G. J. Nalepa, "Anomaly Detection in Asset Degradation Process Using Variational Autoencoder and Explanations," *Sensors*, vol. 22, p. 291, 2021, doi: 10.3390/s22010291.
- [74] Y. Lv, K. Xiong, X. Guo, and Y. Liu, "An Improved Variational Autoencoder-Based Anomaly Detection Model for Rolling Bearing," presented at the 2024 Global Reliability and Prognostics and Health Management Conference (PHM-Beijing), 2024. doi: 10.1109/phm-beijing63284.2024.10874546.
- [75] R. N. Mfondoum, A. Ivanov, P. Koleva, V. Poulkov, and A. Manolova, "Outlier Detection in Streaming Data for Telecommunications and Industrial Applications: A Survey," *Electronics*, vol. 13, p. 3339, 2024, doi: 10.3390/electronics13163339.

- [76] Y. Zheng, Y. qi Zhang, and J. Yang, “K-means clustering and Deep Q-Network enhanced fault diagnosis for ZPW-2000A jointless track circuits,” *Eng. Res. Express*, vol. 7, pp. 0352b8-0352b8, 2025, doi: 10.1088/2631-8695/ae026b.
- [77] B. A. Hemade, S. Ataya, A. A. El-Fergany, and N. M. A. Ibrahim, “Mitigating Multicollinearity in Induction Motors Fault Diagnosis Through Hierarchical Clustering-Based Feature Selection,” *Appl. Sci.*, vol. 15, p. 7012, 2025, doi: 10.3390/app15137012.
- [78] C. Li *et al.*, “A comparison of fuzzy clustering algorithms for bearing fault diagnosis,” *J. Intell. Fuzzy Syst.*, vol. 34, pp. 3565–3580, 2018, doi: 10.3233/jifs-169534.
- [79] J. Xiong, X. Liu, X. Zhu, H. Zhu, H. Li, and Q. Zhang, “Semi-Supervised Fuzzy C-Means Clustering Optimized by Simulated Annealing and Genetic Algorithm for Fault Diagnosis of Bearings,” *IEEE Access*, vol. 8, pp. 181976–181987, 2020, doi: 10.1109/access.2020.3021720.
- [80] J. H. Choi, S. K. Jang, W. H. Cho, S. Moon, and H. Kim, “Motor PHM on Edge Computing with Anomaly Detection and Fault Severity Estimation through Compressed Data Using PCA and Autoencoder,” *Mach. Learn. Knowl. Extr.*, vol. 6, pp. 1466–1483, 2024, doi: 10.3390/make6030069.
- [81] G. Robertson, M. C. Thomas, and J. A. Romagnoli, “Topological preservation techniques for nonlinear process monitoring,” *Comput. Chem. Eng.*, vol. 76, pp. 1–16, 2015, doi: 10.1016/j.compchemeng.2015.02.002.
- [82] Y. Dong, K. Chen, and Z. Ma, “Comparative Study on Semi-Supervised Learning Applied for Anomaly Detection in Hydraulic Condition Monitoring System,” presented at the 2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2023. doi: 10.1109/smc53992.2023.10394193.
- [83] B. Chokr, N. Chatti, A. Charki, T. Lemenand, and M. Hammoud, “Feature extraction-reduction and machine learning for fault diagnosis in PV panels,” *Sol. Energy*, vol. 262, p. 111918, 2023, doi: 10.1016/j.solener.2023.111918.

- [84] Y. Zhou, S. Yan, Y. Ren, and S. Liu, "Rolling bearing fault diagnosis using transient-extracting transform and linear discriminant analysis," *Measurement*, vol. 178, pp. 109298–109298, 2021, doi: 10.1016/j.measurement.2021.109298.
- [85] M. H. Gharavian, F. Almas Ganj, A. R. Ohadi, and H. Heidari Bafroui, "Comparison of FDA-based and PCA-based features in fault diagnosis of automobile gearboxes," *Neurocomputing*, vol. 121, pp. 150–159, 2013, doi: 10.1016/j.neucom.2013.04.033.
- [86] S. Dong, J. Liu, B. Han, S. Wang, H. Zeng, and M. Zhang, "UMAP-Based All-MLP Marine Diesel Engine Fault Detection Method," *Electronics*, vol. 14, pp. 1293–1293, 2025, doi: 10.3390/electronics14071293.
- [87] F. Ulger, S. E. Yuksel, and A. Yilmaz, "Anomaly Detection for Solder Joints Using β -VAE," *IEEE Trans. Compon. Packag. Manuf. Technol.*, vol. 11, pp. 2214–2221, 2021, doi: 10.1109/tcpmt.2021.3121265.
- [88] G. Dewangan and S. Maurya, "Fault diagnosis of Machines using Deep Convolutional Beta-Variational Autoencoder," *IEEE Trans. Artif. Intell.*, 2021, doi: 10.1109/tai.2021.3110835.
- [89] M. Zaben, M. A. Hassan, M. Y. Worku, and M. A. Abido, "Dimension Reduction Techniques for Machine Learning based AC Microgrid Fault Diagnosis: A Systematic Review," *IEEE Access*, 2024, doi: 10.1109/access.2024.3486786.
- [90] Y. Yang *et al.*, "PVeSight: Dimensionality reduction-based anomaly detection and visual analysis of photovoltaic strings," *Vis. Inform.*, vol. 9, pp. 100243–100243, 2025, doi: 10.1016/j.visinf.2025.100243.
- [91] A. O. Ifeanyi and J. B. Coble, "A Practical Comparison of Data-Driven Prognostics Methods for Energy Systems," *Nucl. Sci. Eng.*, vol. 199, pp. 1473–1491, 2025, doi: 10.1080/00295639.2025.2455349.
- [92] L. Li, Z. Zhao, X. Zhao, and K.-Y. Lin, "Gated Recurrent Unit Networks for Remaining Useful Life Prediction," *IFAC-Pap.*, vol. 53, pp. 10498–10504, 2020, doi: 10.1016/j.ifacol.2020.12.2795.

