

УДК 681.518:004

DOI <https://doi.org/10.32689/maup.it.2025.1.3>**Надія БОЛЮБАШ**

кандидат педагогічних наук, доцент,

доцент кафедри інтелектуальних інформаційних систем,

Чорноморський національний університет імені Петра Могили, Nadiya.Bolubash@chmnu.edu.ua

ORCID: 0000-0002-2274-2422

Олександра ФІНЬКОВАмагістрантка кафедри інтелектуальних інформаційних систем, Чорноморський національний університет імені Петра Могили, foruw.af@gmail.com

ORCID: 0009-0007-1941-4042

АНАЛІЗ ПОКАЗНИКІВ СЕНСОРІВ ДЛЯ ПРОГНОЗНОГО ТЕХНІЧНОГО ОБСЛУГОВУВАННЯ ТЕХНОЛОГІЧНИХ ЛІНІЙ ВАЖКОЇ ПРОМИСЛОВОСТІ

Анотація. У статті розглянуто напрями цифрової трансформації технічного обслуговування технологічних ліній важкої промисловості, спрямовані на передбачення потенційної несправності обладнання до його повної функціональної відмови. Обґрунтовано вибір методів виявлення проблемних даних, що надходять від сенсорів технологічної лінії, націлених на зменшення інтервалу часу між виникненням проблеми та її виявленням. Розглянуто підходи до забезпечення оптимального оновлення даних моделей Predictive Maintenance, які забезпечують кращу точність прогнозування відмов.

Метою статті є дослідження та виявлення ефективних методів аналізу якості даних показників сенсорів технологічних ліній у важкій промисловості для підвищення точності прогнозування поломок при проведенні прогнозного технічного обслуговування.

Методологія. Проаналізовано програмно-апаратні рішення, спрямовані на підвищення точності прогнозу несправностей технологічних ліній, що базуються на RCM-методології. Використано методи кореляційного аналізу даних, описової та контекстної статистики для моніторингу даних показників сенсорів. Запропоновано послідовність етапів виявлення проблемних даних в умовах реального виробництва на підприємствах важкої промисловості, які забезпечують автоматизовану генерацію їх потенційних джерел.

Наукова новизна дослідження полягає у виявленні в умовах Industry 4.0 методів і підходів до аналізу показників сенсорів технологічних ліній, спрямованих на підвищення точності моделей прогнозного технічного обслуговування.

Висновки. Супроводження прогнозних моделей Predictive Maintenance, які обслуговують технологічні лінії важкої промисловості, в умовах реального виробництва вимагає здійснення коригування та оновлення їх параметрів на основі постійного моніторингу стану обладнання у режимі реального часу. Для забезпечення виявлення проблемних даних обґрунтовано доцільність розробки інформаційної системи, яка реалізує аналіз даних показників сенсорів із застосуванням методів описової, контекстної статистики та кореляційного аналізу даних. Результати впровадження розробленої інформаційно-аналітичної системи, яка включає в себе рекомендаційну систему на етапі формування набору даних для аналізу, супроводжувалися підвищенням точності прогнозування несправностей і зменшенням часу між виникненням та виявленням проблем, які призводять до відмови обладнання. Що свідчить про вирішення експлуатаційних задач із більш високою точністю та ефективністю.

Ключові слова: технологічна лінія, прогнозне технічне обслуговування, прогнозне технічне обслуговування на основі стану, прогнозна модель, описова статистика, контекстна статистика, кореляційний аналіз.

Nadiia BOLIUBASH, Oleksandra FINCOVA. ANALYSIS OF SENSOR INDICATORS FOR PREDICTIVE MAINTENANCE OF HEAVY INDUSTRY PROCESS LINES

Abstract. The article considers the directions of digital transformation in the maintenance of process lines of heavy industry, aimed at predicting potential equipment malfunctions before their complete functional failure. The choice of methods for detecting problematic data coming from sensors of the process line is justified, aimed at reducing the time interval between the occurrence of a problem and its detection. Approaches to ensuring optimal updates of Predictive Maintenance models are considered, which enhance the accuracy of failure prediction.

The purpose of the article is to research and identify effective methods for analyzing the quality of data from sensors of process lines in heavy industry to increase the accuracy of failure prediction in predictive maintenance.

Methodology. Software and hardware solutions aimed at increasing the accuracy of forecasting faults in process lines based on the RCM methodology have been analyzed. Methods of correlation analysis, descriptive and contextual statistics were used to monitor sensor indicator data. A sequence of stages for detecting problematic data in real-world production conditions in heavy industry is proposed, which provide automated generation of potential sources of faults.

The scientific novelty of the research lies in the identification of methods and approaches to analyzing the performance of sensors of process lines in the conditions of Industry 4.0, aimed at increasing the accuracy of predictive maintenance models.

Conclusions. Maintaining Predictive Maintenance models that serve heavy industry process lines in real production conditions requires adjusting and updating their parameters based on constant monitoring of the equipment status in real time. To ensure the detection of problematic data, the feasibility of developing an information system, implementing the analysis of sensor indicators data using descriptive statistics, contextual statistics, and correlation analysis methods. The

results of implementing the developed information and analytical system, which includes a recommendation system at the stage of forming a data set for analysis, were accompanied by an increase in failure prediction accuracy and a decrease in the time between the occurrence and detection of problems leading to equipment failures. This indicates that operational tasks are being solved with higher accuracy and efficiency.

Key words: process line, predictive maintenance, condition-based predictive maintenance, predictive model, descriptive statistics, contextual statistics, correlation analysis.

Постановка проблеми та аналіз останніх досліджень і публікацій. В умовах високих темпів інформатизації сучасного суспільства здійснюється реалізація Industry 4.0 – четвертої промислової революції, яка передбачає перехід до автоматизованого цифрового виробництва під управлінням інтелектуальних систем у режимі реального часу [2, 13]. Поява технології промислового Інтернету речей (англ. Industrial Internet of Things, IIoT) суттєво оптимізувала управління промисловими операціями шляхом підключення промислових активів до інформаційних систем [10]. У рамках Industry 4.0 та IIoT широко розповсюдженням у різних сферах виробництва є застосування для обслуговування технологічних ліній прогресивних стратегій технічного обслуговування, які базуються на RCM-методології (англ. Reliability Centered Maintenance) [7]. Ця методологія спрямована на забезпечення надійності обладнання шляхом недопущення відхилення параметрів стану обладнання до критичних значень, які можуть призвести до поломки.

Технологічні лінії є сукупністю машин та апаратів, сполучених транспортними пристроями, які утворюють єдиний технологічний ланцюг виробничого процесу, специфічний для кожної індустрії та підприємства. Технічне обслуговування забезпечує надійну та ефективну роботу технологічних ліній, а для відслідковування роботи їх пристрої та обладнання забезпечені сенсорами. Традиційні підходи до технічного обслуговування включають реактивне, коригувальне та профілактичне обслуговування [8]. Реактивне обслуговування відбувається у разі повної поломки обладнання, коригувальне – коли проблема виявлена, але збою в роботі ще немає. Профілактичне обслуговування включає регулярні за встановленим графіком перевірки роботи обладнання.

