

УДК 004.8:637.1:519.246.8

К.Ю. ЧОРНОБАЙ*, С.В. ГРИБКОВ*, О.Л. СЕДИХ*

ІНТЕГРОВАНІЙ ПІДХІД ДО ПРОГНОЗНОГО УПРАВЛІННЯ ТЕХНІЧНИМ СТАНОМ ТЕХНОЛОГІЧНОГО ОБЛАДНАННЯ МОЛОКОПЕРЕРОБНИХ ПІДПРИЄМСТВ НА ОСНОВІ МАШИННОГО НАВЧАННЯ

*Національний університет харчових технологій, м. Київ, Україна

Анотація. У статті досліджено проблему підвищення експлуатаційної надійності технологічного обладнання молокопереробних підприємств у контексті переходу до інтелектуалізованих стратегій технічного обслуговування. Метою дослідження є розроблення інтегрованого підходу до прогнозного управління технічним станом обладнання на основі поєднання методів машинного навчання, аналізу багатовимірних часових рядів та концепції цифрового двійника з урахуванням динаміки деградаційних процесів. У роботі виконано системний аналіз стратегій технічного обслуговування, виявлено обмеження регламентних підходів із фіксованими інтервалами та обґрунтовано доцільність застосування гібридної моделі, що інтегрує обслуговування за технічним станом із прогнозно-орієнтованими механізмами. Експериментально на основі ретроспективних даних експлуатації обладнання встановлено статистично значущу перевагу ансамблевого методу XGBoost порівняно з альтернативними моделями за показниками F1-міри та ROC-AUC. Запропонований підхід дозволяє формувати рекомендації на наступний необхідний період щодо технічного обслуговування, що безпосередньо впливає на оперативне планування виробництва: обладнання в критичному стані виключається з виробничого циклу до проведення ремонтних робіт, що мінімізує ризики незапланованих простоїв, втрат сировини та порушень технологічних режимів. Розроблений модуль прогнозування реалізує оцінювання ймовірності відмови та залишкового ресурсу в реальному часі, що забезпечує підвищення ймовірності раннього виявлення потенційно аварійних станів. Практична значущість результатів полягає у впровадженні розробленого підходу в систему підтримки прийняття рішень, що дозволяє мінімізувати незаплановані простої, оптимізувати графіки технічного обслуговування та знизити технологічні втрати сировини. Запропонований підхід узгоджується з принципами цифрової трансформації промисловості та може бути використаний як основа для побудови інтелектуальних систем управління в рамках концепцій Industry 4.0/5.0.

Ключові слова: інформаційні технології, управління технічним станом, прогнозування, цифрові двійники, машинне навчання, молокопереробне підприємство.

Abstract. The article addresses the problem of improving the operational reliability of technological equipment at dairy processing enterprises in the context of the transition to intelligent maintenance strategies. The aim of the study is to develop an integrated approach to predictive management of technical condition of the equipment based on the combination of machine learning methods, multidimensional time series analysis, and the digital twin concept, taking into account the dynamics of degradation processes. The study presents a systematic analysis of maintenance strategies, identifies the limitations of schedule-based approaches with fixed intervals, and substantiates the feasibility of applying a hybrid model that integrates condition-based maintenance with predictive-oriented mechanisms. Based on retrospective operational data, the experimental results demonstrate a statistically significant advantage of the ensemble method XGBoost compared to alternative models in terms of F1-score and ROC-AUC metrics. The proposed approach enables the generation of maintenance recommendations for the next required period, which directly affects operational production planning as equipment in critical condition is excluded from the production cycle until maintenance is performed, thereby minimizing the risks of unplanned downtime, raw material losses, and violations of technological regimes. The developed forecasting module implements real-time assessment of the probability of failure and residual resource, which increases the probability of

early detection of potentially emergency conditions. The practical significance of the results lies in the implementation of the proposed approach within a decision support system, enabling the reduction of unplanned downtime, optimization of maintenance schedules, and minimization of technological losses of raw materials. The proposed approach is consistent with the principles of industrial digital transformation and can serve as a foundation for the development of intelligent management systems within the frameworks of Industry 4.0 and Industry 5.0 concepts.

Keywords: *information technologies, technical condition management, forecasting, digital twins, machine learning, dairy processing enterprise.*

DOI: 10.34121/1028-9763-2026-2-134-145

1. Вступ

Характерною особливістю молокопереробних підприємств є жорстка регламентованість технологічних процесів, реалізація яких здійснюється на визначеному технологічному обладнанні, інтегрованому у виробничі лінії та цехи. Тривалість виготовлення молочної продукції визначається технологічним циклом, що охоплює стадії приймання та підготовки сировини, теплової обробки, ферментації (за необхідності), охолодження та фасування, і може варіюватися від кількох хвилин до кількох діб залежно від виду продукції та наявності процесів ферментації і дозрівання, які визначають її фізико-хімічні та органолептичні властивості [1].

У молокопереробній промисловості ключове значення мають хіміко-технологічні процеси, спрямовані на керувану трансформацію складу та властивостей молочної сировини. До них належить теплова обробка (пастеризація, ультрапастеризація, стерилізація), яка забезпечує мікробіологічну безпечність і модифікацію білкових структур; гомогенізація як процес диспергування жирової фази з метою стабілізації емульсійної системи; сепарування як фазове розділення під дією відцентрових сил; коагуляція казеїну з утворенням просторової білкової структури під впливом кислотних або ферментативних агентів; а також біохімічне сквашування, в ході якого молочнокислі мікроорганізми трансформують лактозу в молочну кислоту, формуючи структурно-реологічні та органолептичні характеристики продукту [1].

