

© Гончарук І.П., Головань А.І.

ІННОВАЦІЙНА СИСТЕМА МАШИННОГО НАВЧАННЯ ДЛЯ МОНІТОРИНГУ СУДНОВОГО ОБЛАДНАННЯ В РЕАЛЬНОМУ ЧАСІ

У цій статті представлено інноваційну систему онлайн-моніторингу стану. Вона складається з нової об'єктно-орієнтованої бази даних, алгоритму машинного навчання та детальної моделі для прогнозування відмов обладнання. База даних моніторингу стану, яка є об'єктно-орієнтованою базою даних, створеною на мові Python, була розроблена для того, щоб уникнути будь-якої реляційно-об'єктної невідповідності проблем, які часто виникають при використанні реляційних баз даних у складних додатках з використанням методів машинного навчання. База даних інтелектуально зберігає дані з різних датчиків, а потім впорядковує дані в конвеєр до системи діагностики та прогнозування, пропонуючи постійну оцінку стану судових механізмів з високою швидкістю і точністю. Запропонована система технічного обслуговування на основі стану, базується на виявленні змін стану обладнання в режимі реального часу, використовуючи алгоритм локального фактору відхилення для виявлення новизни. Навчання, валідація та тестування алгоритму були виконані з використанням даних про деградацію енергетичної установки. Результати показують що після налаштування алгоритму він з високою точністю визначив, коли механічна системи змінює стан як для турбіни і компресора, так і для інших судових технічних засобів.

Ключові слова: технічний стан, моніторинг, прогнозування, реальний час, об'єктно-орієнтована база даних, машинне навчання, штучний інтелект, локальний фактор відхилення, судові технічні засоби, механізми, судно.

Постановка проблеми. У сучасному суднопластві моніторинг стану судових механізмів традиційно здійснюється вручну або за допомогою простих автоматизованих діагностичних і прогнозуючих систем. Однак такі системи є частиною першого покоління підходів до технічного обслуговування за станом (обслуговування на основі стану), які базуються на фіксованих інтервалах обслуговування або обмеженому аналізі поточного стану обладнання. Основною проблемою є те, що традиційні методи аналізу стану механізмів базуються на статистичному аналізі вибіркового даних, що не завжди дозволяє точно прогнозувати відмови через випадковий характер зношування обладнання. До того ж, більшість методів обслуговування на основі стану у морському секторі потребують значного обсягу даних, які важко отримати, а також великої обчислювальної потужності для обробки алгоритмів машинного навчання. Ще однією проблемою є складність адаптації алгоритмів до різних експлуатаційних режимів судна. Судно працює у змінних умовах – маневрування в порту, хід у відкритому морі, негода тощо, що ускладнює моделювання роботи його механізмів. Крім того, існуючі реляційні бази даних погано взаємодіють із алгоритмами машинного навчання, що створює проблеми сумісності між системами управління та прогнозування технічного стану судового обладнання. З огляду на ці виклики, необхідне впровадження інноваційної системи моніторингу, що використовує об'єктно-орієнтовану базу даних (ООБД) та алгоритми машинного навчання для точного й швидкого аналізу змін у стані судових механізмів. Така система повинна забезпечувати:

1. Автоматизований збір та обробку даних у режимі реального часу з різних сенсорів без необхідності залучення експертів.
2. Виявлення відхилень у роботі обладнання за допомогою алгоритму локального фактору відхилення (ЛФВ) для аналізу нових аномалій.
3. Адаптацію до різних режимів експлуатації судна, з урахуванням змінних навантажень та умов роботи судових механізмів.

4. Оптимізацію використання обчислювальних ресурсів, завдяки застосуванню об'єктно-орієнтованої бази даних, яка усуває проблеми несумісності між алгоритмами машинного навчання та реляційними базами даних.

Таким чином, створення такої системи дозволить підвищити рівень безпеки та ефективності експлуатації суднових механізмів, зменшити кількість непередбачуваних відмов та витрати на ремонт і технічне обслуговування.

