

Д. О. ШЕВЧЕНКО, асп., Харківський національний університет імені В.Н. Каразіна, Харків;

В. Є. СТРИЛЕЦЬ, канд. техн. наук, Харківський національний університет імені В. Н. Каразіна, Харків

БАГАТОРІВНЕВА ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ДІАГНОСТУВАННЯ ТЕХНІЧНИХ СИСТЕМ НА ОСНОВІ ДАНИХ МОНІТОРИНГУ

У статті розроблено та досліджено багаторівневу інформаційну технологію технічного діагностування динамічних систем на основі даних моніторингу. Актуальність дослідження зумовлена складністю деградаційних процесів у сучасних промислових об'єктах, таких як турбовентиляторні двигуни, та необхідністю підвищення точності прогнозування їхнього технічного стану для запобігання економічним втратам і ризикам безпеки. Запропонована інформаційна технологія базується на принципах комплементарності діагностичних підходів, багаторівневої організації, модульності, ансамблювання рішень, поєднання прогнозування та класифікації, а також використання диференційованих часових представлень. Експериментальна перевірка проведена на еталонних наборах даних NASA C-MAPSS (FD001 та FD004). Результати продемонстрували високу ефективність. F1-оцінка класифікації стану перевищила 92% для складного багаторежимного набору даних FD004. Порівняльний аналіз показав, що розроблена технологія забезпечує найвищу стійкість до змін операційних режимів робіт. Падіння якості при переході від простих до складних умов експлуатації є мінімальним порівняно з існуючими аналогами. Іл.: 2. Табл.: 3. Бібліогр.: 39 назв.

Ключові слова: технічне діагностування, динамічні системи, багаторівнева інформаційна технологія, дані моніторингу, багатовимірні часові ряди, прогнозування залишкового ресурсу, ансамблювання рішень, глибоке навчання, NASA C-MAPSS.

Постановка проблеми та її актуальність. Складна природа деградації динамічних систем (турбовентиляторних двигунів, підшипників тощо) створює значні економічні ризики [1 – 3]. Розвиток концепцій Індустрії 4.0 та ІоТ дозволив накопичувати великі масиви даних моніторингу [4, 5], що зробило ефективним застосування методів машинного та глибокого навчання для виявлення аномалій, класифікації несправностей і прогнозування залишкового ресурсу (RUL) [1, 6, 7].

Сучасні підходи охоплюють широкий спектр інструментів: від класичного машинного навчання та статистичних методів до гібридних нейромережових архітектур і ансамблевих систем [8 – 10]. Попри значну кількість розробок, існуюче інформаційне забезпечення має низку недоліків: фрагментарність методів, відсутність уніфікованих часових представлень для різних компонентів [11, 12], гомогенність ансамблів та недостатню спеціалізацію модулів у багаторівневих системах [9, 10].

Отже, існує потреба у створенні багаторівневої інформаційної технології (ІТ), що інтегрує комплементарні підходи машинного навчання, що і визначає актуальність роботи.

Метою даної роботи підвищення точності та забезпечення стійкості технічного діагностування динамічних систем в умовах складності операційних режимів шляхом розробки багаторівневої інформаційної технології за рахунок інтеграції комплементарних підходів машинного навчання з ансамблюванням діагностичних рішень. Об'єктом роботи є процеси діагностування турбовентильаторних двигунів на основі даних моніторингу, а предметом – методи, математичні моделі та інформаційні технології обробки даних моніторингу стану технічних систем при їх діагностуванні.

Багаторівнева інформаційна технологія технічного діагностування та її компоненти. На основі аналізу недоліків існуючих підходів розроблено багаторівневу інформаційну технологію діагностування. Процеси розподілені за трьома рівнями:

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

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

3. Рівень прийняття інтегрованого рішення здійснює ансамблювання результатів, отриманих від різних аналітичних модулів, та

синтез інтегрованого висновку. Результатом функціонування моделі є показники, що включають оцінку технічного стану об'єкта (бінарна мітка), рівень достовірності прийнятого рішення та значення прогнозованого залишкового ресурсу.

Кожна функціональна операція технології реалізується через відповідні математичні методи.

Метод попередньої обробки та підготовки даних. Рівень попередньої обробки забезпечує якість та узгодженість вхідних даних для всіх компонентів інформаційної технології. В основу підходу покладено методи відновлення пропущених значень, нормалізації та трансформації даних [13 – 15], які було розширено механізмами комплексної інженерії та селекції ознак. Це дозволяє формувати диференційовані часові представлення, адаптовані до специфічних форматів вхідної інформації різномірних методів діагностування. Для мінімізації надмірності та мультиколінеарності реалізовано автоматизований вибір найбільш інформативних ознак за двома критеріями: пороговим відсіканням на основі кореляції Пірсона та аналізом вагових коефіцієнтів важливості, отриманих за допомогою алгоритму випадкового лісу. Додатково інженерія ознак передбачає формування нових ознак через арифметичні комбінації вхідних параметрів.