Зазначені процеси реалізуються у спеціалізованому обладнанні (пастеризаційно-охолоджувальні установки, гомогенізатори, сепаратори, резервуари для сквашування тощо), яке функціонально інтегрується у технологічні лінії відповідно до асортиментної політики підприємства та вимог ресурсної ефективності.

Своєчасне проведення ремонтно-профілактичних робіт забезпечує надійне функціонування технологічного обладнання та стабільність виробничих процесів. Систематичне технічне обслуговування, що базується на регламентованих інтервалах і фактичному технічному стані обладнання, дозволяє своєчасно виявляти та усувати передвідмовні стани, зумовлені зносом, корозійними та кавітаційними явищами, іншими деградаційними процесами [2].

Впровадження превентивних заходів сприяє підвищенню якості продукції завдяки стабілізації критичних технологічних параметрів, зокрема температурних режимів і характеристик потоку (швидкості, турбулентності, зсувних напружень).

Інтеграція ремонтно-профілактичних стратегій із цифровими системами моніторингу, побудованими на засадах Industrial Internet of Things, забезпечує перехід до предиктивного обслуговування, де управлінські рішення формуються на основі аналізу потокових даних, моделей прогнозування та методів машинного навчання.

Актуальною задачею є розроблення та дослідження підходів до прогнозування і раннього виявлення несправностей технологічного обладнання молокопереробного виробництва на основі використання інформаційних технологій. У межах цієї задачі передбачається розглянути варіації застосування різних інформаційних технологій, здійснити їх порівняльний аналіз за ефективністю та надійністю, а також оцінити зниження

сукупних витрат на усунення поломок обладнання, енергоспоживання та мінімізацію ризиків критичних відмов технологічних систем. У такій постановці задача формалізується як відображення багатовимірного простору ознак, сформованого на основі часових рядів сенсорних вимірювань, у простір станів обладнання або ймовірностей виникнення відмов у майбутні моменти часу.

2. Дослідження сучасних методів попереднього виявлення та прогнозування відмов

Молокопереробне виробництво характеризується високим рівнем безперервності технологічних процесів та жорсткими санітарно-гігієнічними вимогами, що істотно обмежують допустимість незапланованих зупинок обладнання. У традиційній практиці експлуатації молокопереробних підприємств виявлення та усунення відмов технологічного обладнання ґрунтується переважно на поєднанні регламентного технічного обслуговування, періодичних інспекцій та реактивного підходу до ліквідації несправностей. Така парадигма передбачає, що значна частина дефектів ідентифікується або в процесі планових оглядів, або вже після появи явних ознак відмови, що зумовлює обмежену передбачуваність і залежність від кваліфікації обслуговуючого персоналу [3].

У науковій літературі виділяють ряд стратегій: реактивна, планово-попереджувальна, обслуговування за технічним станом, прогнозно-орієнтоване обслуговування.

У найпростішому випадку застосовується реактивна стратегія обслуговування (run-to-failure), за якої втручання здійснюється виключно після настання відмови. Такий підхід функціонує в умовах стохастичної природи відмов і не передбачає використання прогнозних моделей. Його перевагою є мінімальні витрати на моніторинг, однак він супроводжується високими ризиками простоїв, втрат продукції та порушенням технологічних режимів.

Планово-попереджувальна стратегія (preventive maintenance) базується на регламентованих інтервалах обслуговування, що визначаються календарним часом або напрацюванням обладнання. Незважаючи на зниження ймовірності відмов, такий підхід не враховує індивідуальні траєкторії деградації, що призводить до надлишкових або передчасних втручань.

Обслуговування за технічним станом (condition-based maintenance) передбачає використання сенсорних даних для моніторингу параметрів функціонування. Рішення про технічне втручання приймається при досягненні порогових значень показників стану, що дозволяє адаптувати стратегію обслуговування до фактичного зносу обладнання.

Прогнозно-орієнтоване обслуговування (predictive maintenance) базується на використанні моделей машинного навчання для оцінювання майбутнього стану системи або залишкового ресурсу (Remaining Useful Life, RUL). У формалізованому вигляді така стратегія може бути подана як задача мінімізації очікуваних витрат (1) [4].

$$\min_{\pi} E \left[C_{fail} * P_{fail} + \int_1^{N_{maint}} C_{maint} \right], \quad (1)$$

де π — політика обслуговування;

C_{fail} — агрегований економіко-експлуатаційний параметр, який формалізує наслідки відмови обладнання показника витрат, що виникають у разі аварійної відмови, та складається з прямих витрат (ремонт або заміна вузла, аварійне обслуговування (понаднормові роботи, витрати на запасні частини), з непрямих витрат (простій виробничої лінії, втрата продукції (наприклад, зіпсоване молоко), порушення технологічного циклу, енергетичні втрати при перезапуску системи; санітарно-технологічні втрати (необхідність повторного СІР-циклу (clean-in-place)), списання партій продукції через порушення температурних режимів, ризику невідповідності НАССР-вимогам);

P_{fail} — ймовірність відмови у заданому часовому вікні;

C_{maint} — узагальнена вартість усіх ресурсів, необхідних для планового або коригувального технічного обслуговування;

$0 N_{maint}$ — кількість планових або коригувальних заходів [5].