- [93] A. Boujamza and S. Lissane Elhaq, "Attention-based LSTM for Remaining Useful Life Estimation of Aircraft Engines," *IFAC-Pap.*, vol. 55, pp. 450–455, 2022, doi: 10.1016/j.ifacol.2022.07.353.
- [94] İ. Çiçek, E. C. Mengüç, and N. Acır, "A Comparative Study of CNN-Based Predictive Maintenance Techniques on C-MAPSS Dataset," presented at the 2025 IEEE 7th Symposium on Computers & Informatics (ISCI), 2025. doi: 10.1109/iscic65687.2025.11167805.
- [95] A. F. Azyus, S. Kusuma, and B. Kurniawan, "Remaining Useful Life Prediction of Turbofan Engines Using CNN-GRU: A Comparative Study on C-MAPSS Dataset," *J. Mech. Civ. Ind. Eng.*, vol. 6, pp. 19–27, 2025, doi: 10.32996/jmci.2025.6.1.3.
- [96] A. Muneer, S. M. Taib, S. Naseer, R. F. Ali, and I. A. Aziz, "Data-Driven Deep Learning-Based Attention Mechanism for Remaining Useful Life Prediction: Case Study Application to Turbofan Engine Analysis," *Electronics*, vol. 10, p. 2453, 2021, doi: 10.3390/electronics10202453.
- [97] K. Ensarioglu, "Hierarchical RUL Prediction for Turbofan Engines Based on Health Stage Classification and Change Point-Guided Data Augmentation," *IEEE Access*, vol. 13, pp. 134241–134260, 2025, doi: 10.1109/access.2025.3593206.
- [98] D. Rengasamy, B. Rothwell, and G. P. Figueredo, "Asymmetric Loss Functions for Deep Learning Early Predictions of Remaining Useful Life in Aerospace Gas Turbine Engines," presented at the International Joint Conference on Neural Networks - IJCNN (WCCI), 2020. doi: 10.1109/ijcnn48605.2020.9207051.
- [99] J.-L. Lin, Y. Zhang, K. Zhu, B. Chen, and F. Zhang, "Asymmetric Loss Functions for Contract Capacity Optimization," *Energies*, vol. 13, p. 3123, 2020, doi: 10.3390/en13123123.
- [100] Y. Yang and H. Wang, "Random Forest-Based Machine Failure Prediction: A Performance Comparison," *Appl. Sci.*, vol. 15, pp. 8841–8841, 2025, doi: 10.3390/app15168841.

- [101] B. A. Ture, A. Akbulut, A. H. Zaim, and C. Catal, “Stacking-based ensemble learning for remaining useful life estimation,” *Soft Comput.*, 2023, doi: 10.1007/s00500-023-08322-6.
- [102] K. Su, J. Liu, and H. Xiong, “A multi-level adaptation scheme for hierarchical bearing fault diagnosis under variable working conditions,” *J. Manuf. Syst.*, vol. 64, pp. 251–260, 2022, doi: 10.1016/j.jmsy.2022.06.009.
- [103] M. Namdari and H. Jazayeri-Rad, “A Hierarchical Multi-Label Classification Approach for Fault Diagnosis in Industrial Units,” *Int. J. Emerg. Eng. Res. Technol.*, vol. 5, pp. 1–10, 2017.
- [104] J. Wang *et al.*, “An adaptive multi-stage method for predicting remaining useful life based on degradation morphology,” *Measurement*, vol. 253, pp. 117639–117639, 2025, doi: 10.1016/j.measurement.2025.117639.
- [105] Q. Bao, W. Qin, and Z. Yun, “A Multi-Stage Adaptive Method for Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Swarm Intelligence Optimization,” *Batteries*, vol. 9, p. 224, 2023, doi: 10.3390/batteries9040224.
- [106] Y. Liu *et al.*, “A novel condition monitoring approach using hybrid lightweighted adaptive models for complex machinery,” *Eng. Appl. Artif. Intell.*, vol. 162, pp. 112461–112461, 2025, doi: 10.1016/j.engappai.2025.112461.
- [107] Y. Wang, M. Ragab, Y. Hou, Z. Chen, M. Wu, and X. Li, “Deep Domain Adaptation for Turbofan Engine Remaining Useful Life Prediction: Methodologies, Evaluation and Future Trends,” *ArXiv Cornell Univ.*, 2025, doi: 10.48550/arxiv.2510.03604.
- [108] D. Landau, P. de, M. Mitici, and N. Saurabh, “Federated learning framework for collaborative remaining useful life prognostics: an aircraft engine case study,” *ArXiv Cornell Univ.*, 2025, doi: 10.48550/arxiv.2506.00499.
- [109] L. Meitz, M. Heider, T. Schöler, and J. Hähner, “On Data-Preprocessing for Effective Predictive Maintenance on Multi-Purpose Machines,” presented at the Conference: 12th International Conference on Data Science, Technology and Applications, 2023. doi: 10.5220/0012146700003541.