Підготовка диференційованих часових представлень для різномірних компонентів ІТ після завершення обробки виконується такими методами:

– *Метод ковзного вікна.* Нехай часовий ряд представлено послідовністю векторів спостережень $X = \{x_t \mid t=1, \dots, L\}$, де $x_t \in R^m$ – вектор параметрів у момент t ; m – кількість параметрів; L – загальна кількість часових кроків. Метод формує з цього ряду набір підпослідовностей (вікон) з перекриттям фіксованої довжини w і кроком зсуву s . i -те вікно визначається як:

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

де S_i – i -те ковзне вікно; w – розмір вікна; s – крок зсуву між послідовними вікнами; i – індекс вікна. Результатом є тривимірний масив $N \times w \times m$.

– *Метод часових вікон з агрегацією статистик.* Нехай часовий ряд $X = \{x_t \mid t=1, \dots, L\}$, ($x_t \in R^m$) поділяється на n_w послідовних вікон без перекриття. Для кожного вікна k обчислюються вектори середніх значень

μ_k та стандартних відхилень σ_k . Результируючий вектор ознак $F \in R^d$, $d = n_w \times m \times 2$, формується шляхом конкатенації статистик:

$$F = [\mu_1, \sigma_1, \mu_2, \sigma_2, \dots, \mu_n, \sigma_n], \quad (2)$$

Перевагою методу є здатність захоплювати часову прогресію деградації, де різні вікна відображають стан об'єкту на різних етапах експлуатації.

Сформовані за формулами (1) та (2) часові представлення передаються на рівень діагностування стану об'єкта для подальшої обробки.

Метод класифікації стану на основі ансамблювання контрольованих та неконтрольованих методів. Для класифікації стану на основі агрегованих вікон розроблено метод, що поєднує контрольоване та неконтрольоване навчання. Паралельна обробка у двох гілках дозволяє одночасно розпізнавати відомі типи деградації та виявляти нові аномальні структури. Аналіз виконується за такими напрямками:

- 1) контрольований – на базі випадкового лісу [16] для бінарної класифікації стану;
- 2) неконтрольований – на основі ізоляційного лісу та Z-оцінки [17, 18].

Прийняття рішень реалізовано у два етапи:

- 1) об'єднання показників неконтрольованих методів за алгоритмом, описаним у [17];
- 2) формування фінального висновку на основі ваг обох гілок аналізу.

Математично ансамблювання для спостереження x можна представити як:

$$P(x) = w_s P_s(x) + w_u P_u(x), \quad (3)$$

де w_s та w_u – вагові коефіцієнти контрольованого та неконтрольованого аналізу відповідно; $P_s(x)$ – ймовірність стану, яка визначена випадковим лісом; $P_u(x)$ – ймовірність аномальності після синтезу оцінки аномальності. Тоді формування висновку включає використання результату ансамблювання та формування достовірності прийнятого рішення про стан об'єкта.

Метод виявлення аномалій та зменшення розмірності. Для виявлення аномалій та зменшення розмірності на основі агрегованих вікон розроблено метод диференційованого навчання автокодувальників (АЕ). Архітектура нейромережі та переваги АЕ описані у [15, 17, 19]. Суть підходу полягає у використанні двох стратегій навчання:

1. АЕ1 (виявлення аномалій). Він тренується виключно на даних справного стану. Це забезпечує високу помилку реконструкції при появі деградації. Поріг виявлення θ визначається за правилом k -сигм на основі розподілу помилок реконструкції справних даних:

$$\theta = \mu_{train} + k\sigma_{train}, \quad (4)$$

де μ_{train} та σ_{train} – середнє значення та стандартне відхилення помилок реконструкції на навчальній вибірці; k – множник чутливості, що налаштовується на етапі перевірки.

2. АЕ2 (зменшення розмірності). Він тренується на повному спектрі даних. Завдяки нелінійним функціям активації АЕ2 формує у латентному просторі найбільш інформативні ознаки, виявляючи складніші залежності порівняно з лінійними методами.

Як результат, запропонований метод виявлення аномалій та зменшення розмірності на основі диференційованого навчання автокодувальників дозволяє одночасно отримувати два типи інформації, а саме діагностичне рішення про стан об'єкту та дані зменшеної розмірності.