Прескриптивна стратегія (prescriptive maintenance) розширює predictive-підхід шляхом інтеграції моделей прогнозування з методами оптимізації та теорії керування. Вона може бути формалізована як задача стохастичного керування, наприклад, у вигляді марковського процесу прийняття рішень (2) [5].

$$a^* = \arg \min_{a \in A} E \left[\sum_t C(s_t, a_t) \right], \quad (2)$$

де s_t — стан системи;

a_t — керуюча дія;

C — функція витрат.

Враховуючи контекст молокопереробного виробництва, доцільним є використання гібридних підходів, у яких планово-попереджувальні регламенти поєднуються з прогнозними моделями та моніторингом стану, що дозволяє мінімізувати простой та уникати порушень технологічних режимів.

У технологічних системах молокопереробних підприємств відмови обладнання мають виразно фізико-технічну природу та проявляються через деградацію матеріалів, порушення гідродинамічних і теплових режимів, а також через динамічні навантаження. Їх доцільно представляти як множину станів часткової або повної відмови, що можуть бути ідентифіковані за сукупністю спостережуваних параметрів.

Для забезпечення раннього виявлення та прогнозування відмов, крім традиційних, необхідно здійснювати постійний моніторинг на основі цифрових двійників, які доцільно розглядати як формалізовану кіберфізичну систему, що забезпечує двонаправлене відображення стану фізичного об'єкта у віртуальному середовищі та зворотний вплив аналітичних результатів на процес експлуатації. Цифровий двійник виступає інтеграційним середовищем, що поєднує технологічні процеси (пастеризація, гомогенізація, охолодження, фасування), сенсорні потоки даних та аналітичні моделі. Інформаційна модель системи може бути представлена у вигляді часових рядів (3):

$$X(t) = \{x_1(t), x_2(t), \dots, x_n(t)\}, \quad Y(t + \tau), \quad (3)$$

де $X(t)$ — вектор параметрів стану обладнання;

$Y(t + \tau)$ — цільова змінна, що відображає майбутній технічний стан або ймовірність відмови на горизонті прогнозування τ .

Інформаційне забезпечення цифрового двійника формується шляхом інтеграції ретроспективних даних (журнали експлуатації, історія відмов, регламенти обслуговування) та поточних даних IIoT, що надходять від сенсорів температури, тиску, вібрації та енергоспоживання. Узгодження цих джерел передбачає синхронізацію часових шкал, обробку пропусків та фільтрацію шуму, що є критичним для забезпечення коректності моделей [6].

Архітектурно система реалізується як багаторівнева платформа, що містить рівень збору даних (data ingestion), рівень зберігання (data lake або розподілені сховища), рівень обробки (feature engineering, нормалізація) та рівень моделювання. Використання озер даних забезпечує масштабованість і підтримку різноманітних форматів даних, що відповідає сучасним практикам побудови аналітичних платформ [7].

Моделювання технічного стану обладнання базується на поєднанні методів машинного навчання. Для задач із наявними розміченими даними застосовуються методи керованого навчання, зокрема ансамблеві алгоритми, які демонструють високу стійкість до шуму та здатність апроксимувати нелінійні залежності. У випадку домінування часової структури доцільним є використання рекурентних нейронних мереж (LSTM, GRU), які ефективно моделюють довготривалі залежності у часових рядах [8].

За умов обмеженої кількості розмічених відмов або їх статистичної рідкості задача прогнозування технічного стану трансформується у задачу виявлення аномалій. У формалізованому вигляді така задача полягає у визначенні відхилень спостережень $x(t)$ від розподілу нормального режиму функціонування $p(t)$, оціненого на основі історичних даних штатної експлуатації.

У цьому контексті доцільним є застосування методів некерованого або частково керованого навчання. Зокрема, автоенкодера реалізують відображення $f_{\theta} : x \rightarrow \hat{x}$, де аномальність визначається через величину похибки реконструкції $\|x - \hat{x}\|$. Ізоляційні ліси базуються на ідеї рекурсивного розділення простору ознак, у межах якого аномальні спостереження ізолюються за меншу кількість кроків. Методи щільнісної оцінки, зокрема ядерні оцінки густини або суміші гаусівських розподілів, дозволяють ідентифікувати області низької ймовірності як потенційні аномалії.

Зазначені підходи є особливо релевантними для промислових систем, включаючи молокопереробні підприємства, де відмови мають низьку частоту виникнення, а основний масив даних формується у режимі нормальної експлуатації, що обмежує можливості застосування керованого навчання [6, 9].

Вибір конкретної моделі повинен ґрунтуватися не лише на показниках прогностичної точності, але й на рівні інтерпретованості результатів, що є критично важливим для інтеграції у системи підтримки прийняття рішень. У цьому контексті доцільним є застосування методів пояснюваного машинного навчання, зокрема SHAP (SHapley Additive exPlanations), які забезпечують декомпозицію прогнозу за внеском окремих ознак та підвищують прозорість аналітичних висновків для інженерного персоналу [10].

Враховуючи вищезазначене, створюємо та апробуємо модуль для прогнозування відмов.