У важкій промисловості застосування традиційних підходів є високо затратним за рахунок високої вартості обладнання технологічних ліній та значних фінансових втрат під час їх простою і перерв у виробництві. Тут доцільно застосовувати більш прогресивні підходи – прогнозне технічне обслуговування (англ. Predictive Maintenance, PdM), яке використовує дані показників сенсорів і дані про несправності, щоб заздалегідь передбачити майбутню потенційну непрацездатність обладнання [9, 19]. Такий підхід дозволяє на основі сукупних даних, що надходять від сенсорів технологічної лінії, яка є в експлуатації, здійснити прогнозування майбутньої деградації та відмови обладнання. Це надає можливість виконати технічне обслуговування до того, як станеться критичний збій [5, 16].

Прогнозне технічне обслуговування є актуальною темою наукових досліджень, що обумовлено зростанням кількості промислових об'єктів та даних, які отримуються від різноманітного обладнання технологічних ліній. Сучасні дослідження науковців у сфері Predictive Maintenance націлені на створення моделей прогнозування відмов і зосереджені навколо таких основних підходів [2]: на основі чіткого математичного опису фізичних моделей деградації обладнання [11], на основі методів, керованих даними, отриманими від моніторингу стану обладнання [4, 22], на основі гібридних методів, які поєднують елементи перших двох підходів [23].

На підприємствах важкої промисловості прогносні моделі (англ. Predictive Models) в рамках PdM частіше всього реалізують за допомогою методів, керованих даними та з використанням гібридних підходів [9]. Створення і розгортання таких моделей включає збір великих обсягів даних показників сенсорів, їх попередню обробку, проведення аналізу даних із метою виявлення аномалій та здійснення діагностики – чи свідчать виявлені аномалії про несправність, яка може призвести до відмови обладнання. Реалізація кожного з цих етапів життєвого циклу моделі прогнозування відмов базується на застосуванні різних методів і алгоритмів машинного навчання (англ. Machine Learning), інтелектуального аналізу даних (англ. Data Mining), штучного інтелекту (англ. Artificial Intelligence) та статистики [2]. Інтеграція таких моделей у робочі процеси підприємства важкої промисловості включає систему оповіщення працівників технічного обслуговування технологічних ліній у разі виявлення будь-яких аномалій обладнання у вигляді чітких протоколів реагування та попередження.

Однак моделі, які здійснюють прогнозування збоїв та поломки у роботі обладнання, в умовах реального виробництва стикаються з необхідністю постійного оновлення їх параметрів. Це обумовлено як зміною технічних характеристик пристроїв та обладнання технологічних ліній у процесі їх експлуатації, так і наявністю не врахованих при створенні моделі факторів, які є важливими для виявлення аномалій. Для вирішення цієї проблеми здійснюється прогнозне технічне обслуговування на основі стану (англ. Condition-based Predictive Maintenance, CBPdM), відоме також як Maintenance 4.0, яке підтримує рішення прогнозного технічного обслуговування залежно від процесу моніторингу стану технологічної

лінії [18]. CBPdM передбачає аналіз даних показників сенсорів, зібраних під час моніторингу, із метою виявлення проблемних даних, які можуть впливати на точність моделі при прогнозуванні можливих відмов у роботі технологічних ліній. Із урахуванням цієї аналітики відбувається оновлення прогнозних моделей та забезпечується уникнення збоїв у їх роботі.

Як зазначають практики, які займаються розробкою та впровадженням прогнозних моделей, регулярна перевірка та налаштування моделей із використанням нових даних для кращої точності прогнозів є одним із ключових етапів їх обслуговування [13]. Це передбачає співпрацю як фахівців Data Science, які створюють, впроваджують та супроводжують прогнозні моделі, так і практиків, які обслуговують певну технологічну лінію.

Ефективність моделей залежить від якості даних, а проблеми, пов'язані з їх точністю, повнотою та узгодженістю є суттєвим фактором, який впливає на вчасне виявлення потенційних несправностей обладнання та оптимізацію технічного обслуговування. Тому критично важливим для оновлення і коригування параметрів прогнозних моделей є виявлення проблем із даними та обґрунтування вибору методів для проведення їх якісної аналітики. Однак практична реалізація методів такого аналізу як невід'ємного компонента CBPdM не є достатньо вивченою і потребує подальшого опрацювання. Це обумовило **мету статті**, яка полягає у дослідженні та виявленні ефективних методів аналізу якості даних показників сенсорів технологічних ліній у важкій промисловості для підвищення точності прогнозування поломок при проведенні прогнозного технічного обслуговування.

Виклад основного матеріалу. Прогнозне технічне обслуговування використовує часові ряди історичних даних і даних про несправності, які надходять від сенсорів, щоб заздалегідь передбачити проблеми із працездатністю обладнання. Це дозволяє підприємствам оптимізувати планування технічного обслуговування та підвищити надійність технологічних ліній.

Впровадження прогнозних моделей на підприємствах важкої промисловості сьогодні ще не має стандартної еталонної архітектури. Вивчаючи основні компоненти технології PdM, вчені зосереджують увагу на виявленні аномалій, діагностиці та прогнозі майбутньої несправності. CBPdM стежить за процесами збору, вилучення та попередньої обробки даних, щоб підтримувати прийняття рішень за допомогою інформації про стан працездатності системи. Інформацію, отриману в результаті процесу виявлення проблем із якістю даних, можна використовувати на рівні PdM для кращого опису працездатності системи та більш точного прогнозу майбутньої поломки [18].

Для кожної технологічної лінії прогнозна модель зосереджена на якнайшвидшому виявленні сигнатур майбутньої несправності, зафіксованих даними сенсорів, за рахунок зменшення інтервалу часу між виникненням проблеми та її виявленням, коли повної відмови обладнання ще не відбулося [9, 16]. Поширеним способом відображення поведінки обладнання до того, як сталася фактична функціональна несправність, яка приводить до зупинки технологічної лінії, є P-F крива (рис. 1), де S є час виникнення проблеми, P – час її виявлення, а F – час повної відмови обладнання. Застосування Condition-based Predictive Maintenance націлене на максимізацію інтервалу P-F на цій кривій та, відповідно, мінімізацію інтервалу S-P [5].




Рис. 1. P-F крива поведінки обладнання від початку поломки до повної функціональної відмови

Вчені, які досліджують PdM і CBPdM, зазначають, що використання аналітики даних покращує продуктивність і точність моделей прогнозного технічного обслуговування, а також підвищує їх автономність та адаптивність у складних динамічних робочих середовищах [20]. Для обґрунтування вибору методів проведення аналізу якості даних для коригування та оновлення параметрів моделей було здійснено дослідження наявних проблем із даними показників сенсорів технологічних ліній.