Метод нечіткої кластеризації стану. Для виконання кластеризації станів розроблено метод, що поєднує нечіткий алгоритм C -середніх з агентно-орієнтованим підходом для автоматичного визначення кількості кластерів [13, 14, 17]. Метод підтримує два режими функціонування для виявлення аномалій:

1. *Неконтрольований режим.* Рішення базується на векторі ступенів належності та відстані до центрів кластерів. Спостереження вважається аномальним, якщо максимальний ступінь належності нижчий за поріг або відстань до найближчого центру перевищує критичне значення.

2. *Напівконтрольований режим.* Він передбачає маркування кластерів на етапі навчання за мажоритарним правилом (часткою

деградованих станів у кластері). Діагностичне рішення для нового об'єкта приймається за міткою кластера з максимальним ступенем належності.

Гнучкість у виборі режимів дозволяє налаштувати технологію до наявності або відсутності розмітки даних. Результатом методу є бінарна мітка стану та достовірність рішення, що відповідає максимальному ступеню належності спостереження до кластера.

Метод прогнозування залишкового ресурсу (RUL) базується на рекурентній нейронній мережі для розв'язання задачі регресії. На основі багатовимірних часових рядів метод формує числовий прогноз \hat{y} (кількість циклів до відмови) та бінарне діагностичне рішення за пороговим принципом. Тобто, якщо \hat{y} є меншим критичного порога θ , то метод класифікує стан об'єкта як деградований.

Також формується достовірність прийнятого рішення, яка визначається на основі відстані \hat{y} від порогового значення, що описується математично, як:

$$C = \begin{cases} 1 - \frac{\hat{y}}{\theta}, & \text{якщо } Y(x) = 1, \\ \min\left(1, \frac{\hat{y} - \theta}{\theta}\right), & \text{в іншому випадку,} \end{cases} \quad (5)$$

де $Y(x)$ – бінарне діагностичне рішення, \hat{y} – прогноз RUL, θ – пороговий RUL. Для деградованого стану впевненість зростає при зменшенні RUL, для справного стану впевненість зростає при збільшенні відстані від порогу.

Отже, розроблений метод отримує багатовимірні часові ряди на вхід та формує діагностичне рішення, яке включає прогнозований RUL, стан об'єкту та достовірність прийнятого рішення.

Метод класифікації стану на основі гібридної нейронної мережі.

Для класифікації технічного стану розроблено метод на основі гібридної нейронної мережі, архітектура якої поєднує блоки згорткових шарів для вилучення локальних ознак та рекурентних шарів для моделювання довгострокової часової динаміки. Така комбінація, представлена на рис. 1, нівелює обмеження окремих типів мереж у задачах аналізу багатовимірних послідовностей. Процес обробки передбачає послідовну трансформацію тензорів через згортковий, рекурентний та повнозв'язний

блоки, де для узгодження розмірностей даних застосовано шари перестановки осей (Permute).

Параметри моделі, зокрема кількість фільтрів та розміри прихованих шарів, є адаптивними, що дозволяє гнучко налаштувати мережу під специфіку об'єкта. Навчання здійснюється з використанням оптимізатора Adam та функції бінарної крос-ентропії, а стійкість до перенавчання забезпечується застосуванням шарів Dropout і стратегії ранньої зупинки.

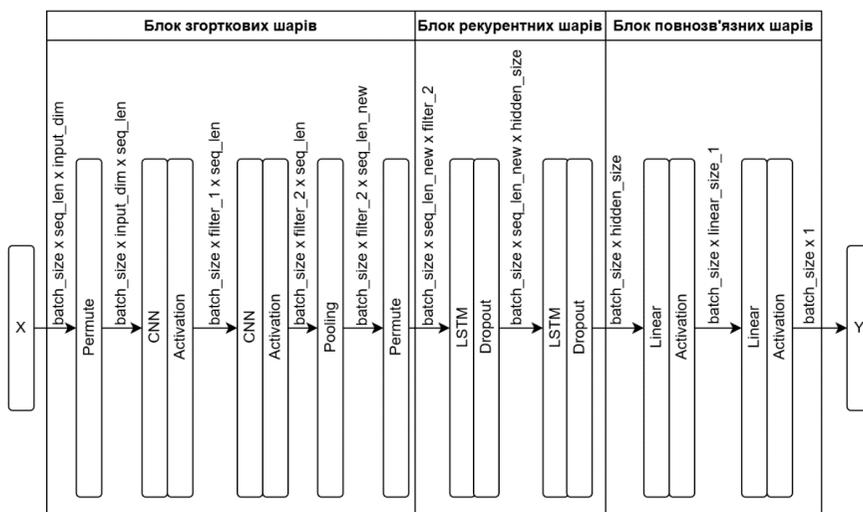


Рис. 1. Архітектура гібридної нейронної мережі

Якщо прогноз \hat{y} перевищує пороговий рівень θ , метод класифікує стан як деградований. Достовірність прийнятого рішення визначається на основі відстані прогнозованої ймовірності:

$$C = \max(\hat{y}, 1 - \hat{y}). \quad (6)$$

Високі або низькі значення ймовірності відповідають високій достовірності. Таким чином, метод трансформує багатовимірні часові ряди у комплексний висновок про стан об'єкта та ступінь достовірності діагнозу.