3. Модуль прогнозування відмов технологічного обладнання

Автори використали підмножину даних, отриманих із реального молокопереробного підприємства, для навчання моделей прогнозування технічного стану обладнання. Дані в наборі зібрані за кожний день протягом п'яти останніх років. Дані охоплюють п'ятирічний період експлуатації та містять інформацію щодо функціонування таких одиниць технологічного обладнання: два гомогенізатори, три насоси, один пастеризатор, три резервуари та два сепаратори. Дані структуровано у форматі CSV із наявністю часових міток, що дозволяє розглядати їх як багатовимірні часові ряди. Для кожного типу обладнання є відповідний набір ознак. Зокрема, для сепараторів використовуються такі параметри: температура продукту, рівень вібрації, струм електродвигуна, ефективність сепарації, вхідний тиск, вміст жиру на виході. Також враховується інформація про технічний стан, що відповідає типам відмов, зокрема для сепараторів: зношення тарілок сепаратора, забивання сопел, дисбаланс барабана, вихід із ладу підшипників.

Програмна реалізація виконана мовою Python із використанням середовища виконання Google Colab. Модуль прогнозування реалізовано у вигляді окремого програмного компонента, який завантажує попередньо навчені моделі разом із відповідними трансформерами ознак, здійснює уніфіковану попередню обробку вхідних

даних та формує прогноз. Передбачено механізми обробки виключних ситуацій для забезпечення коректної роботи з неконсистентними або неповними вхідними даними.

Попередня обробка даних здійснювалась із використанням бібліотеки `pandas` та включала видалення дублікатів і неінформативних ознак, обробку пропущених значень (шляхом медіанного заповнення або регресійного відновлення), а також виявлення і корекцію викидів. З метою запобігання витоку даних нормалізація та стандартизація числових ознак виконувалась виключно на тренувальній вибірці з подальшим застосуванням відповідних перетворень до валідаційних і тестових даних у межах єдиного `pipeline`, реалізованого засобами бібліотеки `scikit-learn` [11].

На етапі розвідувального аналізу даних використовувались методи візуалізації (`matplotlib`, `seaborn`), а також аналіз кореляційної структури ознак. Водночас, з урахуванням потенційної нелінійності залежностей у технічних системах, кореляційний аналіз розглядався як допоміжний інструмент.

Для оцінювання якості моделей застосовано сукупність метрик, характерних для задач класифікації: точність (Accuracy), прецизійність (Precision), повнота (Recall), F1-міра та ROC-AUC. Точність визначає частку правильно класифікованих об'єктів, проте її інформативність обмежується у випадках дисбалансу класів. Прецизійність характеризує достовірність позитивних передбачень, тоді як повнота відображає здатність моделі виявляти всі релевантні випадки відмов. F1-міра забезпечує збалансовану інтеграцію цих показників. Метрика ROC-AUC використовується для оцінювання дискримінативної здатності моделі незалежно від порогу класифікації, однак у випадку значного дисбалансу класів додатково доцільно застосовувати PR-AUC як більш чутливу до рідкісних подій [12].

Навчання моделей здійснювалось із використанням процедури крос-валідації та пошуку гіперпараметрів за методом повного перебору (Grid Search). Після визначення оптимальних параметрів модель перенавчалась на повній тренувальній вибірці. З метою збереження часової узгодженості даних застосовувалась стратегія розбиття вибірки, що враховує часову послідовність спостережень.

Оцінювання узагальнювальної здатності моделей виконувалось на відкладеній тестовій вибірці з подальшим порівнянням із базовою моделлю. Для інтерпретації результатів використовувались матриця помилок, а також графічне зіставлення фактичних і прогнозованих значень.

Автори обрали такі моделі: Gradient Boosting, Random Forest, XGBoost, LSTM, SVM. Проведено обґрунтування обраних методів, що наводиться через їх властивості.

Gradient Boosting доцільно використовувати у задачах прогнозування технічних станів обладнання з огляду на його здатність ефективно моделювати складні нелінійні залежності, характерні для багатовимірних сенсорних даних. Даний підхід належить до ансамблевих методів послідовної композиції базових моделей, переважно дерев рішень, у межах якого кожна наступна модель спрямована на мінімізацію функції втрат, сформованої на попередніх ітераціях. Формально це відповідає реалізації функціонального градієнтного спуску в просторі моделей, що забезпечує поступове уточнення апроксимації цільової залежності.

Використання Gradient Boosting є обґрунтованим у задачах, що вимагають високої точності прогнозування та здатності моделювати складні нелінійні процеси за умови належного контролю перенавчання та оптимізації параметрів моделі. Його використання доцільно у випадках, коли дані характеризуються гетерогенністю, наявністю шуму та складними взаємозв'язками між ознаками, оскільки метод демонструє високу адаптивність до таких умов. Послідовне навчання базових моделей на псевдозалишках, що відповідають антиградієнту функції втрат, дозволяє ефективно коригувати помилки попередніх ітерацій та підвищувати точність прогнозування. Алгоритмічні основи цього підходу були

сформульовані Джером Фрідманом, який запропонував узагальнену схему побудови ансамблів шляхом ітеративної оптимізації функціонала втрат [13].