- [110] E. Cinar, S. Kalay, and I. Saricicek, “A Predictive Maintenance System Design and Implementation for Intelligent Manufacturing,” *Machines*, vol. 10, no. 11, p. 1006, 2022, doi: 10.3390/machines10111006.
- [111] S. Jose, K. T. P. Nguyen, K. Medjaher, R. Zemouri, M. Lévesque, and A. Tahan, “A modular deep learning methodology for multi-fault machine health diagnostics from sparse and imbalanced multimodal data,” *Neurocomputing*, vol. 666, p. 132252, Feb. 2026, doi: 10.1016/j.neucom.2025.132252.
- [112] T. T. Chen and T. Takaishi, “Box-Cox transformation of firm size data in statistical analysis,” presented at the Journal of Physics Conference Series, 2014, pp. 012182–012182. doi: 10.1088/1742-6596/490/1/012182.
- [113] A. F. Agarap, “Deep Learning using Rectified Linear Units (ReLU),” *ArXiv Cornell Univ.*, 2018, doi: 10.48550/arxiv.1803.08375.
- [114] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, “Improving neural networks by preventing co-adaptation of feature detectors.” [Online]. Available: <https://arxiv.org/abs/1207.0580>
- [115] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” *JMLR*, 2015, doi: 10.48550/arXiv.1502.03167.
- [116] S. Ergon, “Asymptotic behavior of the Manhattan distance in n -dimensions: Estimating multidimensional scenarios in empirical experiments,” *ArXiv Cornell Univ.*, 2024, doi: 10.48550/arxiv.2406.15441.
- [117] L. Yao and T.-B. Lin, “Evolutionary Mahalanobis Distance-Based Oversampling for Multi-Class Imbalanced Data Classification,” *Sensors*, vol. 21, pp. 6616–6616, 2021, doi: 10.3390/s21196616.
- [118] J. Shlens, “Notes on Kullback-Leibler Divergence and Likelihood.” [Online]. Available: <https://arxiv.org/abs/1404.2000>
- [119] G. Polat, Ü. M. Çağlar, and A. Temizel, “Class distance weighted cross entropy loss for classification of disease severity,” *Expert Syst. Appl.*, vol. 269, p. 126372, 2025, doi: 10.1016/j.eswa.2024.126372.

- [120] K. Cho *et al.*, “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation,” *ArXiv Cornell Univ.*, 2014, doi: 10.48550/arxiv.1406.1078.
- [121] G. Bird and M. E. Polivoda, “Backpropagation Through Time For Networks With Long-Term Dependencies,” *ArXiv Cornell Univ.*, 2021, doi: 10.48550/arxiv.2103.15589.
- [122] K. Gokcesu and H. Gokcesu, “Generalized Huber Loss for Robust Learning and its Efficient Minimization for a Robust Statistics.” [Online]. Available: <https://arxiv.org/abs/2108.12627>
- [123] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization.” [Online]. Available: <https://arxiv.org/abs/1412.6980>
- [124] Y. Bai *et al.*, “Understanding and Improving Early Stopping for Learning with Noisy Labels,” *ArXiv Cornell Univ.*, 2021, doi: 10.48550/arxiv.2106.15853.
- [125] A. Saxena and K. Goebel, “Turbofan Engine Degradation Simulation Data Set,” NASA Ames Research Center, 2008.
- [126] M. B. Bertelsen and R. Alphas, “Predicting the Remaining Useful Life of a Turbofan Engine using LSTM and Manhattan Distances,” presented at the 2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME), 2023. doi: 10.1109/iceccme57830.2023.10253182.
- [127] Z. Fan, W. Li, K. Chang, and T. Yuan, “PerFormer: A Permutation Based Vision Transformer for Remaining Useful Life Prediction,” *ArXiv Cornell Univ.*, 2025, doi: 10.48550/arxiv.2506.00259.
- [128] Z. Wen, Y. Fang, P. Wei, F. Liu, Z. Chen, and M. Wu, “Temporal and Heterogeneous Graph Neural Network for Remaining Useful Life Prediction,” *ArXiv Cornell Univ.*, 2024, doi: 10.48550/arxiv.2405.04336.
- [129] Y. Wang and Y. Zhao, “Multi-Scale Remaining Useful Life Prediction Using Long Short-Term Memory,” *Sustainability*, vol. 14, p. 15667, 2022, doi: 10.3390/su142315667.

