

НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ОДЕСЬКА МОРСЬКА
АКАДЕМІЯ»
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ АВТОМАТИКИ ТА
ЕЛЕКТРОМЕХАНІКИ

Кафедра: «Електрообладнання і автоматики суден»

ДИПЛОМНА РОБОТА МАГІСТРА

на тему

ДОСЛІДЖЕННЯ ПРОЦЕСІВ ДІАГНОСТУВАННЯ СУДНОВИХ
ДИЗЕЛЬ – ГЕНЕРАТОРНИХ УСТАНОВОК В ПРОСТОРІ
ПАРАМЕТРІВ СТАНУ

Виконав: здобувач другого (магістерського) рівня
вищої освіти, групи 3601

Спеціальність:

271 – Морський та внутрішній водний транспорт
(шифр і назва спеціальності)

Спеціалізація: «Експлуатація суднового
електрообладнання і засобів автоматики»

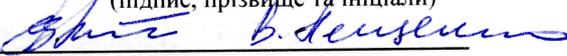
ЧУЙКО ЯРОСЛАВ ІГОРОВИЧ

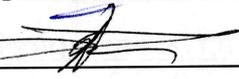
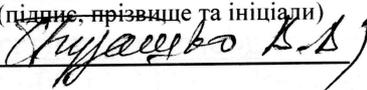
(підпис, прізвище та ініціали)

допущений до захисту 10.12.2025
(дата)

Завідувач кафедри  Ірина ГВОЗДЕВА
(підпис, прізвище та ініціали)

Керівник  Валерій ШЕВЧЕНКО
(підпис, прізвище та ініціали)

Нормоконтролер 
(підпис, прізвище та ініціали)

Рецензент  
(підпис, прізвище та ініціали)

Одеса – 2025

ПРОТОКОЛ

створення та перевірки кваліфікованого та удосконаленого електронного підпису

Дата та час: 05:55:43 09.12.2025

Назва файлу з підписом: ДРМ Чуйко Я.І. ДОСЛІДЖЕННЯ ПРОЦЕСІВ ДІАГНОСТУВАННЯ СУДНОВИХ ДИЗЕЛЬ – ГЕНЕРАТОРНИХ УСТАНОВОК В ПРОСТОРІ ПАРАМЕТРІВ СТАНУ.pdf.asice

Розмір файлу з підписом: 1.4 МБ

Перевірені файли:

Назва файлу без підпису: ДРМ Чуйко Я.І. ДОСЛІДЖЕННЯ ПРОЦЕСІВ ДІАГНОСТУВАННЯ СУДНОВИХ ДИЗЕЛЬ – ГЕНЕРАТОРНИХ УСТАНОВОК В ПРОСТОРІ ПАРАМЕТРІВ СТАНУ.pdf

Розмір файлу без підпису: 1.6 МБ

Результат перевірки підпису: Підпис створено та перевірено успішно. Цілісність даних підтверджено

Підписувач: Чуйко Ярослав Ігорович

П.І.Б.: Чуйко Ярослав Ігорович

Країна: Україна

РНОКПП: 3765803174

Час підпису (підтверджено кваліфікованою позначкою часу для підпису від Надавача): 23:55:21 08.12.2025

Сертифікат виданий: "Дія". Кваліфікований надавач електронних довірчих послуг

Серійний номер: 514B5C86A1E5DA11040000006FD13000A2750105

Тип носія особистого ключа: ЗНКІ криптомодуль ІІТ Гряда-301

Алгоритм підпису: ДСТУ 4145

Тип підпису: Кваліфікований

Тип контейнера: Підпис та дані в архіві (розширений) (ASiC-E)

Формат підпису: 3 повними даними для перевірки (XAdES-B-LT)

Сертифікат: Кваліфікований

Версія від: 2025.08.25 13:00

НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

«ОДЕСЬКА МОРСЬКА АКАДЕМІЯ»

Навчально-науковий інститут автоматики та електромеханіки

Спеціалізація: Експлуатація суднового електрообладнання і засобів
автоматики

Кафедра «Електрообладнання і автоматики суден»

(повна назва кафедри)

ЗАТВЕРДЖУЮ

Зав. кафедри

Ірина ГВОЗДЕВА

« 10 » 12 2025 р.

ЗАВДАННЯ

на дипломну роботу магістра

ЧУЙКО ЯРОСЛАВА ІГОРОВИЧА

(прізвище та ініціали)

1. Тема: ДОСЛІДЖЕННЯ ПРОЦЕСІВ ДІАГНОСТУВАННЯ СУДНОВИХ ДИЗЕЛЬ – ГЕНЕРАТОРНИХ УСТАНОВОК В ПРОСТОРІ ПАРАМЕТРІВ СТАНУ

затверджена наказом ректора № 1503 від « 10 » грудня 2025 року

2. Термін закінчення роботи: « 08 » грудня 2025 року

3. Вихідні дані до роботи: параметри суднового дизель-генератора, дані реєстрації сукупності параметрів стану суднового дизель-генератора на протязі довготривалої експлуатації при різних навантаженнях, програмно-алгоритмічне забезпечення нейромереж регресії, параметри основних елементів системи управління судною електроенергетичною системою.

4. Зміст дипломної роботи магістра: 1. Огляд проблем діагностування технічного стану складних транспортних енергетичних об'єктів, зокрема, дизель-генераторних установок. 2. Проблеми прогнозу технічного стану складних

енергетичних об'єктів, зокрема, дизель-генераторних установок, та методи їх вирішення. 3. Моделювання та прогнозування взаємозв'язків параметрів технічного стану суднових дизель-генераторних установок. 4. Пропозиції та рекомендації.

3. Перелік ілюстрацій до презентації дипломної роботи магістра: функції системи інтегрованого керування станом об'єктів транспортного призначення, класифікація методів параметричного діагностування, структурні схеми та блок-схеми алгоритмів обробки часових рядів, графіки часових залежностей зміни параметрів ДГУ від різних факторів впливу; графіки прогнозних значень температурного режиму дизель-генераторних установок та межі допуску.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів дипломної роботи магістра	Термін виконання етапів роботи	Примітка
1	Отримання завдання до ДРМ	12.11.2024	Виконано
2	Огляд сучасних проблем діагностування технічного стану складних транспортних енергетичних об'єктів, зокрема, дизель-генераторних установок	13.11.2024-03.02.2025	Виконано
3	Аналіз проблеми прогнозу технічного стану складних енергетичних об'єктів, зокрема, дизель-генераторних установок, та методів їх вирішення	04.02.2025-17.03.2025	Виконано
4	Побудова регресійних моделей оцінки стану ДГУ та прогнозування їх параметрів	18.03.2025-25.06.2025	Виконано
5	Розробка рекомендацій щодо практичного застосування	02.10.2025-01.11.2025	Виконано
6	Створення пояснювальної записки	02.11.2025-08.12.2025	Виконано

Курсант (студент) _____

Керівник роботи _____

(підпис)

(підпис)

Ярослав ЧУЙКО

(прізвище та ініціали)

Валерій ШЕВЧЕНКО

(прізвище та ініціали)

РЕФЕРАТ

Дипломна робота магістра: 95 с., 25 рис., 0 табл., 87 джерел.

Тема: ДОСЛІДЖЕННЯ ПРОЦЕСІВ ДІАГНОСТУВАННЯ СУДНОВИХ ДИЗЕЛЬ – ГЕНЕРАТОРНИХ УСТАНОВОК В ПРОСТОРІ ПАРАМЕТРІВ СТАНУ

Актуальність теми. Сучасні тенденції підвищення техніко-економічних, екологічних та експлуатаційних вимог, що пред'являються до суднових електроенергетичних систем (СЕЕС) і, зокрема, до їх найбільш важливої складової, а саме, дизель-генераторних установок (ДГУ), обумовлюють необхідність переходу від планово-попереджувальних ремонтів до стратегії їх обслуговування за поточним технічним станом.

Найбільш важливою проблемою такого переходу є достовірне визначення технічного стану об'єктів діагностування та визначення прогнозу зміни такого стану для встановлення можливості подальшої експлуатації із забезпеченням техніко-економічних показників і безпеки для довкілля. Методи оцінки та відповідності технічного стану, що застосовуються в поточний час в системах технічного діагностування, базуються на принципах традиційного допускового контролю, а в найбільш передових системах застосовуються класичні методи прикладної статистики, зокрема трендовий контроль та трендовий аналіз. Недоліки традиційних підходів зумовлюють високим рівнем помилок першого роду - "помилкових хибних тривоги", що призводить до безпідставного зняття об'єктів з експлуатації і, відповідно, - до економічних втрат, а також до зниження рівня довіри до діагностичних висновків..

Інтенсивний розвиток інформаційних і комп'ютерних технологій, зокрема, методів штучного інтелекту, дозволяє використовувати більш досконалі методи і алгоритми контролю і діагностування технічного стану об'єктів.

Звідси, для реалізації стратегії переходу обслуговування суднових систем за технічним станом і враховуючи можливості сучасної інформаційно-телекомунікаційних технологій, які здатні реалізувати більш досконалі методи та алгоритми технічного діагностування суднових ДГУ, є актуальною проблема створення сукупності методів, методичних основ та програмно-алгоритмічних засобів оцінки та прогнозу технічного стану, які можуть бути застосовувані в

системах технічного діагностування, що враховують моделі статистичного породжування даних та можливості нейромережових технологій. Вирішення вказаної проблеми пропонується за допомогою встановлення взаємозв'язків діагностичних параметрів технічного стану суднових дизель-генераторних установок та побудови моделей цих взаємозв'язків, які з більшою адекватністю відповідають фізиці процесів в ДГУ, та побудові відповідних моделей породження даних і, на цій основі, створення програмно-інструментальних засобів оцінки поточного технічного стану та прогнозу його змін на протязі довготривалої експлуатації.

Таким чином має місце протиріччя між затребуваними практикою вимогами до систем діагностування та можливостями таких систем, що використовуються в СЕЕС.

Зв'язок роботи з науковими програмами, темами, планами: тематика магістерської роботи співпадає з науковими дослідженнями кафедри електрообладнання і автоматики суден Національного університету «Одеська морська академія».

Метою роботи є вирішення вказаного протиріччя між затребуваними практикою вимогами до систем діагностування та можливостями таких систем, що використовуються в СЕЕС, шляхом встановлення взаємозв'язків діагностичних параметрів технічного стану суднових ДГУ та побудови моделей цих взаємозв'язків, які з більшою адекватністю відповідають фізиці процесів в ДГУ, і побудові відповідних моделей породження даних і, на цій основі, створення програмно-інструментальних засобів оцінки поточного технічного стану та прогнозу його змін на протязі довготривалої експлуатації на основі сучасних нейромережових технологій.

Для досягнення вказаної мети вирішені наступні *завдання*:

1. Критичний огляд та порівняння відомих підходів та методів, присвячених проблемі діагностування технічного стану складних енергетичних об'єктів, зокрема, суднових дизель-генераторних установок та сучасним методам вирішення проблеми такого діагностування.

2. Аналіз пропонованих методів трендового контролю та аналізу технічного стану складних енергетичних об'єктів.
3. Огляд методів оцінки та прогнозу технічного стану складних енергетичних об'єктів, зокрема, із застосуванням сучасних нейромережевих технологій.
4. Проведення експериментальних досліджень та моделювання в реальних умовах експлуатації суднових ДГУ, спрямованих на збір статистичних даних, що характеризують їх технічний стан, а також систематизація та аналіз отриманих даних.
5. Розробка статистичних моделей взаємозв'язків діагностичних параметрів суднових ДГУ, методів та алгоритмів оцінки їх технічного стану та прогнозу його зміни а також комп'ютерна реалізація зазначених моделей з використанням сучасних програмних засобів

Об'єктом дослідження дипломної роботи магістра є процеси перетворення енергії у суднових електроенергетичних системах, зокрема, ДГУ, процеси зміни їх технічного стану та інформаційні процеси оцінки і прогнозу зміни технічного стану.

Предметом дослідження є моделі та методи дослідження процесів перетворення енергії у суднових електроенергетичних системах, методи діагностування за технічним станом та прогнозу зміни технічного стану ДГУ.

Методи досліджень: математичні методи моделювання, методи прикладної статистики, методи трендового контролю і аналізу, методи нейромережевих технологій.

Гіпотеза дослідження полягає в тому, що на основі побудови математичних моделей взаємозв'язків діагностичних параметрів та застосування методів нейромережевих технологій, можливо підвищити достовірність діагностичних висновків про технічний стан та прогноз його зміни для суднових ДГУ системами технічного діагностування..

Наукова новизна отриманих результатів:

- На основі огляду і аналізу існуючих рішень, розглянута можливість удосконалення алгоритмів визначення технічного стану суднових ДГА та прогнозу їх технічного стану системами технічного діагностування.

- Набуло подальший розвиток математичне моделювання часових рядів параметрів реєстрації технічного стану дизель-генераторних установок із застосуванням методів регресійного аналізу та нейромережевих технологій.
- Вперше розроблена нелінійна нейромережева регресійна модель залежності температури вихідних газів циліндрів дизельного двигуна ДГУ від навантаження, яка мінімізує середньоквадратичні відхилення результатів вимірів температури, що дозволяє підвищити достовірність діагностичних висновків систем технічного діагностування.

Практичне значення отриманих результатів складається у наступному: на основі аналітичних обґрунтувань, комп'ютерного моделювання та аналізу експериментальних досліджень процесів зміни технічного стану суднових ДГУ встановлено, що нелінійні нейромережеві регресійні моделі відображають залежність діагностичних параметрів від навантаження з достатнім рівнем адекватності та мають переваги над традиційними. Розроблені моделі дозволяють підвищити достовірність діагностичних висновків систем технічного діагностування (СТД) та можуть бути застосовані на суднах різного призначення.

Апробація результатів магістерського дослідження: доповідь з тематики даної роботи обговорювалась на XV міжнародній науково-технічній конференції «Суднова електроінженерія, електроніка і автоматика» (СЕІЕА-2025), яка проходила у Національному Університеті «Одеська морська академія», місто Одеса.

Публікації: Наукова стаття «Проблемні питання оцінки та прогнозу технічного стану дизель-генераторних установок із застосуванням нейромережевих технологій» із зв'язаною тематикою дипломної роботи опубліковано у матеріалах XV міжнародної науково-технічної конференції «Суднова електроінженерія, електроніка і автоматика» (СЕІЕА-2025).

СУДНОВА ЕЛЕКТРОЕНЕРГЕТИЧНА СИСТЕМА, ДИЗЕЛЬ-ГЕНЕРАТОРНА
УСТАНОВКА, ПРОЦЕСИ ОЦІНКИ ТА ПРОГНОЗУ ТЕХНІЧНОГО СТАНУ,
НЕЙРОМЕРЕЖЕВІ ТЕХНОЛОГІЇ

ABSTRACT

Master's thesis: 95 pages, 25 figures, 0 tables, 87 references.

Topic: RESEARCH OF DIAGNOSTIC PROCESSES OF MARINE DIESEL GENERATOR SETS IN THE SPACE OF STATE PARAMETERS

Relevance of the topic: Modern trends in increasing technical, economic, environmental and operational requirements for ship electrical power systems (SEPS) and, in particular, for their most important component, namely, diesel generator sets (DGS), necessitate a transition from planned preventive repairs to a strategy for their maintenance based on the current technical condition.

The most important problem of such a transition is to reliably determine the technical condition of the objects being diagnosed and determine the forecast of changes in such a condition to establish the possibility of further operation while ensuring technical and economic indicators and environmental safety. The methods of assessing and complying with the technical condition currently used in technical diagnostic systems are based on the principles of traditional tolerance control, and in the most advanced systems, classical methods of applied statistics are used, in particular trend control and trend analysis. The shortcomings of traditional approaches lead to a high level of errors of the first kind - "false false alarms", which leads to unjustified removal of objects from operation and, accordingly, to economic losses, as well as to a decrease in the level of confidence in diagnostic conclusions.

The intensive development of information and computer technologies, in particular, artificial intelligence methods, allows the use of more advanced methods and algorithms for monitoring and diagnosing the technical condition of objects.

Hence, to implement the strategy of transition to servicing ship systems according to technical condition and taking into account the capabilities of modern information and telecommunication technologies, which are capable of implementing more advanced methods and algorithms for technical diagnostic of ship DGS, the problem of creating a set of methods, methodological foundations and software and algorithmic means for

assessing and predicting the technical condition, which can be used in technical diagnostic systems that take into account statistical data generation models and the capabilities of neural network technologies, is relevant. The solution to this problem is proposed by establishing the relationships between the diagnostic parameters of the technical condition of ship diesel generator sets and building the models of these relationships that more adequately correspond to the physics of processes in the diesel generator set, and building the corresponding data generation models and, on this basis, creating software and tools for assessing the current technical condition and predicting its changes during long-term operation. Thus, there is a contradiction between the requirements for diagnostic systems demanded by practice and the capabilities of such systems used in the SEES.

Connection of the work with scientific programs, themes, and plans: The topic of the master's thesis coincides with the scientific research of the Department of Electrical Equipment and Ship Automation of the National University "Odesa Maritime Academy".

The purpose of the work is to resolve the indicated contradiction between the requirements for diagnostic systems demanded by practice and the capabilities of such systems used in the SEES by establishing the relationships between the diagnostic parameters of the technical condition of ship diesel generators and building models of these relationships that more adequately correspond to the physics of processes in diesel generators, and building corresponding data generation models and, on this basis, creating software and tools for assessing the current technical condition and predicting its changes during long-term operation based on modern neural network technologies.

To achieve this purpose, the following tasks were solved:

1. Critical review and comparison of known approaches and methods dedicated to the problem of diagnosing the technical condition of complex energy facilities, in particular, ship diesel generator sets, and modern methods for solving the problem of such diagnostics.
2. Analysis of the proposed methods of trend control and analysis of the technical condition of complex energy facilities.
3. Review of methods for assessing and predicting the technical condition of

complex energy facilities, in particular, using modern neural network technologies.

4. Conducting experimental research and modeling in real operating conditions of ship diesel generators aimed at collecting statistical data characterizing their technical condition, as well as systematizing and analyzing the obtained data.

5. Development of statistical models of the relationships between diagnostic parameters of ship diesel generators, methods and algorithms for assessing their technical condition and predicting its change, as well as computer implementation of the specified models using modern software tools

Object of study: The object of the master's thesis is the processes of energy conversion in ship electrical power systems, in particular, diesel generators, the processes of changing their technical condition and information processes of assessing and forecasting changes in technical condition.

Subject of study: The subject of the study is models and methods of studying energy conversion processes in ship electrical power systems, methods of diagnosing the technical condition and forecasting changes in the technical condition of diesel generators.

Research methods: mathematical modeling methods, applied statistics methods, trend control and analysis methods, neural network technology methods.

Hypothesis: The hypothesis of the study is that based on the construction of mathematical models of the relationships between diagnostic parameters and the application of neural network technology methods, it is possible to increase the reliability of diagnostic conclusions about the technical condition and the forecast of its change for ship diesel generators by technical diagnostic systems.

Scientific novelty of the obtained results:

- Based on the review and analysis of existing solutions, the possibility of improving the algorithms for determining the technical condition of ship DGSS and predicting their technical condition by technical diagnostic systems was considered.

- Mathematical modeling of time series of parameters for registering the technical condition of diesel generator sets using regression analysis methods and neural network technologies was further developed.

- For the first time, a nonlinear neural network regression model of the dependence of the temperature of the exhaust gases of the cylinders of a diesel engine of DGS on the load was developed, which minimizes the mean square deviations of the temperature measurement results, which allows increasing the reliability of diagnostic conclusions of technical diagnostic systems.

The practical significance of the results obtained is as follows: based on analytical justifications, computer modeling and analysis of experimental studies of the processes of changing the technical condition of ship DGS, it was established that nonlinear neural network regression models reflect the dependence of diagnostic parameters on the load with a sufficient level of adequacy and have advantages over traditional ones. The developed models allow to increase the reliability of diagnostic conclusions of TDS and can be applied on general-purpose vessels.

Approbation of the results of the master's research: a report on the topic of this work was discussed at the XV International Scientific and Technical Conference "Marine Electrical Engineering, Electronics and Automation" (CEEEA-2025), which was held at the National University "Odesa Maritime Academy", the city of Odesa.

Publications: The scientific article "Problematic issues of assessment and forecasting the technical condition of diesel generator sets using neural network technologies" with the related topic of the thesis was published in the materials of the XV international scientific and technical conference "Marine electrical engineering, electronics and automation" (CEEEA-2025).

SHIP ELECTRIC POWER SYSTEM, DIESEL GENERATOR SET,
PROCESSES OF ASSESSMENT AND FORECAST OF TECHNICAL CONDITION,
NEURAL NETWORK TECHNOLOGIES

ЗМІСТ

ПЕРЕЛІК СКОРОЧЕНЬ.....	14
ВСТУП.....	16
1. ПРОБЛЕМИ ДІАГНОСТУВАННЯ ТЕХНІЧНОГО СТАНУ СКЛАДНИХ ТРАНСПОРТНИХ ЕНЕРГЕТИЧНИХ ОБ'ЄКТІВ.	18
1.1 Загальні принципи діагностування технічного стану складних енергетичних об'єктів	18
1.2 Методи та засоби діагностування технічного стану складних енергетичних об'єктів	22
Висновки до розділу 1	34
2 ПРОБЛЕМИ ПРОГНОЗУ ТЕХНІЧНОГО СТАНУ СКЛАДНИХ ЕНЕРГЕТИЧНИХ ОБ'ЄКТІВ, ЗОКРЕМА, ДГУ, ТА МЕТОДИ ЇХ ВИРІШЕННЯ	35
2.1 Завдання прогнозу технічного стану складних енергетичних об'єктів	35
2.2 Особливості даних часових рядів параметрів технічного стану складних енергетичних об'єктів	40
2.3 Моделі прогнозування часових рядів параметрів технічного стану складних енергетичних об'єктів	44
2.4 Алгоритми прогнозування часових рядів параметрів технічного стану складних енергетичних об'єктів	45
Висновки до розділу 2	54
3 МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ ВЗАЄМОЗВ'ЯЗКІВ ПАРАМЕТРІВ ТЕХНІЧНОГО СТАНУ СУДНОВИХ ДИЗЕЛЬ-ГЕНЕРАТОРНИХ УСТАНОВОК	56
3.1 Програмне середовище для створення статистичних моделей взаємопов'язаних діагностичних параметрів ДГУ, оцінки та прогнозу	

технічного стану	56
3.2 Програмне середовище для створення статистичних моделей взаємопов'язаних діагностичних параметрів ДГУ, оцінки та прогнозу технічного стану на основі нейронних мереж	58
3.3 Відбір параметрів та обґрунтування параметрів для створення статистичних моделей взаємопов'язаних діагностичних параметрів	61
3.4 Статистичне моделювання процесів оцінки та зміни стану температурного режиму ДГУ	71
Висновки до розділу 3	74
4. ПІДСУМКОВІ РЕКОМЕНДАЦІЇ ЩОДО КОНСТРУКЦІЇ ГІБРИДНОЇ СЕЕС, ПОБУДОВА ЇЇ ОДНОЛІНІЙНОЇ СХЕМИ ТА АЛГОРИТМІЗАЦІЯ ЇЇ СИСТЕМИ УПРАВЛІННЯ.....	75
4.1 Підсумкові рекомендації для створення оптимальної конструкції СЕЕС та побудова її однолінійної схеми.....	75
4.2 Опис можливих режимів роботи гібридної СЕЕС, які необхідно враховувати при створенні алгоритмів управління.....	77
4.3 Довірчі інтервали середніх та дисперсій параметрів ДГУ	79
Висновки до розділу 4	81
ВИСНОВКИ.....	82
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	85
ДОДАТКИ	95

ПЕРЕЛІК СКОРОЧЕНЬ

АВ – Автоматичний вимикач,
АДГ – Аварійний дизель – генератор,
АД – Асинхронний двигун,
АКБ – Акумуляторні батареї,
АПС – Аварійно - попереджувальна сигналізація,
АРЩ – Аварійний розподільний щит,
АРН – Автоматичний регулятор напруги,
БЖ – Блок живлення,
ВКК – вибірковий коефіцієнт кореляції;
ГД – Головний двигун,
ГА – Генераторні агрегати,
ГРЩ – Головний розподільний щит,
ДАУ – Дистанційне автоматизоване управління,
ДГ – Дизель – генератор,
ДГУ -Дизель-генераторна установка,
ДМ – діагностична модель;
ЕУ – Енергетична установка,
ККД – Коефіцієнт корисної дії,
КП – Коефіцієнт потужності,
МН - машинне навчання;
ММ – математична модель;
ПТЕ – Правила технічної експлуатації,
СЕЕС – Суднова електроенергетична система,
ОД – об'єкт діагностування;
ПНВТ – паливний насос високого тиску;
СЕЕС – суднова електроенергетична система;
СМПД - статистичні моделі породження даних;
СТД – система технічного діагностування;

ТС – технічний стан;

ТУ – технічні умови;

ШІ – штучний інтелект;

ANN - штучна нейронна мережа;

ARIMA - авторегресивне інтегроване ковзне середнє;

ARCH - авторегресивна умовна гетероскедастичність;

ES - експоненціальне згладжування;

DL - навчання з обмеженою пам'яттю;

GAN – генеративна мережа;

LSTM - довга короткочасна пам'ять;

ML - машинне навчання;

PLC – програмований логічний контролер;

RPM – частота обертання вала (об/хв.);

RNN - рекурентна нейронна мережа;

IVHM– системи інтегрованого керування станом транспортних засобів;

EHM– система керування станом двигуна;

SSA – сингулярний спектральний аналіз;

SVM - метод опорних векторів;

VAR - векторна авторегресія;

ВСТУП

Сучасні тенденції підвищення техніко-економічних, екологічних та експлуатаційних вимог, що пред'являються до суднових електроенергетичних систем (СЕЕС) і, зокрема, до їх найбільш важливої складової, а саме, дизель-генераторних установок (ДГУ), обумовлюють необхідність переходу від планово-попереджувальних ремонтів до стратегії їх обслуговування за поточним технічним станом.