Додатковим аргументом на користь застосування цього методу є його здатність забезпечувати високу прогностичну точність завдяки поетапному уточненню моделі та врахуванню складних закономірностей у даних. Це робить його особливо придатним для задач прогнозного моделювання у промислових системах, де взаємодії між параметрами мають нелінійний характер.

Водночас застосування Gradient Boosting потребує врахування обмежень. Зокрема, метод є чутливим до перенавчання за відсутності належної регуляризації, що вимагає ретельного налаштування гіперпараметрів (глибини дерев, швидкості навчання, кількості ітерацій тощо). Крім того, послідовний характер навчання обумовлює відносно високу обчислювальну складність алгоритму. Перенавчання проявляється у надмірній адаптації моделі до навчальних даних і зниженні її узагальнювальної здатності на нових вибірках, що потребує застосування процедур валідації та контролю складності моделі [14].

Метод Random Forest базується на побудові ансамблю класифікаторів, кожен з яких є деревом рішень, що тренується на випадковій підмножині навчальних даних та ознак. Завдяки такій стохастичній побудові кожного дерева забезпечується різноманітність моделей в середині ансамблю. Результати окремих дерев об'єднуються шляхом голосування для отримання кінцевого прогнозу, що дозволяє досягати вищої точності, стійкості до перенавчання та стабільності у порівнянні з використанням окремого дерева рішення. Формалізація роботи Random Forest потребує чіткого математичного опису ймовірнісної моделі, яка охоплює як механізм побудови окремих дерев, так і поведінку ансамблю загалом. Алгоритмічні засади методу були сформульовані Лео Брейманом, який показав, що поєднання bagging та випадкового вибору ознак дозволяє суттєво зменшити перенавчання та підвищити точність ансамблевих моделей [15]. Додатковою перевагою цього методу є його здатність ефективно працювати з високорозмірними даними та оцінювати важливість ознак, що має практичне значення для інтерпретації результатів і відбору релевантних параметрів. Водночас метод не потребує жорстких припущень щодо розподілу даних і добре масштабується до різних типів задач. Водночас застосування Random Forest супроводжується певними обмеженнями. Зокрема, зі збільшенням кількості дерев зростають обчислювальна складність моделі та вимоги до пам'яті. Крім того, попри відносну інтерпретованість на рівні окремих дерев, ансамблева структура ускладнює глобальне пояснення прийнятих рішень.

Отже, використання цього методу є обґрунтованим у задачах прогнозування, що характеризуються складною структурою даних, наявністю шуму та необхідністю забезпечення високої точності й стабільності результатів за умови врахування обчислювальних витрат і особливостей інтерпретації моделі [16].

Метод XGBoost (Extreme Gradient Boosting) доцільно застосовувати у задачах прогнозування технічних станів обладнання з огляду на його високу ефективність у моделюванні складних нелінійних залежностей та здатність до узагальнення на зашумлених і гетерогенних даних. Даний підхід є розширенням класичного градієнтного бустингу та ґрунтується на ітеративній побудові ансамблю дерев рішень, у якому кожна наступна модель спрямована на мінімізацію функції втрат попереднього ансамблю шляхом апроксимації антиградієнта. Методологічною перевагою XGBoost є використання формалізованого підходу до оптимізації, який базується на другому порядку розкладу функції втрат, що забезпечує більш точне та стабільне налаштування параметрів моделі. Важливим аргументом на користь використання цього методу є вбудовані механізми регуляризації, які включають штрафи за складність дерев (наприклад, обмеження кількості листків, глибини, вагових коефіцієнтів), що сприяє зменшенню перенавчання та підвищенню узагальнювальної здатності моделі. Це особливо актуально в прикладних

задачах з обмеженими або зашумленими даними, характерними для промислових інформаційних систем. XGBoost забезпечує високу точність прогнозування та стійкість до перенавчання, що підтверджує його широке застосування у задачах машинного навчання [17]. Отже, використання XGBoost є обґрунтованим у задачах, що потребують високої прогностичної здатності, ефективної обробки складних структур даних та контролю складності моделі, зокрема у системах прогнозного обслуговування технологічного обладнання [16].

Метод LSTM (Long Short-Term Memory) доцільно застосовувати у задачах прогнозування технічних станів обладнання, що базуються на аналізі часових рядів, оскільки він забезпечує ефективне моделювання залежностей із тривалими часовими проміжками. LSTM здатні зберігати релевантну інформацію протягом тривалих інтервалів часу, що є критично важливим для виявлення деградаційних процесів у технологічних системах. Архітектурно LSTM належать до класу рекурентних нейронних мереж і містять спеціалізовані комірки пам'яті разом із механізмами керування інформаційними потоками, які дозволяють моделі адаптивно визначати, яку інформацію доцільно зберігати, оновлювати або відкидати. Така структура забезпечує здатність мережі враховувати контекст попередніх спостережень і формувати більш точні прогнози майбутніх станів на основі історичних даних. Використання LSTM є обґрунтованим у задачах прогнозного моделювання, де наявні часові залежності складної природи, оскільки ці моделі здатні апроксимувати нелінійні динамічні процеси та враховувати довготривалі кореляції у даних. Це робить їх особливо ефективними у сценаріях, пов'язаних із прогнозуванням відмов обладнання на основі потоків сенсорної інформації. Водночас застосування LSTM супроводжується низкою обмежень: навчання таких моделей є обчислювально ресурсоємним і потребує значних обсягів маркованих даних для досягнення високої якості узагальнення; складність архітектури підвищує ризик перенавчання, що вимагає застосування регуляризаційних методів, а також ретельного налаштування гіперпараметрів [18].