Для складних технологічних ліній існує широкий діапазон типів поломок, виявлення яких у комплексі суттєво підвищує якість прогнозової моделі [6]. Аналіз сучасних досліджень науковців та практиків у сфері прогнозного обслуговування технологічних ліній дозволив виявити можливі джерела проблем із якістю даних. В умовах реального виробництва та експоненційного росту обсягів даних похибки можуть бути обумовлені:

- недосконалою конфігурацією сенсорів технологічної лінії – наявністю сенсорів, дані з яких не несуть інформацію, яка може бути використана для прогнозування несправностей та відсутністю у певних компонентів сенсорів, необхідних для прогнозування відмов [21]: виявлення цієї проблеми вимагає встановлення сенсорів, яких не вистачає та виключення з аналізу даних від сенсорів, які не є суттєвими для виявлення несправностей;
- неналежним калібруванням сенсорів, що спотворює дані, які надходять від них [20]: використання сенсорів потребує їх калібрування при встановленні та періодично у процесі експлуатації на основі досконало розроблених протоколів, які забезпечують точність вимірів та відповідність стандартам;
- наявністю надмірних даних, що обумовлено великою кількістю сенсорів або частою фіксацією значень показників, які надходять від окремих сенсорів [17]: це вимагає застосування методів зменшення розмірності даних або методів агрегації даних на етапі їх попередньої обробки;
- недостатньою інтеграцією IoT-систем та перебоями у їх підключенні, що спричиняє наявність фрагментарних, неповних потоків даних, відсутність синхронізації даних у режимі реального часу [3, 14], неузгодженість даних сенсорів [10, 15]: виявлення таких проблем потребує інтеграції розподілених систем для збору високоточних даних та управління ними, забезпечення синхронізації при проведенні аналізу режимів роботи, для яких характерні відмови у роботі обладнання;
- високою варіативністю даних [17], зовнішніми впливами, які спричиняють шум в даних [14, 15, 17]: виявлення цих проблем вимагає застосування методів, які враховують операційні відмінності між промисловими установками та методів зменшення й усунення шуму на етапі попередньої обробки даних;
- недостатньою деталізацією даних для точних прогнозів [15], низькою роздільною здатністю (англ. resolution) сенсорів, наявністю пропусків у даних [20]: це потребує здійснення коригувань у налаштуваннях чутливості сенсорів та застосування методів для заповнення пропущених даних;
- дублюванням даних, неналежним чином врахованою залежністю даних, які надходять від обладнання: для виявлення цих проблем необхідним є проведення кореляційного аналізу даних показників сенсорів;
- дисбалансом у даних, обумовленим домінуванням часу нормальної роботи та наявністю рідкісних несправностей, що ускладнює прогнозування відмов: усунення такого роду проблем потребує при зборі даних адекватно враховувати проміжки часу, які містять несправності.

Проблеми, які впливають на точність моделей прогнозування відмов, охоплюють різноманітні аспекти якості та кількості даних на кожному з етапів функціонування технологічної лінії. Запропоновані для покращення точності прогнозів і ефективності систем PdM дослідниками апаратно-програмні рішення потребують здійснення аналізу великих обсягів даних, які надходять від усіх сенсорів технологічної лінії.

Проведений аналіз останніх досліджень та публікацій дозволив обґрунтувати вибір статистичних методів, які доцільно застосувати для виявлення проблем із якістю даних. Для здійснення моніторингу показників сенсорів було створено інформаційну систему, адаптовану для виявлення проблемних даних на різних технологічних лініях важкої промисловості [1], яка реалізує аналітику даних у реальному часі та історичних даних сенсорів із застосуванням описової статистики, контекстної статистики та кореляційного аналізу даних. Послідовність етапів аналізу показників сенсорів для прогнозного обслуговування технологічних ліній із використанням розробленої інформаційно-аналітичної системи продемонстровано на рисунку 2.

Розробку web-застосунку системи здійснено з використанням мови програмування Python та фреймворку Flask. Для створення інтерактивних інформаційних панелей було застосовано аналітичний фреймворк Plotly Dash, який на основі використання у зв'язці Flask, React.js, Plotly.js, HTML та CSS дозволив реалізувати візуалізацію моніторингу даних зі зворотними викликами (англ. callbacks), що враховують оновлення даних. Такий підхід надав можливість зручно використовувати аналітичну потужність

Python-бібліотек Pandas, NumPy та Plotly для представлення результатів проведеного аналізу у вигляді гістограм, теплових карт коефіцієнтів кореляції, часових рядів показників сенсорів із позначенням пропусків і періодів завмерлих даних.




Рис. 2. Етапи аналізу показників сенсорів технологічної лінії у розробленій інформаційно-аналітичній системі

Автоматичне створення звітів із результатами проведеного статистичного аналізу було реалізовано за допомогою бібліотеки Pandas-profiling. Графічний інтерфейс web-застосунку створено з використанням бібліотеки Dash Bootstrap Components [12], яка полегшила реалізацію стилю зі складним, адаптивним макетом при відображенні аналітичних блоків, таблиць і фільтрів.

У системі аналізу показників сенсорів технологічних ліній для зберігання даних передбачено використання баз даних Amazon Web Services (AWS) та серверу інформаційної системи. Інформація у вигляді великих обсягів хронологічної послідовності показників сенсорів – часових рядів, зберігається у хмарному сховищі Amazon S3 Bucket. Метадані про сенсори зберігаються на Amazon S3 в форматі JSON і включають: першу та останню дати часового ряду показників сенсорів, список пропусків даних, статистичні характеристики часових проміжків у часовому ряді (мінімальний, максимальний, медіана).

Аналіз даних у сховищі Amazon S3 здійснюється стандартними засобами SQL із використанням інтерактивного сервісу запитів Amazon Athena, який підтримує розподілену обробку даних великих обсягів.

Обрані для аналізу дані та метадані, отримані з хмарного середовища AWS, після обробки зберігаються в СУБД PostgreSQL та на сервері розробленої інформаційно-аналітичної системи. Результати проведеного аналізу у вигляді розрахованих статистичних показників, необхідних для відображення у вигляді таблиць та графіків, зберігаються в форматах .pcl та .parq на сервері системи. Для спрощення роботи з реляційними базами даних було використано Python-бібліотеку SQLAlchemy, для паралельної обробки великих обсягів даних на внутрішніх серверах – Python-бібліотеку multiprocessing. Описаний підхід до зберігання та обробки даних дозволив мінімізувати навантаження на головні сервери і витрати на звернення до AWS. Обраний стек технологій забезпечує ефективну масштабовану обробку і зберігання великих обсягів даних, а також реалізацію статистичних методів і візуалізацію результатів аналізу.

У системі реалізовано розрахунок наступних показників для кожного сенсора: кількість і відсоток окремих варіантів значень, кількість і відсоток нульових та від'ємних значень. Для технологічних ліній з уніфікованим моніторингом розраховують кількість і відсоток наявних та пропущених значень.