- [130] Z. Wu and K. Wu, “Prognostic classification based on random convolutional kernel,” *ArXiv Cornell Univ.*, 2022, doi: 10.48550/arxiv.2204.04527.
- [131] Y. Fan, Y. Dang, and Y. Guo, “Fault Identification Model Using Convolutional Neural Networks with Transformer Architecture,” *Sensors*, vol. 25, pp. 3897–3897, 2025, doi: 10.3390/s25133897.
- [132] U. Yildırım and H. Afşer, “Linear Methods for Predictive Maintenance: The Case of NASA C-MAPSS Datasets,” *Appl. Sci.*, vol. 15, p. 9945, 2025, doi: 10.3390/app15189945.
- [133] S. Rath, D. Saha, S. Chatterjee, and A. K. Chakraborty, “Remaining Useful Life Prediction of Turbofan Engine in Varied Operational Conditions Considering Change Point: A Novel Deep Learning Approach with Optimum Features,” *Mathematics*, vol. 13, pp. 130–130, 2024, doi: 10.3390/math13010130.
- [134] A. Sherifi, “Turbofan Engine Remaining Useful Life (RUL) Prediction Based on Bi-Directional Long Short-Term Memory (BLSTM).” [Online]. Available: https://www.researchgate.net/publication/386112501_Turbofan_Engine_Remaining_Useful_Life_RUL_Prediction_Based_on_Bi-Directional_Long_Short-Term_Memory_BLSTM
- [135] M. Wang *et al.*, “Remaining Useful Life Prediction for Aero-Engines Based on Time-Series Decomposition Modeling and Similarity Comparisons,” *Aerospace*, vol. 9, pp. 609–609, 2022, doi: 10.3390/aerospace9100609.
- [136] T. Xia, Y. Song, Y. Zheng, E. Pan, and L. Xi, “An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation,” *Comput. Ind.*, vol. 115, p. 103182, 2020, doi: 10.1016/j.compind.2019.103182.
- [137] C. Zhang, P. Lim, A. K. Qin, and K. C. Tan, “Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics,” *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 28, pp. 2306–2318, 2017, doi: 10.1109/tnnls.2016.2582798.

- [138] S. Li, C. Zhang, L. Liu, and X. Zhang, “Gated Transient Fluctuation Dual Attention Unit Network for Long-Term Remaining Useful Life Prediction of Rotating Machinery Using IIoT,” *IEEE Internet Things J.*, vol. 11, pp. 18593–18604, 2024, doi: 10.1109/jiot.2024.3363837.
- [139] Z. Chen, M. Wu, R. Zhao, F. Guretno, R. Yan, and X. Li, “Machine Remaining Useful Life Prediction via an Attention-Based Deep Learning Approach,” *IEEE Trans. Ind. Electron.*, vol. 68, pp. 2521–2531, 2021, doi: 10.1109/tie.2020.2972443.
- [140] U. Amin and K. D. Kumar, “Remaining Useful Life Prediction of Aircraft Engines Using Hybrid Model Based on Artificial Intelligence Techniques”, [Online]. Available: <https://ieeexplore.ieee.org/document/9486500>
- [141] Y. Mo, Q. Wu, X. Li, and B. Huang, “Remaining useful life estimation via transformer encoder enhanced by a gated convolutional unit,” *J. Intell. Manuf.*, vol. 32, pp. 1997–2006, 2021, doi: 10.1007/s10845-021-01750-x.
- [142] H. Wang, D. Li, Y. Li, G. Zhu, and R. Lin, “Method for Remaining Useful Life Prediction of Turbofan Engines Combining Adam Optimization-Based Self-Attention Mechanism with Temporal Convolutional Networks,” *Appl. Sci.*, vol. 14, pp. 7723–7723, 2024, doi: 10.3390/app14177723.
- [143] Z. Shang, B. Zhang, W. Li, S. Qian, and J. Zhang, “Machine remaining life prediction based on multi-layer self-attention and temporal convolution network,” *Complex Intell. Syst.*, vol. 8, pp. 1409–1424, 2021, doi: 10.1007/s40747-021-00606-4.
- [144] H. Liu, Z. Liu, W. Jia, and X. Lin, “Remaining useful life prediction using a novel feature-attention-based end-to-end approach,” *IEEE Trans. Ind. Inform.*, vol. 17, pp. 1197–1207, 2021.
- [145] L. Jayasinghe, T. Samarasinghe, C. Yuen, J. Chen, and S. S. Ge, “Temporal Convolutional Memory Networks for Remaining Useful Life Estimation of Industrial Machinery,” *ArXiv Cornell Univ.*, 2019, doi: 10.1109/icit.2019.8754956.