Аналіз останніх досліджень і публікацій. У морському секторі дані зазвичай використовуються для ручного моніторингу сигналів тривоги та тенденцій на борту з деякими випадками простої автоматизованої діагностики даних і прогностичних процедур. Ці прості системи діагностики та прогнозування в поєднанні з експертними знаннями є частиною першого покоління систем технічного обслуговування на основі стану. Як впливає з назви, обслуговування на основі стану відноситься до процесу планування технічного обслуговування машини не через фіксовані проміжки часу (регламентне технічне обслуговування), а відповідно до фактичного стану обладнання. Моніторинг стану має на меті збір даних про стан техніки, які називаються даними моніторингу стану [1]. Останні дослідження зосереджені на розробці систем на основі машинного навчання для моніторингу в реальному часі та прогнозування технічного обслуговування судового обладнання. Ці підходи спрямовані на підвищення ефективності технічного обслуговування, скорочення часу простою і поліпшення експлуатаційних характеристик. У дослідженнях вивчалися різні алгоритми машинного навчання для прогнозування відмов судових дизельних двигунів [2] і судових механізмів [3, 4]. Прескриптивна модель, що використовує генеративні змагальні мережі та аналіз режимів і наслідків відмов, може забезпечити моніторинг у реальному часі та високоточне прогнозування відмов судового обладнання [5, 6]. Для моніторингу дизель-генераторів було запропоновано новий підхід, що використовує генеративні змагальні мережі у поєднанні з аналізом режимів і наслідків відмов, що дозволило досягти 83,13% точності у виявленні відмов [7, 8]. У статті представлено фреймворк на основі машинного навчання для моніторингу та прогнозування споживання палива та аномалій в режимі реального часу в судовому двотактному дизельному двигуні [9, 10]. Ці методології демонструють потенціал для раннього виявлення несправностей, покращення прийняття рішень та оптимізації стратегій технічного обслуговування в морській галузі. Однак необхідні подальші дослідження для вирішення таких проблем, як ідентифікація режимів відмов і оцінка критичності активів для комплексних рішень з предиктивного технічного обслуговування.

Мета дослідження полягає у розробці та впровадженні інноваційної системи моніторингу технічного стану судових механізмів у реальному часі, засновану на алгоритмах машинного навчання та об'єктно-орієнтованих базах даних.

Основні результати дослідження. У сучасній літературі існує два основних підходи до обслуговування на основі стану, а саме: підхід, що ґрунтується на моделях та підхід на основі даних. Підхід, заснований на моделях, включає в себе фізичне розуміння цільових системи і включає такі методи, як експертні системи на основі правил, скінченних автоматів та якісних міркувань, або нечіткого моделювання. Як впливає з назви, експертні системи вимагають значного людського досвіду для того, щоб знайти рішення. Основним недоліком цих систем є нездатність до узагальнення (вони є специфічними для однієї системи), адаптації в нових умовах і навчання на своїх помилках. Підхід на основі даних також відомий як підхід машинного навчання, який використовує зібрані та накопичувані дані для автоматичного вивчення поведінки системи. Ці моделі підтримують розпізнавання і класифікацію складних несправностей без особливих знань про процес, сигнали і моделі несправностей. Деякі популярні методи машинного навчання, які можна для підходу, заснованого на даних, є нейронні мережі, дерева рішень.

Вищезазначені підходи, однак, створюють певні труднощі в їх застосуванні в морському секторі. Моделеподібні підходи забезпечують лише часткові рішення, які підходять для конкретного обладнання в певних умовах експлуатації, але вони не можуть точно відобразити та узагальнити динамічні зміни, що відбуваються у просторі та часі. З іншого боку, підходи, засновані на даних, вимагають великої кількості якісних маркованих навчальних даних для кожного

досліджуваного випадку, в тому числі даних з різних експлуатаційних профілів судна та/або частоти відмов. Ці дані вимагають значної кількості часу для збору, великий обсяг пам'яті на борту, системи управління базами даних, здатні обробляти великі обсяги даних, підвищених витрат на передачу даних на берег через супутниковий зв'язок для аналізу, а також додатковий час для навчання алгоритмів і отримання результатів. Критичний огляд сучасної літератури показав, що існуючі системи обслуговування на основі стану мають обмежене застосування і здебільшого базуються на простому статистичному аналізі. У зв'язку з цим, як ніколи раніше, необхідно запропонувати структуру обслуговування на основі стану, яка включатиме передові методи машинного навчання і моделювання для того, щоб запропонувати кращі діагностичні та прогностичні можливості, ніж існуючі системи, а також підвищену практичну цінність.

Запропонована структура обслуговування на основі стану (ООС): для вирішення основних проблем впровадження ООС у судноплавстві застосовується інноваційний підхід. Нова система ООС має просту архітектуру і може бути застосовуватися в більш ніж одній машинній системі без необхідності будь-яких попередніх даних і, що більш важливо, втручання будь-якої людини (експерта). Для цього створена база даних, яка полегшить процес машинного навчання завдяки своїй об'єктно-орієнтованій природі. У база даних буде інтелектуально збережено дані лише для моніторингу стану та очищено пам'ять кожного разу, коли навчання алгоритму буде завершено. Потім буде використано підхід, заснований на даних, підхід буде використовуватися для оцінки деградації обладнання та оптимізації результатів в модель відмов для прогнозування технічного обслуговування. Характеристики нової структури ООС (див. рис. 1) можна узагальнити наступним чином: проста та ефективна ООБД для зберігання даних моніторингу стану, машинного навчання, методи використання збережених даних для виявлення деградації та моделі відмов для використання результатів аналізу машинного навчання для забезпечення покращеного технічного обслуговування та надійності.