Метод ансамблювання діагностичних рішень. Рівень прийняття інтегрованого рішення реалізує метод ансамблювання діагностичних висновків за трьома стратегіями. Метод базується на векторі вагових коефіцієнтів $w = (w_1, \dots, w_5)$, де кожне $w_i \in [0, 1]$ відображає важливість i -го методу у інтегрованому рішенні. Вагові коефіцієнти задовольняють

умову нормалізації. Можливість встановлення $w_i = 0$ дозволяє виключати компоненти з низькою якістю діагностування.

Тоді кожен метод $i \in \{1 - 5\}$ формує діагностичне рішення A_i та достовірність прийнятого рішення C_i . Математично можна формалізувати стратегії наступним чином:

$$S_b = \sum_{i=2}^6 w_i A_i, \quad (7)$$

$$S_c = \sum_{i=2}^6 w_i A_i C_i, \quad (8)$$

$$S_s = \sum_{i=2}^6 w_i [A_i C_i + (1 - A_i)(1 - C_i)], \quad (9)$$

$$S_h = \frac{S_b + S_c + S_s}{3}. \quad (10)$$

Бінарне голосування (7) враховує лише дискретні рішення модулів без оцінки їхньої впевненості та забезпечує високу інтерпретованість, проте ігнорує варіативність достовірності окремих методів. В свою чергу зважене голосування за достовірністю (8) посилює вплив найбільш впевнених рішень, використовуючи C_i як вагові множники. Найбільш стійку інтеграцію рішень забезпечує гібридне голосування, яке мінімізує конфлікти між методами шляхом усереднення бінарного (7), зваженого (8) та м'якого (9) підходів. Тоді показник гібридного голосування визначається як середнє арифметичне трьох компонентів (10). Як результат, така стратегія демонструє найкращу стійкість до різномірності діагностичних методів.

Інтегрований висновок формується на основі результату обраної стратегії ансамблювання S_w . Фінальне бінарне рішення визначається порівнянням S_w із порогом θ , де стан класифікується як деградований при $S_w > \theta$. Достовірність інтегрованого рішення розраховується як нормалізована відстань від порога:

$$C_t = \frac{|S_w - \theta|}{1 - \theta}, \quad (11)$$

при цьому вищі значення вказують на зростання впевненості системи у висновку. Таким чином метод ансамблювання формує наступний інтегрований висновок про стан об'єкта: оцінка технічного стану (бінарне

рішення), достовірність прийнятого рішення та прогнозований RUL, що доповнює бінарне рішення кількісною інформацією про очікуваний час до відмови у робочих циклах.

Інтегрована робота інформаційної технології. Для математичного опису введемо умовні позначення. Нехай X_{raw} є множиною вхідних даних моніторингу, X_{seq} є багатовимірними часовими рядами, X_{agg} – агреговані часові вікна. Дані зменшеної розмірності визначені, як Z . Кожен метод діагностування та ансамблювання $i \in \{1, 2, 3, 4, 5, f\}$ формує бінарне діагностичне рішення A_i та достовірність C_i . Прогнозоване RUL визначено, як \hat{y} .

Схема інтегрованої роботи методів в багаторівневій інформаційній технології діагностування представлена на рис. 2, де чітко вказані відповідності використання розроблених методів до функціональних компонентів інформаційної системи.

Таким чином, розроблена багаторівнева інформаційна технологія забезпечує перехід від необроблених даних моніторингу до комплексного діагностичного висновку. Це дозволяє не лише констатувати поточний стан об'єкта з відповідним рівнем достовірності, а й кількісно оцінити залишковий ресурс для прийняття обґрунтованих рішень щодо подальшої експлуатації об'єкта діагностування.