Метод SVM (Support Vector Machines) належить до класу алгоритмів навчання з учителем і традиційно розглядається як один із базових інструментів побудови моделей класифікації та регресії у задачах аналізу даних. Його ключова концепція полягає у побудові оптимальної гіперплощини розділення класів у просторі ознак у такий спосіб, щоб максимізувати геометричний зазор між класами, що безпосередньо корелюється з підвищенням узагальнювальної здатності моделі. Такий підхід забезпечує високу стійкість до перенавчання порівняно з методами, що ґрунтуються виключно на емпіричній мінімізації ризику, оскільки оптимізаційна постановка SVM орієнтована на мінімізацію структурного ризику та контроль верхньої межі узагальнювальної похибки [19].

Додатковою перевагою SVM є його здатність ефективно працювати в умовах обмеженої кількості навчальних даних та високої розмірності простору ознак, що є типовим для прикладних задач у біомедичній інформатиці, технічній діагностиці та інших доменах складних систем. Завдяки цьому, метод демонструє стабільні узагальнювальні властивості навіть при наявності шуму в даних та складних нелінійних залежностях між змінними [20]. У порівнянні з класичними підходами машинного навчання SVM забезпечує більш контрольовану поведінку моделі завдяки формалізованому критерію максимізації зазору та структурному ризику, що зменшує ймовірність перенавчання та підвищує надійність прогнозування в практичних застосуваннях [20].

Створений модуль застосовує всі зазначені моделі для кожного обладнання. Так відбувається прогнозування збоїв та критичних станів. У табл. 1 наведено застосування всіх зазначених методів для обладнання (насос із ID-ідентифікатором PUMP-001) та метрики для кожної створеної моделі (XGBoost, Gradient Boosting, Random Forest, SVM, LSTM). А в табл. 2 представлено усереднені показники моделей для всіх одиниць обладнання.

Таблиця 1 — Таблиця порівняння моделей

ID-обладнання	Тип обладнання	Модель	Точність	Похибка	Прецизійність	Повнота	F1-міра	ROC-AUC
PUMP-001	Насос	XGBoost	0,9945	0,0055	0,9412	1,0000	0,9697	0,9993
PUMP-001	Насос	Gradient Boosting	0,9945	0,0055	1,0000	0,9375	0,9677	1,0000
PUMP-001	Насос	Random Forest	0,9917	0,0083	0,9143	1,0000	0,9552	0,9996
PUMP-001	Насос	SVM	0,9477	0,0523	0,6275	1,0000	0,7711	0,9994
PUMP-001	Насос	LSTM	0,9441	0,0559	0,6154	1,0000	0,7619	1,0000

Таблиця 2 — Таблиця порівняння моделей

Модель	Точність	Похибка	Прецизійність	Повнота	F1-міра	ROC-AUC
Gradient Boosting	0,9239	0,0761	0,8231	0,6922	0,7186	0,9422
LSTM	0,8949	0,1051	0,4322	0,5483	0,4543	0,9469
XGBoost	0,9432	0,0568	0,8929	0,6836	0,7350	0,9489
Random Forest	0,9464	0,0536	0,7924	0,5729	0,6389	0,9837
SVM	0,9389	0,0611	0,7029	0,6286	0,6075	0,8800

Результати порівняльного аналізу моделей машинного навчання для задачі прогнозування відмов технологічного обладнання свідчать про наявність суттєвих відмінностей у їхній прогностичній здатності залежно від обраної метрики якості. Узагальнено встановлено, що ансамблеві методи демонструють найвищу ефективність у контексті багатовимірних сенсорних даних, характерних для промислових систем моніторингу. Модель XGBoost забезпечує найкращий баланс між точністю та повнотою, що відображається у максимальному значенні F1-міри (0,7350). Це дозволяє розглядати її як найбільш збалансований підхід для задачі виявлення та прогнозування відмов, де критично важливо мінімізувати як пропущені інциденти, так і хибні спрацювання.

Водночас модель Random Forest характеризується найвищою загальною точністю (0,9464) та найменшим середнім рівнем похибки (0,0536), що вказує на її високу надійність у задачах класифікації нормальних станів обладнання. Однак її знижена повнота порівняно з XGBoost свідчить про обмежену здатність до виявлення всіх потенційних відмов, що є критичним недоліком у контексті прогнозного технічного обслуговування.

Додатково встановлено наявність проблемної ділянки даних для обладнання типу Резервуар TANK-003, де середня похибка перевищує 30 %. Це свідчить про недостатню інформативність або неоднорідність вибірки, що обумовлює необхідність розширення набору даних або побудови спеціалізованих індивідуалізованих моделей для даного класу обладнання.

Система формує рекомендації на наступний місяць у вигляді таблиці (табл. 3). Отримані результати демонструють ефективність застосованого підходу до прогнозування технічного стану та формування превентивних рекомендацій для обслуговування технологічного обладнання молокопереробного підприємства.