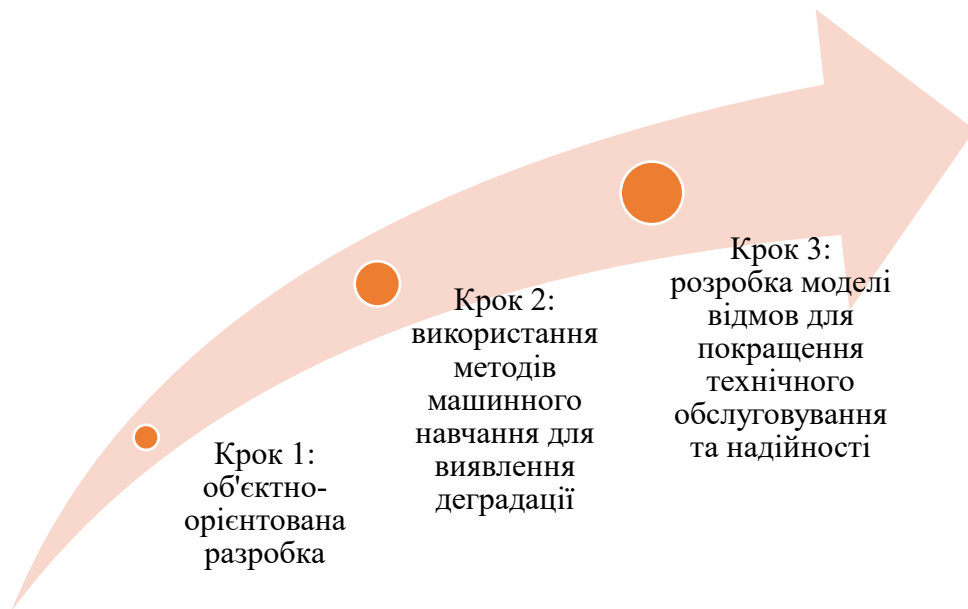


Рисунок 1 – Цільова структура ООС

Після огляду нової структури ООС, першим кроком стала розробка ООБД, щоб мінімізувати будь-які часові затримки через помилки або несумісність, з якими стикаються традиційні бази даних, коли їх використовують разом з методами машинного навчання.

Нова база даних була повністю створена на мові Python з використанням інструментів, наданих ООБД. База даних об'єктів - це ООБД з відкритим вихідним кодом для прозорого та

постійного зберігання об'єктів Python. Оскільки ООБД повністю написана на Python, для роботи з базою даних не потрібна окрема мова, і це не дуже впливає на код, щоб зробити об'єкти стійкими. Крім того, немає ніякої бази даних, яка частково приховує базу даних. Використання ООБД краще, ніж використання об'єктно-реляційного відображення, оскільки в ньому майже немає нічого між кодом і базою даних, а зв'язки між об'єктами обробляються дуже природно, підтримуючи складні об'єктні графи без з'єднань. Як було показано, рішення використання ООБД значно підвищить швидкість взаємодії методів машинного навчання з даними, накопиченими системою.

Наступним кроком був вибір алгоритму, який би зміг визначити, коли виконується умова погіршення роботи механізмів. До цього часу реляційна база даних була найпоширенішою моделлю даних і переважна більшість сучасних систем баз даних базується на цій моделі. Поява домінування об'єктно-орієнтованого програмування в розробці програмного забезпечення та прагнення подолати деякі обмеження реляційної моделі призвели до розвитку об'єктно-орієнтованих баз даних. У запропонованій структурі ООС, база даних використовується в поєднанні з об'єктно-орієнтованим програмуванням. Існує загальновідома проблема між реляційними базами даних та об'єктно-орієнтованим програмуванням, яка називається "об'єктно-реляційна невідповідність". Ця невідповідність може виникнути лише тоді, коли об'єктно-орієнтована програма використовує реляційну базу даних для збереження даних. Замість того, щоб керувати зв'язками за допомогою різних таблиць зі спільними первинними ключами, ООБД дозволяє розробникам використовувати звичайні посилання на об'єкти Python. Таким чином, ООБД не вимагає попередньо визначеної структури стовпців і типів даних для об'єктів, які вона зберігає, що означає, що атрибути об'єктів можуть легко змінюватися як за кількістю, так і за типом. З усього вищесказаного випливає, що використання ООБД в новій структурі ООС є більш ефективним оскільки об'єктно-орієнтовані бази даних розроблені таким чином, що їх можна інтегрувати безпосередньо або без особливих зусиль з програмним забезпеченням, розробленим за допомогою об'єктно-орієнтованих мов програмування. Мета бази даних у запропонованій структурі ООС полягає в тому, щоб максимізувати швидкість методів машинного навчання і не зберігати тисячі непотрібних екземплярів даних. Для цього вона інтелектуально зберігає дані для навчання і стирає їх після того, як вони були використані для навчання алгоритму, звільняючи місце для нових навчальних даних, коли вони потрібні. Саме тому нова база даних отримала назву: База даних моніторингу стану (БДМС).