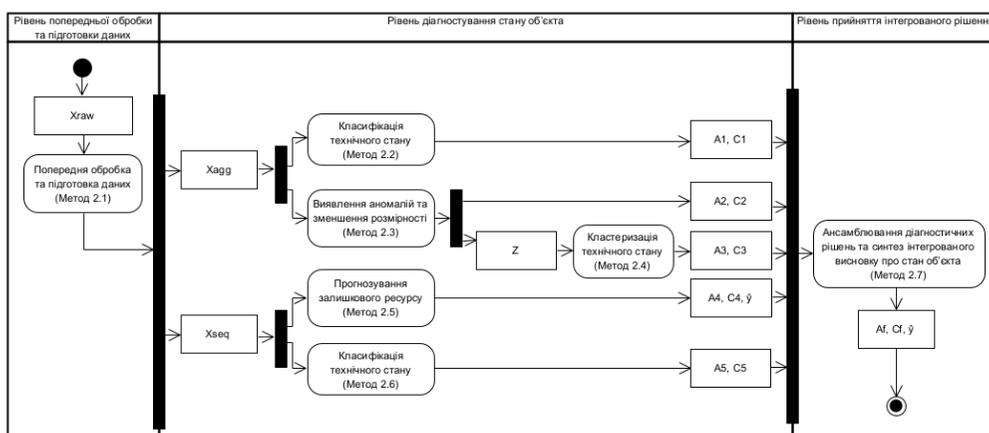


Рис. 2. Схема інтегрованої роботи методів в багаторівневій інформаційній технології діагностування

Огляд результатів та якості діагностування інформаційної технології. Для експериментальної перевірки технології використано еталонний набір даних C-MAPSS (NASA) [20], що широко застосовується для оцінки алгоритмів діагностування та прогнозування RUL [25 – 39]. Дослідження проведено на двох підмножинах, що містять 21 параметр сенсорів: FD001 – один режим експлуатації, один тип відмови; FD004 – шість режимів, два типи відмов. Дані розділено на тренувальну, перевірочну та тестову вибірки. Для автоматизованої підготовки використано метод 2.1. Бінарне маркування станів виконано на основі значень RUL. Спостереження у яких RUL є більше 50 вважаються справними, інші – деградованими.

Для оцінки якості інформаційної технології використовуються набори метрик в залежності від типу задачі, оскільки вона вирішує задачі бінарної класифікації та регресії. Основними метриками оцінювання якості бінарної класифікації є точність (Accuracy), точність виявлення (Precision), повнота виявлення (Recall) та F1-міра. Тоді для задачі регресії були обрані наступні метрики: середньоквадратична помилка (MSE), корінь середньоквадратичної помилки (RMSE), середня абсолютна помилка (MAE) і коефіцієнт детермінації (R^2). Обрані метрики доповнюють одна одну та забезпечують комплексну оцінку якості розробленої інформаційної технології діагностування.

Оцінка якості розробленої інформаційної технології здійснювалася на основі порівняльного аналізу результатів для підмножин FD001 та FD004. Обсяг вибірки для тестування склав: для FD001 – 100 останніх вікон та 11 196 повних траєкторій; для FD004 – 246 останніх вікон та 36 502 повні траєкторії життєвого циклу. Узагальнені результати наведені у табл. 1.

Результати на останніх вікнах траєкторій демонструють високу стійкість технології до ускладнення умов експлуатації. При переході до багаторежимного набору FD004, F1-оцінка знижується лише на 1.81%. Більше того, точність виявлення на FD004 покращується до 94.74% (+3.31% порівняно з FD001) зі зниженням повноти до 90%, що обумовлено складністю виявлення деградованих станів в умовах багаторежимності.

Таблиця 1

Результати оцінки якості на FD001 та FD004

Метрика	FD001		FD004	
	Останні вікна	Повні траєкторії	Останні вікна	Повні траєкторії
Класифікація				
Точність	96.00%	96.54%	95.12%	96.09%
Точність виявлення	91.43%	74.53%	94.74%	70.65%
Повнота	96.97%	85.55%	90.00%	62.49%
F1-оцінка	94.12%	79.66%	92.31%	66.32%
Хибні спрацювання	3	259	4	584
Пропущені відмови	1	128	8	844
Регресія				
RMSE	16.82	16.34	18.41	16.38
MAE	11.58	11.47	12.32	10.04
R ²	0.824	0.67	0.801	0.537
Середня помилка	+0.81	-3.52	-3.58	-5.72

При переході від діагностування критичних станів до аналізу повних траєкторій спостерігається закономірне зниження метрик. Для FD001 F1 – оцінка знижується на 14.46%, а для FD004 – на 25.99%. Це пояснюється складністю раннього виявлення деградації (при RUL > 80), де симптоми несправності майже не відрізняються від нормальних флуктуацій сигналу. Метрики MAE залишаються стабільними в обох сценаріях. Зниження R² до 0.537 на повних траєкторіях FD004 відображає ширший діапазон значень RUL та високу варіативність даних на початкових етапах роботи.

Слід відмітити зміну середньої помилки прогнозу. Якщо на FD001 (останні вікна) помилка складає +0.81, то на повних траєкторіях та наборі FD004 вона стає від'ємною (до -5.72). Це свідчить про стратегію недооцінювання залишкового ресурсу, що є критично важливим для запобігання раптовим відмовам у реальних авіаційних двигунах.