Найбільш важливою проблемою такого переходу є достовірне визначення технічного стану об'єктів діагностування та визначення прогнозу зміни такого стану для встановлення можливості подальшої експлуатації із забезпеченням техніко-економічних показників і безпеки для довкілля. Методи оцінки та відповідності технічного стану, що застосовуються в поточний час в системах технічного діагностування, базуються на принципах традиційного допускового контролю, а в найбільш передових системах застосовуються класичні методи прикладної статистики, зокрема трендовий контроль та трендовий аналіз. Недоліки традиційних підходів зумовлюють високим рівнем помилок першого роду - "помилкових хибних тривог", що призводить до безпідставного зняття об'єктів з експлуатації і, відповідно, - до економічних втрат, а також до зниження рівня довіри до діагностичних висновків..

Інтенсивний розвиток інформаційних і комп'ютерних технологій, зокрема, методів штучного інтелекту, дозволяє використовувати більш досконалі методи і алгоритми контролю і діагностування технічного стану об'єктів.

Звідси, для реалізації стратегії переходу обслуговування суднових систем за технічним станом і враховуючи можливості сучасної інформаційно-телекомунікаційних технологій, які здатні реалізувати більш досконалі методи та алгоритми технічного діагностування суднових ДГУ, є актуальною проблема створення сукупності методів, методичних основ та програмно-алгоритмічних засобів оцінки та прогнозу технічного стану, які можуть бути застосовувані в системах технічного діагностування, що враховують моделі статистичного

породжування даних та можливості нейромережових технологій. Вирішення вказаної проблеми пропонується за допомогою встановлення взаємозв'язків діагностичних параметрів технічного стану суднових дизель-генераторних установок та побудови моделей цих взаємозв'язків, які з більшою адекватністю відповідають фізиці процесів в ДГУ, та побудові відповідних моделей породження даних і, на цій основі, створення програмно-інструментальних засобів оцінки поточного технічного стану та прогнозу його змін на протязі довготривалої експлуатації .

1 ПРОБЛЕМИ ДІАГНОСТУВАННЯ ТЕХНІЧНОГО СТАНУ СКЛАДНИХ ТРАНСПОРТНИХ ЕНЕРГЕТИЧНИХ ОБ'ЄКТІВ

1.1. Загальні принципи діагностування технічного стану складних енергетичних об'єктів

Загальним принципам діагностування технічного стану складних енергетичних об'єктів транспортного призначення та їх складових в предметній галузі присвячена низка нормативних документів та праць [1–8].

Автоматизовані системи діагностування аналізують інформацію по наступним напрямкам: контроль стану виробу й локалізація дефектів [9–11]. На рис. 1.1 наведено функції системи інтегрованого керування станом об'єктів транспортного призначення.

Системи інтегрованого керування станом транспортних засобів (IVHM) використовуються провідними компаніями для контролю стану різних підсистем, включаючи двигуни, електронні засоби й елементи конструкції [10]. Дані надходять від датчиків, розміщених по всьому об'єкту, й передаються до централізованої системи, де вони обробляються й аналізуються. Цей аналіз дозволяє виявляти будь-які аномальні закономірності та тенденції, які можуть указувати на потенційні проблеми або перебої в системах об'єкту, спрогнозувати час до відмови, що дозволяє більш ефективно планувати технічне обслуговування, скорочуючи непередбачувані простої й підвищуючи експлуатаційну працездатність суден.



Рисунок 1.1 – Функції системи інтегрованого керування станом об'єктів транспортного призначення

Складовою частиною системи IVHM є система керування станом двигуна (Engine Health Management EHM) [9]. Вона представляє собою ієрархічну розподілену інформаційну систему, яка реалізує шість етапів обробки й аналізу інформації: збирання й обробку діагностичної інформації, моніторинг і діагностування технічного стану, оцінку працездатності, прогнозування технічного стану й підтримку прийняття рішень. Система EHM складається з наземних і бортових систем, які працюють у тандемі через систему зв'язку. EHM виконує такі функції: моніторинг стану й діагностування несправностей проточної частини газотурбінного двигуна (ГТД), моніторинг стану оливи, вібрації й ресурсу. У системі EHM використовуються складні математичні алгоритми, такі як фільтр Калмана, генетичні алгоритми, алгоритми машинного навчання.

Методам діагностування, оснований на аналізі параметрів робочого процесу, притаманно деякі характерні відмінності, які в сукупності визначають особливе місце цих методів у системі контролю стану об'єкта. Діагностичні інформація міститься в значеннях параметрів робочого процесу об'єкта, які зареєстровано при його роботі.

Для класифікації методів параметричного діагностування їх систематизують за декількома ключовими ознаками, які характеризують алгоритми діагностування.

Класифікацію може бути виконано за типом використовуваної апріорної інформації про стан об'єкта (інформація експериментальна чи модельна), за типом математичної моделі (ММ) об'єкта дослідження (лінійна чи нелінійна) й за способом локалізації несправності. Така класифікація основана на роботі [12], а також на оглядах методів діагностування.

Згідно рис. 1.2. методи обробки вихідної інформації, що використовуються з метою локалізації несправностей, можна розділити на два основні класи: методи, які працюють із експериментальною апріорною інформацією про об'єкт, і методи, які використовують ММ зміни стану. Для великої кількості агрегатів, зокрема елементів СЕЕС, не існує систематизованої бази даних дефектних станів, а створення такої бази ускладнено випадковим характером дефектів, що виникають, багато з яких проявляються достатньо рідко. Тому при розробці методів параметричного діагностування основну увагу привертають методи, що засновані на ідентифікації ММ процесів зміни стану і побудові відповідної моделі породження даних, і діагностування в просторі параметрів технічного стану об'єкта діагностування.

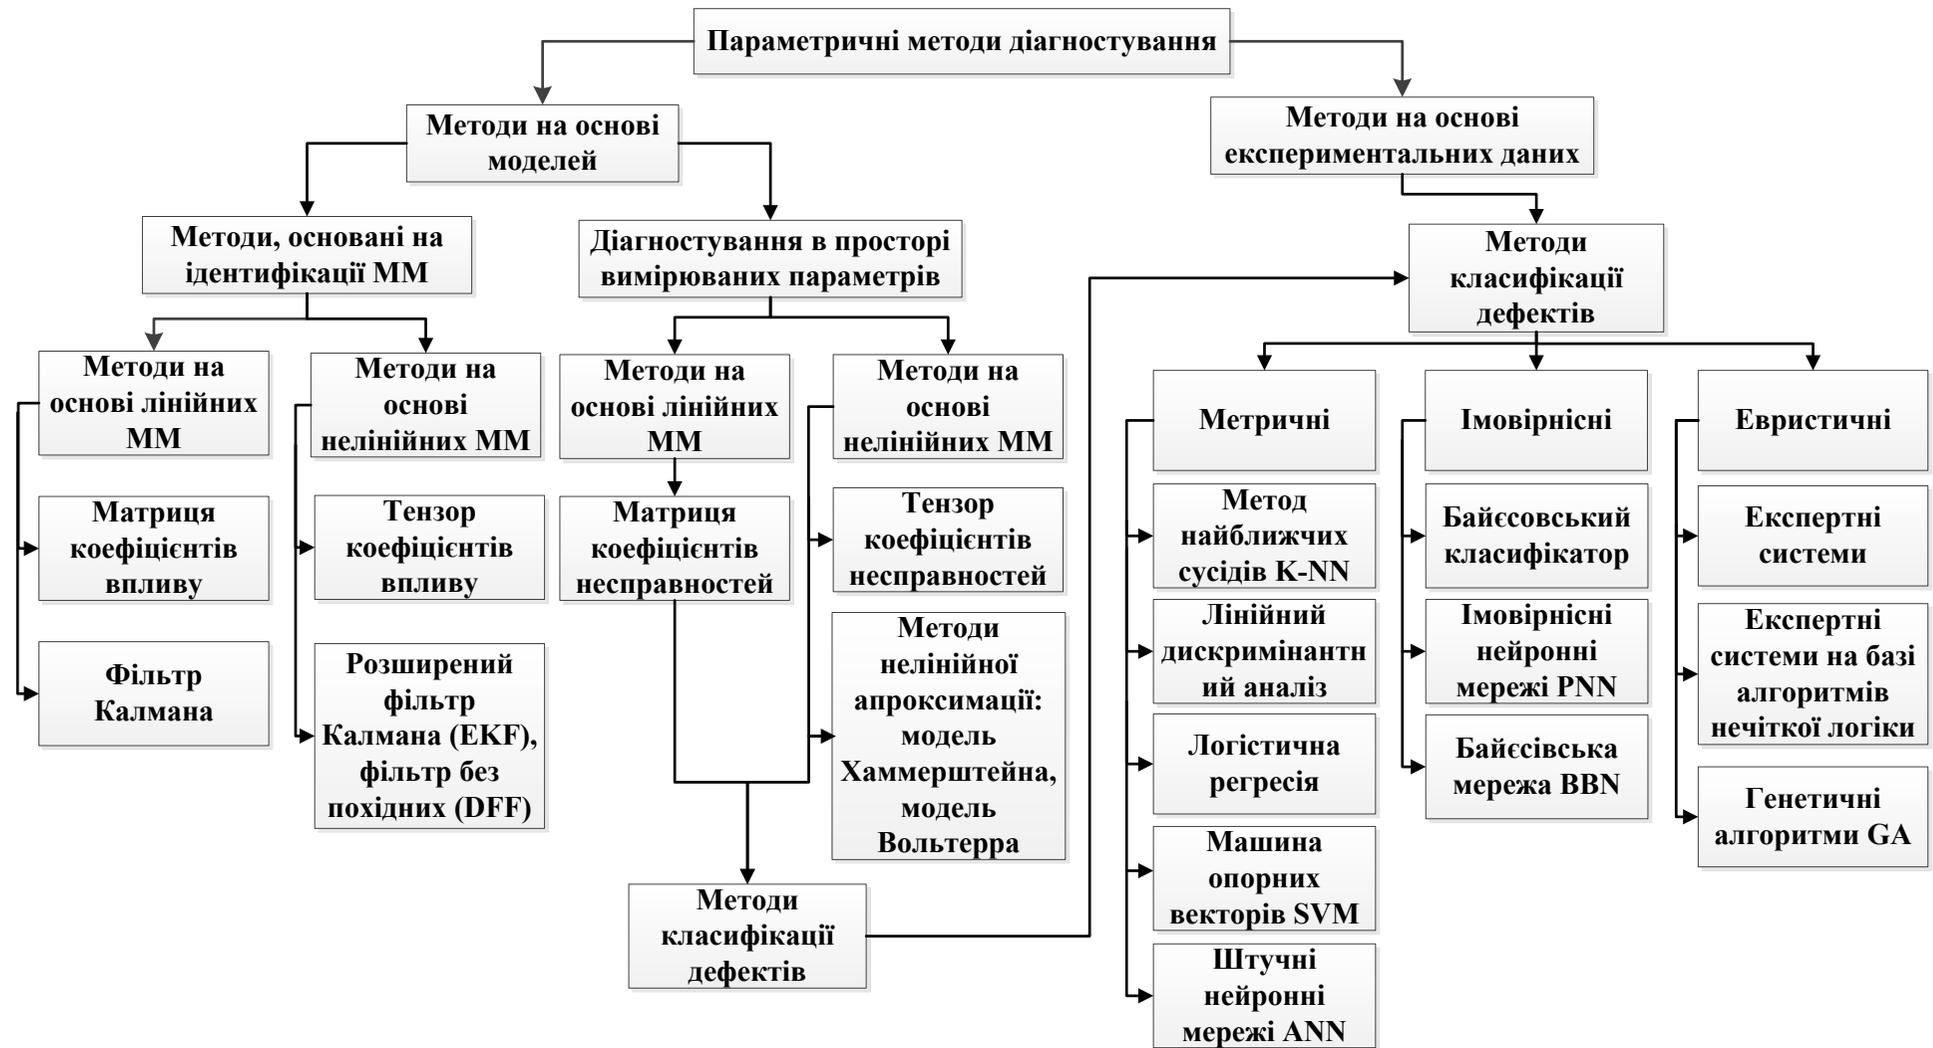


Рисунок 1.2 – Класифікація методів параметричного діагностування

1.2 Методи та засоби діагностування технічного стану складних енергетичних об'єктів

Діагностування технічного стану певного об'єкту транспортного призначення є складним науково-технічним завданням, яке повинно знайти своє вирішення в апаратних та програмно-алгоритмічних засобах відповідних систем автоматизації.

Взагалі метою діагностування технічного стану певного об'єкту вважається визначення його працездатності: можливості виконувати покладені на нього функції, що зазначені в нормативних документах: ДСТУ, технічних умовах, керівництвах до експлуатації тощо. Досягнення поставленої мети забезпечується не тільки встановленням відхилень контрольованих параметрів такого об'єкту від номінальних значень в певних межах допускового контролю, що становить завдання трендового контролю та трендового аналізу, а також визначенням причини та місця відмови певної частини (елементу) складного об'єкту та/або системи автоматизації.

За умов реалізації стратегії експлуатації за технічним станом, необхідною складовою процесу діагностування є визначення прогнозу можливої експлуатації досліджуваного об'єкту до вичерпання ресурсу при збереженні техніко-економічних та екологічних показників.

Щодо науково-технічної основи вирішення завдань діагностування, то її складають методи прикладної статистики та теорії надійності, методи інтелектуальної обробки даних в умовах невизначеності, тобто методи штучного інтелекту.

Щодо програмно-алгоритмічного забезпечення вирішення завдань діагностування, воно ґрунтується на методах багатовимірному аналізу даних, методах трендового контролю та прийняття рішень в умовах невизначеності (нечітка логіка), методах трендового аналізу (методі головних компонент, методу факторного аналізу, методу нейромережевого регресійного аналізу та інших).

Питанням розробки методів та засобів діагностування технічного стану складних енергетичних об'єктів, зокрема ДГУ транспортного призначення, присвячено низка праць [13 – 23].

Таким чином, вирішення завдання діагностування технічного стану складного енергетичного об'єкту можливо представити як низку послідовного вирішення наступних взаємопов'язаних, інколи суперечливих, завдань:

1) Системний аналіз об'єкту діагностування

На цьому етапі встановлюються загальні умови руху об'єкту в його простору стану. Встановлюються метричні простори вхідних дій, як контрольованих, так і неконтрольованих, метричний простір вихідних реакцій, і, що найбільш важливо, властивості системного оператора, що перетворює вхідні дії у вихідні реакції.

Результатом такого етапу є математична модель об'єкту в його простору стану (математичний опис руху параметрів стану при зміні вхідних дій). За ДСТУ такий етап вважається етапом “Досліджування об'єкту”, що передбачує його ідентифікацію, тобто встановлення взаємозв'язків між вхідними діями та вихідними реакціями відомими методами. Як результат такого етапу може бути математичний опис руху досліджуваного об'єкту у простору стану у вигляді відповідних векторно-матричних рівнянь, передаточних функцій, частотних характеристик тощо. Математична модель досліджуваного об'єкту діагностування (ОД), при її верифікації за даними стендових випробувань та експлуатації, може бути використана, як для верифікації даних вимірювань параметрів технічного стану, так і для отримання даних щодо вимірювального каналу, за яким встановлена відмова.

2) Допусковий контроль

На цьому етапі встановлюються перевищення межі відхилень вимірювальних значень контрольованих діагностичних параметрів технічного стану об'єкту від заздалегідь визначених меж, які визначені “Технічними

умовами” (ТУ) виробника. Якщо фіксується таке відхилення значення деякого параметру технічного стану об’єкту діагностування, має місце відмова щодо працездатного його стану.

Але, слід мати на увазі, що така відмова може бути наслідком непрацездатності каналу вимірювань. Тому, у відповідальних системах автоматизації канали вимірювань визначних параметрів технічного стану об’єктів діагностування дублюються. І тільки в тому випадку, якщо міжканальна різниця перевищує певну межу, може бути зафіксована відмова каналу вимірювання. Зазвичай використовується правило трьох сігма (середньоквадратичного значення похибок вимірювання). Тобто, якщо міжканальна різниця перевищує таку межу, вважається, що вимірювальний канал знаходиться в стані відмови. В такому випадку доцільно використовувати дані, які отримані від резервного каналу або комп’ютерно реалізованої математичної моделі об’єкту діагностування.

3) Трендовий контроль

На цьому етапі встановлюється зміна відхилень вимірювальних значень контрольованих параметрів технічного стану об’єкту діагностування від номінальних значень на протязі значного, (наперед зазначеного в ТУ) проміжку часу, від межового значення. Вимірювальні значення контрольованих параметрів технічного стану об’єкту діагностування фіксуються апаратними засобами у вигляді часових рядів.

Для визначення таких змін використовуються відомі критерії та статистики трендового контролю, зокрема кумулятивних сум, Хальда-Аббе, Фішера та інші.

При використанні відомих критеріїв та статистик трендового контролю має місце альтернативна гіпотеза;

– або вибірка даних відповідає гіпотезі щодо належності до нормальної сукупності статистично незалежних випадкових величин,

– або не відповідає такій гіпотезі на заздалегідь заданому рівню значимості.

Тому спрацьовування трендового критерію зовсім не означає наявності тренду як такого. Це означає тільки той факт, що опорна гіпотеза не може бути прийнятою. З огляду на теоретичні засади прикладної статистики критеріїв наявності тренду в часових рядах даних реєстрації технічного стану об'єктів діагностування взагалі не існує, оскільки певні статистичні гіпотези можуть бути тільки спростовані. Така особливість методів трендового контролю зумовлена невизначеністю самого поняття “тренд”. Досі не існує єдиної точки зору на визначення такого поняття. В більшості випадків під трендом розуміється адитивна детермінована складова в часових рядах. Застосовані моделі тренду (лінійний, поліноміальний, експоненційний, тощо) відрізняються широким різноманіттям, тому власне неможливо побудувати критерії їх наявності в часових рядах.

Слід мати на увазі, за наявності природного відпрацювання ресурсу об'єкту діагностування тренд параметрів завжди існує. Тому має місце деякий компроміс між обсягом вибірок даних реєстрації та заздалегідь встановленим рівнем значимості певного трендового критерію.

Трендові критерії розподіляються на два великі класи: параметричні та непараметричні. Параметричні критерії, як, наприклад, вказані раніше, є функціоналами від дійсних значень відліків часових рядів. Непараметричні критерії (Спірмена, Бартлета, Вілкоксона та інші) не пов'язані безпосередньо з дійсними значеннями відліків, а враховують їх ранги, тобто порядок розташування у варіаційному ряді. Параметричні критерії добре пристосовані до обмежень на розмірність вибірки, швидко нормалізуються, мають незначний час спрацьовування, але мають високу чутливість до нецензурованих викидів, відмінності розподілу від нормального для опорної гіпотези. Непараметричні критерії, навпроти, нечутливі до вказаних ефектів, але потребують значного обсягу вихідних даних для спростування опорної гіпотези на завданому рівні значимості.

Серед параметричних критеріїв та статистик найбільше застосування отримали наступні.

Критерій вибіркового коефіцієнта кореляції (ВКК)

Статистика ВКК має наступний вигляд:

$$R(x_n, N, k) = \frac{\sum_{n=1}^N [x_n - m(x_n)][x_{n-k} - m(x_{n-k})]}{\sqrt{\sum_{n=1}^N [x_n - m(x_n)]^2 \sum_{n=1}^N [x_{n-k} - m(x_{n-k})]^2}}, \quad (1.1)$$

$$\text{де } m(x_n) = \frac{1}{N} \sum_{n=1}^N x_n; m(x_{n-k}) = \frac{1}{N} \sum_{n=k+1}^N x_{n-k}.$$

Критерій відношення дисперсій (Фішера)

Статистика критерію заснована на співвідношенні:

$$v(x_n, N, M) = \frac{D(x_n, N)}{D(x_n, M)} = \frac{VR_{sort}}{VR_{long}}, \quad (1.2)$$

де $D(x_n, N), D(x_n, M)$ – поточні дисперсії часового ряду довжиною N та M .

За умови відповідності часового ряду опорній гіпотезі вказана статистика має v – розподілення, яке має назву розподіленням Фішера.

Критерій рівності середніх (Стьюдента).

Статистика критерію має вигляд:

$$St(x_n, N_1, N_2) = \frac{m_1 - m_2}{\sqrt{\frac{\sigma_1^2}{N_1^2} + \frac{\sigma_2^2}{N_2^2}}}, \quad (1.3)$$

де m_1, σ_1^2 – вибіркові середнє та дисперсія першої вибірки часового ряду довжиною N_1 , m_2, σ_2^2 – вибіркові середнє та дисперсія другої вибірки часового ряду довжиною N_2 .

За умови відповідності часового ряду опорній гіпотезі, вказана статистика має розподіл Стьюдента [1], із $N_1 + N_2 - 2$ ступенями свободи.

Серед непараметричних критеріїв та статистик найбільше застосування отримали наступні.

Ранговий критерій Вальда-Вольфовітца

Нехай R_i – ранг огляду в упорядкованому по збільшенню ряду значень часового ряду.