Для вибірки значень показників кожного сенсора передбачено розрахунок та виведення стандартних показників описової статистики:

- загальна кількість значень N , мінімальне $X_{\min}$ та максимальне значення $X_{\max}$;
- медіана та середнє арифметичне значення $\bar{X}$;
- розмах значень $R = X_{\max} - X_{\min}$, процентилі $P_5, P_{25}, P_{75}, P_{95}$;
- міжквартильний розмах:

$$IPQ = Q_3 - Q_1, \quad (1)$$

де $Q_3 = P_{75}, Q_1 = P_{25}$;

- середнє абсолютне відхилення (англ. Mean Absolute Deviation):

$$MAD = \frac{1}{N} \sum_{i=1}^N |X_i - \bar{X}|, \quad (2)$$

де X_i – i -те значення показника сенсора;

- дисперсія σ^2 (англ. Variance) та середньоквадратичне відхилення (англ. Standard Deviation) σ , де:

$$\sigma^2 = \frac{(X_i - \bar{X})^2}{N-1}; \quad (3)$$

- гістограма розподілу та таблиця із кількістю 20 найуживаніших значень.

Реалізовано розрахунок коефіцієнтів:

- варіації (англ. Variation):

$$CV = \frac{\sigma}{\bar{X}}; \quad (4)$$

- асиметрії (англ. Skewness):

$$As = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{X_i - \bar{X}}{\sigma} \right)^3; \quad (5)$$

- ексцесу (англ. Kurtosis):

$$Ex = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{X_i - \bar{X}}{\sigma} \right)^4 - 3. \quad (6)$$

У режимі реального часу збирається велика кількість контекстних даних, на основі яких здійснюється розрахунок для часового ряду показників кожного сенсора із виведенням у табличному та графічному вигляді:

- для часових проміжків: 1) кількості часових проміжків, 2) кількості варіантів тривалості часових інтервалів між сусідніми значеннями (для з'ясування уніфікованості), 3) статистичних показників тривалості інтервалів (мінімальне та максимальне значення, медіана та середньоарифметичне значення, процентилі 25% і 75%);

- для пропусків даних: 1) найдовшої тривалості пропущених даних, 2) дати початку та завершення найдовшого пропуску даних; 3) кількості періодів пропусків, 4) загальної тривалості часу без даних в годинах та відсотках;

– для завершених даних: 1) найдовшої тривалості завершених даних, 2) дати початку та завершення найдовшого періоду завершених даних; 3) загальної тривалості часу завершених даних в годинах та відсотках.

Для проведення кореляційного аналізу у системі обрано розрахунок універсального коефіцієнта кореляції ϕk , який дозволяє фіксувати як лінійну так і нелінійну залежність між змінними та узгоджено працює з даними, які можуть бути представлені у різних шкалах. Цей коефіцієнт приймає значення в інтервалі від 0 до 1, його розрахунок по замовчуванню супроводжується застосуванням методів вилучення шуму. Високий коефіцієнт кореляції може бути обумовлений як залежністю значень одного сенсора під впливом зміни значень іншого сенсора, так і дублюванням даних.

Робота з web-застосунком інформаційної системи починається з вибору сценарію: користувач може обрати існуючий звіт або створити новий (рис. 3). Якщо хоча б один звіт існує, активною буде вкладка Select project із переліком існуючих звітів, кожен з яких можна обрати для перегляду та у разі потреби оновити. Для створення нового звіту необхідно відкрити вкладку Create project.




Рис. 3. Вибір сценарію роботи

На *першому етапі* проведення аналізу даних у розробленій системі здійснюється формування набору даних, яке включає у себе запит до хмарного середовища Amazon Web Services, у якому зберігається уся наявна інформація стосовно певної технологічної лінії, та відбір машин і сенсорів, дані з яких будуть аналізуватися із вказівкою часового проміжку, який буде вважатися пропуском. Отримані у відповідь на цей запит дані зберігаються на внутрішньому сервері системи і використовуються для подальшого аналізу, для якого необхідно вказати межі часового проміжку. При формуванні набору даних є можливість міняти параметри налаштувань: перелік обраних машин, сенсорів, межі часових проміжків та повторно проводити аналіз із модифікованим набором даних.

На *другому етапі* після налаштування параметрів аналізу показників сенсорів технологічної лінії із застосуванням бібліотеки Pandas-profiling здійснюється формування багатосторінкового статистичного аналітичного звіту, результати якого у web-застосунку системи можна переглядати на вкладках (рис. 4): Summary – підсумки, Sensors Basic Stats – основна статистика, Freeze Sensors Analysis – аналіз завершених даних, Correlation Analysis – кореляційний аналіз, Gaps and Time Interval Analysis – аналіз пропусків і часових інтервалів. Звіт зберігається на внутрішньому сервері системи та додається у перелік уже існуючих звітів.

На *третьому етапі* роботи з системою здійснюється перегляд та аналіз отриманих результатів фахівцем Data Science. Застосування інформаційно-аналітичної системи дозволяє автоматизувати процеси виявлення проблем із даними, надаючи рекомендації їх можливих потенційних джерел. Аналітик, який працює з системою, у разі потреби сумісно з технічними працівниками, які обслуговують технологічну лінію на підприємстві, з'ясовує реальні причини проблемного надходження даних. Врахування

специфіки кожної проблеми слугує основою для подальшого прийняття адекватних рішень, націлених на покращення якості даних та підвищення точності прогнозування відмов.




Рис. 4. Вкладки сторінки з результатами проведеного аналізу

Автоматично визначений перелік сенсорів, які можуть містити проблемні дані, можна переглянути на вкладці Summary web-застосунку (рис. 5).

До проблемних будуть відібрані сенсори, що мають:

- сталі значення на всьому часовому проміжку: виявлені константи вилучають із аналізу;
- менше 10 окремих значень: сенсор може бути індикативним (позначає перемикання механізмів, а не процес їх роботи) або фіксувати значення, представлені у категоріальній шкалі;

The table below includes sensors with some problematic statistical characteristics.
Problematic values are highlighted, hover on column header for more explanations.

Freeze Sensors Analysis Correlation Analysis Gaps and Time Interval Analysis

Automatically selected sensors ⓘ

Export

#	Sensor	Distinct value No	Zero values %	Missing values %	Coefficient of variation	Kurtosis	Type	Time interval distinct values No	Longest gap (hrs)	Longest freeze (hrs)	Highly correlated sensors No	Predefined conditions
	filter data											
1	CRS_A	5	92.33	0	3.47	463.38	Numeric	1	76.92	1670.5	0	0
2	CRS_DS	723	54.84	0	43.5	18.37	Numeric	1	76.92	143.28	2	0
3	CRS_CT	1736	92.59	0	21.51	25.25	Numeric	1	1224.29	1224.29	0	0

Рис. 5. Таблиця сенсорів, які мають проблемні дані

- більше 10% нульових та пропущених значень: сенсори, які фіксують показники працюючого устаткування, майже ніколи не можуть бути нульовими;
- високі значення коефіцієнту варіації: свідчать про неоднорідність значень показників сенсора;
- високі значення коефіцієнту ексцесу: є мірою інтенсивності викидів;
- не числовий тип даних: перед передачею даних до моделі повинен бути перетворений до числової шкали;
- велику різницю між мінімальним, медіанним та максимальним значеннями тривалості інтервалів: це може свідчити про наявність неякісних даних;
- довгі тривалості часових проміжків: потребують з'ясування причин нерівномірного надходження даних;
- довгі тривалості періоду пропущених даних: потребують з'ясування причин і в залежності від цього можуть бути вилучені з аналізу або заповнені даними (наприклад, дані можуть надходити тільки тоді, коли змінюються);
- довгі тривалості періоду завмерлих даних: часто свідчать про наявність проблем на етапі накопичення та передачі даних (дані можуть бути уже агреговані або бути результатом апаратної помилки при передачі даних);
- високі коефіцієнти кореляції з групою більше ніж трьох сенсорів: потребують з'ясування причин залежності чи виявлення наявності дублювання даних.