Порівняльний аналіз з існуючими підходами технічного діагностування. Розглянемо результати порівняння за задачею бінарної класифікації стану системи. Результати порівняльного аналізу математичних моделей і методів бінарної класифікації стану об'єкту

наведено у табл. 2. Методи та математичні моделі без посилань представляють експерименти, проведені у рамках дослідження.

Аналіз табл. 2 свідчить, що більшість існуючих методів суттєво втрачають якість при переході від FD001 до складного набору FD004. Хоча деякі підходи ефективніші на простих даних, їхня стійкість до змін операційних умов є низькою. Запропонована ІТ демонструє найкращу F1-оцінку на FD004 та найменше падіння якості серед усіх аналогів. Здатність зберігати високу точність у багаторежимних умовах підтверджує ефективність розробленої технології для реальних систем із високою варіативністю параметрів.

Хоча основною задачею розробленої інформаційної технології є оцінка стану, вона також виконує прогнозування RUL. Результати порівняльного аналізу математичних моделей і методів наведено у табл. 3.

Аналіз табл. 3 підтверджує, що при переході до FD004 точність прогнозування у всіх методів знижується. Хоча на FD001 деякі підходи демонструють кращі результати, розроблена ІТ забезпечує найвищу стійкість до багаторежимності. RMSE на FD004 лише на 0.18 вище за лідера (DA-TCN), але при цьому стабільність показників у 4 рази вища.

Таблиця 2

Порівняння математичних моделей і методів класифікації на наборах даних FD001 та FD004

Модель/ Метод	FD001 F1 (%)	FD004 F1 (%)	Різниця (%)
CNN-LSTM [21]	89.7	-	-
MmoE-GRU [22]	57.21	60.55	+3.34
Decision Tree	74.2	63.4	-10.8
Time Net [23]	94.02	72.76	-21.26
MmoE-BiGRU [22]	79.66	76.53	-3.13
ROCKET [22]	89.19	78.11	-11.08
Support Vector Machine	87.1	79.8	-7.3
SB-BiGRU [22]	67.66	80.32	+12.66
Gradient Boosting	91.2	83.1	-8.1
Random Forest	92.54	83.95	-8.59
LSTM [24]	94.0	85.0	-9.0
Vanilla Transformer [23]	96.24	87.81	-8.43
Linear [25]	92.0	89.1	-2.9
CNN-LSTM [23]	94.24	90.83	-3.41
Запропонована ІТ	94.12	92.31	-1.81

Таблиця 3

Порівняння математичних моделей і методів прогнозування RUL на наборах даних FD001 та FD004

Метод	FD001 RMSE	FD004 RMSE	Різниця
LSTM [26]	27.74	30.32	+2.58
DBN [27]	18.48	30.02	+11.54
Gradient Boosting [27]	18.8	29.46	+10.66
MODBNE [27]	17.96	29.45	+11.49
LSTM-AON [28]	16.81	28.10	+11.29
LSTM + Attention [29]	14.45	27.08	+12.63
SKF [27]	19.24	26.76	+7.52
GA-CNN-LSTM [30]	15.92	26.32	+10.40
DCNN [27]	12.61	23.31	+10.70
RCNN-Abi-LSTM [31]	12.98	22.29	+9.31
Multi-attention-TCN [32]	13.25	21.69	+8.44
GATA-TCN [33]	12.80	21.04	+8.24
GM-LSTM [34]	14.08	20.91	+6.83
CNN-LSTM-SAM [35]	12.6	20.5	+7.9
CNN-Bi-LSTM-3Dattention [36]	13.12	20.24	+7.12
Att-LSTM [37]	13.95	20.21	+6.26
CNN-BGRU-SA [38]	13.88	19.39	+5.51
DA-TCN [39]	11.78	18.23	+6.45
<i>Запропонована IT</i>	16.82	18.41	+1.59

Ключовою перевагою IT є показник різниці RMSE між наборами, що становить лише 1.59 проти 6.45 у найближчого конкурента. Така мінімальна деградація точності гарантує стабільну роботу технології в реальних індустріальних умовах з мінливими режимами експлуатації.

Висновки. У роботі представлена багаторівнева інформаційна технологія діагностування технічних систем на основі даних моніторингу, яка включає три рівні: попередньої обробки та підготовки даних, діагностування стану об'єкту та прийняття інтегрованого рішення. Розроблена модель функціонування технології визначає основні функціональні компоненти та їх взаємодію, а схема інтегрованої роботи методів в інформаційній технології формалізує використання методів.