Коефіцієнт серіальної кореляції Вальда-Вольфовітца має наступний вигляд:

$$R_{ww} = \sum_{i=1}^{N-1} \left(R_i - \frac{N+1}{2} \right) \left(R_{i+1} - \frac{N+1}{2} \right) \quad (1.4)$$

Розподіл такої статистики для опорної гіпотези є асимптотично нормальним із середнім $M(R_{ww})$ і дисперсією $D(R_{ww})$, де

$$M(R_{ww}) = 0, D(R_{ww}) = \frac{N^2(N+1)(N-3)(5N+6)}{720}. \quad (1.5)$$

Гіпотеза випадковості не підтверджена, якщо

$$\left| R_{ww}^* \right| = \frac{R_{ww}}{\sqrt{D(R_{ww})}} > u_{\frac{1+\alpha}{2}}. \quad (1.6)$$

Критерій Бартелса

Нехай R_i – ранг огляду в упорядкованому по збільшенню ряду значень часового ряду.

Статистика Бартелса має вигляд:

$$R_{ww} = \sum_{i=1}^N (R_i - R_{i+1})^2 / \sum_{i=1}^N \left(R_i - \frac{N+1}{2} \right)^2 \quad (1.7)$$

Розподіл такої статистики для опорної гіпотези є асимптотично нормальним.

Гіпотеза випадковості не підтверджена, якщо

$$|B^*| = \frac{B-2}{2\sqrt{5/(5N+7)}} > u_{\frac{1+\alpha}{2}}. \quad (1.8)$$

Критерій інверсій

Якщо у вибірці значень часового ряду, записаних у порядку їх визначення, за деяким значенням слідує менше по величині, то має місце інверсія. Загальне число інверсій I є статистикою критерію випадковості отриманих значень. Розподіл такої статистики для опорної гіпотези асимптотично нормальний зі середнім $M(I)$ та дисперсією $D(I)$, де

$$M(I) = \frac{N(N-1)}{4}, D(I) = \frac{2N^3 + 3N^2 - 5N}{72}. \quad (1.9)$$

Гіпотеза випадковості не підтверджена, якщо

$$|I^*| = \frac{|I - M(I)|}{\sqrt{D(I)}} > u_{\frac{1+\alpha}{2}}. \quad (1.10)$$

В практичних застосуваннях використовують правило Неймана-Пірсона, тобто наперед задається ймовірність помилки першого роду, а саме ймовірність “хибної тривоги”, наприклад 0,001. Звідси встановлюється пороговий рівень відповідної трендової статистики. Зауважимо, що ймовірність помилки другого роду, тобто “пропуску тренду” встановити неможливо, що є загальним недоліком методів трендового контролю. Досвід застосування методів трендового контролю в системах діагностування вказує на їх суттєвий принциповий недолік, а саме, високий рівень потоку “хибних тривог”. Хибне спрацьовування трендового критерію, за умови належної реакції на таке явище, потребує необґрунтованої зупинки обладнання для встановлення можливої несправності апаратними засобами контролю. За цієї причини виникає “простой”, що супроводжується значними матеріальними та економічними витратами. Тому на практиці існує деяка недовіра до застосування методів трендового контролю в практично реалізованих

системах діагностування, що потребує застосування більш досконалих методів оцінки технічного стану, зокрема, методів трендового аналізу.

4) Трендовий аналіз

Недоліки методів трендового контролю, які історично були застосовані першими, зумовили необхідність застосування більш досконалих методів оцінки технічного стану об'єктів діагностування за даними реєстрації у вигляді багатовимірних часових рядів. З іншої сторони, удосконалення апаратних засобів дозволяє в поточний час зберігати та обробляти в реальному часі значні обсяги інформації не тільки в наземних, а також в бортових системах діагностування.

Об'єктом досліджень за допомогою трендового аналізу є процеси зміни технічного стану у довготривалій експлуатації складних енергетичних комплексів, які відображаються у вигляді багатовимірних масивів даних (часових рядів).

Предметом таких досліджень є математичні статистичні моделі породження даних (СМПД), методи декомпозиції даних на складові, методики та програмно-алгоритмічні інструментальні засоби прикладного аналізу та прогнозу розвитку тренду.

Загально прийнятим методом дослідження часових рядів є їх розкладання на компоненти, які відповідають фізичній природі їх утворення, а саме:

- трендову компоненту,
- циклічну (періодичну, сезонну) компоненту,
- випадкову компоненту.

Таке представлення є суто емпіричним і не ґрунтується на теоретико-аналітичних засновах.

Для визначення трендової компоненти приймаються гіпотези щодо лінійного тренду, поліноміальної його апроксимації, та інші. Слід зауважити,

що такі гіпотези стосуються тільки детермінованого тренду. Однак, вікно аналізу може містити суміш випадкових компонент із різним *simple time*, що може сприйматися як відрізок тренду, яким, насправді, він не являється.

Щодо циклічної компоненти загальноприйнятим є підхід щодо апроксимації деяким відрізком гармонійного ряду. Однак, в часових рядах така компонента є багатоскладовою і, як правило, нестационарною, що значно ускладнює вирішення завдань аналізу.

Щодо випадкової компоненти загальною вважається належність до вибірки із генеральної сукупності незалежних нормально розподілених значень. Однак, при вирішенні багатьох прикладних завдань, така належність не може бути підтверджена на завданому рівні значимості. Розподіл випадкової складової, як правило, не є нормальним і має більш складний опис. Тому, на жаль, при практичних застосуваннях, жодна із наведених гіпотез не може бути підтверджена методами прикладної статистики.

З огляду на вказані обставини, досить широке розповсюдження отримали аналітично-обчислювальні методи розкладання часового ряду, які не обмежені вимогами, що вказані наперед. Такими методами є метод головних компонент, метод факторного аналізу, їх модифікації у вигляді методу SSA, “Гусениця” та інші.

Як це обґрунтовано в теорії прикладної статистики та з огляду на можливість вирішення завдань прогнозу розвитку тренду, можливим методом трендового аналізу слід вважати таким, що забезпечує оптимальне розкладання часового ряду на ортогональні компоненти, будь якої природи за їх фізичною сутністю. Такий метод поглинає вказані відомі і надає повну інформацію щодо складових часового ряду.

За відомими методами трендового аналізу (SSA, “Гусениця” та інші), вважається, що повна інформація щодо змін часового ряду міститься у траєкторній матриці X_t розміром $n \times k$ відліків часового ряду

$$\begin{aligned}
\vec{x}_1 &= [x_1 \ x_2 \ \dots \ x_n] \\
\vec{x}_2 &= [x_2 \ x_3 \ \dots \ x_{n+1}] \\
&\dots \\
\vec{x}_k &= [x_k \ x_{k+1} \ \dots \ x_{n+k-1}]
\end{aligned}
\tag{1.11}$$

Завдання аналізу складається в розподілу строчок вказаної матриці на ортогональні компоненти.

Вирішення вказаного завдання досягається послідовною реалізацією наступних етапів:

1. Виконується вирішення задачі на власні значення та власні вектори для матриці автокореляції

$$X_t X_t^T \vec{u}_i = \lambda_i \vec{u}_i, \tag{1.12}$$

де стовбці \vec{u}_i утворюють матрицю U із ортогональних векторів матриці $X_t X_t^T$

2. Визначається матриця головних компонент часового ряду

$$F = U^T X_t, \tag{1.13}$$

де її строчки упорядковані по убутанню власних чисел матриці $X_t X_t^T$.

3. Виконується розкладання строчок траєкторної матриці по головним компонентам

$$\vec{x}_s = \sum_{i=1}^k b_{si} \vec{f}_i, \tag{1.14}$$

де $s = \overline{1, k}$, b_{si} – коефіцієнти впливу, що визначаються рішенням перевизначеної системи лінійних алгебраїчних рівнянь:

$$F^T \vec{b}_s = \vec{x}_s. \tag{1.15}$$

4. Відшукується рішення вказаної системи алгебраїчних рівнянь із використанням псевдозверненої матриці:

$$\vec{b}_s^T = (FF^T)^{-1} F \vec{x}_s^T. \tag{1.16}$$

Оскільки $(FF^T) = \text{diag} \{ \lambda_i \}$, $i = \overline{1, k}$, то має місце

$$b_{sj} = \vec{x}_s \vec{f}_j^T / (\vec{f}_j \vec{f}_j^T) = \lambda_j^{-1} \vec{x}_s \vec{f}_j^T, \tag{1.17}$$

де \vec{f}_j – строчки матриці головних компонент.

Якщо власне значення $\lambda_1 = \lambda_{\max}$ відповідає трендовій компоненті, то маємо

$$\vec{x}_{tr,s} = b_{s1} \vec{f}_1, \quad (1.18)$$

Відповідно визначаються інші компоненти розкладання часового ряду.

На рис. 1.3 представлений описаний алгоритм та застосовані наступні позначення:

S_s – старт;

A_1 – формування часових рядів $y(t_k)$ вимірювань;

A_2 – формування часових рядів ДМ $y_M(t_k)$;

A_3 – розподіл кількості відхилень у часових рядах $x(t_k) = y(t_k) - y_M(t_k)$ від ДМ;

A_4 – формування траєкторної матриці X ;

A_5 – визначення автокореляційної матриці $X^T X$;

A_6 – вирішення проблеми $X^T X \vec{u} = \lambda \vec{u}$ на власні значення λ_i та власні вектори \vec{u}_i ;

A_7 – обчислення матриці головних компонент $F = U^T X$;

P_8 – порівняння власних значень автокореляційної матриці;

A_9 – визначення тренду методом головних компонент;

A_{10} – визначення тренду за допомогою методу ковзного середнього.

S_F – фініш.

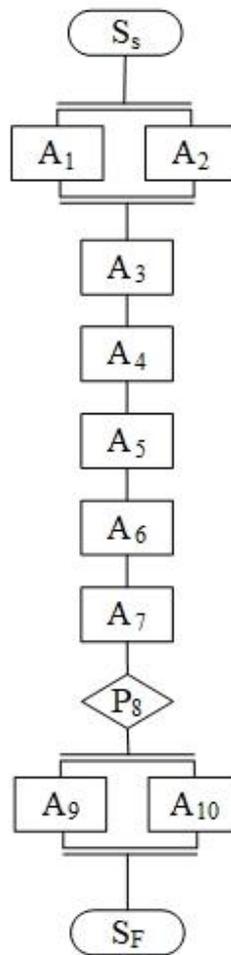


Рисунок 1.3 – Схема алгоритму визначення складової тренду

5) Прогноз розвитку тренду.

Найбільш важливим завданням трендового аналізу і взагалі моніторингу технічного стану об'єктів діагностування незалежно від використовуваних методів та засобів є встановлення тенденцій його розвитку на деякий передбачуваний час. Саме вирішення такого завдання надає можливість встановити достатній час майбутнього використання об'єкту діагностування.

Висновки до розділу 1

У розділі розглянуто загальні принципи діагностування технічного стану складних енергетичних об'єктів транспортного призначення та їх системах, окрема, СЕЕС та їх важливої складової у вигляді дизель-генераторної установки. Представлені основні етапи діагностування і їх детальна характеристика.

Основними висновками є наступні:

1. Запропонована класифікація методів параметричного діагностування і їх систематизація за ключовими ознаками, які характеризують алгоритми діагностування.

2. Обґрунтовано підхід щодо побудови методів параметричного діагностування, в якому основну увагу привертають методи, що засновані на ідентифікації математичної моделі процесів зміни стану і побудові відповідної моделі породження даних, і діагностування в просторі параметрів технічного стану об'єкта діагностування.

3. Розглянуті методи та засоби діагностування технічного стану складних енергетичних об'єктів, які містять етапи системного аналізу об'єкту діагностування, допускового контролю, трендового контролю, трендового аналізу та прогноз розвитку тренду.

2 ПРОБЛЕМИ ПРОГНОЗУ ТЕХНІЧНОГО СТАНУ СКЛАДНИХ ЕНЕРГЕТИЧНИХ ОБ'ЄКТІВ, ЗОКРЕМА ДГУ, ТА МЕТОДИ ЇХ ВИРІШЕННЯ

2.1 Завдання прогнозу технічного стану складних енергетичних об'єктів

2.1.1 Огляд методів прогнозу

Прогнозування часових рядів має вирішальне значення для ефективної роботи складних енергетичних об'єктів та процесів прийняття рішень щодо їх технічного стану. Вірогідне прогнозування майбутніх тенденцій є важливим для оптимізації ресурсів, планування експлуатації та загальної ефективності енергетичної системи судна. Важливим питанням є комплексний огляд існуючих та пропонованих моделей прогнозування часових рядів та їх застосування в суднових електроенергетичних системах. Відомі фундаментальні принципи моделей прогнозування, зокрема традиційні статистичні методи, такі як авторегресивне інтегроване ковзне середнє (ARIMA) та експоненціальне згладжування (ES), які широко використовуються завдяки швидкодії та алгоритмічним перевагам, але мають певні обмеження їх застосування для складних багатовимірних процесів із складними взаємозв'язком даних, що характерно для СЕЕС.

Для вирішення цих проблем є перспективними методи штучного інтелекту, включаючи метод опорних векторів (SVM) та штучну нейронну мережу (ANN). Такі моделі пропонують більші можливості та мають переваги перед статистичними методами, але їх не замінюють.

Перспективними є гібридні моделі, які поєднують сильні сторони різних методів для досягнення покращеної ефективності прогнозування. Такі гібридні моделі мають деякі переваги.

Знаходять застосування нові генеративні моделі, такі зокрема, як мережа GAN, для прогнозування часових рядів. Слід мати на увазі важливість вибору відповідної статистичної моделі породження даних на основі конкретних вимог щодо експлуатації СЕЕС, можливостей отримання вихідних даних та мети прогнозування.

2.1.2 Характеристика методів прогнозу

Розвиток методів штучного інтелекту (ШІ) сприяло деяким змінам в розробці та експлуатації СЕЕС та інших судових систем, що забезпечує досягнення в експлуатаційній ефективності, підвищенні якості та прогнозної експлуатації за технічним станом.

Удосконалені алгоритми машинного навчання (МН) нейронних мереж у сукупності із відомими статистичними методами є основою для оцінки взаємозв'язків у даних великої розмірності та складних процесів, що дозволяє підвищити статистичну значимість та обґрунтованість висновків.

Зокрема, прогнозне обслуговування, що базується на нейромережових методах, дозволило упереджено виявляти потенційні збої обладнання, значно скорочуючи час простою та пов'язані з ним витрати [24,25]. Складні системи, коли вони підтримуються алгоритмами ШІ, підвищують якість експлуатації, автономно виявляючи дефекти, тим самим забезпечуючи узгодженість процесів [26]. Інтеграція цих інтелектуальних моделей не тільки забезпечує підвищення надійності складних систем, але й надає перспективи розвитку інноваційних, стійких та ефективних технологічних процесів.

Суднові системи, зокрема СЕЕС, за своєю суттю генерують дані часових рядів, які являють собою виміри значень важливих параметрів, отриманих через деякі інтервали часу, включаючи динамічні та часові зміни у процесах зміни стану СЕЕС [27]. Такі дані містять змінні різного типу, зокрема такі, як темпи виробництва, використання устаткування та показники якості, і є ключовими для фіксації часових залежностей та основних закономірностей у

технологічних операціях [28]. Значення даних часових рядів у прогнозуванні є надзвичайно важливим і це дозволяє споживачам оптимізувати свої ресурси, підвищувати операційну ефективність та впроваджувати стратегії прогнозного обслуговування [29]. Використовуючи закономірності, вбудовані в дані часових рядів, моделі прогнозування можуть передбачати майбутні потреби для технічних систем, забезпечуючи надійні, стійкі та ефективні технологічні цикли в умовах дедалі більш складних завдань.

Складність сучасних технологічних процесів, що характеризуються складними ланцюгами поставок, змінним навантаженням та потребою в точності, вказує на важливість точного прогнозування часових рядів. Наприклад, прогнозне обслуговування шляхом прогнозування потенційних збоїв може не тільки забезпечити безперебійне виробництво, але й продовжити термін служби обладнання, що призводить до значної економії коштів [29]. Прогнозування допомагає зменшити витрати на запаси, покращити матеріальні потоки та забезпечити своєчасну реакцію, тим самим підвищуючи загальну ефективність [30].

Промисловість активно інвестує в розробку систем штучного інтелекту для оптимізації своїх виробничих процесів. У 2023 році ринок штучного інтелекту у виробничому секторі оцінювався в 3,8 мільярда доларів США з очікуваним сукупним річним темпом зростання (CAGR) 45%, і, за оцінками, до 2033 року він досягне 156,1 мільярда доларів США [31]. Очікується, що попит на системи прогнозного обслуговування матиме швидке зростання доходів, які вже використовуються в різних галузях кінцевого споживання. На обладнанні розміщені різні датчики для збору даних та аналізу робочих параметрів таких, як температура, вібрації та інші. Алгоритми штучного інтелекту використовують ці дані для навчання прогнозних моделей та надання інформації персоналу.

2.1.3 Розвиток моделей прогнозування часових рядів

Хронологічний розвиток методологій прогнозування часових рядів демонструє низку статистичних та алгоритмічних інновацій. Початкові підходи були переважно статистичними, з такими простими моделями, як ковзна середня (MA), авторегресія (AR) та ES, що забезпечували фундаментальну основу для раннього аналізу даних, що залежить від часу. Ці класичні моделі втілювали суть прогнозування часових рядів, дозволяючи практикам виявляти закономірності та тенденції в часових наборах даних з різних дисциплін.

Досягнення кінця 20-го століття представили вдосконалені версії традиційних моделей, включаючи ARIMA, векторну авторегресію (VAR) та авторегресивну умовну гетероскедастичність (ARCH). Серед них модель ARIMA зберегла своє провідне значення в галузі прогнозування та часто використовується з новими методами машинного навчання (ML) та навчання з обмеженою пам'яттю (DL). Хоча моделі DL є підмножиною ML, їхня складність та широке розмаїття спеціалізованих архітектур таких, як рекурентна нейронна мережа (RNN), довга короткочасна пам'ять (LSTM) та (GRU), виправдовують їх представлення як окремої категорії. Хронологія показана на рис. 2.1.

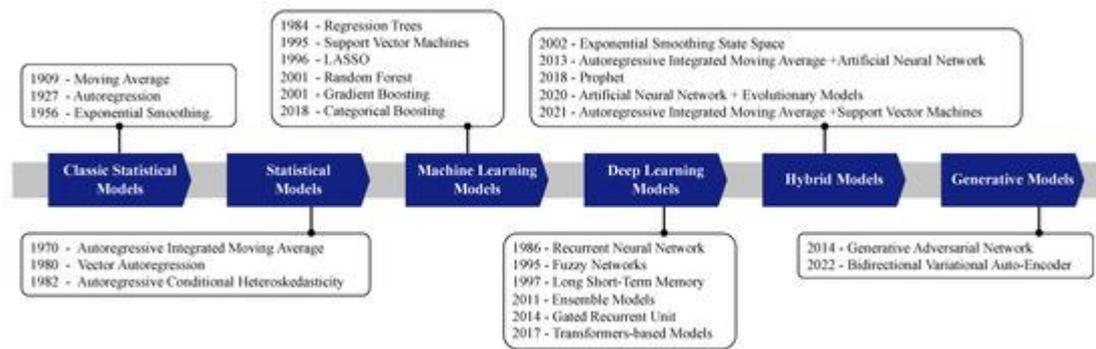


Рисунок 2.1 – Хронологічний розвиток моделей прогнозування часових рядів

Класичні статистичні моделі заклали основу для прогнозування часових рядів. Моделі машинного навчання принесли новий вимір з розширеними алгоритмами, зосередженими на підвищенні точності прогнозування. Моделі DL, незважаючи на те, що є підмножиною ML, виділяються окремо завдяки своїй унікальній архітектурі, що робить їх центральним елементом сучасних досліджень та застосувань. Гібридні моделі являють собою комбінацію однієї або кількох фундаментальних моделей для використання сильних сторін кожного компонента. Ці моделі поєднують різні методології для підвищення точності та надійності прогнозування. Наприклад, інтеграція моделі ES з моделлю ANN покращує здатність моделі фіксувати лінійні та особливо нелінійні закономірності в наборах даних часових рядів. Хоча ES та ANN можуть обчислювати як лінійні, так і нелінійні характеристики даних, сама по собі ANN має обмежену здатність обробляти лінійні дані так само точно, як і нелінійні закономірності [33]. Генеративні моделі, такі, як GAN, запровадили інноваційні підходи до прогнозування часових рядів, зосереджуючись на генерації та розумінні складних розподілів даних.

Статистичні моделі, особливо методи Бокса-Дженкінса [32], розглядаються для прогнозування часових рядів з 1970-х років. З розвитком машинного навчання та його варіацій було розроблено багато моделей, які перевершують класичні статистичні моделі. Однак методи, засновані на

нейронних мережах, наразі досягають кращих результатів, а нові архітектури моделей зосереджені на дослідженнях, що забезпечують гнучкість зі зміною закономірностей у даних.

Огляд моделей прогнозування часових рядів наведено в низці статей. Торрес та ін. [50] розглянули моделі глибокого навчання (DL) для прогнозування, включаючи математичну структуру цих моделей. Подібне дослідження було представлено Ларою-Бенітес та ін. [51], яке надало експериментальний огляд моделей глибокого навчання. Інше комплексне дослідження було проведено Дебом та ін. [29], де автори проаналізували моделі прогнозування часових рядів споживання енергії. Масіні та ін. [52] опублікували огляд про досягнення в моделях машинного навчання для прогнозування часових рядів та надали математичні деталі моделей. Енсафі та ін. [46] опублікували експериментальне порівняння деяких моделей машинного навчання. Гаспарін та ін. [53] опублікували приклад використання прогнозування електричного навантаження за допомогою алгоритмів глибокого навчання та порівняли їхню ефективність.

Існують різні моделі прогнозування для даних часових рядів, таких, як набори даних зображень, аудіо та тексту, а також для даних часових рядів, включаючи набори даних про фінанси, погоду та системи охорони здоров'я. Технічні системи з їхньою притаманною складністю та багатограними змінними вимагають детального дослідження, яке не лише включає прогностичну точність моделей, але й охоплює ширший спектр факторів, що мають вирішальне значення для практичного впровадження.

2.2 Особливості даних часових рядів параметрів технічного стану складних енергетичних об'єктів

Дані часових рядів – це набір спостережень, записаних через певні проміжки часу. Вони стали основою аналітичного моделювання різних областей завдяки своїй здатності фіксувати тенденції даних та часові

особливості. Тому прогнозування часових рядів передбачає використання попередніх точок даних для прогнозування майбутніх значень, використовуючи властиву послідовну часову природу даних для виявлення основних закономірностей, сезонності та тренду. Цей метод прогнозного моделювання є ключовим у багатьох галузях, таких як енергетика, промисловість, фінанси, економіка та екологія, де розуміння та прогнозування майбутніх станів має вирішальне значення для прийняття обґрунтованих рішень.

Послідовність часових рядів – це набір точок даних, розташованих хронологічно, зазвичай вибірково через регулярні проміжки часу. Хоча це визначення підходить для багатьох застосувань, можуть виникнути певні проблеми, а саме:

- Відсутність даних: прогалини в даних часових рядів часто трапляються через такі проблеми, як несправності датчиків або помилки збору даних. Загальні стратегії вирішення цієї проблеми включають імітацію відсутніх значень або пропуск уражених записів [54].
- Викиди: дані часових рядів іноді можуть містити аномалії або викиди. Їх можна або видалити за допомогою надійних статистичних методів, або включити їх до моделі [55].
- Нерегулярні інтервали: дані, що спостерігаються через непостійні інтервали, називаються потоками даних, коли обсяг великий, або просто називаються нерівномірно розподіленими часовими рядами. Моделі повинні враховувати цю нерегулярність [50].

Правильний вибір моделі породження даних може безпосередньо вирішити певні проблеми. Однак, коли дані збираються через непостійні проміжки часу, таку модель необхідно відповідно скоригувати [56].