Текстовий блок вкладки Summary включає переліки проблем з даними, на які варто звернути увагу (рис. 6).

Sensors with zero values: 98 sensors with more than 10% and less than 100% of zero values: Median percent of zero values for these sensors: 100.0.	Time interval: 143 sensors with not constant time interval: There are up to 95 different interval values per sensors.
Sensors with missing values: Not found.	Freezes: 167 sensors with freezes: Median number of freezes per sensor is 2. Median freeze duration per sensor is 142.2 hours.
Sensors with negative values: 20 sensors with negative values: Median percent of negative values for these sensors: 0.33.	Gaps: 183 sensors with gaps: Median number of gaps per sensor is 3. Median gap duration per sensor is 75.76 hours.
Sensors with high coefficient of variation: 30 sensors with CV > 1: Median CV value for these sensors: 1.85.	Correlation groups: 28 correlation group(s) found. Number of correlated sensors in each group varies from 1 to 15.
Sensors with higher chances of outliers (based on kurtosis values): 27 sensors with kurtosis > 5: Median kurtosis value for these sensors: 207.42.	
Categorical sensors: Not found.	

Рис. 6. Текстовий блок із переліком даних, які містять проблеми

У наведеному на рисунку 6 прикладі до таких віднесено дані, які містять від'ємні значення (це можуть бути помилкові дані). Високі коефіцієнти експесу свідчать про наявність викидів у 27 сенсорів – на їх фоні виявлення аномалій може бути ускладнене. Якщо викиди не синхронізовані з аномаліями інших сенсорів, необхідно перевірити якість передачі даних від цих сенсорів. Виявлено 28 груп сенсорів із високим коефіцієнтом кореляції та наявністю у кожній групі до 15 сенсорів. У такому випадку прогнозна модель може надавати перевагу у виявленні аномалій, пов'язаних із даними, які надходять від цих сенсорів та не помітити інші аномалії. У 167 сенсорів є завмерлі дані, які тривають по кілька днів – це потребує з'ясування причин та у разі необхідності внесення відповідних коректив. 183 сенсори мають пропуски – це можуть бути незмінні або втрачені значення. Із 220 сенсорів 143 мають неуніфіковані інтервали (від 0,5 секунд до годин). Це потребує внесення змін до даних, спрямованих на їх уніфікацію, на етапі попередньої обробки даних. При цьому використовують інформацію, яка міститься у таблиці з основними характеристиками усіх сенсорів вкладки Summary (рис. 7).

All machine Sensors													
Export													
	Sensor	Type	Gaps			Freezes			Intervals				
			Longest (hrs)	Total (hrs)	% of Duration	Longest (hrs)	Total (hrs)	% of Duration	Min	Mean	Median	Std	Max
	filter data.												
x	0_CA 3176	Constant	1224.29	3176.42	105.25	2190.47	2190.47	72.58					
x	0_H 63	Numeric	38.99	63.26	0.41				0.5	0.5	0.5	0	0.5
x	0_F4V	Constant	1224.29	3176.42	105.25	2190.47	2190.47	72.58					
x	0_N_V	Constant	1224.29	3176.42	105.25	2190.47	2190.47	72.58					
x	0_V 56	Numeric	39.08	63.35	0.41				0.5	0.5	0.5	0	0.5
x	0_V42	Numeric	39.08	63.36	1.79	1.03	1.03	0.03	0.5	0.5	0.5	0	0.5
x	0_V4N	Constant	1224.29	3176.42	105.25	2190.47	2190.47	72.58					
x	0_VBC	Numeric	39	63.27	1.79	1.02	1.02	0.03	0.5	0.5	0.5	0	0.5
x	0_VBN	Constant	1224.29	3176.42	105.25	2190.47	2190.47	72.58					
x	0_VCA 63	Numeric	38.99	63.26	1.79	4.01	5.09	0.14	0.5	0.5	0.5	0	0.5
x	0_VCN 3176	Constant	1224.29	3176.42	105.25	2190.47	2190.47	72.58					
x	VCH1	Binary	344.84	2982.91	19.25	322.36	520.29	3.36	76.5	732.4	793.47	410.15	1329.57
x	V 3176	Binary	1208.34	3137.6	93	2643.91	2666.78	79.05	478.55	925.24	925.24	631.72	1371.93

Рис. 7. Таблиця All machine Sensors вкладки Summary

Вкладка web-застосунку Sensors Basic Stats наляє можливість для перегляду основних статистичних характеристик сенсорів, представлених у таблицях (рис. 8, рис. 9) та гістограм розподілу їх значень.

Sensors Basic Statistics								
Sensor name	Distinct values No	Distinct values (%)	Total No of values	Negative values No	Negative values (%)	Zero values No	Zero values (%)	Type
Filter data:								
CR 28	8	28.57	28	0	0	16	57.14	Numeric
CR 31	8	25.81	31	0	0	17	54.84	Numeric
CR 33	8	24.24	33	0	0	18	54.55	Numeric
CR 376	6	0.02	37636	0	0	37554	99.78	Numeric
CR 261	255835	97.92	261257	0	0	12	0	Numeric
CR 15	3	0.18	1557	0	0	0	0	Numeric
CR 104	2	1.92	104	0	0	55	52.88	Binary
CR 17	2	1.57	127	0	0	66	51.97	Binary
CR 39	2	1.34	149	0	0	77	51.68	Binary
CR 4	1	25	4	0	0	0	0	Constant 1
CR 104	421	4.03	10452	0	0	0	0	Numeric
CR 307	85372	31.84	307282	0	0	0	0	Numeric
CR 38	118728	35.85	388825	0	0	0	0	Numeric

Рис. 8. Таблиця Basic Statistics вкладки Sensors Basic Stats

Перегляд гістограм дозволяє візуально відслідкувати наявність викидів та асиметричність у розподілі значень показників сенсорів, виявити індикативні сенсори та сенсори, які працюють у багаторежимному режимі (рис. 10). Це необхідно врахувати перед подачею даних до прогнозної моделі PdM для коректного оновлення її параметрів, спрямованого на більш точне та швидше виявлення аномальних значень.