Як було доведено, рішення про використання ООБД значно підвищить швидкість взаємодії методів машинного навчання з даними, накопиченими системою. Наступним кроком був вибір алгоритму, який би зміг визначити, коли виконується умова погіршення стану механізмів.

ЛФВ - це алгоритм, вперше представлений Бройнігом у 2000 році, і його метою було виявити локальні викиди в наборі даних. Алгоритм не просто класифікує дані у бінарний спосіб, а саме, викиди чи ні, а скоріше присвоює кожній точці даних локальний коефіцієнт викидів, який показує, наскільки точка даних є викидом, щось подібне до кластеризації на основі щільності. Автори спочатку знайшли найменшу гіперсферу з центром у заданих вибірках, яка містила k найближчих сусідів, а ЛФВ обчислювали шляхом ділення k на об'єм гіперсфери. ЛФВ створює границю прийняття рішення з функції прийняття рішення, навченої на навчальному наборі даних який складається зі "звичайних" даних, а потім оцінює, чи є нова точка даних новинкою чи ні. Бажану межу прийняття рішення можна отримати, змінюючи ЛФВ поріг. ЛФВ працює дуже добре у багатьох випадках, часто перевершуючи конкурентів, наприклад, у виявленні мережевих вторгнень та в обробці класифікаційних еталонних даних. На закінчення, велика загальна застосовність, а також продемонстрована ефективність порівняно з іншими алгоритмами алгоритму ЛФВ є причинами того, що його було обрано в якості алгоритму для використання в нашій системі ООС.

Додатковою метою цієї статті є визначення з високою точністю, коли механізм змінює свій стан, за допомогою моніторингу значень, що відображають його стан. Виявлення зміни стану обладнання є дуже важливим для системи ООС, що розробляється. Щоб досягти цього, для

навчання алгоритму машинного навчання потрібні марковані дані, що представляють різні стани машин необхідні для навчання алгоритму машинного навчання. Етап навчання складається з навчання алгоритму на даних, що представляють один стан, з одночасним налаштуванням його параметрів для максимальної точності визначення, коли з'являються дані з різних станів. Потім налаштований алгоритм потрібно протестувати з новими невідомими даними, як для одного стану, так і для різних, і зробити висновок про його точність. Нарешті, цей процес також включає одночасне тестування нового БДМС для зберігання та доступу до даних. Детальну інформацію про судно можна побачити в Таблиці 1.

Таблиця 1. Опис судна

	Проектні характеристики судна
Загальна довжина (м)	140
Водотоннажність (т)	5900
Максимальна швидкість судна (вузли)	27
Двигуни	Газотурбінний LM2500, 32 000 кВт
Гвинти	2

Використання симулятора, перевіреного на реальних даних. Буде використано набір даних з репозиторію UCI (2019), якій є для вільного використання, для навчання, валідації та тестування алгоритму ЛФВ. Набір даних включає 25 ознак (див. Таблицю 2) і для кожного масиву з 25 ознак наведено коефіцієнти для крутного моменту, корпусу, компресора та турбіни.

Всі показники, які опосередковано відображають стан системи, були отримані та збережені в наборі даних для всіх швидкостей судна. Дані для швидкості судна 18 вузлів були використані для навчання, валідації та тестування алгоритму, але аналіз чутливості кінцевої моделі було проведено для всього спектру різних швидкостей судна та експлуатаційних профілів.