- [146] M. Sayah, D. Guebli, Z. Noureddine, and Z. A. Masry, “Deep LSTM Enhancement for RUL Prediction Using Gaussian Mixture Models,” *Autom. Control Comput. Sci.*, vol. 55, pp. 15–25, 2021, doi: 10.3103/s0146411621010089.
- [147] K. You, Q. Guangqi, and Y. Gu, “A 3D Attention-enhanced Hybrid Neural Network for Turbofan Engine Remaining Life Prediction Using CNN and BiLSTM Models,” *IEEE Sens. J.*, 2023, doi: 10.1109/jsen.2023.3296670.
- [148] J. Sun, L. Zheng, Y. Huang, and Y. Ge, “Remaining Useful Life Prediction Based on CNN-BGRU-SA,” presented at the Journal of Physics: Conference Series, 2022, p. 012007. doi: 10.1088/1742-6596/2405/1/012007.
- [149] Y. Song, S. Gao, Y. Li, L. Jia, Q. Li, and F. Pang, “Distributed Attention-Based Temporal Convolutional Network for Remaining Useful Life Prediction,” *IEEE Internet Things J.*, vol. 8, pp. 9594–9602, 2021, doi: 10.1109/jiot.2020.3004452.
- [150] Y. Xin, S. Hu, and G. Yang, “DA-TCN Based Temperature Prediction Algorithm for Heating Furnace,” in *2024 IEEE 13th Data Driven Control and Learning Systems Conference (DDCLS)*, May 2024, pp. 611–617. doi: 10.1109/DDCLS61622.2024.10606591.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у наукових фахових виданнях, що входять до міжнародних

наукометричних баз Scopus та Web of Science

1. Donets V.V., Strilets V.Y., Ugryumov M.L., **Shevchenko D.O.**, Prokopovych S.V., Chagovets L.O. Methodology of the countries' economic development data analysis. *System Research and Information Technologies*. 2023. No. 4. P. 21–36. Scopus, Q4. DOI: 10.20535/SRIT.2308-8893.2023.4.02. ISSN: 1681-6048

2. Donets V., **Shevchenko D.**, Holikov M., Strilets V., Shmatkov S. Application of a data stratification approach in computer medical monitoring systems. *Eastern-European Journal of Enterprise Technologies*. 2024. Vol. 2, no. 9 (128). P. 6–16. Scopus, Q3. DOI: 10.15587/1729-4061.2024.298805. ISSN: 1729-3774

Статті у наукових фахових виданнях України

3. Лихач О., Угрюмов М., **Шевченко Д.**, Шматков С. Методи виявлення викидів в пробних вибірках при управлінні процесами в системах за станом. *Вісник Харківського національного університету імені В. Н. Каразіна серія «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління»*. 2022. Вип. 53. С. 21-40. DOI: 10.26565/2304-6201-2022-53-03.

(Особистий внесок здобувача: розробка класифікації методів виявлення аномалій, аналіз метрик оцінювання, створення практичної реалізації методів виявлення аномалій, їх тестування та формування висновків, відповідні частини наведені в роботі.

Особистий внесок Лихач О.: аналіз існуючих методів виявлення аномалій включаючи традиційні та глибокого навчання, визначення переваг та недоліків кожного, відповідна частина наведена в роботі.

Особистий внесок Угрюмов М.: постановка проблеми дослідження, перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування.

Особистий внесок Шматков С.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

4. Донець В., Стрілець В., **Шевченко Д.**, Шматков С. Агентно-орієнтований метод кластеризації даних оптового дистриб'ютора. *Вісник Харківського національного університету імені В. Н. Каразіна серія «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління»*. 2022. Вип. 55. С. 6-18. DOI: 10.26565/2304-6201-2022-55-01.

(Особистий внесок здобувача: попередня обробка даних з використанням методів роботи з асиметрією, нормалізації, виявлення аномалій, агрегування даних та аналіз даних з їх візуалізацією, результати наведені у відповідній частині роботи.

Особистий внесок Донець В.: впровадження розробленого методу мультиагентної нечіткої кластеризації на даних оптового дистриб'ютора, відповідні результати наведені в практичній частині роботи

Особистий внесок Стрілець В.: підготовка набору даних для тестування, перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування. Відповідні результатом є матеріалами публікації.

Особистий внесок Шматков С.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

5. **Shevchenko D.**, Ugryumov M., Artiukh S. Monitoring data aggregation of dynamic systems using information technologies. *Innovative technologies and scientific solutions for industries*. 2023. No. 1 (23). P. 123–131. DOI: 10.30837/ITSSI.2023.23.123.

(Особистий внесок здобувача: аналіз проблемної області, опис стандартного та варіаційного автокодувальників, розробка архітектур

автокодувальників, реалізація та практична перевірка архітектур, формування висновків.

Особистий внесок Mykhaylo Ugruytov: постановка проблеми дослідження, перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування.

Особистий внесок Serhiy Artiukh: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

6. Бондаренко К., Стрілець В., **Шевченко Д.** Прогнозування економічних показників за допомогою моделі LSTM. *Вісник Харківського національного університету імені В. Н. Каразіна серія «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління».* 2024. Вип. 64. С. 13-24. DOI: 10.26565/2304-6201-2024-64-02.

(Особистий внесок здобувача: побудова і оцінка моделі LSTM, порівняння і аналіз результатів моделей, формування висновків, результати наведені у відповідній частині роботи.

Особистий внесок Бондаренко К.: підготовка та аналіз набору даних, побудова і оцінка моделі ARIMA, результати наведені у відповідній частині роботи.