Дані часових рядів зазвичай складаються з трьох основних компонентів [57]:

1. Тренд: відображає тенденцію, у якій дані змінюються з часом, без урахування сезонних впливів та випадковості. Тренди можуть бути лінійними, експоненціальними або параболічними, та інших типів.
2. Сезонність (циклічність): до цього компонента належать закономірності, що наближено повторюються через регулярні проміжки часу. Погодні умови, технологічні цикли можуть спричиняти сезонність.
3. Залишки: після врахування тренду та сезонності залишаються залишки. Якщо причину цих флуктуацій можна визначити, вони потенційно можуть сигналізувати про майбутні зміни в тренді.

Таким чином, часовий ряд – це комбінація вказаних компонентів. Ілюстрацію даних часового ряду з урахуванням сезонності, тренду та випадкових залишків показано на рис. 2.2. Реальні дані часто мають значну нерегулярну складову, що робить їх нестационарними (де середнє значення та дисперсія змінюються з часом). Така нерегулярність ускладнює прогнозування. Традиційні методи прогнозування часто розкладають часовий ряд на його компоненти та прогнозують кожен компонент окремо. Успіх методу прогнозування часто визначається його здатністю передбачати нерегулярну складову, де методи інтелектуального аналізу даних виявилися особливо ефективними.

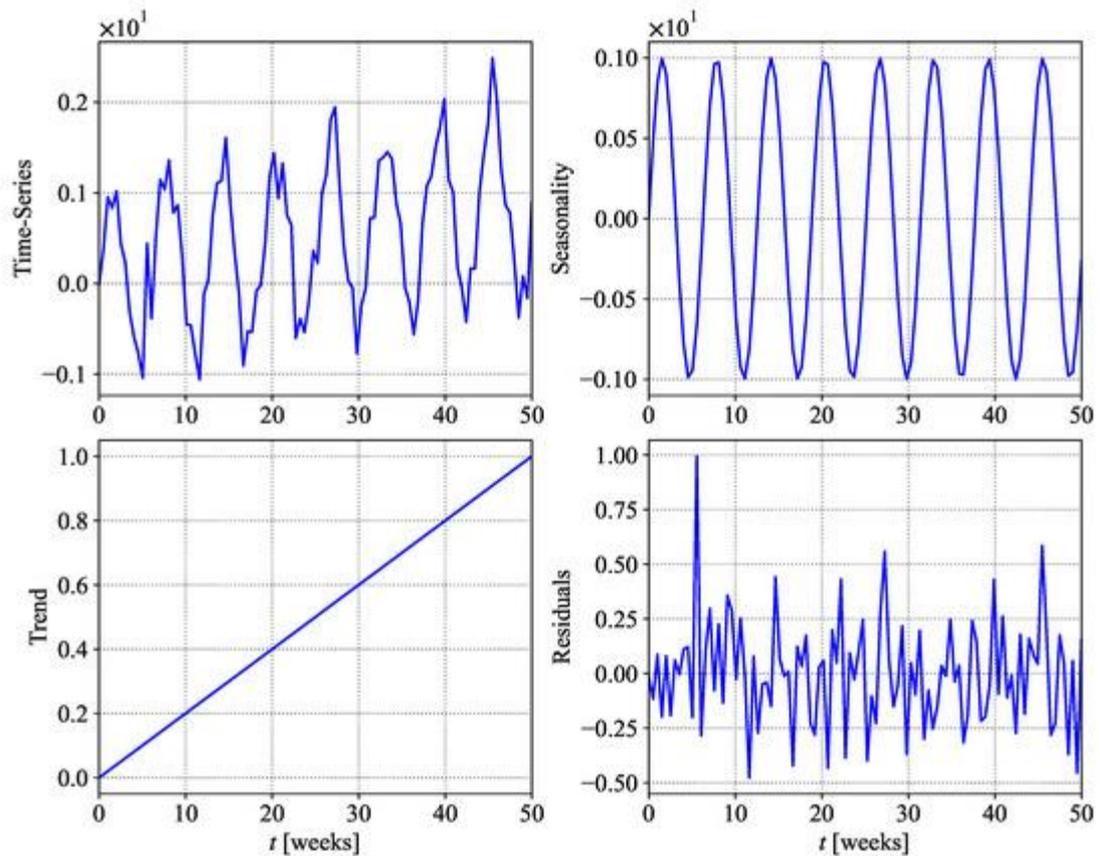


Рисунок 2.2 – Вибірка даних часових рядів, що ілюструє тренд, сезонність та випадкові залишки

Дані часових рядів можуть бути одновимірними (одна залежна від часу ознака) або багатовимірними (кілька залежних від часу ознак). Моделі прогнозування часових рядів здебільшого розроблені для обробки обох типів вхідних даних.

Часовий ряд:

$$y = y(t-L), \dots, y(t), y(t+1), \dots, y(t+h) \quad (2.1)$$

є одновимірним часовим рядом. Він має L попередніх значень, та $y(t-i)$ – значення y для часу $t-i$ де $i=0, \dots, L$. Вихідними даними моделей прогнозування є оціночне значення $y(t+1)$, та $\hat{y}(t+1)$. Цільова функція полягає в мінімізації функціоналу від похибки $y(t+1) - \hat{y}(t+1)$.

Багатовимірні часові ряди можна представити у матричній формі як сукупність одновимірних даних, де такі дані є рядками або стовпцями відповідних матриць вихідних даних.

2.3. Моделі прогнозування часових рядів параметрів технічного стану складних енергетичних об'єктів

Прогнозування часових рядів є важливим та широко використовуваним методом у різних галузях, таких як фінанси, економіка, прогнозування погоди та управління енергетикою [32, 58, 59, 60]. Такий метод передбачає розробку статистичних моделей для прогнозування майбутніх значень у послідовному наборі даних на основі попередніх даних [32, 61].

Традиційні статистичні моделі включають одновимірні методи, такі, як ARIMA [62], її сезонний варіант (SARIMA) [32, 61] та експоненціального згладжування (ETS) [49]. Багатовимірні методи, такі, як векторна авторегресія (VAR) [63] та байєсівські структурні часові ряди (BSTS) [64] враховують кілька вхідних змінних, що може забезпечити точніші прогнози. Моделі машинного навчання, такі, як SVM [44], дерева регресії [65] та випадкові ліси [45, 66], також застосовувалися до вирішення завдань прогнозування часових рядів. Такі моделі часто вимагають аналізу ознак для визначення часових особливостей даних [67]. В останні роки моделі на основі глибокого навчання стали потужним інструментом для прогнозування часових рядів. Мережі з довгостроковою пам'яттю (LSTM) [47] та ґратований рекурентний блок (GRU) [68] – це дві широко використовувані архітектури RNN, які можуть фіксувати довгострокові залежності в послідовних даних. Згорткові нейронні мережі (CNN) [69] та моделі на основі трансформаторів, такі як трансформатор часових рядів (TST) [48, 70], також використовуються для прогнозування часових рядів.

Найбільш розповсюдженими є моделі прогнозування часових рядів, що включають ANN, ARIMA, MA та ES, дерева регресії, k-найближчих сусідів

(KNN), SVM, нечіткі моделі та деякі гібридні моделі. Їхні ширші категорії показано на рис. 2.3.

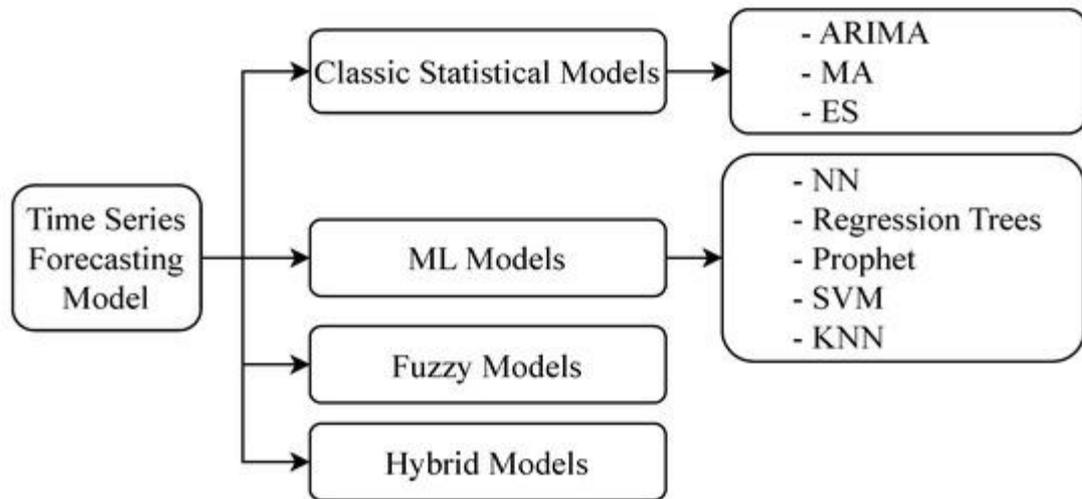


Рисунок 2.3 – Класифікація моделей прогнозування часових рядів

2.4. Алгоритми прогнозування часових рядів параметрів технічного стану складних енергетичних об'єктів

2.4.1 Авторегресивне інтегроване ковзне середнє

Модель ARIMA – це загальноприйнятий метод прогнозування часових рядів, особливо для одновимірних даних [32,43,62,71]. Моделі ARIMA спираються на комбінацію трьох компонентів: AR, диференціювання (I) та MA [61, 72]. Функція AR представляє залежність значення даних від їх попередніх спостережень (лагів), враховуючи часовий лаг та коефіцієнти. Компонент MA моделює складові похибки, враховуючи залежність від попередніх складових похибки та їх відповідних коефіцієнтів [34, 73, 74]. Нарешті, компонент I стосується диференціювання, застосованого до набору даних для забезпечення стаціонарності шляхом виключення трендів та сезонності. На рис. 2.4 представлено загальний потік ARIMA, включаючи вибірку автокореляцію (SAC) та вибірку часткову автокореляцію (SPAC). Моделі

ARIMA представлені позначенням $ARIMA.(p, d, q)$, де p – параметр порядку AR, d – ступінь диференціації для функції I, а q – порядок компонента MA [61, 62]. Відповідні значення для p , d та q зазвичай оцінюються за допомогою інформаційного критерію (AIC Akaike) або байєсівського інформаційного критерію (BIC) для вибору моделі [75,76, 77, 78].

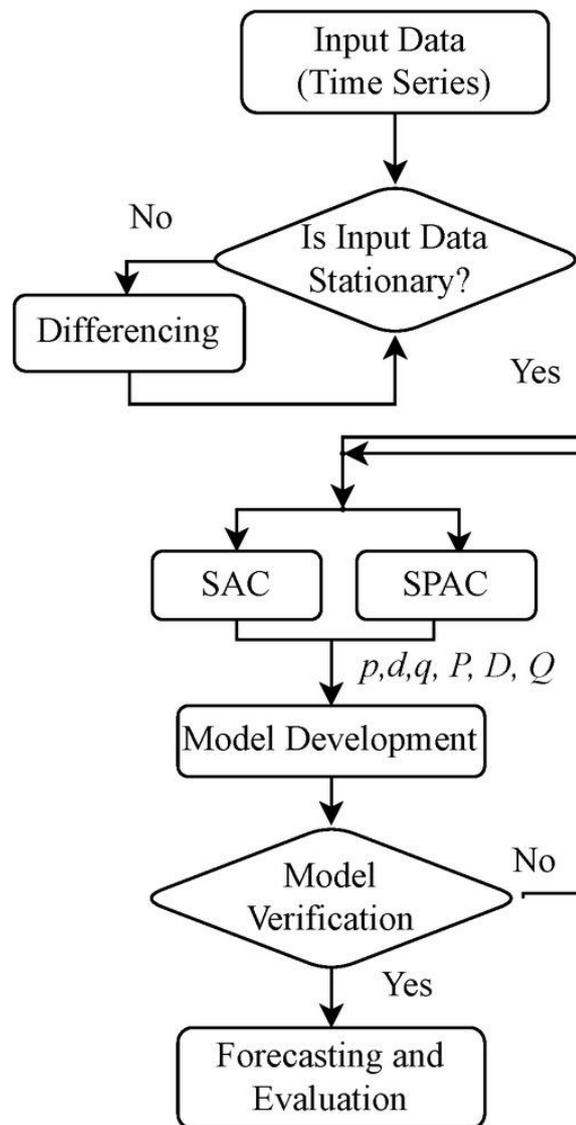


Рисунок 2.4 – Блок-схема для ARIMA

У вказаній моделі частина авторегресії використовує дані з попередніх кроків для прогнозування майбутніх кроків у часі за допомогою функції регресії. Інтегрована частина перетворює вхідні дані нестационарних часових рядів на стаціонарні дані за допомогою диференціювання. Цей процес

продовжується до отримання стабільних рядів даних. Ковзне середнє обчислює середнє значення у фіксованому часовому вікні [79].

1) AR-компонента (порядок p): ця компонента фіксує залежність між спостереженням та кількома спостереженнями із затримкою.

$$X_t = \beta + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \epsilon_t \quad (2.2)$$

де X_{t-} це затримка даних часового ряду, α — коефіцієнт затримки, який оцінюється моделлю, β є значенням перетину з віссю або константою, ϵ — член похибки, а p — порядок затримки.

2) I-компонента (порядок d): ця компонента стосується диференціювання часового ряду, щоб зробити його стаціонарним.

$$\nabla d X_t = X_t - X_{t-1} \quad (2.4)$$

3) Компонента ковзного середнього (порядок q): ця компонента застосовує модель ковзного середнього до спостережень із затримкою, використовуючи спостереження та його складову похибки ϵ .

$$X_t = \mu + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (2.5)$$

Об'єднуючи AR та MA, отримуємо

$$X_t = \beta + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (2.6)$$

У технічних застосуваннях моделі ARIMA використовувалися для прогнозування різних типів даних, таких, як попит, виробництво та рівень запасів, що забезпечувало цінну інформацію для відповідних секторів. В енергетичній галузі [34] використовувалися моделі ARIMA для прогнозування ціни на електроенергію, та продемонструвавши здатність моделі створювати точні прогнози. Аналогічно, Де Феліче та ін. [35] застосували моделі ARIMA для прогнозування короткострокових прогнозів погоди для прогнозування попиту в енергетичному секторі, досягнувши значного зменшення похибки

прогнозу порівняно з іншими прогнозами. У промисловості Торрес та ін. [36] використовували моделі ARIMA для прогнозування щомісячного виробництва ламінованих пластмас в Іспанії, отримавши похибку в 4,96% та перевершивши інші методи, такі як ES. Ван та ін. [37] застосували ARIMA для прогнозування щомісячного виробництва сталі в Китаї, досягнувши середньої абсолютної похибки (MAE) 0,0797 та середньоквадратичної похибки (RMSE) 0,1055, що підкреслює ефективність моделі у виявленні основних закономірностей у даних. У нафтогазовій промисловості Хуан та ін. [38] застосували моделі ARIMA для прогнозування цін на сир у нафту, досягнувши похибки 6,26% та продемонструвавши здатність моделі перевершувати інші методи, включаючи узагальнену авторегресивну умовну гетероскедастичність (GARCH) та ETS. Автори [39] застосували ARIMA для прогнозування споживання природного газу, отримавши похибку 4,17%, що вказує на перевагу моделі над традиційним методом найменших квадратів. У транспортному секторі Вільямс та ін. [40] використовували моделі ARIMA для прогнозування обсягів руху на автомагістралях, досягнувши покращення точності прогнозування на 6% порівняно з традиційною моделлю MA. Автори [41] застосували ARIMA для прогнозування короткострокового потоку руху, повідомивши про похибку 8,9% та продемонструвавши потенціал моделі для покращення управління дорожнім рухом та планування інфраструктури. Незважаючи на успіх моделей ARIMA в різних галузевих програмах прогнозування даних, певні обмеження, такі, як припущення про лінійність та необхідність стаціонарності даних, зберігаються [43, 62]. Щоб усунути ці обмеження та покращити ефективність прогнозування, дослідники досліджували гібридні моделі, що поєднують ARIMA з іншими методами, таким, як алгоритми машинного навчання або штучні нейронні мережі [42, 80].

2.4.2 Штучна нейронна мережа

Штучні нейронні мережі (ШНМ) створюються шляхом взаємозв'язку вузлів або нейронів, які обробляють інформацію на трьох рівнях: (1) вхідному, (2) прихованому та (3) вихідному. Кожне з'єднання між цими вузлами має відповідну вагу, яка налаштовується під час процесу навчання, щоб мінімізувати різницю між прогнозованими та фактичними вихідними даними [81]. ШНМ здобули популярність у багатьох дисциплінах, включаючи прогнозування часових рядів, завдяки своїй здатності моделювати складні нелінійні зв'язки без апріорних припущень щодо структури даних. Вони можуть фіксувати складні закономірності, тренди та сезонність у даних часових рядів, що робить їх придатними для різних завдань прогнозування.

Навчання штучної нейронної мережі (ШНМ) передбачає передачу їй попередніх даних часових рядів, що дозволяє мережі встановити основні закономірності. Після навчання ШНМ може передбачати майбутні значення. Алгоритм зворотного поширення помилки зазвичай використовується для навчання, коригуючи ваги в мережі для мінімізації помилки прогнозування [82]. В останні роки були впроваджені більш просунуті архітектури нейронних мереж, такі, як мережі LSTM та GRU, спеціально для обробки даних часових рядів. Ці архітектури можуть запам'ятовувати довгострокові залежності в даних, що робить їх особливо ефективними для завдань прогнозування [47].

2.4.3 Нейронні мережі прямого зв'язку

Мережа FFNN є одними з найпростіших типів штучних нейронних мереж. У мережі FFNN потік інформації є односпрямованим і поширюється лише в прямому напрямку. Інформація надходить від вхідних вузлів, проходячи через приховані шари та досягаючи вихідних вузлів. В архітектурі немає циклів або петель [58]. Базова архітектура FFNN показана на рис. 2.5.

Основною перевагою FFNN є їхня здатність апроксимувати будь-яку функцію за наявності достатньої кількості прихованих шарів і вузлів. Ця універсальна здатність апроксимації робить їх особливо придатними для моделювання нелінійних зв'язків, які часто спостерігаються в даних часових рядів [83].

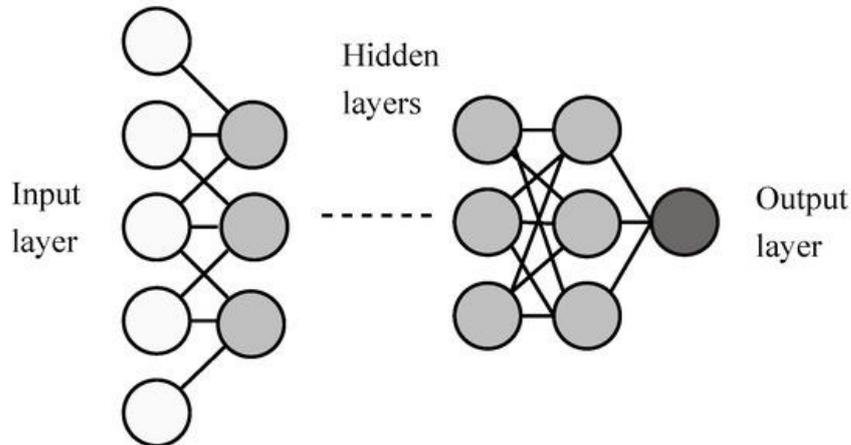


Рисунок 2.5 – Базова архітектура мережі FFNN

Мережу FFNN можна представити композицією кількох функцій, по одній для кожного шару [84]. Для простої FFNN з одним прихованим шаром рівняння можна представити так:

$$h = \sigma(W_1x + b_1) \quad (2.7)$$

$$y = \sigma(W_2h + b_2) \quad (2.8)$$

де x – вхідний вектор. W_1 і W_2 є ваговими матрицями для вхідного та прихованого шарів відповідно, b_1 і b_2 є векторами зміщення для вхідного та прихованого шарів відповідно, σ – це функція активації, яка налаштовується відповідно до застосування та середовища. Найбільш використовуваними функціями активації є логістична, сигмоподібна, ReLU (випрямлена лінійна одиниця), h – це вихід прихованого шару, а y – кінцевий вихід мережі. У прогнозуванні часових рядів, FFNN можна навчити прогнозувати тренди в даних, використовуючи попередні значення. Вхідний шар зазвичай складається з вузлів, що представляють попередні кроки в часі, тоді як вихідний шар представляє майбутні кроки в часі. Приховані шари фіксують

основні закономірності та взаємозв'язки в даних. Навчання включає коригування ваг мережі, щоб мінімізувати різницю між базовими та фактичними значеннями [58] [. Однак, хоча мережі типу FFNN можуть бути потужними, вони також мають свої проблеми. Вони можуть легко переналаштувати навчальні дані, якщо вони не будуть належним чином регуляризовані, а їхня природа “чорної скриньки” може ускладнити їх інтерпретацію. Незважаючи на ці проблеми, FFNN успішно застосовуються в різних завданнях прогнозування часових рядів [85].

2.4.4 Рекурентні нейронні мережі

Мережі типу RNN (рекурсивні нейронні мережі) – це підмножина нейронних мереж, призначених для ідентифікації закономірностей у даних, таких як часові ряди, зображення, аудіо або текстові дані. На відміну від традиційних нейронних мереж прямого зв'язку, RNN мають з'єднання, які зациклюються на самих собі, що дозволяє зберігати інформацію [63]. Різні архітектури RNN показано на рис. 2.6. Ці різні архітектури включають: конфігурацію “сингулярний вхід – сингулярний вихід”, конфігурацію “один до багатьох”, конфігурацію множинних входів – одиничних виходів, конфігурацію з кількома входами та кількома виходами.

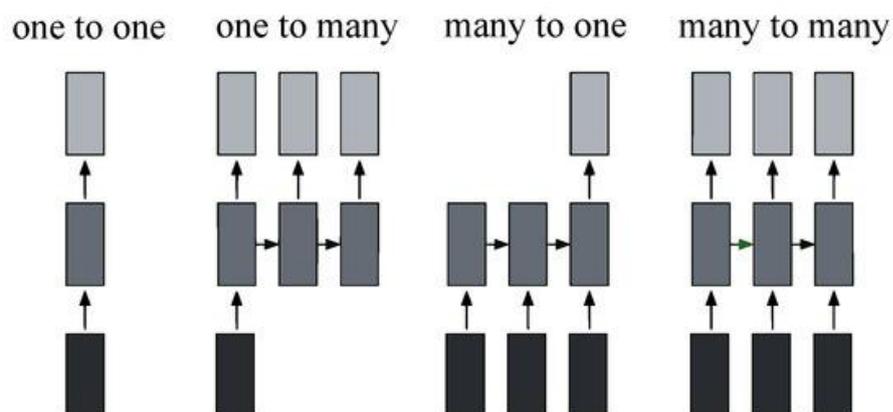


Рисунок 2.6 – Різні архітектури мережі RNN для прогнозування часових рядів

Конфігурація “сингулярний вхід – сингулярний вихід” (один до одного): ця конфігурація являє собою класичну структуру нейронної мережі з прямою зв'язком, що характеризується одиничним входом та очікуванням одного виходу.

Конфігурація “один до багатьох” має вхід – кілька виходів (один до багатьох): Одне зображення слугує вхідними даними фіксованого розміру, тоді як вихідні дані містять слова або речення різної довжини, що робить їх адаптивними до різноманітних текстових описів.

Конфігурація множинних входів – одиничних виходів (багато до одного): ця конфігурація знаходить своє застосування в завданнях класифікації. Вхідними даними, наприклад, очікується послідовність слів або навіть абзаців, тоді як вихідними даними є безперервні значення, що відображають ймовірність позитивного результату.