Sensors Descriptive Statistics															
Sensor	Minimum value	Q5K	Q25K	Median	Average value	Q75K	Q95K	Maximum value	Standard deviation	QAD	SCV	IQR	Range of values	Kurtosis	Skewness
Filter data:															
CR 28	0	0	0	0	4.61	4.5	21.4	41	9.13	0	1.98	4.5	41	10.05	3.06
CR 31	0	0	0	0	4.55	5	18.5	41	8.72	0	1.92	5	41	10.98	3.15
CR 33	0	0	0	0	4.48	6	17.6	41	8.65	0	1.93	6	41	11.19	3.2
CR 376	0	0	0	0	0.02	0	0	8	0.37	0	21.51	0	8	463.38	23.55
CR 261	0	34.47	51.82	68.82	65.64	88.02	98.99	100	17.93	13.8	0.27	28.2	100	-0.79	-0.39
CR 15	1	1	1	2	1.74	2	4	4	0.95	1	0.54	1	3	0.99	1.36
CR 104	0	0	0	0	0.47	1	1	1	0.5	0	1.06	1	1	-2.03	0.12
CR 17	0	0	0	0	0.48	1	1	1	0.5	0	1.04	1	1	-2.03	0.08
CR 39	0	0	0	0	0.48	1	1	1	0.5	0	1.04	1	1	-2.02	0.07
CR 4	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0
CR 104	0.49	0.72	0.72	0.73	0.78	0.85	0.86	0.86	0.06	0.01	0.08	0.13	0.37	-1.43	0.25
CR 307	0.67	0.73	0.73	0.74	0.79	0.86	0.87	0.87	0.06	0	0.08	0.13	0.2	-1.79	0.42
CR 38	0.67	0.73	0.73	0.74	0.79	0.86	0.87	0.87	0.06	0	0.08	0.13	0.2	-1.78	0.42

Рис. 9. Таблиця Basic Descriptive Statistics вкладки Sensors Basic Stats

У прикладі, наведеному на рисунку 10, чітко відслідковується, що показники більшості сенсорів мають 2-3 відокремлені групи значень на графіках розподілу. Це було ідентифіковано як проблему з якістю даних та з'ясовано, що при передачі даних від працівників, які обслуговують технологічну лінію, не було повідомлено про роботу машини у кількох режимах.

Врахування багаторежимної роботи включало: 1) визначення сенсорів і їх значень, які ідентифікують перемикання режимів; 2) визначення тривалості «сліпих зон» для виявлення аномалій на межах періодів перемикання. Із врахуванням цього параметри моделі прогнозування відмов було модифіковано і суттєво підвищено точність виявлення аномалій, які є причиною несправностей.

Результати з аналізом виявлених у сенсорів зазмерлих даних можна переглянути на вкладці Freeze Sensors Analysis у табличному та графічному форматі (рис. 11, рис. 12). Представлена тут інформація дозволяє виявити сенсори з проблемними даними, які не змінюються дуже довго.




Рис. 10. Гістограми розподілу значень показників сенсорів групи

Sensor	Longest freeze start	Longest freeze end	Longest freeze duration (hrs)	Number of freezes	Total time freeze (hrs)	%freezes from total duration (%)
CRS 6	2022-06-17T11:01:15	2022-08-18T05:58:39	5.5	30	61.5	0.24
CRS 55	2022-09-14T15:02:14	2022-09-16T17:00:09	7.75	3	23	0.09
CRS 07	2022-09-11T23:30:27	2022-09-19T05:51:04	15.5	3	31	0.24
CRS 25	2022-09-11T23:30:27	2022-09-19T05:50:59	36.25	6	69.25	0.27
CRS 66	2022-09-11T23:30:27	2022-09-19T05:50:59	15.5	24	193	0.75
CRS 19	2022-05-18T23:30:33	2022-08-18T05:58:39	12.75	14	58.5	0.23
CRS 9	2022-09-03T22:55:06	2022-09-05T01:17:06	1004.5	27	5933.5	44.05

Рис. 11. Таблиця сенсорів із завмерлими даними

На рисунку 12 один із сенсорів має періоди завмерлих даних довгої тривалості і є проблемним. Це потребує з'ясування причин такого надходження даних, у залежності від чого дані можуть бути вилучені з аналізу (якщо сенсор передає сталі дані) або відкориговані відповідним чином, якщо має місце помилка у агрегації або передачі даних.




Рис. 12. Візуалізація часових періодів завмерлих даних сенсорів

Інформація про групи сенсорів із високим коефіцієнтом кореляції представлена на вкладці Correlation Analysis веб-застосунку системи у табличному форматі та у вигляді графіків. На рисунку 13 наведено приклад виведення теплової карти коефіцієнтів кореляції.

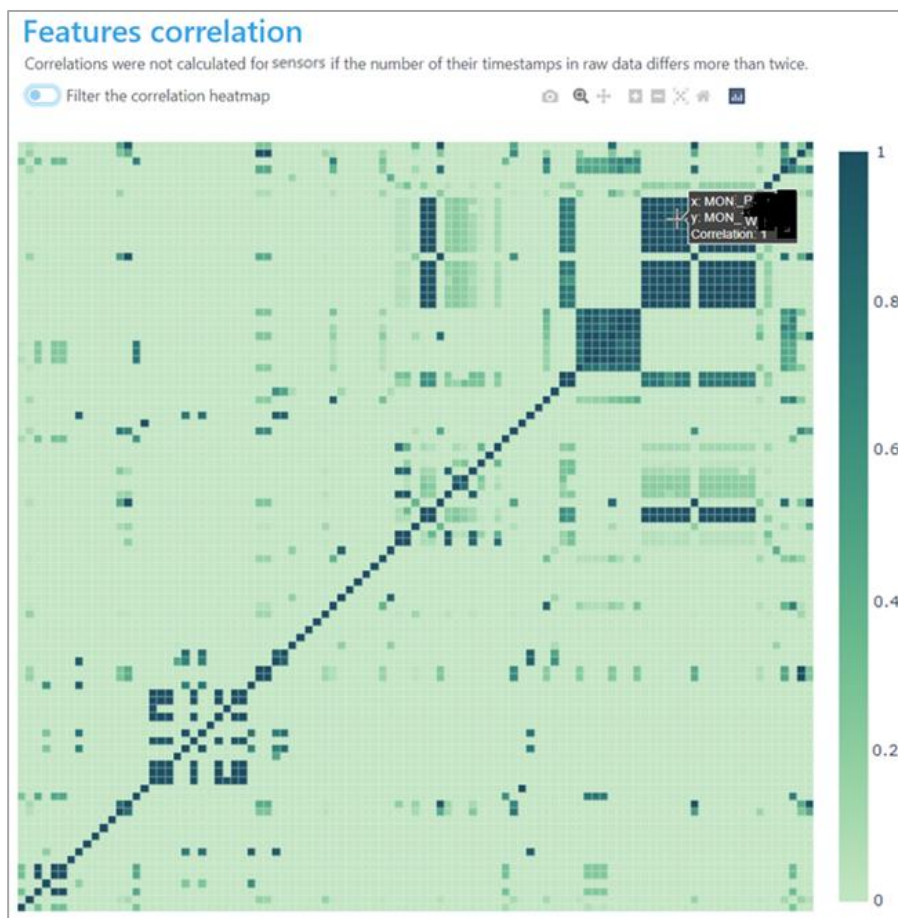


Рис. 13. Теплова карта коефіцієнтів кореляції

Оскільки технологічна лінія зазвичай містить велику кількість сенсорів, реалізовано можливість фільтрування сенсорів та можливість задання порогових значень при виведенні розрахованих коефіцієнтів кореляції з відображенням теплової карти у різних форматах. Більш детально інформацію про кожну групу високорельованих сенсорів можна переглянути у таблиці вкладки Correlation Analysis.