Для експериментальної перевірки використано еталонний набір даних NASA C-MAPSS (підмножини FD001 та FD004). Експериментальні результати продемонстрували високу ефективність у вирішенні задач бінарної класифікації стану та прогнозування RUL. На останніх вікнах

траєкторій досягнута F1-оцінка понад 92% для обох наборів зі зниженням якості лише 1.81% при переході до багаторежимного набору. Важливою характеристикою є стратегія недооцінювання залишкового ресурсу, що мінімізує ризики критичних відмов у реальних авіаційних системах.

Порівняльний аналіз підтвердив переваги розробленої технології. У задачі класифікації технологія продемонструвала найкращу F1-оцінку на складному наборі FD004 та найменше падіння якості між наборами серед усіх аналогів. У задачі прогнозування RUL забезпечена найвища стійкість з різницею RMSE між наборами 1.59, що у 4 рази краще за найближчого конкурента. Хоча деякі підходи досягають вищих абсолютних значень метрик на простих даних, розроблена технологія демонструє найкращий баланс між точністю та стійкістю в умовах варіативності операційних режимів.

Практичне значення полягає у застосуванні для підвищення надійності критичних промислових систем, що дозволяє знизити економічні втрати від непередбачуваних відмов та оптимізувати графіки технічного обслуговування.

Слід зазначити, що результати отримані на синтетичних даних NASA C-MAPSS з контрольованими умовами. Ефективність окремих компонентів може відрізнятись при застосуванні до реальних промислових даних з більшою варіативністю шумів та типів відмов. Подальші дослідження можуть бути спрямовані на апробацію технології на реальних промислових даних та дослідження можливості багатокласової діагностики з ідентифікацією конкретних типів несправностей.

Список літератури:

1. Tsui, K.L., Chen, N., Zhou, Q., Hai, Y., Wang, W. Prognostics and Health Management: A Review on Data Driven Approaches. *Mathematical Problems in Engineering*. 2015, 1–17. <https://doi.org/10.315/2015/793161>
2. Ran, Y., Zhou, X., Lin, P., Wen, Y., Deng, R. A Survey of Predictive Maintenance: Systems, Purposes and Approaches, <https://arxiv.org/abs/1912.07383>
3. Riccio, C., Menanno, M., Zennaro, I., Savino, M.M. A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters. *Machines*. 12, 443 (2024). <https://doi.org/10.3390/machines12070443>
4. Yildirim, C., Franco-Pereira, A.M., Lillo, R.E. Condition monitoring and multi-fault classification of hydraulic systems using multivariate functional data analysis. *Heliyon*. 11, e41251 (2025). <https://doi.org/10.1016/j.heliyon.2024.e41251>

5. A. Parida, P. Tretten. Condition monitoring and diagnosis of modern dynamic complex systems using criticality aspect of key performance indicators. *International Journal of COMADEM*. 20, 35–39 (2017)
6. Salinas-Camus, M., Goebel, K., Eleftheroglou, N. A comprehensive review and evaluation framework for data-driven prognostics: Uncertainty, robustness, interpretability, and feasibility. *Mechanical Systems and Signal Processing*. 237, 113015 (2025). <https://doi.org/10.1016/j.ymssp.2025.113015>
7. Lei, L., Li, W., Zhang, S., Wu, C., Yu, H. Research Progress on Data-Driven Industrial Fault Diagnosis Methods. *Sensors*. 25, 2952–2952 (2025). <https://doi.org/10.3390/s25092952>
8. Al Farizi, W.S., Hidayah, I., Rizal, M.N. Isolation Forest Based Anomaly Detection: A Systematic Literature Review, <https://ieeexplore.ieee.org/abstract/document/9617498>
9. Mian, Z., Deng, X., Dong, X., Tian, Y., Cao, T., Chen, K., Tareq Al Jaber. A literature review of fault diagnosis based on ensemble learning. *Engineering applications of artificial intelligence*. 127, 107357–107357 (2024). <https://doi.org/10.1016/j.engappai.2023.107357>
10. Ahmad, S., Styp-Rekowski, K., Sasho Nedelkoski, Kao, O. Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines. *arXiv (Cornell University)*. (2021). <https://doi.org/10.48550/arxiv.2101.3139>
11. Ndao, M.L., Youness, G., Niang, N., Saporta, G. Improving predictive maintenance: Evaluating the impact of preprocessing and model complexity on the effectiveness of eXplainable Artificial Intelligence methods. *Engineering Applications of Artificial Intelligence*. 144, 110144 (2025). <https://doi.org/10.1016/j.engappai.2025.110144>
12. Syed, M.A.B., Hasan, M.R., Chowdhury, N.I., Rahman, M.H., Ahmed, I. A systematic review of time series algorithms and analytics in predictive maintenance. *Decision Analytics Journal*. 15, 100573 (2025). <https://doi.org/10.1016/j.dajour.2025.100573>
13. V. V. Donets, V. Y. Strilets, M. L. Ugryumov, D. O. Shevchenko, S. V. Prokopovych, and L. O. Chagovets. *METHODOLOGY OF THE COUNTRIES' ECONOMIC DEVELOPMENT DATA ANALYSIS*. *System Research and Information Technologies*, vol. 2023, no. 4, pp. 21–36, 2023.
14. Donets V., Strilets V., Shevchenko D., Shmatkov S. Agent-oriented method of clustering the wholesale distributor data. *Bulletin of V.N. Karazin Kharkiv National University, series «Mathematical modeling. Information technology. Automated control systems»*. 2022. (55). С. 6-18.
15. Shevchenko, D., Ugryumov, M. and Artiukh, S. (2023) “Monitoring data aggregation of dynamic systems using information technologies”, *Innovative technologies and scientific solutions for industries*, 1 (23), pp. 123–131. doi: 10.30837/ITSSI.2023.23.123.
16. Yang, Y., Wang, H.: Random Forest-Based Machine Failure Prediction: A Performance Comparison. *Applied Sciences*. 15, 8841–8841 (2025). <https://doi.org/10.3390/app15168841>
17. Donets, V., Shevchenko, D., Holikov, M., Strilets, V., & Shmatkov, S. (2024). Application of a data stratification approach in computer medical monitoring systems. *Eastern-European Journal of Enterprise Technologies*, 2(9 (128), 6–16.
18. Лихач О. Ю., Угрюмов М. Л., Шевченко Д. О., Шматков С. І. Методи виявлення викидів в пробних вибірках при управлінні процесами в системах за станом. *Вісник Харківського національного університету імені В. Н. Каразіна серія "Математичне*