Конфігурація з кількома входами та кількома виходами (багато-до-багатьох): Ця універсальна модель підходить для таких завдань, як машинний переклад, зокрема, Google Translate. Мережа добре підходить для обробки вхідних даних різної довжини, таких, як англійські речення, та створення відповідних речень різними мовами. Крім того, вона застосовна до класифікації відео на рівні кадру, що вимагає від нейронної мережі обробки кожного кадру окремо. Через взаємозалежність між кадрами, рекурентні нейронні мережі стають важливими для поширення прихованих станів від одного кадру до наступного в цій конкретній конфігурації.

Математично, прихований стан ht простої мережі типу РНН у момент часу t визначається як:

$$ht = \sigma(W_h h_{t-1} + W_x x_t + b_h) \quad (2.9)$$

де x_t представляє вхідні дані в час t . h_{t-1} позначає прихований стан у час $(t - 1)$. W_h і W_x є ваговими матрицями. b_h є членом зміщення і може бути константою. σ – функція активації. Вихід u_t у момент часу t тоді виражається так:

$$y_t = Wh y_{ht} + by \quad (2.10)$$

Мережі RNN особливо підходять для прогнозування, оскільки вони розроблені для запам'ятовування попередніх вхідних даних у їх прихованому стані, що дозволяє їм фіксувати часові залежності [87]. Однак традиційні RNN можуть зіткнутися з проблемами довгострокових залежностей через такі проблеми, як зникнення даних та значні градієнти. Для вирішення цих проблем були введені такі варіанти, як мережі LSTM та GRU [47].

Висновки до розділу 2

У розділі проаналізовано сучасні проблеми прогнозу технічного стану складних технічних та енергетичних об'єктів, зокрема, СЕЕС та їх важливої складової, а саме, дизель-генераторних установок Основними висновками є наступні:

1. Прогнозування часових рядів має вирішальне значення для ефективної роботи складних енергетичних об'єктів та процесів прийняття рішень щодо їх технічного стану. Вірогідне прогнозування майбутніх тенденцій є важливим для оптимізації ресурсів, планування експлуатації та загальної ефективності енергетичної системи судна..

2. Відомі фундаментальні принципи моделей прогнозування, зокрема традиційні статистичні методи, які широко використовуються завдяки швидкодії та алгоритмічним перевагам, але мають місце певні обмеження їх застосування для складних багатовимірних процесів із складними взаємозв'язком даних, що характерно для СЕЕС.

3. Для вирішення складних завдань прогнозування є перспективними методи машинного навчання, включаючи метод опорних векторів та штучну нейронну мережу. Такі моделі пропонують більші можливості та мають переваги перед статистичними методами, але їх не замінюють.

4. Перспективними є гібридні моделі, які поєднують сильні сторони різних методів для досягнення покращеної ефективності прогнозування, а також генеративні моделі для прогнозування часових рядів. Слід мати на увазі важливість вибору відповідної статистичної моделі породження даних на основі конкретних вимог щодо експлуатації СЕЕС, можливостей отримання вихідних даних та мети прогнозування

5. Суднові системи, зокрема СЕЕС, за своєю суттю генерують дані часових рядів, які являють собою виміри значень важливих параметрів, отриманих через деякі інтервали часу, включаючи динамічні та часові зміни у процесах зміни стану СЕЕС. Значення даних часових рядів у прогнозуванні є

надзвичайно важливим і це дозволяє оптимізувати ресурси, підвищувати операційну ефективність та впроваджувати стратегії прогнозного обслуговування

6. Прогнозне обслуговування шляхом прогнозування потенційних збоїв та неномінальних відхилень може не тільки забезпечити безперебійне функціонування, але й продовжити термін служби обладнання, що призводить до значної економії коштів. Прогнозування допомагає зменшити витрати, покращити матеріальні та енергетичні потоки та забезпечити своєчасну реакцію, тим самим підвищуючи загальну ефективність СЕЕС.

3 МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ ВЗАЄМОЗВ'ЯЗКІВ ПАРАМЕТРІВ ТЕХНІЧНОГО СТАНУ СУДНОВИХ ДИЗЕЛЬ-ГЕНЕРАТОРНИХ УСТАНОВОК

Розділ присвячений розробці, з використанням сучасних інформаційних технологій, статистичних моделей, які відображають взаємозв'язок діагностичних параметрів технічного стану дизель-генераторних установок. Встановлені найбільш значимі зв'язки між параметрами реєстрації технічного стану ДГУ. Розроблені нелінійні регресійні моделі, як традиційні поліноміальні, так і нейромережеві, взаємозв'язку температури вихідних газів циліндрів дизельного двигуна від його навантаження та виконана її перевірка на адекватність. Встановлена та підтверджена можливість прогнозування технічного стану ДГУ за обраними параметрами на основі побудови нейромережі регресії.

3.1 Програмне середовище для створення статистичних моделей взаємопов'язаних діагностичних параметрів ДГУ, оцінки та прогнозу технічного стану

При виконанні дослідження для побудови комп'ютерних моделей оцінки та прогнозу стану ДГУ використовуються сучасні програмні засоби, у тому числі, для вирішення завдань математичного обчислювання та моделювання застосовується програмне середовище MATLAB. Вказаний пакет прикладних програм надає користувачеві велику кількість можливостей для аналізу даних, які покривають більшість областей прикладної математики та прикладних застосувань, а саме:

- Матриці та лінійна алгебра — алгебра матриць, лінійні рівняння, власні значення і вектори, сингулярності, факторизація матриць та інше.

- Многочлени та інтерполяція — корені многочленів, операції над многочленами та їх диференціювання, інтерполяція та екстраполяція кривих...
- Математична статистика та аналіз даних — статистичні функції, статистична регресія, цифрова фільтрація, швидке перетворення Фур'є та інші.
- Обробка даних — набір спеціальних функцій, включаючи побудову графіків, оптимізацію, пошук нулів, чисельне інтегрування та інше.
- Диференційні рівняння — вирішення диференційних і диференційно-алгебраїчних рівнянь, диференційних рівнянь із запізнюванням, рівнянь з обмеженнями, рівнянь в часткових похідних та інше.
- Розріджені матриці — спеціальний клас даних пакету MATLAB, що використовується у спеціалізованих додатках.
- Цілочисельна арифметика — виконання операцій цілочисельної арифметики в середовищі MATLAB.

Статистична обробка експериментальних даних була виконана за допомогою програмного пакету Statistic Toolbox (пакет для статистичних розрахунків) середовища MATLAB), що представляє з себе набір програм, що дозволяють виконувати різноманітні статистичні розрахунки. Вказаний інструмент орієнтований на досить широкий спектр задач: від генерації випадкових чисел і підбора кривих під експериментальні дані до планування експериментів і задач промислово-статистичного контролю. Інструментальні засоби пакету дозволяють використовувати, як його систему команд в режимі командної строки, так і набір графічних інтерактивних програм (графічний інтерфейс користувача). Найголовнішою перевагою пакету Statistic Toolbox є досить великий набір його функцій (приблизно 200) і, головне – можливість (з використанням інших засобів MATLAB) організувати моделювання стохастичних об'єктів та процесів, в тому числі тих, характеристики яких змінюються у часі.

3.2 Програмне середовище для створення статистичних моделей взаємопов'язаних діагностичних параметрів ДГУ, оцінки та прогнозу технічного стану на основі нейронних мереж

Побудова нейронних мереж є окремим завданням програмного середовища, для якого застосовується відповідний пакет (Toolbox).

В процесі дослідження використана радіально-базисна нейронна мережа прямого розповсюдження.

Радіальна базисна нейронна мережа (РБНС) складається із двох шарів: схованого радіального базисного шару з S^1 нейронів і вихідного лінійного шару з S^2 нейронів. Елементи першого шару РБНС обчислюють відстані між вхідним вектором і векторами ваг першого шару, сформованих з рядків матриці $W^{2,1}$. Вектор порогів B і відстані поелементно множаться. Вихід першого шару можна виразити формулою

$$A^1 = radbas(\|W - X\| \cdot B),$$

де A^1 – вихід першого шару; функція *radbas* – радіально-базисна функція; W – матриця ваг першого шару мережі; X – вхідний вектор; B – вектор порогів першого шару.

Відповідно до формули побудови радіальні базисні нейрони з вектором ваг, близьким до X , згенерують значення, близькі до 1. Якщо нейрон має вихід 1, то це значення вагами другого шару буде передано на його лінійні нейрони. Фактично радіальний базисний нейрон з виходом 1 перетворює виходи всіх інших нейронів у нулі. Проте, типовим є випадок, коли кілька нейронів дають на виходах значимий результат, хоча й з різним ступенем.

Радіальні базисні мережі навчаються в три етапи. Опишемо етапи навчання.

Перший етап - виділення центрів (ваг). Центри, представлені в РБН-Шарі, оптимізуються першими за допомогою навчання без учителя. Центри можуть бути виділені різними алгоритмами, зокрема навчанням Кохонена.

Алгоритми повинні розмістити центри, відбиваючи кластеризацію вихідних даних.

Другий етап - призначення відхилень. Відхилення можуть бути призначені різними алгоритмами, наприклад алгоритмом «найближчого сусіда».

Третій етап - лінійна оптимізація. Можна використовувати методи навчання по дельта-правилу, та зворотному поширенню помилки.

Нейронні мережі регресії (НМР, які використані в поточному дослідженні) мають такий же, як і РБНМ, перший шар, але другий шар будується спеціальним образом. Для апроксимації функцій часто використовуються узагальнені мережі регресії (generalized regression neuron networks). Другий шар, як і у випадку РБНМ, виконує заелементний добуток рядка $W_{1,2}$ і вектори виходу першого шару a^1 . Він має стільки нейронів, скільки існує цільових пар <вхідний вектор/цільовий вектор>. Матриця ваг W – це набір цільових строк. Цільове значення – це значення апроксимуємої функції в навчальній вибірці. Припустимо, є один вхідний вектор x_i , що згенерує на виході першого шару вихід, близький до 1. У результаті вихід другого шару буде близький до t_i одному зі значень апроксимуємої функції, використаної при формуванні другого шару.

Функція *newrb* створює радіальну базисну мережу й має наступний синтаксис:

$$net = newrb(P, T, goal, spread).$$

Радіальні базисні мережі використовують для апроксимації функцій. Функція *newrb* конструює схований (перший) шар з радіальних базисних нейронів і використовує значення середньої квадратичної помилки (*goal*). Функція *newrb(P, T, goal, spread)* має наступні аргументи: P – матриця Q вхідних векторів розмірності R на Q ; T – матриця Q векторів цільових класів S на Q ; *goal*–середня квадратична помилка, за замовчуванням 0,0; *spread*– розкид

радіальної базисної функції, за замовчуванням 1,0. Функція створює й повертає як об'єкт радіальну базисну мережу. Велике значення розкиду приводить до більшої гладкості апроксимації. Занадто великий розкид вимагає багато нейронів, для того щоб забезпечити швидкодію, для змінної функції, занадто малий – для досягнення гладкості апроксимації. Підібрати значення розкиду можна за допомогою багаторазових викликів функції *newrb*. Радіально базисна мережа створюється в середовищі MATLAB наступним чином:

$$net = newrb(P, T, spread).$$

Функція *newrb* проектує радіальну базисну мережу з нульовою помилкою для заданих векторів. Функція *newrb(P, T, spread)* має три параметри: *P*-Матриця Q вхідних векторів розмірності R на Q ; *T*-матриця Q цільових векторів – описувачів класу розмірності S на Q ; *spread*-розкид радіальної базисної функції, за замовчуванням 1,0. Функція створює радіальну базисну мережу.

Функція *newgrnn* проектує НМ регресії – це вид радіальної базисної мережі, що часто використовується для апроксимації функцій і будує мережу для апроксимації:

$$net = newgrnn(P, T, spread).$$

Функція *newgrnn(P, T, spread)* має наступні входи: *P*- P - матриця Q вхідних векторів розмірності R на Q ; *T*-матриця Q цільових векторів класів розмірності S на Q ; *spread* – розкид радіальних базисних функцій, за замовчуванням 1,0. Функція повертає НМ регресії. Чим більше розкид, тим більше гладкою буде функція апроксимації. Для того щоб настроїти функцію апроксимації на вихідні дані, використовують розкид менший, чим типова відстань між вхідними векторами.

Функція *newgrnn* будує двошарову мережу. Перший шар містить радіальні базисні нейрони, що обчислюють відстань між входами й вагами за допомогою *netprod*. Другий шар має нейрони з функцією активації *purelin*. Тільки в першого шару існує *bias*.

Функція *newpnn* створює імовірнісну НМ, проєктовану за допомогою функції

$$net = newpnn(P, T, spread).$$

Імовірнісна НМ – це вид радіальної базисної мережі, як і НМ регресії, але дані мережі використовуються для рішення завдання класифікації, а не апроксимації. Функція $net = newpnn(P, T, spread)$ має такі ж параметри, як і вищеописана функція *newgrnn*. Якщо розкид близький до нуля, імовірнісна НМ діє як класифікатор на основі принципу вибору «найближчого сусіда», у протилежному випадку мережа візьме до уваги кілька близьких векторів.

3.3 Відбір параметрів та обґрунтування параметрів для створення статистичних моделей взаємопов'язаних діагностичних параметрів

Підготовчим етапом створення статистичних моделей в рамках запропонованого підходу стало накопичення даних (діагностичних параметрів) технічного стану дизель-генераторних агрегатів, які входять до складу досліджуємої СЕЕС. Для цього використана електронна форма для щоденного фіксування 30 параметрів, що характеризують роботу кожної з ДГУ. Таким чином був отриманий масив даних, що складається з 30 векторів параметрів даних. Для моделювання були обрані параметри робочих процесів ДГУ № 1, так як кількість його робочих годин є найбільшою, а вибірка найбільш показовою. Загальна кількість вимірювань, кожного параметра ДГУ № 1 становить 101.

Для виконання функції контролю встановленими на судні системами моніторингу в режимі реального часу фіксується велика кількість електричних та механічних параметрів суднової електроенергетичної системи. Зокрема це: температура вихідних газів циліндрів, вхідна температура повітря у турбонагнітач, вихідна температура теплового контуру прісної води охолодження, вихідна температура змащувального масла, вхідний тиск змащувального масла, вихідна температура палива та температура морської води. Електричні параметри вимірюються та визначаються окремо для кожного дизельного-генератора. Суднова система автоматизації забезпечує вимірювання наступних параметрів для кожної із трьох фаз:

- напруга [В];
 - поточне значення сили струму [А];
 - частота [Гц];
 - активна (реальна) потужність [кВт];
 - активна (реальна) потужність, у відношенні до номіналу [%];
 - реактивна потужність [кВар];
 - повна потужність [кВА];
 - коефіцієнт потужності [-];
 - вироблена енергія [кВт / рік] ;
- час роботи (загальний, не перезавантажуваний) [ч]

Для вирішення завдання аналізу (і прогнозу) технічного стану ДГУ доцільно вибрати лише найбільш інформативні параметри. Велика кількість параметрів призводить з одного боку до більш деталізованої моделі, а з іншого боку – до збільшення ознакового простору технічного стану ДГУ та до ускладнення розрахунків за обраною моделлю. Таким чином, першим завданням став відбір числа діагностичних параметрів, необхідного і достатнього для технічного діагностування ДГУ. Вибір діагностичних параметрів був здійснений за критерієм інформативності.

Слід мати до уваги, що основною причиною зміни технічного стану ДГУ є зміна навантаження. Тому саме така залежність має визначне значення для

встановлення відповідності технічного стану ДГУ вимогам щодо експлуатації та можливостей прогнозування зміни такого технічного стану.

Обрання параметрів технічного стану ДГУ із сукупності даних реєстрації дає змогу встановити шукану залежність. Таким статистично обґрунтованим критерієм є значення коефіцієнту взаємкореляції сукупності параметрів реєстрації технічного стану ДГУ відносно параметру навантаження.

На Рис. 3.1 представлено значення коефіцієнтів взаємкореляції параметрів ДГУ в залежності від навантаження.

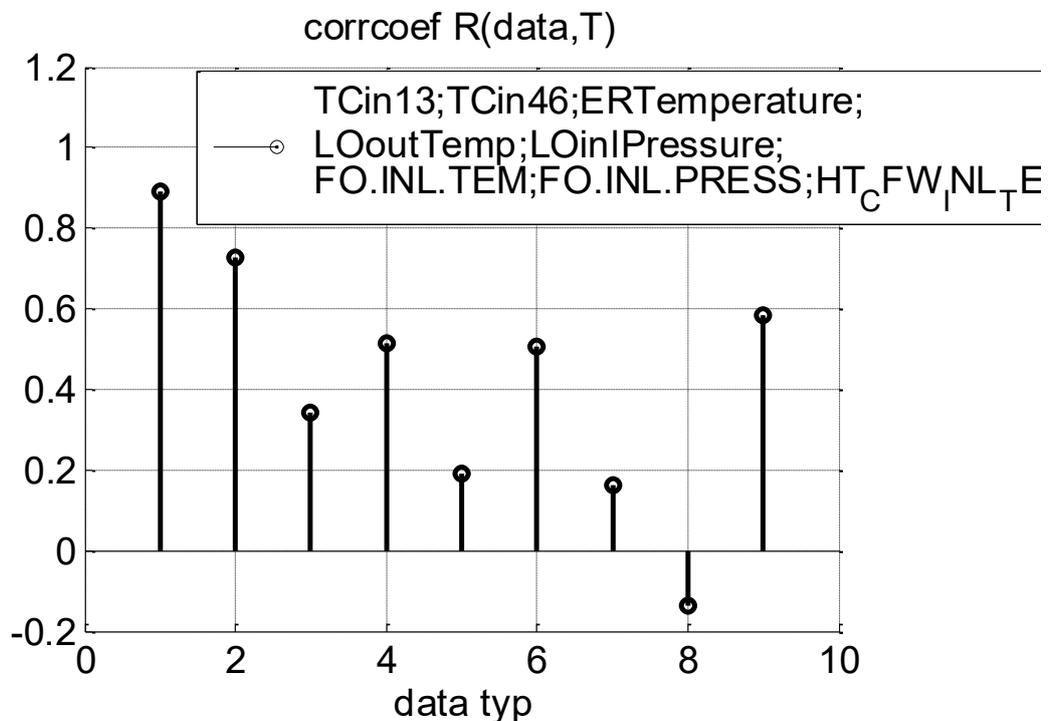


Рисунок 3.1 – Вихідні дані для статистичного аналізу

У якості основного діагностичного параметра, згідно статистичного аналізу, обрана температура вихідних газів. Температура вихідних газів є опосередкованим показником теплонапруженості та розподілення навантаження між циліндрами дизельного двигуна. Пониження температури вихідних газів одразу після циліндрів може свідчити про довільне виключення

циліндрів, що пов'язане з зависанням плунжера паливного насосу високого тиску (ПНВТ). Занадто висока або нерівномірна температура вихідних газів може свідчити про порушення процесів згорання. Наприклад, висока температура вихідних газів в одному із циліндрів може бути викликана перенавантаженням циліндра (велика подача палива), поганим розпилюванням палива, пізньою подачею палива, низькою компресією в циліндрі; забрудненням продувних і випускних вікон.

Підвищення температури випускних газів всіх циліндрів (можливо темне забарвлення випускних газів) може свідчити про такі несправності як: перенавантаження ДГУ, викликане погіршенням зовнішніх умов або надмірною подачею палива; низьким тиском продувного повітря; підвищенням температури після турбонагнітачу; займанням маслянистих відкладень в підпоршневій ємності або продувному ресивері.

Для візуалізації даних експерименту були побудовані графіки відібраних для дослідження параметрів (температура вихідних газів циліндрів № 1– № 5 (рис. 3.2, рис. 3.3), сила струму навантаження (рис. 3.4). Коефіцієнти взаємкореляції температури газів та струму по циліндрам ДГУ наведені на рис. 3.5, що підтверджує вихідну гіпотезу. Регресійні моделі температури газів та струму ДГУ представлені на рис. 3.6. Прогноз температури газів ДГУ за циліндрами ілюструють діаграми рис. 3.7 – рис. 3.11.

Межі допуску температури газів ДГУ (за методикою Kongsberg) наведено на рис. 3.12, рис. 3.13.