Аналіз поведінки найбільш корельованих сенсорів кожної групи можна переглядати у вигляді графіків часових рядів значень їх показників. У прикладі, наведеному на рисунку 14, продемонстровано практично однакову поведінку 5 сенсорів групи. З'ясувалося, що причиною такого надходження даних було їх дублювання. Дублікати було вилучено з подальшого аналізу перед подачею даних до моделі прогнозування відмов для оновлення її параметрів.




Рис. 14. Графіки часових рядів зі значеннями показників сенсорів групи

Вкладка Gaps and Time Interval Analysis web-застосунку містить результати аналізу часових інтервалів і пропущених даних у часових рядах показників сенсорів. Опис пропущених даних подається у вигляді діаграми Ганта, яка візуально полегшує роботу аналітика з виявлення проблемних даних (рис. 15). Оскільки пропуски можуть свідчити як про низьку якість даних, так і про дуже стабільну роботу пристрою. Це потребує з'ясування способу агрегації даних, в залежності від якого дані можуть бути вилучені з аналізу як зайві або коректно враховані при передачі до прогнозної моделі Predictive Maintenance.

У прикладі, наведеному на рисунку 15, продемонстровано нерівномірне надходження даних. З'ясування причин такої подачі даних дозволило установити, що це було обумовлено підходом до збереження даних на підприємстві: дані передавалися тільки тоді, коли змінювалися. Для врахування такого режиму роботи було додано дані з частотою, уніфікованою з частотою інших сенсорів, а пропуски заповнено останніми наявними значеннями. Передача модифікованих даних до прогнозної моделі для оновлення її параметрів дозволила підвищити точність прогнозу несправностей.

Статистичні показники тривалості інтервалів (мінімальне, максимальне, медіанне та середньоарифметичне значення, проценти 25% і 75%) на вкладці Gaps and Time Interval Analysis представлені у таблиці та у вигляді діаграми розмаху (рис. 16). Розташовані на одному графіку діаграми розмаху дозволяють у зручному для сприйняття форматі візуально порівнювати розподіли тривалості часових інтервалів різних сенсорів.




Рис. 15. Візуалізація часових періодів завмерлих даних



Рис. 16. Статистичні показники тривалості інтервалів

Інформація про часові проміжки для кожного сенсора подається також у вигляді точкових діаграм із лініями похибок, аналіз яких дозволяє відділити випадкові похибки від систематичних (рис. 17). У прикладі, наведеному на рисунку 17, наведено графіки, що відображають нерівномірність надходження

даних у часі. Разом із інформацією про пропуски, завмерлі дані та особливості гістограм розподілу значень показників сенсора це дозволяє обґрунтовано обрати спосіб заповнення пропущених значень, метод отримання повторних вибірок, вікно і крок для виявлення аномалій. Такий підхід допомагає отримати додаткову інформацію для оновлення параметрів прогнозних моделей із метою підвищення їх точності та якості.




Рис. 17. Точкові діаграми з лініями похибок тривалості часових проміжків

На *четвертому етапі* роботи з інформаційно-аналітичною системою після з'ясування особливостей надходження усіх даних, які було ідентифіковано як джерела можливих проблем, формується перелік апаратно-програмних рішень, спрямованих на підвищення якості даних, які надходять від сенсорів технологічної лінії. До апаратних рішень відносять зміни, які реалізують безпосередньо на виробництві: у конфігурації сенсорів, їх калібруванні та налаштуванні чутливості, ліквідації перебоїв у підключенні IoT-систем. На програмному рівні подальша робота з даними, в залежності від специфіки виявлених проблем, включає внесення відповідних коректив до попередньої обробки даних (уніфікація частоти даних, заповнення пропусків) та визначення аномалій (включення пропущених аномалій та вилучення тих, що були помилково віднесені до аномалій). Дані можуть бути модифіковані відповідним чином або вилучені, якщо вони продубльовані або не несуть корисної інформації. Із врахування усіх внесених змін здійснюється оновлення параметрів моделей прогнозування відмов.

Впровадження системи в обслуговування технологічних ліній важкої промисловості супроводжувалося підвищенням точності та якості прогнозу несправностей. Оцінка точності моделей здійснювалася за показником F1-score, який у середньому підвищився на 10% (рис. 18). Про підвищення якості прогнозних моделей свідчить зменшення часу виявлення проблем, які призводять по несправності обладнання технологічної лінії (рис. 19). Його оцінка здійснювалася за допомогою методу Каплана-Майєра і у середньому це значення було зменшене у 6 разів.

Висновки. Швидкий розвиток технологій Industry 4.0 супроводжується впровадженням прогресивних стратегій прогнозного технічного обслуговування технологічних ліній, які передбачають постійну оцінку стану обладнання у режимі реального часу, допомагаючи максимізувати час його безвідмовної роботи та продуктивність, мінімізуючи загальну вартість обслуговування. Проте експлуатація технологічних ліній в умовах реального виробництва супроводжується зміною у характеристиках обладнання, що потребує корегування та оновлення параметрів моделей, які здійснюють прогнозне технічне обслуговування.




Рис. 18. Підвищення точності прогнозних моделей PdM




Рис. 19. Зменшення часу виявлення проблем, які призводять до несправності технологічної лінії

Дослідження факторів, які викликають зниження точності прогнозу моделей PdM, дозволило установити, що до проблемних можна віднести сенсори, дані яких мають: від'ємні значення, суттєву кількість нульових та пропущених значень або невелику кількість окремих значень; високі значення коефіцієнту варіації та ексцесу; неуніфіковані з іншими сенсорами і довгі часові інтервали між сусідніми значеннями часового ряду показників; довгі тривалості часових проміжків пропущених і завмерлих даних; високі коефіцієнти кореляції з групою інших сенсорів. Це дало можливість обґрунтувати вибір кореляційного аналізу і методів описової та контекстної статистики для аналізу показників великої кількості сенсорів технологічних ліній із метою виявлення проблем із якістю даних.