Особистий внесок Стрілець В.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи.)

7. **Шевченко Д.О.,** Стрілець В.Є. Багаторівнева інформаційна технологія діагностування технічних систем на основі даних моніторингу. *Вісник НТУ «ХП».* Серія: Інформатика та моделювання. 2026. Вип. 1 (15). С.134-154. DOI: 10.20998/2411-0558.2026.01.09.

(Особистий внесок здобувача: постановка проблеми, розробка і опис багаторівневої інформаційної технології та її компонентів, реалізація та практична перевірка технології, проведення порівняльного аналізу та формування висновків.

Особистий внесок Стрілець В. Є.: перевірка наукової достовірності отримуваних результатів, перевірка тексту роботи, редагування.)

Наукові праці, які засвідчують апробацію матеріалів дисертації

8. Бакуменко Н.С., Донець В.В., Шевченко Д.О., Одинець О.О., Угрюмов М.Л. Методи кластеризації даних на основі інформаційних критеріїв. *Збірник наукових праць міжнародної науково-технічної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2021)»*. Харків: ХНУ ім. В.Н. Каразіна, квіт. 2021, С. 20—23.

9. Шевченко Д.О., Лихач О.Ю., Угрюмов М.Л. Методи виявлення викидів в системах автоматизованого збору даних. *Збірник наукових праць міжнародної науково-технічної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2022)»*. Харків: ХНУ ім. В.Н. Каразіна, листоп. 2022. С. 204—209.

10. Shevchenko D.O., Ugrumov M.L., Kholmohortseva I. S. Anomaly detection methods in data processing using computational intelligence methods. *Academic and Scientific Challenges in the 21st Century: CLIL in Action*. Харків: ХНУ ім. В.Н. Каразіна, 2023, р. 342.

11. Шевченко Д.О., Стрілець В.Є. Зменшення розмірності даних моніторингу в динамічних системах. *Збірник наукових праць міжнародної науково-технічної конференції «Комп'ютерне моделювання в наукоємних технологіях (КМНТ-2023)»*. Харків: ХНУ ім. В.Н. Каразіна, 2023. С. 162—166.

12. Shevchenko D., Strilets V., Dobriak V. Recurrent Neural Networks for Multivariate Time Series Prediction in Technical Diagnostics Tasks. *IEEE 15th International Conference on Dependable Systems, Services and Technologies, DESSERT'2025*, Athens, Greece, Dec. 2025, 13 p.

ОПТИМІЗОВАНА КОНФІГУРАЦІЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ ДЛЯ РОБОТИ НА ПІДМНОЖИНАХ FD001 ТА FD004

""

Конфігурація багаторівневої інформаційної технології технічного діагностування на підмножині FD001

""

Метод 1: Метод попередньої обробки та підготовки даних - кількість часових вікон для агрегації статистик (формула 3.8)

```
TEMPORAL_WINDOWS_CONFIG = {  
    'n_windows': 4,  
}
```

Метод 7: Метод ансамблювання діагностичних рішень - вагові коефіцієнти методів рівня діагностування (підрозділ 3.3)

```
ENSEMBLE_WEIGHTS = {  
    1: 0.00, # Метод 1: Метод попередньої обробки та підготовки даних (не бере участі в ансамблюванні)  
    2: 0.15, # Метод 2: Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів  
    3: 0.05, # Метод 3: Метод виявлення аномалій та зменшення розмірності на основі автокодувальників (AE1)  
    4: 0.05, # Метод 4: Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу  
    5: 0.40, # Метод 5: Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі  
    6: 0.35 # Метод 6: Метод класифікації стану на основі гібридної нейронної мережі CNN-LSTM  
}
```

Метод 2: Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів (підрозділ 3.2.1)

```
LEVEL2_CONFIG = {
```

```
    # Контрольована гілка: випадковий ліс (формула 3.9)
```

```
    'n_estimators': 200,
```

```
    'max_depth': 20,
```

```
    'min_samples_split': 10,
```

```
    'min_samples_leaf': 5,
```

```
    'class_weight': 'balanced',
```

```
    # Поріг бінарного діагностичного рішення  $\theta$ 
```

```
    'decision_threshold': 0.4,
```

```
    # Ваги ансамблювання контрольованої та неконтрольованої гілок (формула 3.13)
```

```
    'supervised_weight': 0.7, #  $w_s$  - вага контрольованої компоненти
```

```
    'unsupervised_weight': 0.3, #  $w_u$  - вага неконтрольованої компоненти
```

```
    'ensemble_threshold': 0.5,
```

```
    # Неконтрольована гілка: ізоляційний ліс (формула 3.10) та Z-оцінка (формула 3.11)
```

```
    'z_threshold': 3.0,
```

```
    'isolation_contamination': 0.1,
```

```
}
```