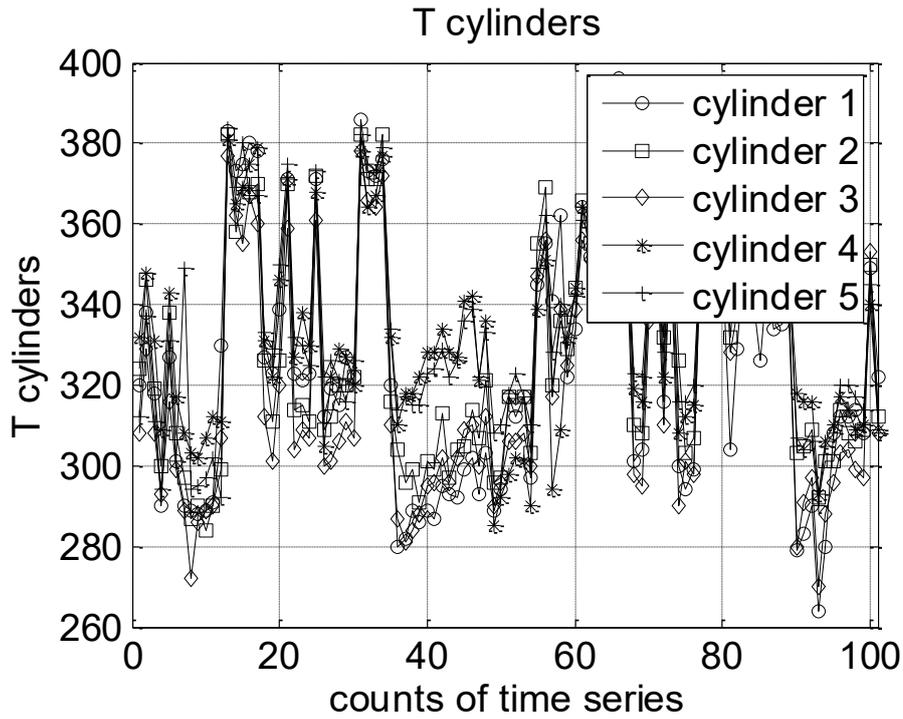


Рисунок 3.2 – Часовий ряд температур вихідних газів по циліндрам
№ 1 – № 5 ДГУ № 1

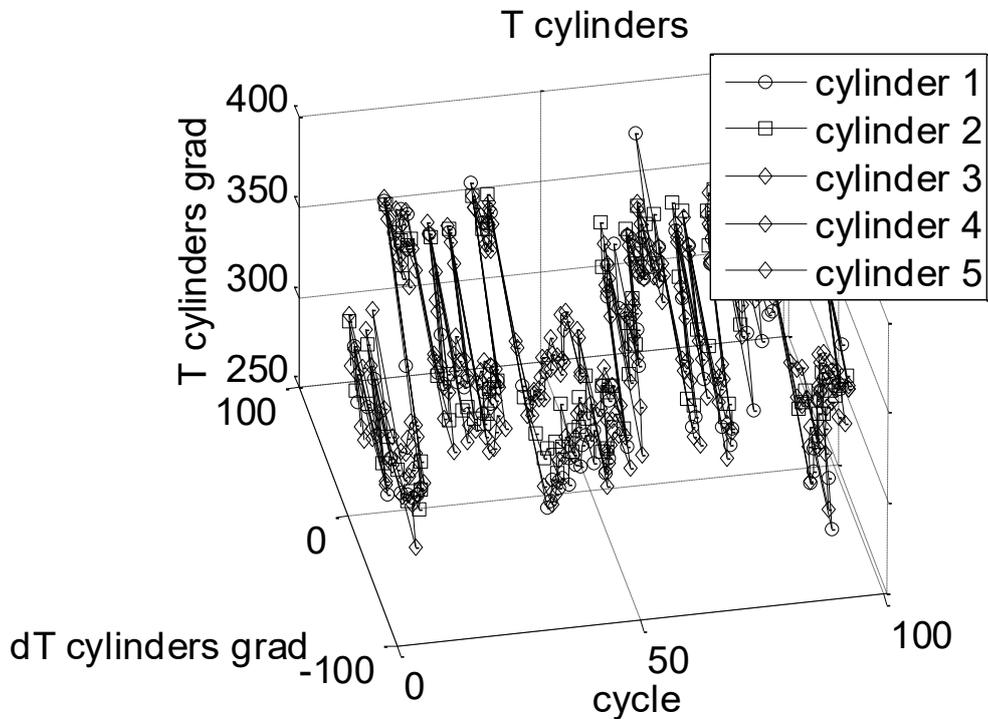


Рисунок 3.3 – Часовий ряд температур вихідних газів по циліндрам
№ 1 – № 5 ДГУ № 1

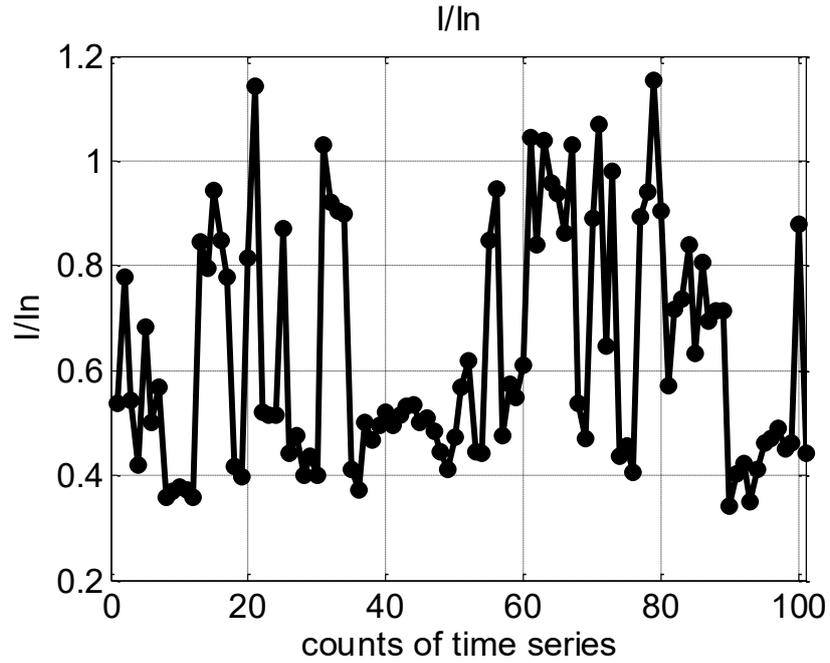


Рисунок. 3.4 – Часовий ряд сили струму
(характеризує навантаження на ДГУ № 1)

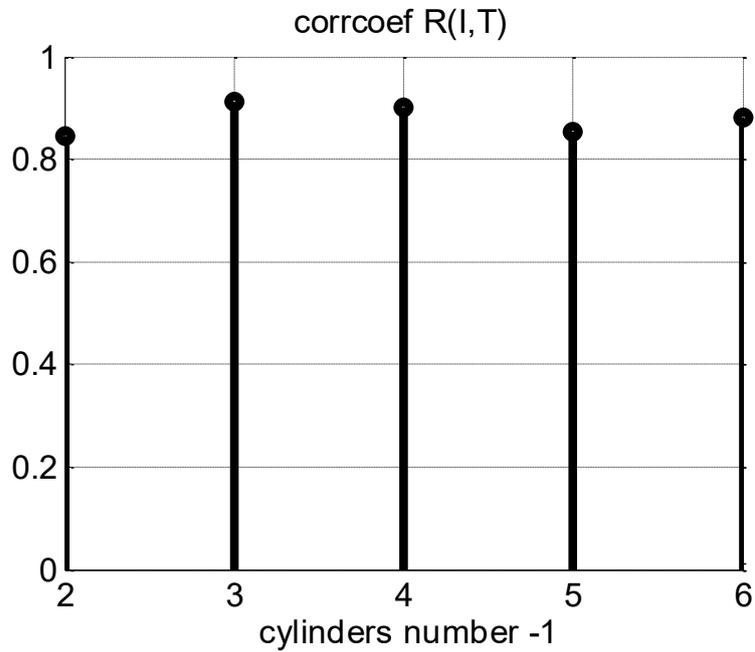


Рисунок. 3.5 – Коефіцієнти взаємкореляції температури газів та струму по
циліндрам ДГУ

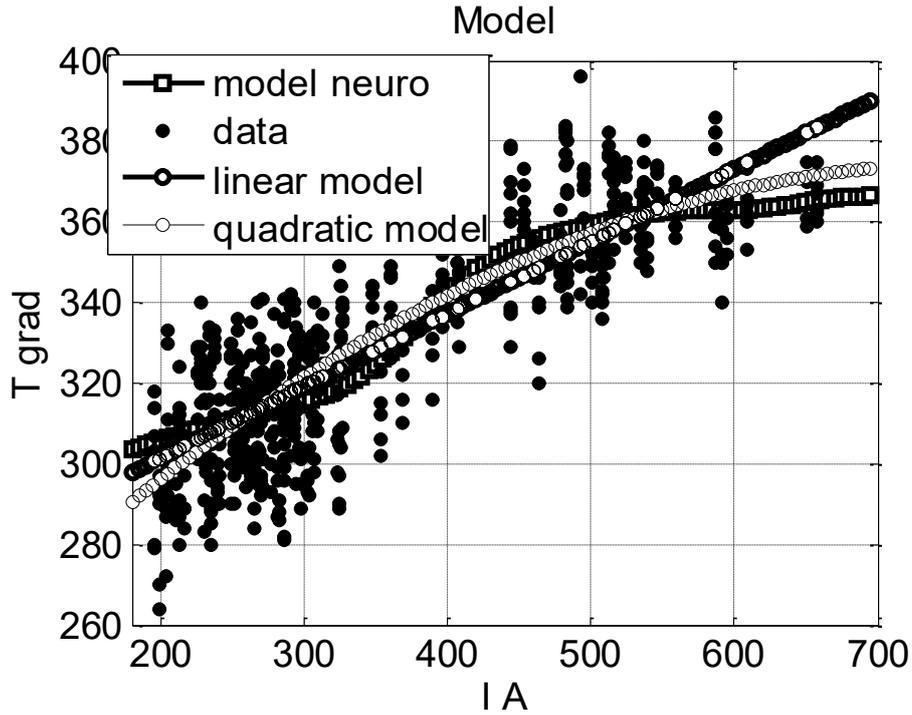


Рисунок. 3.6 – Регресійні моделі температури газів та струму ДГУ

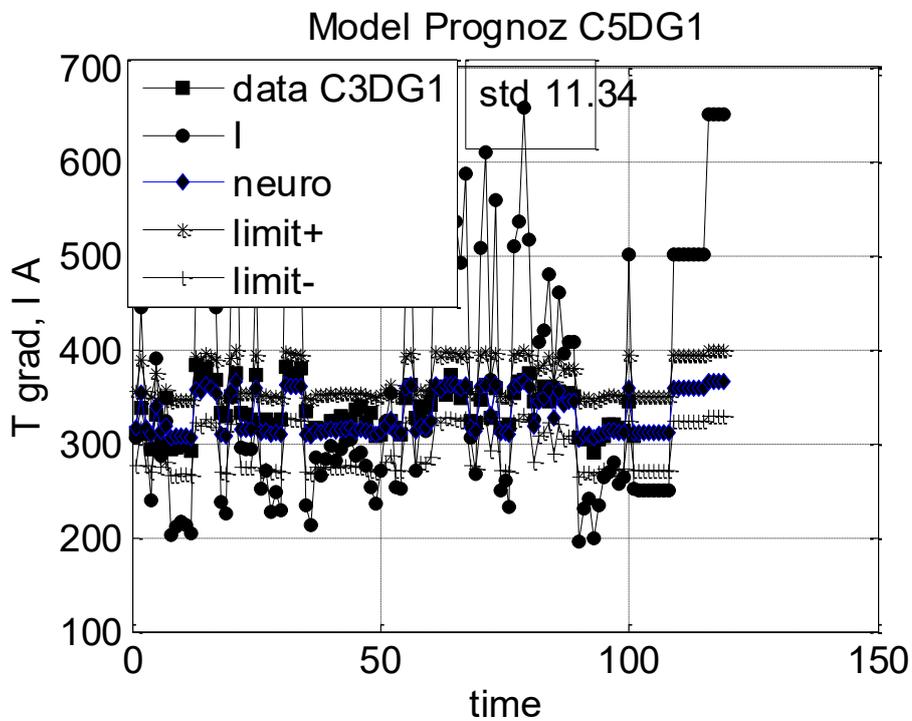


Рисунок. 3.7 – Прогноз температури газів ДГУ за циліндром 5

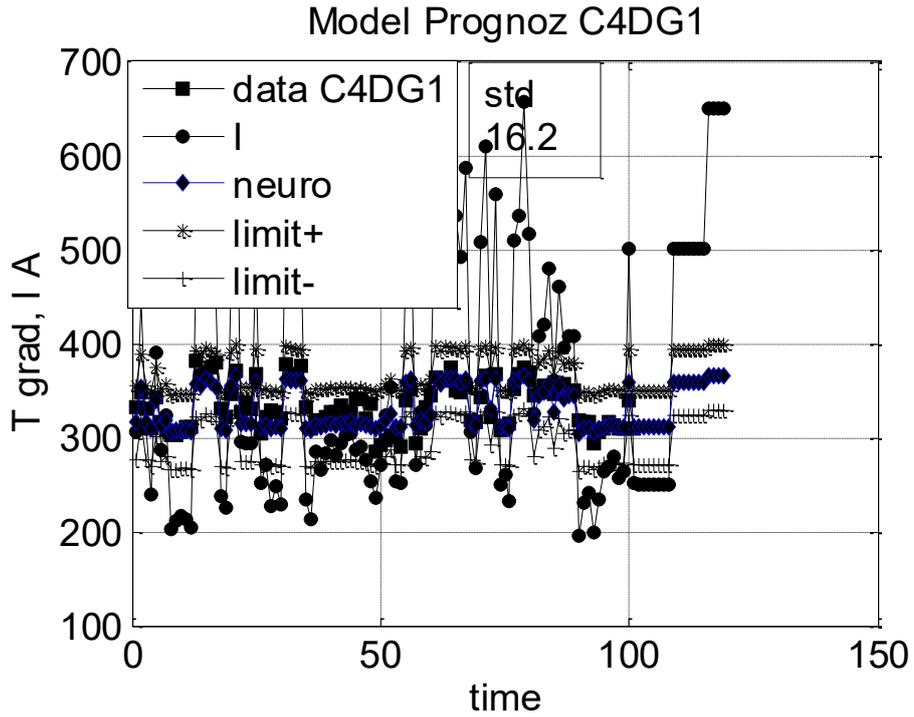


Рисунок. 3.8 – Прогноз температури газів ДГУ за циліндром 4

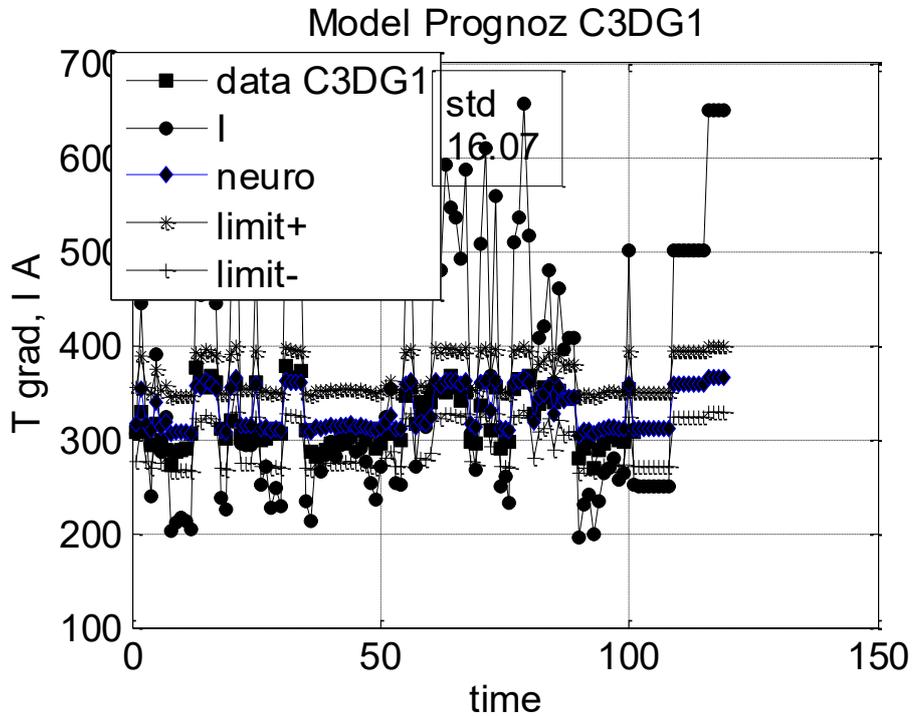


Рисунок. 3.9 – Прогноз температури газів ДГУ за циліндром 3

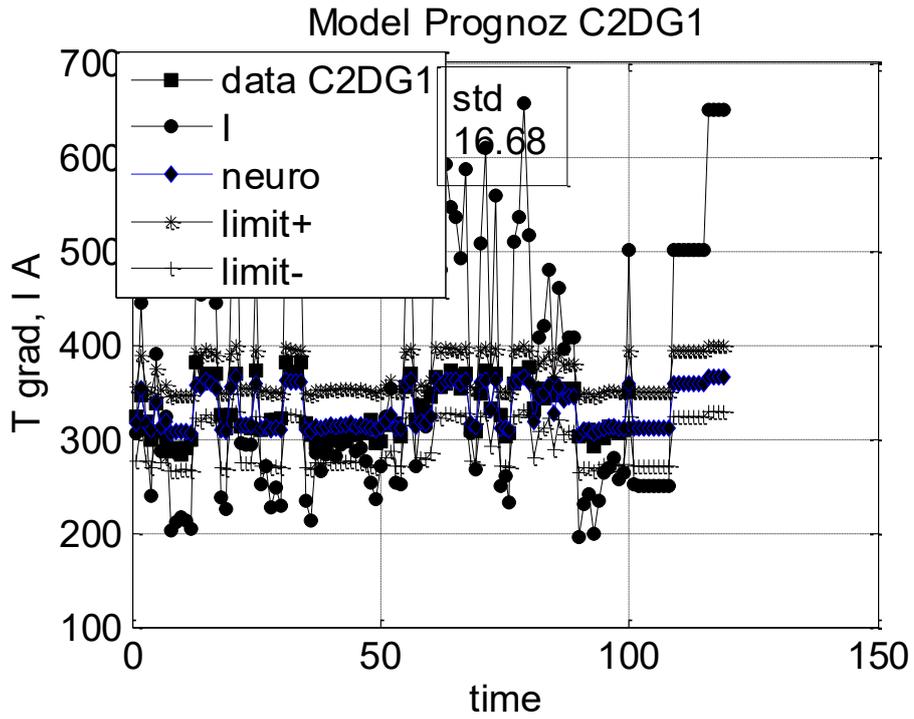


Рисунок. 3.10 – Прогноз температури газів ДГУ за циліндром 2

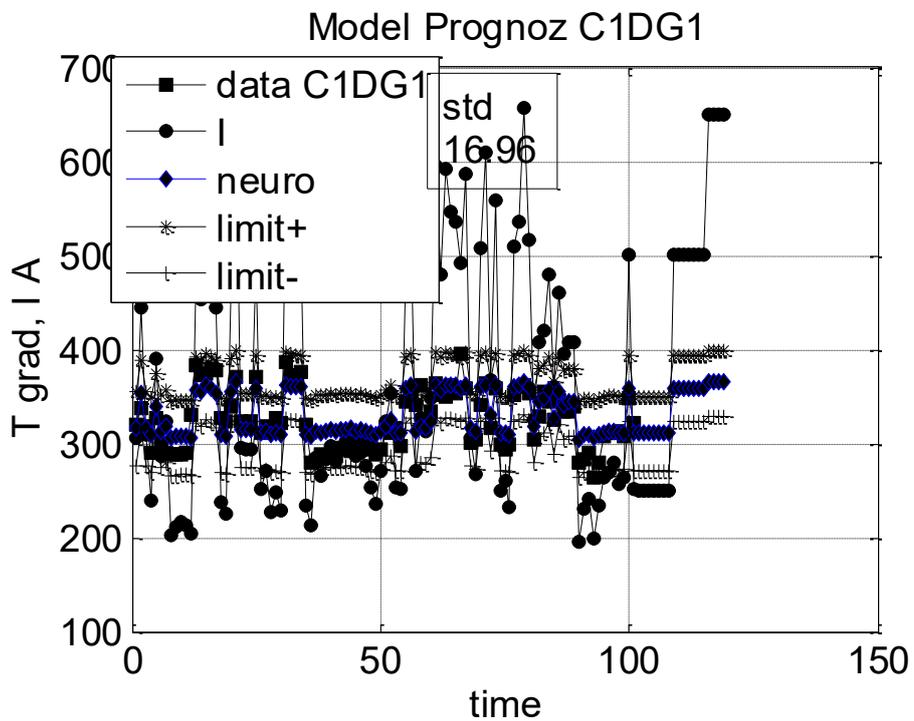


Рисунок. 3.11 – Прогноз температури газів ДГУ за циліндром 1

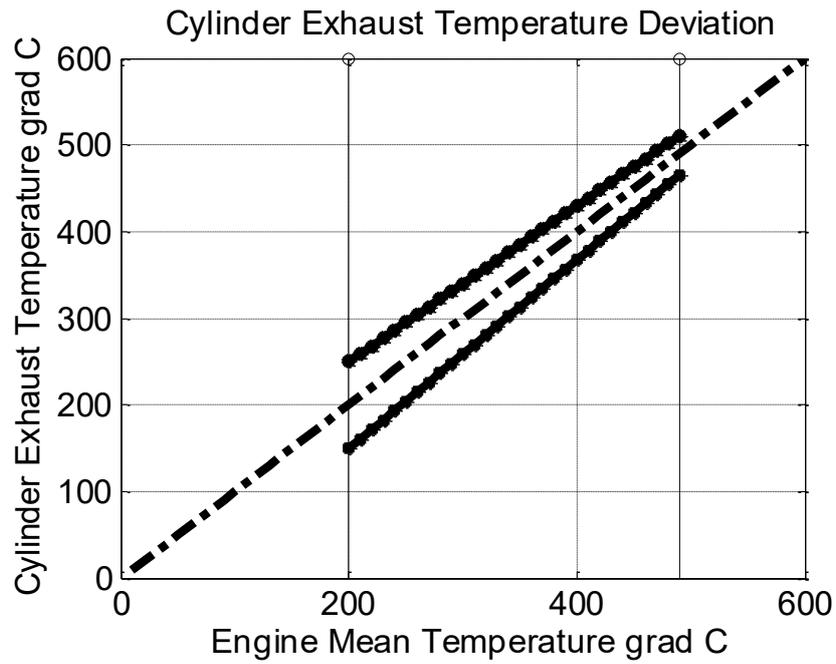


Рисунок. 3.12 – Допуск температури газів ДГУ за методикою Kongsberg

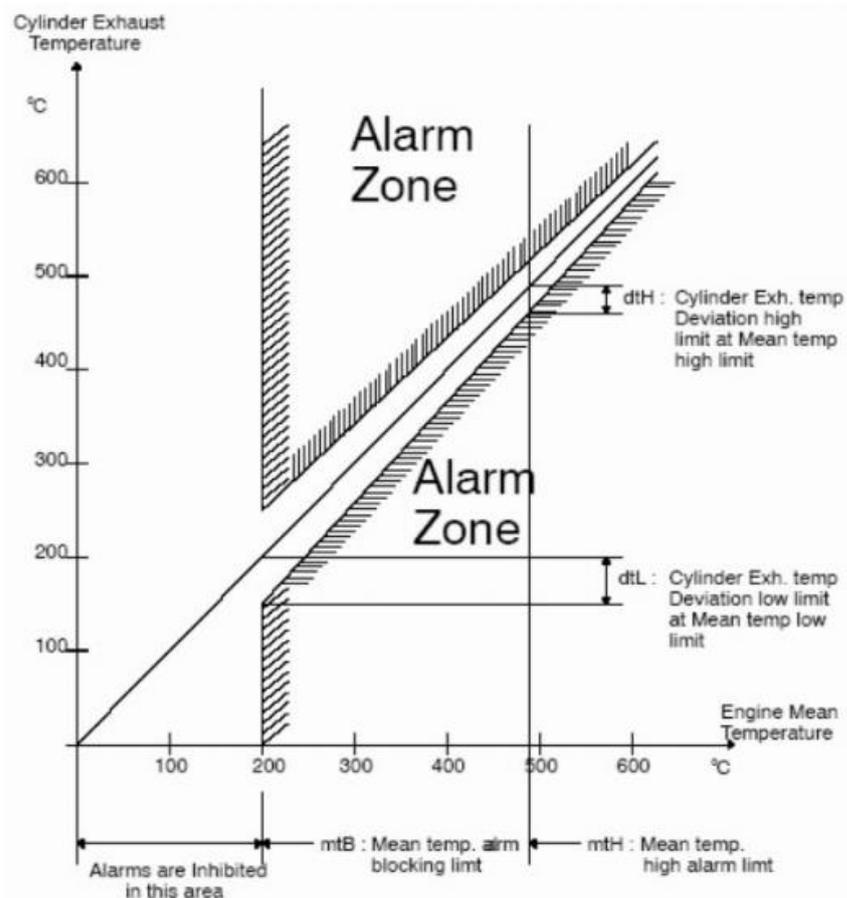


Рисунок. 3.13 – Допуск температури газів ДГУ за методикою Kongsberg

Таким чином, результати статистичної обробки вихідних даних та прогнозу зміни стану ДГУ за обраним параметром надають наступні дані щодо середньоквадратичної похибки (STD):

Циліндр 1: 11,34 grad

Циліндр 2: 16,02 grad

Циліндр 3: 16,07 grad

Циліндр 4: 16,68 grad

Циліндр 5: 16,96 grad

Середньоквадратичні значення похибки за відомими класичними регресійними моделями становлять більш ніж 20 grad, що, власне, свідчить про переваги нейромережевої моделі.

3.4 Статистичне моделювання процесів оцінки та зміни стану температурного режиму ДГУ

Для статистичного обґрунтування результатів оцінки та прогнозу технічного стану ДГУ на протязі довготривалої експлуатації виконано статистичне моделювання таких процесів методами прикладної статистики, зокрема, методом Монте-Карло.

Схема такого моделювання із застосуванням додатку Simulink наведена на рисунку 3.14, а результати його застосування на рисунках 3.15 та 3.16.