На основі запропонованого підходу було розроблено інформаційно-аналітичну систему, яка на етапі формування набору даних автоматично виявляє потенційні джерела проблем із якістю даних, що можуть вплинути на точність прогнозування несправностей. Результати експериментальної апробації засвідчили, що інформація з даними всіх сенсорів стала доступною одночасно. Це дає можливість порівнювати резолюцію різних груп сенсорів та обирати прийнятні для усіх сенсорів значення. Було

прискорено та покращено в залежності від специфіки виробництва вибір методу заповнення пропусків у даних, виявлення та аналіз викидів, аномалій, груп сенсорів із високим коефіцієнтом кореляції. Аналіз тривалості деградації та кореляції між аномаліями показників сенсорів дає змогу відслідковувати зміни корельованих аномалій із часом наближення збою і дозволяє відкоригувати спосіб відбору даних для подальшого аналізу з метою їх раннього виявлення.

Впровадження розробленої системи для прогнозного технічного обслуговування технологічних ліній важкої промисловості дозволило покращити відбір і підготовку даних для подальшого аналізу, супроводжувалося підвищенням точності прогнозування відмов і зменшенням інтервалів часу між виникненням несправностей та їх виявленням. Що свідчить про підвищення якості прогнозних моделей Predictive Maintenance та запобігає виходу з ладу і простою обладнання технологічних ліній, подовжуючи загальний термін служби життєво важливих активів.

Список використаних джерел:

1. Болюбаш Н. М., Фінькова О. В. Система аналізу даних для прогнозного технічного обслуговування технологічних ліній. *Матеріали XXVII Всеукраїнської науково-практичної конференції «Могилянські читання – 2024: Досвід та тенденції розвитку суспільства в Україні: глобальний, національний та регіональний аспекти». Технічні науки*. Миколаїв: Вид-во ЧНУ імені П. Могили. 2024. С. 163–167. URL: <https://dSPACE.chmnu.edu.ua/jspui/bitstream/123456789/2507/1/Технічні%20науки.pdf#page=165>.
2. Темчур В. С., Баран Т. Г. Методи глибокого навчання моделей для прогнозного обслуговування. *Вчені записки ТНУ ім. В.І. Вернадського. Серія: технічні науки*. 2023. Т. 34 (73), № 6. С. 155–162. URL: <https://doi.org/10.32782/2663-5941/2023.6/23>.
3. Achouch M., Dimitrova M., Ziane K., Sattarpanah Karganroudi S., Dhouib R., Ibrahim H., Adda M. On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. *Applied Sciences*. 2022. Vol. 12, No 16. P. 8081. URL: <https://doi.org/10.3390/app12168081>.
4. Baptista M., Sankararaman S., et al. Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*. 2018. Vol. 115. P. 41–53. URL: <https://doi.org/10.1016/j.cie.2020.107060>.
5. Blann D. Maximizing the P-F interval through condition-based maintenance. URL: <https://www.maintworld.com/Applications/Maximizing-the-P-F-Interval-Through-Condition-Based-Maintenance>.
6. Buyske S., Fagerstrom R., Ying Z. A class of weighted log-rank tests for survival data when the event is rare. *Journal of the American Statistical Association*. 2020. Vol. 95, No 449. P. 249–258. URL: <https://doi.org/10.1080/01621459.2000.10473918>.
7. Geisbush, J., Ariaratnam, S. T. Reliability centered maintenance (RCM): literature review of current industry state of practice. *Journal of Quality in Maintenance Engineering*. 2023. Vol. 29, No. 2. PP. 313–337. URL: <https://doi.org/10.1108/JQME-02-2021-0018>.
8. Hamasha M. M., Bani-Irshid A. H., Al Mashaqbeh S., et al. Strategical selection of maintenance type under different conditions. *Scientific Reports*. 2023. Vol. 13, P. 15560. URL: <https://doi.org/10.1038/s41598-023-42751-5>.
9. Horrell M., Reynolds L., McElhinney A. Data Science in Heavy Industry and the Internet of Things. *Harvard Data Science Review*. 2020. Issue 2 (2). URL: <https://doi.org/10.1162/99608f92.834c6595>.
10. Keleko A. T., Kamsu-Foguem B., Ngouna R. H., Tongne A. Artificial Intelligence and Real-Time Predictive Maintenance in Industry 4.0: a bibliometric analysis. *AI and Ethics*. 2022. Vol 2. P. 533–577. URL: <https://doi.org/10.1007/s43681-021-00132-6>.
11. Li L., Liu M., Shen W., Cheng G. An expert knowledge-based dynamic maintenance task assignment model using discrete stress-strength interference theory. *Knowledge-Based Systems*. 2017. Vol. 131. P.135–148. URL: <https://doi.org/10.1016/j.knosys.2017.06.008>.
12. Nokeri T. C. Dash Bootstrap Components. In: *Web App Development and Real-Time Web Analytics with Python*. Pub.: Berkeley, CA. 2022. P. 87–97. URL: https://doi.org/10.1007/978-1-4842-7783-6_6.
13. Oliynyk K. 5 Use Cases of Predictive Maintenance using IoT. URL: <https://webbylab.com/blog/use-cases-of-iot-based-predictive-maintenance>.
14. Ong H., Niyato D., Yuen C. Predictive Maintenance for Edge-Based Sensor Networks. 2020. URL: <https://arxiv.org/pdf/2007.03313>.
15. Patel M., Vasa J., Patel B. Predictive Maintenance: A Comprehensive Analysis and Future Outlook. Published in *2nd International Conference on Futuristic Technologies (INCOFT)*. 2024. URL: <https://doi.org/10.1109/INCOFT60753.2023.10425122>.
16. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*. 2019. Vol. 1, No 5. P. 206–215. URL: <https://doi.org/10.1038/s42256-019-0048-x>.
17. Serradilla O., Zugasti E., Zurutuza U. Deep Learning Models for Predictive Maintenance: A Survey. 2020. URL: <https://doi.org/10.48550/arXiv.2010.03207>.
18. Sharma J., Mittal M.L., Soni G. Condition-based maintenance using machine learning and role of interpretability: a review. *International Journal of System Assurance Engineering and Management*. Vol. 15. P. 1345–1360. URL: <https://doi.org/10.1007/s13198-022-01843-7>.
19. Sikorska J., Hodkiewicz M., Ma L. Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*. 2011. Vol. 25, No 5. P. 1803–1836. URL: <https://doi.org/10.1016/j.ymssp.2010.11.018>.

20. Ucar A., Karakose M., Kırımca N. Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends. *Applied Sciences*. 2024. Vol. 14, No 2. P. 898. URL: <https://doi.org/10.3390/app14020898>.
21. Wheeler K.R., Kurtoglu T., Poll S.D. A survey of health management user objectives related to diagnostic and prognostic metrics. In *Proceedings International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*. 2009. P. 1287–1298. URL: <https://doi.org/10.1115/DETC2009-87073>.
22. Yuan M., Wu Y., Lin L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. In *Proceedings International Conference on Aircraft Utility Systems (AUS)*. IEEE. 2016. P. 135–140. URL: <https://doi.org/10.1109/AUS.2016.7748035>.
23. Zhang C., Lim P., Qin A. K., Tan K. C. Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics. *IEEE Transactions on Neural Networks and Learning Systems*. 2017. Vol. 28, No 10. P. 2306–2318. URL: <https://doi.org/10.1109/TNNLS.2016.2582798>.