Метод 3: Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням (підрозділ 3.2.2)

```
LEVEL3_CONFIG = {
```

```
    # Архітектура автокодувальників  $AE_1$  та  $AE_2$  (рис. 3.1)
```

```
    'latent_dim': 50, # Розмірність латентного простору  $l$ 
```

```
    'h1': 256, # Перший прихований шар кодувальника/декодера
```

```

'h2': 64,          # Другий прихований шар кодувальника/декодера

# Параметри навчання
'epochs': 20,
'batch_size': 128,
'learning_rate': 0.001,

# Множник чутливості k для порогового критерію виявлення аномалій  $AE_1$ 
(формула 3.17)
're_sigma_multiplier': 1.0,
}

# Метод 4: Метод нечіткої кластеризації стану на основі агентно-орієнтованого
підходу (підрозділ 3.2.3)
LEVEL4_CONFIG = {
    # Параметри агентно-орієнтованої нечіткої кластеризації C-середніх
(формули 3.20–3.23)
    'n_clusters': 40,          # Початкова кількість агентів-кластерів
    'max_iterations': 30,     # Максимальна кількість ітерацій селекції

    # Режим формування діагностичного рішення
    'mode': 'supervised',     # Напівконтрольований режим (формула 3.26)

    # Порогові значення діагностичного рішення
    'membership_threshold': 0.5, # Поріг належності  $\theta_u$  (формула 3.24)
    'distance_sigma_multiplier': 1.0, # Поріг відстані  $\theta_d$  (формула 3.25)
}

# Метод 5: Метод прогнозування залишкового ресурсу на основі рекурентної
нейронної мережі (підрозділ 3.2.4)
LEVEL5_CONFIG = {
    'architecture': 'gru',    # Тип рекурентної комірки (рис. 3.3)

```

```

'window_size': 20,          # Довжина послідовності w (формула 3.6)
'hidden_size': 512,        # Розмірність прихованого шару h (формула 3.28)
'n_layers': 3,             # Кількість шарів L
'dropout': 0.25,
'loss_function': 'huber',  # Функція втрат Хьюбера (формула 3.29)
'learning_rate': 1e-4,
'batch_size': 64,
'epochs': 100,
'adam_beta1': 0.9,         # Параметри оптимізатора Adam
'adam_beta2': 0.999,
'patience': 50,           # Пороговий залишковий ресурс  $\theta$  для бінарного
решення (формула 3.30)
}
# Метод 6: Метод класифікації стану на основі гібридної нейронної мережі
CNN-LSTM (підрозділ 3.2.5)
LEVEL6_CONFIG = {
    'window_size': 20,      # Довжина послідовності w (формула 3.6)

    # Блок згорткових шарів (формула 3.31)
    'conv1_filters': 32,    # Фільтри першого згорткового шару
    'conv1_kernel': 5,     # Розмір ядра
    'conv2_filters': 64,
    'conv2_kernel': 3,
    'pool_size': 3,        # Розмір шару максимального об'єднання

    # Блок рекурентних шарів LSTM (формула 3.32)
    'lstm_hidden': 50,     # Розмірність прихованого шару h
    'fc_hidden': 50,       # Розмірність повнозв'язного шару
    'dropout': 0.2,

```

```

# Параметри навчання
'epochs': 80,
'batch_size': 32,
'learning_rate': 1e-5,
'classification_threshold': 0.3, # Поріг бінарного діагностичного рішення  $\theta$ 
(формула 3.35)
}
# Метод 7: Метод ансамблювання діагностичних рішень - параметри рівня
прийняття інтегрованого рішення (підрозділ 3.3)
ANOMALY_THRESHOLDS = {
    'voting_threshold': 0.35, # Пороговий показник  $\theta$  для фінального бінарного
рішення  $A_f$ 
    'voting_mode': 'binary', # Стратегія бінарного голосування (формула 3.36)
}

"""
Конфігурація багаторівневої інформаційної технології технічного
діагностування на підмножині FD004
"""

# Метод 1: Метод попередньої обробки та підготовки даних - кількість часових
вікон для агрегації статистик (формула 3.8)
TEMPORAL_WINDOWS_CONFIG = {
    'n_windows': 4
}
# Метод 7: Метод ансамблювання діагностичних рішень - вагові коефіцієнти
методів рівня діагностування (підрозділ 3.3)
ENSEMBLE_WEIGHTS = {
    1: 0.00, # Метод 1: Метод попередньої обробки та підготовки даних (не бере
участі в ансамблюванні)

```

2: 0.20, # Метод 2: Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів

3: 0.04, # Метод 3: Метод виявлення аномалій та зменшення розмірності на основі автокодувальників (AE₁)

4: 0.06, # Метод 4: Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу

5: 0.45, # Метод 5: Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі

6: 0.25 # Метод 6: Метод класифікації стану на основі гібридної нейронної мережі CNN-LSTM

}

Метод 2: Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів (підрозділ 3.2.1)

LEVEL2_CONFIG = {

Контрольована гілка: випадковий ліс (формула 3.9)

'n_estimators': 200,

'max_depth': 20,

'min_samples_split': 10,

'min_samples_leaf': 5,

'class_weight': 'balanced',

Поріг бінарного діагностичного рішення θ

'decision_threshold': 0.45,

Ваги ансамблювання контрольованої та неконтрольованої гілок (формула 3.13); $w_u=0$ - виключення неконтрольованої компоненти