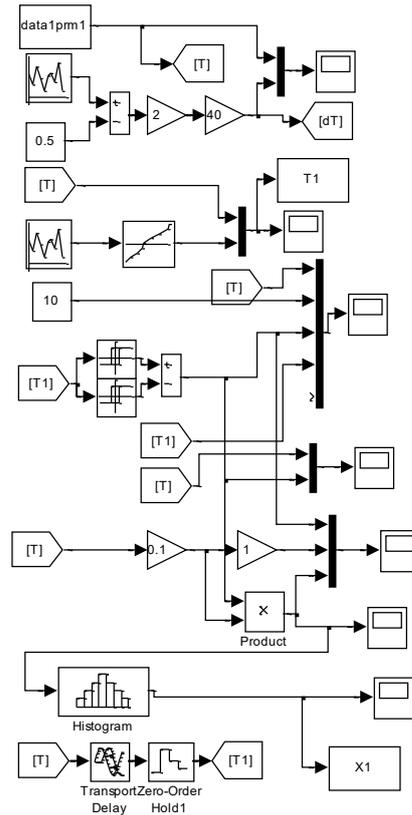


Рисунок. 3.14 – Модель статистичне моделювання процесів оцінки та зміни стану температурного режиму ДГУ

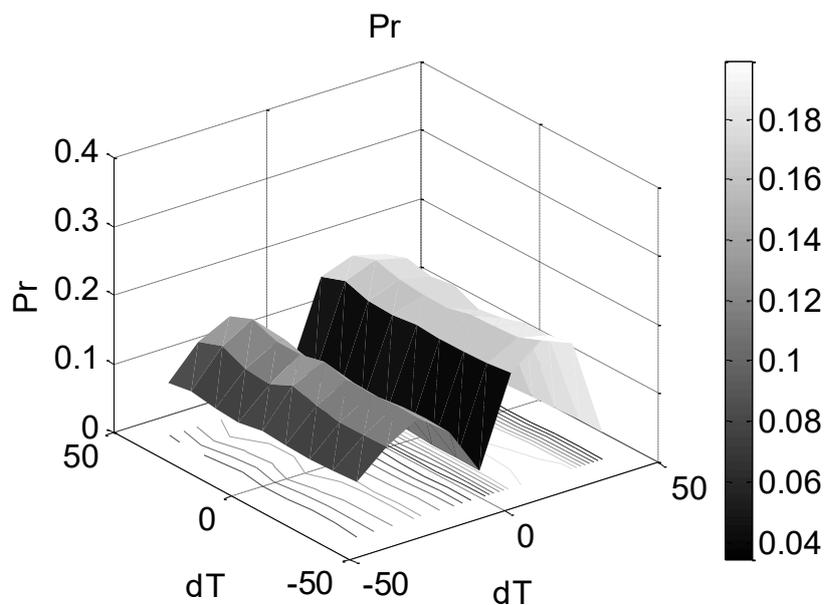


Рисунок. 3.15 – Результати статистичне моделювання процесів оцінки та зміни стану температурного режиму ДГУ за вірогідністю відхилень

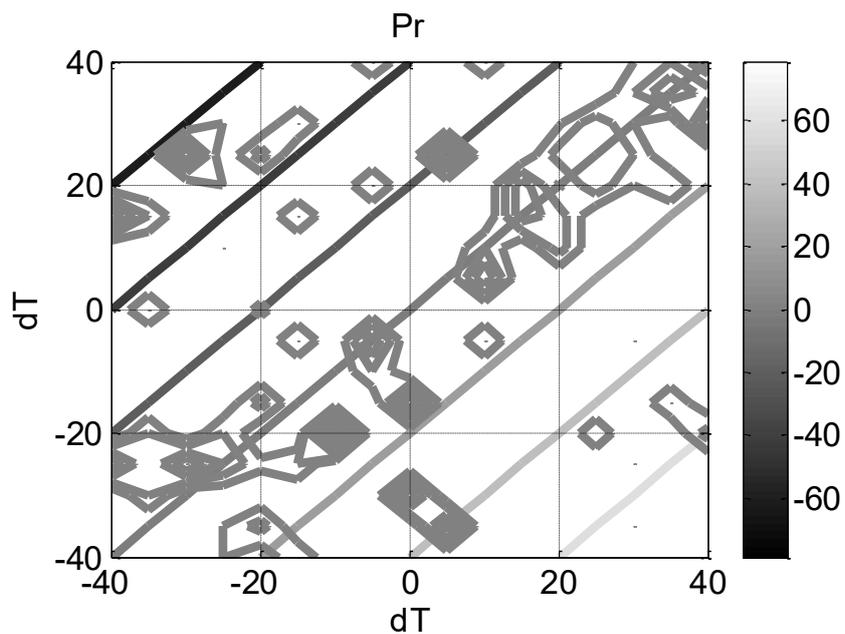


Рисунок. 3.16 – Результати статистичного моделювання процесів оцінки та зміни стану температурного режиму ДГУ у площині відхилень температури

Як це слідує із результатів статистичного моделювання, довірна ймовірність відхилень температури вихідних газів від завданих відомою методикою меж не перевищує 0,15, що не становить статистично значимою величиною.

Висновки до розділу 3

У розділі представлені результати розробки, з використанням сучасних інформаційних технологій, статистичних моделей, які відображають взаємозв'язок діагностичних параметрів технічного стану дизель-генераторних установок.

Основними висновками є наступні:

1. Виконано статистичний аналіз та встановлені найбільш значимі зв'язки між параметрами реєстрації технічного стану ДГУ за значенням коефіцієнта взаємкореляції.

2. Розроблені нелінійні регресійні моделі, як традиційні поліноміальні, так і нейромережеві, взаємозв'язку температури вихідних газів циліндрів дизельного двигуна від його навантаження та виконана її перевірка на адекватність.

3. Встановлена та підтверджена можливість прогнозування технічного стану ДГУ за обраними параметрами на основі побудови нейромережі регресії.

4. Встановлено, що нейромережа регресії забезпечує вірогідне прогнозування зміни обраного параметра діагностування в різних режимах навантаження з похибкою, яка відповідає нормативним межам допуску температури

4 ПРАКТИЧНІ РЕКОМЕНДАЦІЇ ЩОДО ОБРОБКИ ЧАСОВИХ РЯДІВ ДЛЯ МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ ТЕХНІЧНОГО СТАНУ СУДНОВИХ ДИЗЕЛЬ-ГЕНЕРАТОРНИХ УСТАНОВОК

Розділ присвячений необхідним алгоритмам і процедурам обробки часових рядів для використання методів прикладної статистики, сучасних методів трендового контролю, трендового аналізу та прогнозування технічного стану суднових ДГУ на протязі довготривалої експлуатації.

4.1 Визначення статистичних властивостей часових рядів реєстрації параметрів технічного стану ДГУ

Для визначення статистичних властивостей часових рядів реєстрації параметрів технічного стану ДГУ наперед застосовуються відомі методи та критерії прикладної статистики, зокрема, критерії хі-квадрат, Смирнова-Колмогорова щодо приналежності вихідних даних до генеральної сукупності незалежно розподілених випадкових величин. Таке визначення дозволяє обґрунтувати відомі інтервальні статистичні оцінки.

Використання критерію згоди (критерію Пірсона) полягає у обчисленні величини

$$\chi^2 = \sum_{k=1}^m (p_k - p_{mk})^2 / p_{mk}$$

де p_k – ймовірності чи відносні частоти по гістограмі досліджуваної вибірки, p_{mk} – ймовірності чи відносні частоти по гістограмі вибірки статистичної моделі породження даних, щодо якої перевіряється гіпотеза належності, m – кількість інтервалів розбиття інтервалу варіації даних (розмаху вибірки).

Отримане значення порівнюється з його критичним значенням $\chi^2(\alpha, N)$, де α – рівень значущості, N – число ступенів свободи. Якщо

отримане за вибіркою значення вирішальної статистики перевищує критичне значення, то гіпотеза приналежності до генеральної сукупності незалежно розподілених випадкових величин, заданої обраної статистичної моделі породження даних, відкидається прийнятому рівні значимості. Число ступенів свободи визначається співвідношенням $N - 1 - s$, де s – число параметрів, що визначаються за вибіркою, наприклад вибіркові середнє і дисперсія. Для вибору кількості інтервалів можуть бути рекомендовані, зокрема, формули Старджесу

$$m = \log_2 n + 1$$

Брукса та Каррузера

$$m = 5 \lg n,$$

залежно від вибіркового значення контрексесу χ вибірки, що перевіряється.

Критерій згоди Смирнова-Колмогорова дозволяє порівняти дві незалежні вибірки під час встановлення гіпотези приналежності до однієї й тієї генеральної сукупності. Порівняння проводиться за однакових для обох вибірок межах і кількості інтервалів m групування даних. Статистика двостороннього критерію Смирнова-Колмогорова має вигляд

$$D = \max |F_1 / n_1 - F_2 / n_2|$$

де F_1, F_2 – значення накопичених частоти вибірок, n_1, n_2 – загальні обсяги вибірок. Розподіл вказаної статистики табульований. При порівнянні досліджуваної вибірки з обраною аналітичною моделлю граничне значення вибирається із співвідношення

$$D_{kp} = \sqrt{-0.5 \ln(\alpha / 2) / n},$$

де α - рівень значущості, $n_1 = n_2 = n$, $n > 35$.

Якщо отримане за вибіркою значення вирішальної статистики D перевищує критичне значення D_{kp} , то гіпотеза приналежності до генеральної сукупності незалежно розподілених випадкових величин, заданої обраної

статистичної моделі породження даних, відкидається прийнятому рівні значимості. Перевагою критерію згоди Смирнова-Колмогорова і те, що дозволяє визначити рівень значимості, не вдаючись до використання якихось таблиць при $n > 35$.

4.2 Визначення умов стаціонарності часових рядів параметрів ДГУ

Умови стаціонарності часових рядів надаються критеріями Стьюдента та Фішера рівності середніх для оцінки стаціонарності

Для реалізації баз даних, що характеризують умови проведення випробувань, виконати перевірку рівності середніх із заданою довірчою ймовірністю

$$P_{\text{довсау}} = 1 - \alpha \geq P_{\text{дов}}$$

використовуючи формулу

$$T_{ij} = |m_{vi} - m_{vj}| \cdot \sqrt{\frac{L}{\hat{\sigma}_{vi}^2 + \hat{\sigma}_{vj}^2}}$$

Якщо T_{ij} перевищує квантиль розподілу Стьюдента з $2(L-1)$ ступенями свободи, то гіпотеза про рівність середніх значень параметрів умов випробувань не може бути прийнята, і відповідні дані виключаються при побудові графіків, але використовуються для подальших розрахунків.

Аналогічно використовується статистика критерію Фішера

$$F = D_{mx} / D_{nx},$$

де D_{mx}, D_{nx} дисперсії вибірок обсягу m та n відповідно.

У припущенні про належність вибірок однієї генеральної сукупності некорельованих випадкових величин гіпотеза про рівність середніх значень відкидається заданому рівні значимості, якщо обчислене значення статистики перевищує критичне $F_{kp} = F(\alpha, m, n)$, обумовлене по таблицях F – розподілу з (m, n) ступенями свободи.

Для реалізації баз даних виконати перевірку рівності середніх за критерієм Фішера із заданою довірчою ймовірністю $P_{\text{довсгау}} = 1 - \alpha \geq P_{\text{дов}}$, використовуючи формулу

$$F = ((n-1) \sum_{k=1}^m (x_k - \bar{x}_m)^2) / ((m-1) \sum_{k=1}^n (x_k - \bar{x}_n)^2)$$

Якщо значення F перевищує $F_{kp} = F(\alpha, m, n)$ квантиль розподілу Стьюдента з (m, n) ступенями свободи, то гіпотеза про рівність середніх значень параметрів умов випробувань не може бути прийнята, і відповідні дані виключаються при побудові графіків, але використовуються для подальших розрахунків.

Для визначення нестационарних ділянок часових рядів застосовуються критерій Кохрейну

Критерій Кохрейну оцінки нестационарності часових рядів ґрунтується на вивченні характеру поведінки відносин дисперсій згідно з наступним співвідношенням

$$VR_k = \sigma_k^2 / \sigma_1^2,$$

де VR – variance ratio,

$$\sigma_k^2 = T \times Var(x_i - x_{i-k}),$$

T – число відліків низки, x_i – значення відліків.

Встановлено, що $\{x_i\}$ є процесом випадкового блукання (Винерівським процесом), має місце співвідношення: $VR_k \equiv 1$.

Якщо ж процес $\{x_i\}$ є стаціонарним щодо лінійного тренду, або просто стаціонарним процесом, то тоді $VR_k \rightarrow 0$, при $k \rightarrow \infty$.

При практичному використанні дисперсії необхідно замінити їх оцінками і отримане відношення помножити на $T/(T-k-1)$ для досягнення незміщеності одержуваної оцінки. Потім необхідно побудувати графік значень отриманих оцінок для різних значеннях $k = 1, 2, \dots, K$ і з поведінки цього графіка встановити

належність ряду до класам стаціонарних чи нестаціонарних випадкових процесів.

Рівносильним поданням статистики відносин дисперсій є наступний її вид

$$VR_k = 1 + 2 \sum_{j=1}^k (1 - j(k+1))r_j,$$

де r_j – значення автокореляційної функції низки послідовних різниць

$$\Delta x_i = (x_i - x_{i-k}).$$

Критерій Кохрейна є зручним способом загальної оцінки властивостей часового ряду, проте він нечутливий до лінійного тренду. Тому його використання необхідно доповнити стандартною оцінкою лінійної регресії відліків ряду, що дозволить встановити лінійний тренд.

4.3 Довірчі інтервали середніх та дисперсій параметрів ДГУ

Для стаціонарної зміни параметрів ДГУ і за ідентичності умов випробувань для кожного з режимів, що встановилися на інтервалі $T_{зад}$, виконується оцінка математичних очікувань і дисперсій вимірюваних параметрів. Довірчий інтервал для математичного очікування (середнього значення параметра ДГУ на даному стаціонарному режимі) у вигляді двостороннього довірчого інтервалу

$$\hat{m} - \Delta m \leq m \leq \hat{m} + \Delta m$$

з довірчою ймовірністю $P_{дов} = (1 - q)$, де q - рівень значущості, визначається за формулою

$$\hat{m} - \frac{\hat{\sigma}^2}{\sqrt{L \cdot M}} \cdot tq \leq \hat{m} + \frac{\hat{\sigma}^2}{\sqrt{L \cdot M}} \cdot tq,$$

де tq є квантилем t - розподілу Стюдента (передбачається, що помилки вимірювань параметрів ДГУ підпорядковуються або апроксимуються нормальним розподілом).

Середні значення визначаються звичайним чином, а значення tq для ймовірності $P_{\text{дов}}$ беруться з таблиці t - розподілу.

Значення похибок визначення середніх з довірчою ймовірністю $P_{\text{дов}}$

$$\Delta m = tq \frac{\hat{\sigma}^2}{\sqrt{L \cdot M}}$$

визначаються для кожного з параметрів ДГУ на сукупності наступних стаціонарних режимів, що встановилися.

Якщо похибка Δm визначення середнього значення будь-якого параметра ДГУ, розрахована при довірчій ймовірності $P_{\text{дов}}$ на інтервалі $T_{\text{зад}}$ для L реалізацій параметра є незадовільною (перевищує задану величину похибки), то кількість L реалізацій даного параметра збільшується до таких значень $L\Delta m$, при яких похибка Δm з довірчою ймовірністю $P_{\text{дов}}$, яка визначається за наведеною формулою, буде задовільною (меншою або рівною заданому значенню похибки визначення даного параметра ДГУ). Якщо при збільшенні L похибка Δm не зменшується, необхідно повторно виконати обробку вимірів для даного стаціонарного режиму.

Висновки до розділу 4

У розділі представлені рекомендації щодо обробки часових рядів для моделювання та прогнозування технічного стану суднових дизель-генераторних установок.

Основними висновками є наступні:

1. Встановлені принципи визначення статистичних властивостей часових рядів реєстрації параметрів технічного стану ДГУ.
2. Визначені умови стаціонарності часових рядів параметрів ДГУ.
3. Встановлені довірчі інтервали середніх та дисперсій часових рядів параметрів ДГУ

ВИСНОВКИ

Для реалізації стратегії переходу обслуговування суднових систем за технічним станом і враховуючи можливості сучасної інформаційно-телекомунікаційних технологій, які здатні реалізувати більш досконалі методи та алгоритми технічного діагностування суднових ДГА, є актуальною проблема створення сукупності методів, методичних основ та програмно-алгоритмічних засобів оцінки та прогнозу технічного стану, які можуть бути застосовувані в системах технічного діагностування, що враховують моделі статистичного породження даних та можливості нейромережевих технологій. Вирішення вказаної проблеми, що становило мету роботи, пропонується за допомогою встановлення взаємозв'язків діагностичних параметрів технічного стану суднових дизель-генераторних установок та побудови моделей цих взаємозв'язків, які з більшою адекватністю відповідають фізиці процесів в ДГУ, та побудові відповідних моделей породження даних і, на цій основі, створення програмно-інструментальних засобів оцінки поточного технічного стану та прогнозу його змін на протязі довготривалої експлуатації. Мета роботи досягнута вирішенням низки науково-прикладних завдань, що дозволило отримати наступні результати та висновки.

1. Запропонована класифікація методів параметричного діагностування і їх систематизація за ключовими ознаками, які характеризують алгоритми діагностування.

2. Обґрунтовано підхід щодо побудови методів параметричного діагностування, в якому основну увагу привертають методи, що засновані на ідентифікації математичної моделі процесів зміни стану і побудові відповідної моделі породження даних, і діагностування в просторі параметрів технічного стану об'єкта діагностування.

3. Розглянуті методи та засоби діагностування технічного стану складних енергетичних об'єктів, які містять етапи системного аналізу об'єкту

діагностування, допускового контролю, трендового контролю, трендового аналізу та прогноз розвитку тренду.

4. Встановлено, що прогнозування часових рядів має вирішальне значення для ефективної роботи складних енергетичних об'єктів та процесів прийняття рішень щодо їх технічного стану. Вірогідне прогнозування майбутніх тенденцій є важливим для оптимізації ресурсів, планування експлуатації та загальної ефективності енергетичної системи судна..

5. Відомі фундаментальні принципи моделей прогнозування, зокрема традиційні статистичні методи, які широко використовуються завдяки швидкодії та алгоритмічним перевагам, але мають місце певні обмеження їх застосування для складних багатовимірних процесів із складними взаємозв'язком даних, що характерно для СЕЕС.

6. Для вирішення складних завдань прогнозування є перспективними методи машинного навчання, включаючи метод опорних векторів та штучну нейронну мережу. Такі моделі пропонують більші можливості та мають переваги перед статистичними методами, але їх не замінюють.

7. Суднові системи, зокрема СЕЕС, за своєю суттю генерують дані часових рядів, які являють собою виміри значень важливих параметрів, отриманих через деякі інтервали часу, включаючи динамічні та часові зміни у процесах зміни стану СЕЕС. Значення даних часових рядів у прогнозуванні є надзвичайно важливим і це дозволяє оптимізувати ресурси, підвищувати операційну ефективність та впроваджувати стратегії прогнозного обслуговування.

8. Прогнозне обслуговування шляхом прогнозування потенційних збоїв та ненормальних відхилень може не тільки забезпечити безперебійне функціонування, але й продовжити термін служби обладнання, що призводить до значної економії коштів. Прогнозування допомагає зменшити витрати, покращити матеріальні та енергетичні потоки та забезпечити своєчасну реакцію, тим самим підвищуючи загальну ефективність СЕЕС.

9. Виконано статистичний аналіз та встановлені найбільш значимі

зв'язки між параметрами реєстрації технічного стану ДГУ за значенням коефіцієнта взаємкореляції.

10. Розроблені нелінійні регресійні моделі, як традиційні поліноміальні, так і нейромережеві, взаємозв'язку температури вихідних газів циліндрів дизельного двигуна ДГУ від його навантаження та виконана її перевірка на адекватність.

11. Встановлена та підтверджена можливість прогнозування технічного стану ДГУ за обраними параметрами на основі побудови нейромережі регресії.

12. Встановлено, що нейромережа регресії забезпечує вірогідне прогнозування зміни обраного параметра діагностування в різних режимах навантаження з похибкою, яка відповідає нормативним межам допуску температури

Результати роботи дозволяють обґрунтувати загальний висновок, що впровадження сукупності методів, методичних основ та програмно-алгоритмічних засобів оцінки та прогнозу технічного стану, які можуть бути застосовувані в системах технічного діагностування, що враховують моделі статистичного породжування даних та можливості нейромережевих технологій дозволяє в перспективі перейти до реалізації стратегії переходу обслуговування суднових систем за технічним станом, і, тим самим, підвищити ефективність і надійність СЕЕС, оптимізувати їх роботу, скоротити витрати палива і забезпечити відповідність екологічним стандартам.

Подальші дослідження мають бути спрямовані на вдосконалення алгоритмів діагностування та розробку економічно вигідних технічних рішень для впровадження таких систем діагностування у судноплавстві.

ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. ДСТУ 2860–94. Надійність техніки. Терміни та визначення. – Вид. офіц. – Чинний від 1994–12–28. – К. : Держстандарт України, 1995. – 91 с.
2. ДСТУ 9050:2020 Система технічного обслуговування та ремонтування техніки. Терміни та визначення понять. – Чинний від 01.04.2021. – Режим доступу: <https://online.budstandart.com/>
3. Kroes, M. Aircraft maintenance and Repair. 8th edition / M. Kroes, R. Sterkenburg. – McGraw Hill Professional, 2019. – 624 с.
4. Kim J. A comparative study of time-based maintenance and condition-based maintenance for optimal choice of maintenance policy [Electronic resource] / J. Kim, Y. Ahn, H. Yeo // Structure and Infrastructure Engineering. – 2016. – Т. 12, № 12. – С. 1525–1536. – Режим доступу: <http://dx.doi.org/10.1080/15732479.2016.1149871>.
5. Ahmad, R. An overview of time-based and condition-based maintenance in industrial application [Electronic resource] / R. Ahmad, S. Kamaruddin // Computers & Industrial Engineering. – 2012. – Т. 63, № 1. – С. 135–149. – Режим доступу: <https://doi.org/10.1016/j.cie.2012.02.002>.
6. ISO 13374-1:2003. Condition monitoring and diagnostics of machines – Data processing, communication and presentation – Part 1: General guidelines. – Вид. офіц. – Чинний від 2003-03-13. – International Organization for Standardization, 2003. – 16 с.
7. ISO 13374-2:2007. Condition monitoring and diagnostics of machines – Data processing, communication and presentation – Part 2: Data processing. – Вид. офіц. – Чинний від 2007-07-09. – International Organization for Standardization, 2007. – 33 с.
8. ISO 13374-4:2015. Condition monitoring and diagnostics of machines – Data processing, communication and presentation – Part 4: Presentation. – Вид. офіц. – Чинний від 2015-11-19. – International Organization for Standardization, 2015. – 5 с.