Спочатку були зібрані дані для певної швидкості судна (18 вузлів). Потім ці дані були замінені на ті, що представляють ідеальний стан обладнання, і на ті, що представляють всі можливі умови деградації. Ідеальний стан вважається таким коли коефіцієнт зносу обладнання дорівнює одиниці, а інший стан позначається, коли коефіцієнт зносу не дорівнює одиниці. Наступний крок це збереження даних в БДМС. ООБД пропонує ефективний спосіб зберігання об'єктів. Ця структура може ефективно зберігати великі масиви інформації, зберігаючи у пам'яті нещодавно або часто використовувані об'єкти, які нещодавно або інтенсивно використовувалися, зберігаються у кеші пам'яті для прискорення роботи. Крім того, пошук по всій базі даних можна здійснювати дуже швидко, оскільки об'єкти зберігаються у збалансованій деревоподібній структурі даних. VTrees є ефективною структурою для зберігання великих обсягів інформації. VTrees бувають різних типів, наприклад, OOVTrees та IOVTrees. Перший тип оптимізовано для використання об'єктів як ключів, так і значень, а другий - для використання цілих чисел як ключів, а об'єктів як значень. Процес створення БДМС можна описати наступним чином: створіть кореневий об'єкт, щоб ініціювати бази даних та використання IOVTree для ефективного зберігання даних у кореневому об'єкті. Дані були успішно збережені до нової архітектури БДМС та алгоритму машинного навчання використовували дані безпосередньо звідти з максимальною швидкістю, оскільки алгоритм і база даних були побудовані на мові Python.

Таблиця 2 – Виміряні характеристики

	Одиниці
Положення важеля	[]
Швидкість	[вузли]
Крутний момент на валу	[кН м]
Швидкість	[об/хв]
Тяга (правий борт)	[Н]
Тяга (порт)	[Н]
Крутний момент на валу (порт)	[кН м]
Частота обертання валу (порт)	[об/хв]
Крутний момент на валу (правий борт)	[кН м]
Частота обертання на валу (правий борт)	[об/хв]
Температура на виході	[°C]
Швидкість газогенератора	[об/хв]
Витрата палива	[кг/с]
Сигнал керування	[%]
Тиск повітря на виході	[бар]
Температура повітря на виході	[°C]
Зовнішній тиск	[бар]
Тиск на виході, л.с.	[бар]
Керуючий сигнал	[]
Коефіцієнт тяги (правий борт)	[]
Швидкість (правий борт)	[об/хв]
Коефіцієнт тяги (порт)	[]
Швидкість (порт)	[об/хв]
Крутний момент порт)	[кН м]
Крутний момент (правий борт)	[кН м]

На Рисунку 2 показано виконані етапи експерименту. Алгоритм навчався лише на значеннях, що представляють певний стан (ідеальний), а потім він був перевірений та протестований, як для прогнозування зміни стану, так і для прогнозування того, чи стан не змінився. Експеримент проводився двічі, один раз для компресора і один раз для турбіни.



Рисунок 2 – Етапи проведення експерименту

Метрикою, що використовувалася для визначення ефективності алгоритму, були точність передбачення, коли умова була змінена, і точність передбачення, коли умова залишалася незмінною. Точність визначається за формулою (1).

$$\text{Точність} = \frac{\text{Кількість правильних прогнозів}}{\text{загальна кількість прогнозів}} \quad (1)$$

Де чисельник в (1) означає кількість правильних прогнозів алгоритму, а знаменник - загальну кількість передбачень (включаючи помилкові).

Для експерименту 80% даних, що представляють деградацію, були використані для валідації а решту - для тестування. Щодо кількості навчальних даних, то з ідеального стану, 80% було використано для навчання, 10% - для валідації і 10% - для тестування. Мета використання валідаційного набору полягає в тому, щоб мати можливість встановити найкращі гіперпараметри для алгоритму ЛФВ з максимальною точністю. Найважливішими гіперпараметрами є k для виконання k -NN кластеризації та параметр "забруднення", який допомагає краще встановити порогове значення для границі.

Після того, як було визначено постановку експерименту, наступні кроки полягали у виконанні навчання та валідації алгоритму, визначення найкращих параметрів для найвищої точності та використання фінального алгоритму на тестовому наборі даних. Крім того, були потрібні подальші експерименти з меншою кількістю навчальних даних, щоб дослідити вплив, який впливає кількість навчальних даних на точність моделі. Нарешті, аналіз чутливості був проведений для всіх експлуатаційних профілів судна.

Параметри алгоритму, які були налаштовані, так: кількість сусідів та величина забруднення. Перший параметр - це мінімальна кількість точок даних, які можуть утворювати кластери в навчальному наборі даних. Другий параметр - це частка викидів у навчальному наборі даних, задана у відсотках, наприклад, значення 0.1 означає 10% забруднення. При підборі він використовується для визначення порогу прийняття рішення яка визначатиме, чи є нова точка даних аномальною, чи ні. Найкращі значення параметрів алгоритму виявилися однаковими як для турбінного, так і для компресорного експериментів, що свідчить про те, що ці параметри мають загальну застосовність до конкретної задачі. Це важливий результат, який означає, що налаштований алгоритм може бути застосований до різного обладнання для виявлення зносу, якщо його навчити на даних про його поточний стан. На Рис. 3 показано точність експерименту з компресором. Алгоритм відмінно працює з середньою точністю для правильного передбачення, якщо умова має змінитися чи ні, становить 92%.