Наявність критичних станів для обладнання SEP-001 та SEP-002 свідчить про необхідність негайної організаційно-технічної інтервенції включно з позаплановим технічним обслуговуванням, резервуванням критичних запасних частин та посиленням моніторингом експлуатаційних параметрів. Тому при плануванні виготовлення продукції слід врахувати і не використовувати зазначене обладнання до проведення технічного обслуговування. Водночас решта одиниць обладнання демонструє стабільний функціональний стан зі значним залишковим ресурсом, що дозволяє застосовувати стратегію планово-попереджувального обслуговування без необхідності термінових втручань.

Таблиця 3 — Рекомендовані дії на наступний період

ID-обладнання	Тип обладнання	Статус	Рекомендовані дії
SEP-001	Сепаратор	Критичний*	Термінове ТО, підготувати запасні частини
SEP-002	Сепаратор	Критичний*	Посилений моніторинг, планувати ТО протягом тижня
НОМ-001	Гомогенізатор	Стабільний	Планове технічне обслуговування, моніторинг параметрів
НОМ-002	Гомогенізатор	Стабільний	Планове технічне обслуговування, моніторинг параметрів
PAS-001	Пастеризатор	Стабільний	Планове технічне обслуговування, моніторинг параметрів
TANK-001	Резервуар	Стабільний	Планове технічне обслуговування, моніторинг параметрів
TANK-002	Резервуар	Стабільний	Планове технічне обслуговування, моніторинг параметрів
TANK-003	Резервуар	Стабільний	Планове технічне обслуговування, моніторинг параметрів
PUMP-001	Насос	Стабільний	Планове технічне обслуговування, моніторинг параметрів
PUMP-002	Насос	Стабільний	Планове технічне обслуговування, моніторинг параметрів
PUMP-003	Насос	Стабільний	Планове технічне обслуговування, моніторинг параметрів

Отже, з точки зору прикладної доцільності для систем прогнозування стану обладнання, пріоритет слід надавати моделі XGBoost як такій, що забезпечує оптимальний компроміс між чутливістю та специфічністю, а отже мінімізує ризики непередбачених простоїв технологічного обладнання. Обґрунтування вибору конкретної моделі враховує не лише прогностичну точність, але й інтерпретованість результатів, що є критично важливим для інтеграції у системи підтримки прийняття рішень. У цьому аспекті доцільним є використання методів пояснюваного машинного навчання, які дозволяють оцінити внесок окремих ознак у формування прогнозу, а також забезпечити прозорість прийняття рішень для інженерного персоналу та при оперативному плануванні.

4. Висновки

У результаті проведеного дослідження розв'язано актуальне науково-прикладне завдання підвищення експлуатаційної надійності технологічного обладнання молокопереробних

підприємств шляхом розроблення та впровадження інтегрованого підходу до прогнозного управління, що поєднує методи машинного навчання, аналіз багатовимірних часових рядів та концепцію цифрового двійника.

Проведений системний аналіз стратегій технічного обслуговування технологічного обладнання засвідчив, що традиційні підходи, засновані на регламентному обслуговуванні, характеризуються обмеженою адаптивністю до реального технічного стану обладнання та не враховують стохастичний характер деградаційних процесів. Встановлено, що перехід до обслуговування технічного стану та прогнозно-орієнтованого обслуговування забезпечує підвищення точності діагностики завдяки використанню безперервного моніторингу параметрів та моделей прогнозування залишкового ресурсу. Обґрунтовано доцільність застосування гібридної стратегії, яка інтегрує регламентні процедури з адаптивними прогнозними механізмами, що дозволяє досягти балансу між надійністю, вартістю обслуговування та виробничими обмеженнями.

На основі порівняльного експериментального дослідження моделей машинного навчання (Gradient Boosting, Random Forest, XGBoost, LSTM, SVM) на багатовимірних часових рядах сенсорних даних встановлено, що ансамблеві методи, зокрема XGBoost, демонструють найвищу прогностичну ефективність за критеріями F1-міри та ROC-AUC, що свідчить про їх здатність забезпечувати збалансоване співвідношення між чутливістю до відмов та специфічністю щодо хибних спрацювань. У межах дослідження критичний стан обладнання формалізовано як перевищення заданого порогового значення ймовірності відмови або зниження оцінки залишкового ресурсу нижче допустимого рівня. Розроблений модуль прогнозування дозволив виявити критичні стани для технологічного обладнання, що потребують негайного технічного втручання (позапланове ТО, резервування запасних частин).

Запропонований підхід дозволяє формувати рекомендації на наступний необхідний період щодо технічного обслуговування, що безпосередньо впливає на оперативне планування виробництва: обладнання в критичному стані виключається з виробничого циклу до проведення ремонтних робіт, що мінімізує ризики незапланованих простоїв, втрат сировини та порушень технологічних режимів.

Розроблений модуль прогнозування інтегровано у контур підтримки прийняття рішень, що забезпечує автоматизоване формування рекомендацій щодо технічного обслуговування на заданому часовому горизонті планування. Це дозволяє здійснювати обґрунтоване виключення обладнання з виробничого процесу для проведення профілактичних або відновлювальних робіт, мінімізуючи ризики незапланованих простоїв, втрат сировини та порушення технологічних режимів.

Отже, поєднання математичного моделювання, методів машинного навчання та концепції цифрових двійників формує нову парадигму управління технологічним обладнанням, що відповідає вимогам Industry 4.0/5.0 та сприяє підвищенню конкурентоспроможності молокопереробних підприємств.