'z_threshold': 3.0,

'isolation_contamination': 0.05,

'supervised_weight': 1.0, # w_s - вага контрольованої компоненти

'unsupervised_weight': 0.0 # wu - неконтрольована компонента виключена
(підрозділ 4.2.1)

}

Метод 3: Метод виявлення аномалій та зменшення розмірності на основі автокодувальників з диференційованим навчанням (підрозділ 3.2.2)

LEVEL3_CONFIG = {

'latent_dim': 30, # Розмірність латентного простору l

'h1': 512, # Перший прихований шар кодувальника/декодера

'h2': 256, # Другий прихований шар кодувальника/декодера

'epochs': 50,

'batch_size': 128,

'learning_rate': 0.0005,

're_sigma_multiplier': 0.3, # Множник чутливості k для порогового критерію AE_1 (формула 3.17)

'use_dual_autoencoders': True # Диференційоване навчання AE_1 та AE_2

}

Метод 4: Метод нечіткої кластеризації стану на основі агентно-орієнтованого підходу (підрозділ 3.2.3)

LEVEL4_CONFIG = {

'n_clusters': 50, # Початкова кількість агентів-кластерів

'membership_threshold': 0.5, # Поріг належності θ_u (формула 3.24)

'distance_sigma_multiplier': 1.0, # Поріг відстані θ_d (формула 3.25)

'max_iterations': 30,

'mode': 'unsupervised', # Неконтрольований режим (підрозділ 4.2.3 - оптимальний для FD004)

}

Метод 5: Метод прогнозування залишкового ресурсу на основі рекурентної нейронної мережі (підрозділ 3.2.4)

LEVEL5_CONFIG = {

```

'architecture': 'lstm',          # Тип рекурентної комірки LSTM (рис. 3.2) -
оптимальний для багаторежимних даних
'window_size': 20,              # Довжина послідовності w (формула 3.6)
'hidden_size': 512,            # Розмірність прихованого шару h (формула 3.28)
'n_layers': 2,                  # Кількість шарів L
'dropout': 0.2,
'loss_function': 'huber',      # Функція втрат Хьюбера (формула 3.29)
'learning_rate': 1e-4,
'batch_size': 64,
'epochs': 100,
'adam_beta1': 0.9,
'adam_beta2': 0.999,
'rul_warning': 50              # Пороговий залишковий ресурс  $\theta$  для бінарного
ршення (формула 3.30)
}
# Метод 6: Метод класифікації стану на основі гібридної нейронної мережі
CNN-LSTM (підрозділ 3.2.5)
LEVEL6_CONFIG = {
    'window_size': 20,          # Довжина послідовності w (формула 3.6)

    # Блок згорткових шарів (формула 3.31)
    'conv1_filters': 32,
    'conv1_kernel': 5,
    'conv2_filters': 64,
    'conv2_kernel': 3,
    'pool_size': 3,

    # Блок рекурентних шарів LSTM (формула 3.32)
    'lstm_hidden': 50,
    'fc_hidden': 50,

```

```
'dropout': 0.2,  
  
# Параметри навчання (адаптовані для багаторежимних даних FD004)  
'epochs': 100,  
'batch_size': 256,  
'learning_rate': 0.0001,  
'classification_threshold': 0.5 # Поріг бінарного діагностичного рішення  $\theta$   
(формула 3.35)  
}  
  
# Метод 7: Метод ансамблювання діагностичних рішень - параметри рівня  
прийняття інтегрованого рішення (підрозділ 3.3)  
ANOMALY_THRESHOLDS = {  
    'voting_threshold': 0.5, # Пороговий показник  $\theta$  для фінального бінарного  
рішення  $A_f$   
    'voting_mode': 'hybrid', # Стратегія гібридного голосування (формула 3.39)  
- оптимальна для FD004  
}
```

Онлайн сервіс створення та перевірки кваліфікованого та удосконаленого електронного підпису

ПРОТОКОЛ
створення та перевірки кваліфікованого та удосконаленого електронного підпису

Дата та час: 22:01:41 21.04.2026

Назва файлу з підписом: Shevchenko_diss.pdf
Розмір файлу з підписом: 2.4 МБ

Перевірені файли:
Назва файлу без підпису: Shevchenko_diss.pdf
Розмір файлу без підпису: 2.4 МБ

Результат перевірки підпису: Підпис створено та перевірено успішно. Цілісність даних підтверджено

Підписувач: Шевченко Дмитро Олександрович
П.І.Б.: Шевченко Дмитро Олександрович
Країна: Україна
РНОКПП: 3636404992

Час підпису (підтверджено кваліфікованою позначкою часу для підпису від Надавача): 22:01:36 21.04.2026

Сертифікат виданий: "Дія". Кваліфікований надавач електронних довірчих послуг
Серійний номер: 514B5C86A1E5DA1104000000EE262200FB976405
Тип носія особистого ключа: ЗНКІ криптомодуль ІІТ Гряда-301
Алгоритм підпису: ДСТУ 4145
Тип підпису: Кваліфікований
Тип контейнера: Підписаний PDF-файл (PAdES)
Формат підпису: З повними даними для перевірки (PAdES-B-LT)
Сертифікат: Кваліфікований

Версія від: 2026.04.06 13:00