Рисунок 3 – Результати експерименту для компресора

На Рис. 4 показано точність експерименту з турбіною. Алгоритм знову працює дуже добре із середньою точністю для правильного передбачення, якщо виконується умова змінилася чи ні, 90%. Висока точність обох експериментів запевняє нас, що алгоритм виявить будь-яке відхилення від поточного стану техніки.




Рисунок 4 – Результати експерименту для турбіни

Точність експериментів відноситься до певної кількості навчальних даних. У експерименті було використано приблизно 6550 прикладів для обох випадків (6550 для компресора та 6554 для турбіни). Цікаво дослідити, чи можна зменшити кількість даних так, щоб навчання алгоритму може бути швидшим. Як видно з Рис. 5, для того, щоб мати хоча б 80% точності у правильному визначенні як однієї умови, так і іншої, алгоритм потребує щонайменше 5000 тренувальних даних.




Рисунок 5 – Вплив навчальних даних на точність моделі

Однак використання 6550 навчальних даних дасть суттєво вищу точність (+10%) і йому слід надавати перевагу (Рис. 6). Переходячи до турбіни, Рис. 5 показує результати, подібні до результатів для компресора. Здається, що для досягнення 80% точності моделі потрібно щонайменше 5000 точок даних точності, що також вказує на те, що поріг у 6550 точок даних також може бути застосований і в цьому випадку. Експерименти, проведені щодо кількості навчальних даних, необхідних для достатньої точності, показують, що поріг 6550 навчальних даних необхідний для прийнятної відсоток точності. Проте, оскільки майже половина даних відноситься до різних умов, але не умови, які вважаються погіршенням, очікується, що кількість навчальних даних для розуміння погіршення умов буде набагато меншою в реальності. Подальше тестування з даними, зібраними з датчиків на борту комерційних суден допоможе встановити цей поріг з більшою впевненістю.

Оскільки швидкість судна використовувалася як параметр, що вказує на експлуатаційний профіль судна, важливо подивитися, як алгоритм працює на різних швидкостях судна.

Слід зазначити, що для кожного операційного профілю алгоритм навчається заново, з параметрами, які були встановлені. Це означає, що в цьому експерименті немає валідаційного набору. Доступні швидкості суден у базі даних такі: 3, 6, 9, 12 вузлів.

На Рисунку 7 показано результати аналізу чутливості для компресора. Середнє значення точність правильного визначення зміни стану і того, що стан є однаковим для всіх швидкостей становить 94% і 89% відповідно. Це дає в цілому 92% точність і показує узгодженість алгоритму з різними експлуатаційними профілями.