СПИСОК ДЖЕРЕЛ

1. Dairy Processing Handbook. Tetra Pak / Tetra Pak International S.A. 2025. 468 p. URL: <https://dairyprocessinghandbook.tetrapak.com> (дата звернення: 13.01.2026).
2. Lee J., Bagheri B., Jin C. Introduction to cyber manufacturing. *Manufacturing Letters*. 2016. Vol. 8. P. 11–15. URL: <https://www.sciencedirect.com/journal/manufacturing-letters> (дата звернення: 13.01.2026).
3. Yavuz O., Yürekli M., Öztaş G. Reliability Centered Maintenance Practices in Food Industry. *Procedia Computer Science*. 2019. Vol. 158. P. 227–234. DOI: <https://doi.org/10.1016/j.procs.2019.09.043> (дата звернення: 13.01.2026).

4. Zhang W., Yang D., Wang H. Data-driven methods for predictive maintenance of industrial equipment: A survey. *Expert Systems with Applications*. 2020. Vol. 158. DOI: <https://doi.org/10.1016/j.eswa.2020.113517> (дата звернення: 13.01.2026).
5. Lee J. *Industrial AI: Applications with Sustainable Performance*. Singapore: Springer Singapore, 2020. 162 p. DOI: <https://doi.org/10.1007/978-981-15-2144-7> (дата звернення: 13.01.2026).
6. Zhang W., Yang D., Wang H. Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Systems Journal*. 2019. Vol. 13, N 3. P. 2213–2227. DOI: <https://doi.org/10.1109/JSYST.2019.2905565> (дата звернення: 15.01.2026).
7. Що таке data lake? *AWS Amazon*. URL: <https://aws.amazon.com/big-data/datalakes-and-analytics/what-is-a-data-lake/> (дата звернення: 15.01.2026).
8. Seoh R. Solving Bayesian Network Structure Learning Problem with Integer Linear Programming. *arXiv*. 2020. 104 p. URL: <https://arxiv.org/abs/2007.02829> (дата звернення: 15.01.2026).
9. Маслов Ю.В. Використання цифрових двійників у задачах прогнозування зносу електромеханічних систем. *Вчені записки ТНУ імені В.І. Вернадського. Серія: Технічні науки*. 2025. Т. 36 (75), № 6, Ч. 2. С. 214–220. DOI: <https://doi.org/10.32782/2663-5941/2025.6.2/30>.
10. Molnar C. *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. 2nd ed. Munich: Christoph Molnar, 2022. 317 p. URL: <https://christophm.github.io/interpretable-ml-book/> (дата звернення: 15.01.2026).
11. Scikit-learn: Machine Learning in Python. Common pitfalls and recommended practices. URL: https://scikit-learn.org/stable/common_pitfalls.html (дата звернення: 16.01.2026).
12. Brownlee J. How to Use ROC Curves and Precision-Recall Curves for Classification in Python. *MachineLearningMastery.com*. 2018. URL: <https://machinelearningmastery.com/roc-curves-and-precision-recall-curves-for-classification-in-python/> (дата звернення: 16.01.2026).
13. Friedman J. H. Greedy function approximation: A gradient boosting machine. *Annals of Statistics*. 2001. Vol. 29, N 5. P. 1189–1232. DOI: <https://doi.org/10.1214/aos/1013203451>.
14. Clark B., Lee F. Qué es boosting de gradiente? *IBM*. 2025. URL: <https://www.ibm.com/es-es/think/topics/gradient-boosting> (дата звернення: 16.01.2026).
15. Breiman L. Random Forests. *Machine Learning*. 2001. Vol. 45, N 1. P. 5–32. DOI: <https://doi.org/10.1023/A:1010933404324>.
16. Конотопець М., Туровський О., Аксамітний О., Матійко А. Порівняльний аналіз моделей машинного навчання Random Forest та XGBoost у задачі класифікації інцидентів безпеки. *Herald of Khmelnytskyi National University. Technical sciences*. 2025. Т. 357, № 29. С. 235–245. DOI: <https://doi.org/10.31891/2307-5732-2025-357-29>.
17. XGBoost. *GeeksforGeeks*. 2026. URL: <https://www.geeksforgeeks.org/machine-learning/xgboost/> (дата звернення: 17.01.2026).
18. Khallaf M., Mhawi A. Long Short-Term Memory Networks: A Comprehensive Survey. *AI*. 2025. Vol. 6, N 9. P. 215. DOI: <https://doi.org/10.3390/ai6090215>.
19. Khyathi G., Indumathi K. P., Jumana Hasin A., Lisa Flavin Jency M., Sibyl Siluvai, Krishnaprakash G. Support Vector Machines: A Literature Review on Their Application in Analyzing Mass Data for Public Health. *Cureus*. 2025. Vol. 17, N 1. e77169. DOI: <https://doi.org/10.7759/cureus.77169>.
20. Vovchaliuk S., Haidai Y. Аналіз методу опорних векторів у порівнянні з традиційними методами передбачення ринкових рухів. *Системи управління, навігації та зв'язку*. 2024. Вип. 3. С. 89–93. DOI: <https://doi.org/10.26906/SUNZ.2024.3.089>.

Стаття надійшла до редакції 05.02.2026 / прийнята до друку 28.04.2026