9. Кулик, А. С. Сигнально-параметрическое диагностирование систем управления [Текст] / А. С. Кулик ; Гос. Аэрокосмический ун-т «ХАИ». – Харьков: Бизнес-Информ, 2000. – 260 с.
10. Pecht M. A prognostics and health management roadmap for information and electronics-rich systems [Electronic resource] / M. Pecht, R. Jaai // *Microelectronics Reliability*. – 2010. – Т. 50, № 3. – С. 317–323. – Режим доступа: <https://doi.org/10.1016/j.microrel.2010.01.006>. – Назва з екрана.
11. Sikorska J. Z. Prognostic modelling options for remaining useful life estimation by industry [Electronic resource] / J. Z. Sikorska, M. Hodkiewicz, L. Ma // *Mechanical Systems and Signal Processing*. – 2011. – Т. 25, № 5. – С. 1803–1836. – Режим доступа: <https://doi.org/10.1016/j.ymssp.2010.11.018>.
12. *An introduction to statistical learning* / Gareth James [та ін.]. – Springer, 2015. – 426 с.
13. Гвоздева И.М. Оценка элементов пространства диагностических признаков технического состояния судовых дизель-генераторных агрегатов / И.М. Гвоздева, М.А. Якименко, В.В. Демиров, В.Ф. Миргород, Е. В. Деренг // *Матеріали XX Міжнародної конференції з математичного моделювання (МКММ-2019) [Збірка тез (16-20 вересня 2019 р., м. Херсон)]*. – Херсон: ХНТУ, 2019. – С. 38.
14. Гвоздева І.М. Оцінка елементів простору діагностичних ознак технічного стану судових дизель-генераторних агрегатів / І.М. Гвоздева, М.А. Якименко, В.В. Демиров, В.Ф. Миргород, Є. В. Деренг // *Вісник Херсонського національного технічного університету*. – Херсон. – 2019. – Вип. 2(69). – Частина 2. – С. 39-46.
15. I.Hvozdeva, V. Myrhorod, V.Budashko and V.Shevchenko “Problems of Improving the Diagnostic Systems of Marine Diesel Generator Sets”, 2020 IEEE 15th International Conference in Advanced Trends in Radio electronics, Telecommunications and Computer Engeneering (TCSET), Lviv-Slavske,

- Ukraine, 2020, pp. 350-354. DOI: 10.1109/TCSET49122.2020.235453
(Публикация входит в Scopus)
16. Myrhorod, V. Investigation on the power of some parametric criteria for trend detection in time series / V. Myrhorod, I. Hvozdeva, Y. Derenh/ 12th International Conference for Promoting the Application of Mathematics in Technical and Natural Sciences - AMiTaNS'20, AIP Conference Proceedings; AIP 2302 , 060008-1 - 060008-11 (2020); <https://doi.org/10.1063/5.0034794>.
17. Гвоздева, И.М. Миргород, В.Ф. Демиров, А.А. Математическая модель температурного режима судовых дизель-генераторных установок на основе радиально-базисной нейронной сети [Текст] / И.М. Гвоздева, В.Ф. Миргород, А.А. Демиров // Матеріали Х міжнародної науково-технічної конференції «Суднова електроінженерія, електроніка і автоматика», 24.11.2020 - 25.11.2020. – Одеса: НУ «ОМА», 2020. – С.124-128
DOI:10.31653/2706-7874.SEEEA-2020.11.1-245
18. Myrhorod, V. Multi-parameter Diagnostic Model of the Technical Conditions Changes of Ship Diesel Generator Sets [Text] / V. Myrhorod, I. Hvozdeva, V. Budashko // 2020 IEEE Problems of Automated Electrodrive. Theory and Practice (PAEP), Kremenchuk, 21-25 Sept. 2020, Ukraine: IEEE. Pp. 1-5. DOI: 10.1109/PAEP49887.2020.9240905.
19. Myrhorod, V. One Method of Trend Analysis of Technical Objects Conditions in their Long Term Operation/ V. Myrhorod, I. Hvozdeva,/ 13th International Conference for Promoting the Application of Mathematics in Technical and Natural Sciences - AMiTaNS'21, AIP Conference Proceedings 2522, 040002 (2022); <https://doi.org/10.1063/5.0101097>, EID: 2-s2.0-85140207159, Part of ISSN: 15517616 0094243X
20. Гвоздева, И.М. Идентификация математической модели температурного режима судовых дизель-генераторных установок на основе генетических алгоритмов [Текст] / И.М. Гвоздева, В.Ф. Миргород,

- С.В. Колесник, С.В. Корольчук // Матеріали XI міжнародної науково-технічної конференції «Суднова електроінженерія, електроніка і автоматика», 23.11.2021 - 24.11.2021. – Одеса: НУ «ОМА», 2021. – С.103-108. ISSN 2706-7874. DOI:10.31653/2706-7874.SEEEA-2021.11.1-238
21. Budashko, V. Diagnostics of the Technical Condition of High-Tech Complex by Probabilistic Methods [Text] / V. Budashko, I. Hvozdeva, V. Myrhorod, V. Shevchenko, A. Sandler, O. Glazeva // 16th International Conference on Advanced Trend in Radioelectronics, Telecommunications and Computer Engineering (TCSET), Lviv-Slavske, 22-26 February. 2022, Ukraine: IEEE. Pp. 7-13. ISBN (IEEE) 978-1-6654-6860-2
22. Multiparameter Approximation Model of Temperature Conditions of Marine Diesel Generator Sets, Based on Markov Chain Monte Carlo. Myrhorod, V., Hvozdeva, I., Budashko, V. TransNav, 2022, 16(4), pp. 779–784, DOI: 10.12716/1001.16.04.20, EID: 2-s2.0-85146804722, Part of ISSN: 20836481 20836473
23. Гвоздева І.М. Трендові статистичні моделі та їх комп'ютерна реалізація в судових системах діагностики [Текст] / Гвоздева І.М., Миргород В.Ф., Петков І.В., Круц В.А // Матеріали XII міжнародної науково-технічної конференції «Суднова електроінженерія, електроніка і автоматика», 22.11.2022 - 23.11.2022. – Одеса: НУ «ОМА», 2022. – С.132-135. ISSN 2706-7874 (print). DOI:10.31653/2706-7874.SEEEA-2022.11.1-203
24. Мендоса Валенсія, Х.; Уртадо Морено, Х.Й.; Ньето Санчес, Ф.д. Штучний інтелект як конкурентна перевага у сфері виробництва. У книзі “Телематика та обчислювальна техніка”; Springer International Publishing: Шам, Швейцарія, 2019; с. 171–180.
25. Сусто, Дж. А.; Шірру, А.; Пампурі, С.; Маклун, С.; Бегі, А. Машинне навчання для прогнозного обслуговування: підхід з кількома класифікаторами. IEEE Trans. Ind. Inform. 2015, 11, 812–820.

26. Ван, Б.; Тао, Ф.; Фан, Х.; Лю, К.; Лю, Ю.; Фрайхайд, Т. Розумне виробництво та інтелектуальне виробництво: порівняльний огляд. *Engineering* 2021 , 7 , 738–757.
27. Zhou, X.; Zhai, N.; Li, S.; Shi, H. Метод прогнозування часових рядів промислового процесу з обмеженими даними на основі трансферного навчання. *IEEE Trans. Ind. Inform.* 2023 , 19 , 6872–6882.
28. Чен, Б.; Лю, Ю.; Чжан, К.; Ван, З. Дані часових рядів для аналізу надійності обладнання за допомогою глибокого навчання. *IEEE Access* 2020 , 8 , 105484–105493.
29. Деб, К.; Чжан, Ф.; Ян, Дж.; Лі, С.Є.; Шах, К.В. Огляд методів прогнозування часових рядів споживання енергії будівлями. *Renew. Sustain. Energy Rev.* 2017 , 74 , 902–924.
30. Рівера-Кастро, Р.; Назаров, І.; Сян, Ю.; Плетнеєв, А.; Максимов, І.; Бурнаєв, Е. Методи прогнозування попиту для ланцюгів поставок бережливого виробництва на замовлення. У *Advances in Neural Networks—ISNN 2019; Lecture Notes in Computer Science; Springer International Publishing: Cham, Швейцарія, 2019; с. 213–222.*
31. Market.us. Штучний інтелект на ринку виробництва. 2024. Доступно онлайн: <https://market.us/report/ai-in-manufacturing-market/>
32. Бокс, ГЕП; Дженкінс, Г.М.; Рейнзель, ГХ. Аналіз часових рядів ; Wiley: Хобокен, Нью-Джерсі, США, 2008.
33. Valipour, M. Довгострокове дослідження стоку з використанням моделей SARIMA та ARIMA у Сполучених Штатах: прогнозування стоку за допомогою SARIMA. *Meteorol. Appl.* 2015 , 22 , 592–598.
34. Контрерас, Х.; Еспінола, Р.; Ногалес, Ф.; Конехо, А. Моделі ARIMA для прогнозування цін на електроенергію наступного дня. *IEEE Trans. Power Syst.* 2003 , 18 , 1014–1020.
35. Де Феліче, М.; Алессандрі, А.; Руті, П. М. Прогнозування попиту на електроенергію в Італії: потенційні переваги використання числових моделей прогнозування погоди. *Electr. Power Syst. Res.* 2013 , 104 ,

- P.71–79.
36. Торрес, Х.; Гарсія, А.; Де Блас, М.; Де Франсіско, А. Прогноз середньої годинної швидкості вітру за допомогою моделей ARMA в Наваррі (Іспанія). *Sol. Energy* 2005 , 79 , 65–77.
37. Ван, Л.; Цзоу, Х.; Су, Дж.; Лі, Л.; Чаудхрі, С. Гібридна модель ARIMA-ANN для прогнозування часових рядів. *Syst. Res. Behav. Sci.* 2013 , 30 , 244–259.
38. Хуан, Дж.; Ма, С.; Чжан, Ч. Х. Адаптивне ласо для розріджених багатовимірних регресійних моделей. *Stat. Sin.* 2008 , 18 , 1603–1618.
39. Юй, Р.; Сюй, Ю.; Чжоу, Т.; Лі, Дж. Зв'язок між тривалістю опадів та добовими коливаннями кількості опадів у теплий сезон над центрально-східним Китаєм. *Geophys. Res. Lett.* 2007 , 34.
40. Вільямс, Б.М.; Хоел, Л.А. Моделювання та прогнозування потоку транспортного руху як сезонного процесу ARIMA: теоретична основа та емпіричні результати. *J. Transp. Eng.* 2003 , 129 , 664–672.
41. Влахоянні, Е.І.; Голіас, Дж.К.; Карлафтис, М.Г. Короткострокове прогнозування дорожнього руху: огляд цілей та методів. *Transp. Rev.* 2004 , 24 , 533–557.
42. Хашеї, М.; Біджарі, М. Модель штучної нейронної мережі (p, d, q) для прогнозування часових рядів. *Expert Syst. Appl.* 2010 , 37 , 479–489.
43. Гамільтон, Дж. Д.; Сусмел, Р. Авторегресивна умовна гетероскедастичність та зміни режиму. *J. Econom.* 1994 , 64 , 307–333.
44. Цао, Л.; Тей, Ф. Метод опорних векторів з адаптивними параметрами у прогнозуванні фінансових часових рядів. *IEEE Trans. Neural Networks* 2003 , 14 , 1506–1518.
45. Брейман, Л. Випадкові ліси. *Mach. Learn.* 2001 , 45 , 5–32.
46. Енсафі, Ю.; Амін, С.Х.; Чжан, Г.; Шах, Б. Прогнозування продажів сезонних товарів за часовими рядами за допомогою машинного навчання — порівняльний аналіз. *Int. J. Inf. Manag. Data Insights* 2022 , 2 , 100058.

47. Хохрейтер, С.; Шмідхубер, Й. Довга короткочасна пам'ять. *Neural Comput.* **1997**, *9*, 1735–1780.
48. Васвані, А.; Шазір, Н.; Пармар, Н.; Uszkoreit, J.; Джонс, Л.; Гомес, А. Н.; Кайзер, Лу; Полосухін І. Увага - все, що вам потрібно. У матеріалах про досягнення в нейронних системах обробки інформації; Guyon, I., Luxburg, UV, Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., Garnett, R., Eds.; Curran Associates, Inc.: Ред Хук, Нью-Йорк, США, 2017; Том 30.
49. Хайндман, Р.Дж.; Келер, А.Б.; Снайдер, Р.Д.; Гроуз, С. Структура простору станів для автоматичного прогнозування з використанням методів експоненціального згладжування. *Int. J. Forecast.* **2002**, *18*, 439–454.
50. Торрес, Дж. Ф.; Хаджут, Д.; Себаа, А.; Мартінес-Альварес, Ф.; Тронкосо, А. Глибоке навчання для прогнозування часових рядів: опитування. *Великі дані* **2021**, *9*, 3–21.
51. Лара-Бенітес, П.; Карранса-Гарсія, М.; Рікельме, Х.К. Експериментальний огляд архітектур глибокого навчання для прогнозування часових рядів. *Int. J. Neural Syst.* **2021**, *31*, 2130001.
52. Масіні, Р.П.; Медейрос, М.К.; Мендес, Е.Ф. Досягнення машинного навчання для прогнозування часових рядів. *J. Econ. Surv.* **2021**, *37*, 76–111.
53. Гаспарін, А.; Луковіч, С.; Аліппі, К. Глибоке навчання для прогнозування часових рядів: Електричний випадок навантаження. *CAAI Trans. Intell. Technol.* **2021**, *7*, 1–25.
54. Демірташ, Х. Гнучка імпутація відсутніх даних. *J. Stat. Softw.* **2018**, *85*, 1–5.
55. Тайлер, Д. Е. Робастна статистика: теорія та методи. *J. Am. Stat. Assoc.* **2008**, *103*, 888–889.
56. Прюнгкарн, Р.; Вонг, К.В.; Фунг, К.К. Огляд методів та застосувань інтелектуального аналізу даних. *J. Adv. Comput. Intell. Intell. Inform.* **2017**, *21*, 31–48.

- 57.Шамвей, Р.Х.; Стоффер, Д.С. *Аналіз часових рядів та його застосування: з прикладами R* ; Springer: Cham, Швейцарія, 2017.
- 58.Чжан, Г.; Патуво, Б.Є.; Ху, М.Й. Прогнозування за допомогою штучних нейронних мереж: сучасний стан. *Міжнародний журнал прогнозування*. **1998** , 14 , 35–62.
- 59.Тейлор, Дж. В.; Буїцца, Р. Прогнозування щільності для ціноутворення на погодні деривативи. *Міжнародний журнал прогнозу*. **2006** , 22 , 29–42.
- 60.Герард, Дж. Б.; Клемен, Р. Т. Колінеарність та використання латентної кореневої регресії для об'єднання прогнозів ВВП. *J. Forecast.* **1989** , 8 , 231–238.
- 61.Хайндман, Р. Дж.; Атанасопулос, Г. *Прогнозування: принципи та практика* ; Otexts: Хобокен, Нью-Джерсі, США, 2018.
- 62.Бокс, Г. *Бокс та Дженкінс: Аналіз, прогнозування та контроль часових рядів* ; Palgrave Macmillan: Лондон, Велика Британія, 2013; с. 161–215.
- 63.Люткеполь, Г. *Новий вступ до аналізу кількох часових рядів* , 1-е видання; Springer: Берлін, Німеччина, 2005.
- 64.Скотт, С.Л.; Варіан, Г.Р. Прогнозування сьогодення за допомогою байєсівських структурних часових рядів. *Int. J. Math. Model. Numer. Optim.* **2014** , 5 , 4.
- 65.Квінлан, Дж. Р. Індукція дерев рішень. *Mach. Learn.* **1986** , 1 , 81–106.
- 66.Ляв, А.; Вінер, М. Класифікація та регресія за допомогою randomForest. *R News* **2002** , 2 , 18–22.
- 67.Де Гуйєр, Дж. Г.; Гайндман, Р. Дж. 25 років прогнозування часових рядів. *Міжнародний журнал прогнозування*. **2006** , 22 , 443–473.
- 68.Чо, К.; ван Меррінбур, Б.; Бахданау, Д.; Бенджіо, Ю. Про властивості нейронного машинного перекладу: підходи типу «кодер-декодер». *arXiv* **2014** , arXiv:1409.1259.

- 69.Лекун, Ю.; Ботту, Л.; Бенджіо, Ю.; Хаффнер, П. Градієнтне навчання, застосоване до розпізнавання документів. *Праці IEEE* **1998**, *86*, 2278–2324.
- 70.Лім, Б.; Зорен, С. Прогнозування часових рядів за допомогою глибокого навчання: Огляд. *Philos. Trans. R. Soc. A Math. Phys. Eng. Sci.* **2021**, *379*, 20200209.
- 71.Броквелл, П. Дж.; Девіс, Р. А. (ред.) Моделі простору станів. У книзі «Вступ до часових рядів та прогнозування»; Springer: Нью-Йорк, штат Нью-Йорк, США, 2002; с. 259–316.
- 72.Панкратц, А. *Прогнозування за допомогою одновимірних моделей Box-Jenkins*; Wiley: Hoboken, NJ, USA, 1983.
- 73.Цай, Р.С. *Аналіз фінансових часових рядів*, 2-ге вид.; Ряди Вайлі у теорії ймовірностей та статистиці; Вайлі-Блеквелл: Чичестер, Велика Британія, 2005.
- 74.Чен, П.; Педерсен, Т.; Бак-Йенсен, Б.; Чен, З. Модель часових рядів стохастичної генерації вітрової енергії на основі ARIMA. *IEEE Trans. Power Syst.* **2010**, *25*, 667–676.
- 75.Акайке, Х. Новий погляд на ідентифікацію статистичної моделі. *IEEE Trans. Autom. Control* **1974**, *19*, 716–723.
- 76.Шварц, Г. Оцінка розмірності моделі. *Ann. Stat.* **1978**, *6*, 461–464.
- 77.Андерсон, Д.; Бернем, К. *Вибір моделі та багатомодельний висновок*; Springer: Нью-Йорк, штат Нью-Йорк, США, 2004.
- 78.Ямак, П.Т.; Юйцзянь, Л.; Гадосей, П.К. Порівняння між ARIMA, LSTM та GRU для прогнозування часових рядів. У матеріалах 2-ї Міжнародної конференції з алгоритмів, обчислень та штучного інтелекту 2019 року. ACM, ASAI 2019, Санья, Китай, 20–22 грудня 2019 року.
- 79.Хейс, А. Модель прогнозування авторегресивної інтегрованої ковзної середньої (ARIMA). 2023. Доступно онлайн: <https://www.investopedia.com/terms/a/autoregressive-integrated-moving-average-arima.asp> .

80. Чінар, З.М.; Абдуссалам Нуху, А.; Зішан, К.; Корхан, О.; Асмаель, М.; Сафаї, Б. Машинне навчання в прогностному обслуговуванні для сталого інтелектуального виробництва в Промисловості 4.0. *Сталій розвиток* **2020** , 12 , 8211.
81. Хайкін, С.О. *Нейронні мережі та навчальні машини* , 3-тє вид.; Pearson: Аппер-Седл-Рівер, Нью-Джерсі, США, 2008.
82. Румельхарт, Д.Е.; Хінтон, Г.Е.; Вільямс, Р.Дж. Навчання представлень шляхом зворотного поширення помилок. *Nature* **1986** , 323 , 533–536.
83. Горнік, К.; Стінчкомб, М.; Вайт, Г. Багатошарові мережі прямого зв'язку є універсальними апроксиматорами. *Neural Netw.* **1989** , 2 , 359–366.
84. ЛеКун, Ю.; Бенджіо, Ю.; Хінтон, Г. Глибоке навчання. *Nature* **2015** , 521 , 436–444.
85. Чен, Б. Дж.; Чанг, М. В.; Лін, К. Дж. Прогнозування навантаження за допомогою машин опорних векторів: дослідження на конкурсі EUNITE 2001. *IEEE Trans. Power Syst.* **2004** , 19 , 1821–1830
86. Елман, Дж. Л. Пошук структури в часі. *Cogn. Sci.* **1990** , 14 , 179–211.
87. Мандіч, Д.П.; Чемберс, Дж.А. *Рекурентні нейронні мережі для прогнозування* ; Wiley: Хобокен, Нью-Джерсі, США, 2001.

ДОДАТКИ**Додаток А**Основні параметри судна:

Тип судна: Балкер

Назва судна: LUDOLF OLDENDORFF

Розміри: Довжина- 300 м, Ширина – 50 м, Осадка – 18,5 м

Дедвейт - 207562 т

Водотоннажність в завантаженому стані – 236615 т,

в порожньому – 29052 т

Експлуатаційна швидкість: 12 вузлів

Число ГД: 1, потужність – 16200 кВт

Тип ГД: 6G70ME-C92

Додаток ВПараметри дизель генераторів:

Кількість ДГ: 3 шт

Виробник – HYUNDAI-HIMSEN

Тип 5H21/32

Кількість циліндрів - 5

Потужність дизеля - 930 кВт, 1100кВА

Потужність генератора – 880 кВт

Частота обертів – 900 об/хв

Напруга – 450 В

Струм – 1411.3 А

Частота – 60 Гц



SPECIFICATION OF GENERATOR

USE	DIESEL ENGINE GENERATOR		QUANTITY / SHIP	3 ST/SHIP	
TYPE OF ENCLOSURE	IP 23		APPLIED CLASS	NK	
COOLING SYSTEM	AIR TO AIR		AMBIENT TEMP.	46 °C	
EXCITING SYSTEM	SELF EXCITING BRUSHLESS		INSULATION CLASS	F	
STRUCTURE OF ROTOR	CYLINDRICAL ROTOR		TEMPERATURE RISE	F	
COUPLING METHOD	DIRECT RIGID		APPLIED UNIT	METRIC	
SPECIFICATION			BEARING		
TYPE	HFC7 508-08P		TYPE OF BEARING	SLEEVE BEARING	
OUTPUT CAPACITY	1100 kVA		LOCATION	DRIVEN END	NON-DRIVEN END
RATING	CONTINUOUS		SIZE	-	φ125×L160
PHASES, WIRE, CONN	3 φ, 3 W, Y (DAMPER WINDING)		OIL QUANTITY	-	4.1 LITER
VOLTAGE	AC 450 V		LUB SYSTEM	-	SELF LUB.
CURRENT	1411.3 A		OIL GRADE	ISO VG 68	
FREQUENCY	60 Hz		INLET PRESSURE	- bar	
POLES	8 P		INLET TEMP.	Max	- °C
SPEED	900 RPM		AIR COOLER		
POWER FACTOR	0.8 LAGGING		CAPACITY	-	
GD ² / J	363.2 kg.m ² / 88.3 kg.m ²		FLUID	-	
ROTOR WEIGHT	2028 kg		QUANTITY	- m ³ /h	
TOTAL WEIGHT	4.9 ton		INLET TEMP.	- °C	
CHARACTERISTICS			TEMP RISE	- °C	
OVER CURRENT	Ref. TO ITP		PRESSURE DROP	- kg/cm ²	
VARIATION OF GENERATOR VOLTAGE	±2.5 %		DRY WEIGHT	- kg	
OVER SPEED	120 % / 2 min.		DETECTING SYSTEM		
VOLTAGE ADJUST	±5.0 %		WINDING TEMP.	PT100 OHM × 2EA/PHASE	
MOUNTING METHOD	B5/B20		BEARING TEMP.	THERMOMETER	
REACTANCE & TIME CONSTANT (CALCULATED VALUE)			COOLING AIR TEMP	-	
X _d	300.0 %(UNSATURATED)	T' d	0.0080 Sec.	CONFIRMED ITEM BY OWNER	
X' d	18.6 %(SATURATED)	T'' d	0.0027 Sec.	* LOCATION OF TERMINAL BOX. (VIEW FROM PRIME MOVER)	ALL RIGHT SIDE
X'' d	10.3 %(SATURATED)	T _a	0.0281 Sec.	* CABLE ENTRY	ALL TOP SIDE
R _a	1.1 %			* SPACE HEATER	1PH, 220V, 316W
NOTE			* PAINTING COLOR	6 PB 4/4	
- RECOMMENDED ALARM/TRIP SETTING POINT OF W.T.D 1) ALARM : 160°C			* LOCATION OF AIR COOLER FLANGE (VIEW FROM PRIME MOVER)	-	
			* ROTATING DIRECTION OF GENERATOR (VIEW FROM PRIME MOVER)	C.C.W	
			REMARK		
REV	CONTENTS	DATE	1. THE SPECIFICATION OF * MARK SHOULD BE INFORMED ON YOUR APPROVED DRAWING		
1	Revised by shipyard comment.	2013.10.23	HFC7 508-08P-Rev.1		
2			DATE	DESIGN	CHECKED
3					CHECKED
4					APPROVED
5			2013.10.23	B.M.JEONG	-
				Y.H.LEE	G.B.KIM

RW-W230-155-0

A4(210mm X 297mm)