Рисунок 6 – Вплив навчальних даних на точність моделі




Рисунок 7 – Точність для різних швидкостей судна для компресора

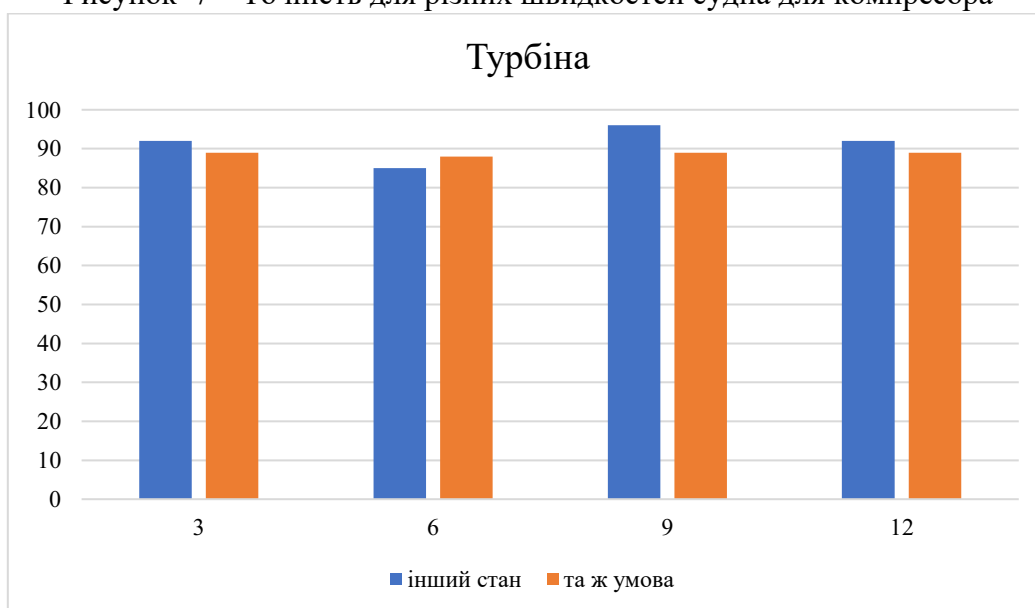


Рисунок 8 – Точність для різних швидкостей судна для турбіни

З іншого боку, результати для турбіни можна побачити на Рис. 8. Тут середні значення точності визначення зміни чи ні для всіх швидкостей становить 90% і 88% відповідно. Це дає в цілому 89% загальної точності, що знову ж таки вказує на достатню кількість точності для всіх операційних профілів. В цілому, аналіз чутливості довів, що алгоритм є достатньо надійним, щоб працювати з високою точністю у всіх експлуатаційних профілях судна, як для турбіни, так і для компресора. Це означає, що його можна використовувати для безперервного моніторингу деградації обладнання в усіх експлуатаційних режимах судна і таким чином підвищуючи надійність і точність системи діагностики і прогнозування.

Висновки. У цій статті представлено нову структуру БДМС, яка поєднує об'єктно-орієнтовану базу даних, методи машинного навчання та систему діагностики і прогнозування. Основні частини цієї системи були протестовані на даних, що відображають процес деградації компресора та турбіни суднової енергетичної установки. Експериментальні результати показали, що алгоритм з високою точністю виявляє зміни стану обох типів обладнання. Крім того, той факт, що налаштований алгоритм демонстрував стабільні параметри для турбіни та компресора, підтверджує його універсальність і можливість застосування до різних машин. Аналіз чутливості виявив, що експлуатаційний профіль судна не впливає на точність прогнозування, незалежно від швидкості руху. Також дослідження підтвердило важливість кількості навчальних даних для ефективності алгоритму, проте подальші експерименти з реальними даними можуть показати зниження мінімального необхідного порогу. Отримані результати підтверджують ефективність запропонованої системи моніторингу судових механізмів у реальному часі. Вона має значні переваги перед традиційними методами технічного обслуговування, що відкриває перспективи для широкого впровадження в морській галузі.

ЛІТЕРАТУРА

1. Головань, А. І. (2023). Концептуальна модель планування та оптимізації графіків технічного обслуговування вантажних суден. *Vodnij Transport*, 1(37), 107–115. <https://doi.org/10.33298/2226-8553.2023.1.37.12>
2. Maione, F., Lino, P., Maione, G., & Giannino, G. (2024). A Machine Learning Framework for Condition-Based Maintenance of Marine Diesel Engines: A Case study. *Algorithms*, 17(9), 411. <https://doi.org/10.3390/a17090411>
3. Jimenez, V. J., Bouhmala, N., & Gausdal, A. H. (2020). Developing a predictive maintenance model for vessel machinery. *Journal of Ocean Engineering and Science*, 5(4), 358–386. <https://doi.org/10.1016/j.joes.2020.03.003>
4. Yigin, B., & Celik, M. (2024). A prescriptive model for failure analysis in ship machinery monitoring using generative adversarial networks. *Journal of Marine Science and Engineering*, 12(3), 493. <https://doi.org/10.3390/jmse12030493>
5. Kocak, G., Gokcek, V., & Genc, Y. (2023). Condition Monitoring and Fault Diagnosis of a Marine Diesel Engine with Machine Learning Techniques. *Pomorstvo*, 37(1), 32–46. <https://doi.org/10.31217/p.37.1.4>
6. Vorkapić, A., Radonja, R., Babić, K., & Martinčić-Ipšić, S. (2020). MACHINE LEARNING METHODS IN MONITORING OPERATING BEHAVIOUR OF MARINE TWO-STROKE DIESEL ENGINE. *Transport*, 35(5), 462–473. <https://doi.org/10.3846/transport.2020.14038>
7. Elijah, O.; Ling, P.A.; Rahim, S.K.A.; Geok, T.K.; Arsad, A.; Kadir, E.A.; Abdurrahman, M.; Junin, R.; Agi, A.; Abdulfatah, A.M.Y. A Survey on Industry 4.0 for the Oil and Gas Industry: Upstream Sector. *IEEE Access* 2021, 9, 144438–144468
8. Angelopoulos, A.; Giannopoulos, A.; Nomikos, N.; Kalafatelis, A.; Hatziefremidis, A.; Trakadas, P. Federated Learning-Aided Prognostics in the Shipping 4.0: Principles, Workflow, and Use Cases. *IEEE Access* 2024, 12, 6437–6454
9. Aslam, S.; Michaelides, M.P.; Herodotou, H. Internet of Ships: A Survey on Architectures, Emerging Applications, and Challenges. *IEEE Internet Things J.* 2020, 7, 9714–9727

10. Lexau, S.J.N.; Breivik, M.; Lekkas, A.M. Automated Docking for Marine Surface—A survey. *IEEE Access* 2023, 11, 132324–132367
11. Hasan, A.; Widyotriatmo, A.; Fagerhaug, E.; Osen, O. Predictive Digital Twins for Autonomous Ships. In *Proceedings of the 2023 IEEE Conference on Control Technology and Applications (CCTA)*, Bridgetown, Barbados, 16–18 August 2023; pp. 1128–1133

REFERENCES

1. Golovan, A. I. (2023). Conceptual model of planning and optimization of cargo ship maintenance schedules. *Vodnij Transport*, 1(37), 107-115. <https://doi.org/10.33298/2226-8553.2023.1.37.12>
2. Maione, F., Lino, P., Maione, G., & Giannino, G. (2024). A Machine Learning Framework for Condition-Based Maintenance of Marine Diesel Engines: A Case study. *Algorithms*, 17(9), 411. <https://doi.org/10.3390/a17090411>
3. Jimenez, V. J., Bouhmala, N., & Gausdal, A. H. (2020). Developing a predictive maintenance model for vessel machinery. *Journal of Ocean Engineering and Science*, 5(4), 358–386. <https://doi.org/10.1016/j.joes.2020.03.003>
4. Yigin, B., & Celik, M. (2024). A prescriptive model for failure analysis in ship machinery monitoring using generative adversarial networks. *Journal of Marine Science and Engineering*, 12(3), 493. <https://doi.org/10.3390/jmse12030493>
5. Kocak, G., Gokcek, V., & Genc, Y. (2023). Condition Monitoring and Fault Diagnosis of a Marine Diesel Engine with Machine Learning Techniques. *Pomorstvo*, 37(1), 32–46. <https://doi.org/10.31217/p.37.1.4>
6. Vorkapić, A., Radonja, R., Babić, K., & Martinčić-Ipšić, S. (2020). MACHINE LEARNING METHODS IN MONITORING OPERATING BEHAVIOUR OF MARINE TWO-STROKE DIESEL ENGINE. *Transport*, 35(5), 462–473. <https://doi.org/10.3846/transport.2020.14038>
7. Elijah, O.; Ling, P.A.; Rahim, S.K.A.; Geok, T.K.; Arsad, A.; Kadir, E.A.; Abdurrahman, M.; Junin, R.; Agi, A.; Abdulfatah, A.M.Y. A Survey on Industry 4.0 for the Oil and Gas Industry: Upstream Sector. *IEEE Access* 2021, 9, 144438–144468
8. Angelopoulos, A.; Giannopoulos, A.; Nomikos, N.; Kalafatelis, A.; Hatziefremidis, A.; Trakadas, P. Federated Learning-Aided Prognostics in the Shipping 4.0: Principles, Workflow, and Use Cases. *IEEE Access* 2024, 12, 6437–6454
9. Aslam, S.; Michaelides, M.P.; Herodotou, H. Internet of Ships: A Survey on Architectures, Emerging Applications, and Challenges. *IEEE Internet Things J.* 2020, 7, 9714–9727
10. Lexau, S.J.N.; Breivik, M.; Lekkas, A.M. Automated Docking for Marine Surface—A survey. *IEEE Access* 2023, 11, 132324–132367
11. Hasan, A.; Widyotriatmo, A.; Fagerhaug, E.; Osen, O. Predictive Digital Twins for Autonomous Ships. In *Proceedings of the 2023 IEEE Conference on Control Technology and Applications (CCTA)*, Bridgetown, Barbados, 16–18 August 2023; pp. 1128–1133

Honcharuk I.P., Golovan A.I.

INNOVATIVE MACHINE LEARNING SYSTEM FOR REAL-TIME MONITORING OF SHIPBOARD EQUIPMENT

This article presents an innovative online condition monitoring system. It consists of a new object-oriented database, a machine learning algorithm, and a detailed model for predicting equipment failures. The condition monitoring database, which is an object-oriented database built entirely in Python, was developed to avoid any relational-object mismatch problems that often arise when using relational databases in complex applications using machine learning techniques. The database will intelligently store data from various sensors and then organize the data into a pipeline to the diagnostic and prognostic

system, offering a continuous assessment of the condition of ship's machinery with high speed and accuracy. The proposed condition-based maintenance system is based on detecting changes in equipment condition in real time, using a local deviation factor algorithm to detect novelty. Training, validation, and testing of the algorithm were performed using data on the degradation of the power plant. The results show that once the algorithm was tuned, it detected with high accuracy when the mechanical system changes state for both the turbine and compressor, and for different ship operating profiles.

Keywords: *technical condition, monitoring, forecasting, real-time, object-oriented database, machine learning, artificial intelligence, local deviation factor, ship's machinery, mechanisms, ship.*

Стаття прийнята 01.03.2025