модельовання. Інформаційні технології. Автоматизовані системи управління". 2022. № 53. С. 21-40.

19. D.O. Shevchenko, M. L. Ugrumov, I. S. Kholmohortseva. Anomaly detection methods in data processing using computational intelligence methods // Збірник наукових праць XII Всеукраїнської міжнародної наукової конференції з міжнародною участю "Academic and Scientific Challenges in the 21st Century: CLIL in Action". – Харків: ХНУ ім. В.Н. Каразіна, 2023. – 342 с.

20. A. Saxena and K. Goebel (2008). Turbofan Engine Degradation Simulation Data Set, NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field, CA.

21. Ensarioglu, K. Hierarchical RUL Prediction for Turbofan Engines Based on Health Stage Classification and Change Point-Guided Data Augmentation. IEEE Access. 13, 134241–134260 (2025). <https://doi.org/10.1109/access.2025.3593206>

22. Wu, Z., Wu, K. Prognostic classification based on random convolutional kernel. arXiv (Cornell University). (2022). <https://doi.org/10.48550/arxiv.2204.04527>

23. Fan, Y., Dang, Y., Guo, Y. Fault Identification Model Using Convolutional Neural Networks with Transformer Architecture. Sensors. 25, 3897–3897 (2025). <https://doi.org/10.3390/s25133897>

24. Wang, Y., Zhao, Y. Multi-Scale Remaining Useful Life Prediction Using Long Short-Term Memory. Sustainability. 14, 15667 (2022). <https://doi.org/10.3390/su142315667>

25. Yıldırım, U., Afşer, H. Linear Methods for Predictive Maintenance: The Case of NASA C-MAPSS Datasets. Applied Sciences. 15, 9945 (2025). <https://doi.org/10.3390/app15189945>

26. Xia, T., Song, Y., Zheng, Y., Pan, E., Xi, L. An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation. Computers in Industry. 115, 103182 (2020). <https://doi.org/10.1016/j.compind.2019.103182>

27. 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. 28, 2306–2318 (2017). <https://doi.org/10.1109/tnnls.2016.2582798>

28. Li, S., Zhang, C., Liu, L., Zhang, X. Gated Transient Fluctuation Dual Attention Unit Network for Long-Term Remaining Useful Life Prediction of Rotating Machinery Using IIoT. IEEE Internet of Things Journal. 11, 18593–18604 (2024). <https://doi.org/10.1109/jiot.2024.3363837>

29. Chen, Z., Wu, M., Zhao, R., Guretno, F., Yan, R., Li, X. Machine Remaining Useful Life Prediction via an Attention-Based Deep Learning Approach. IEEE Transactions on Industrial Electronics. 68, 2521–2531 (2021). <https://doi.org/10.1109/tie.2020.2972443>

30. Amin, U., Kumar, K.D. Remaining Useful Life Prediction of Aircraft Engines Using Hybrid Model Based on Artificial Intelligence Techniques, <https://ieeexplore.ieee.org/document/9486500>

31. Wang, H., Li, D., Li, Y., Zhu, G., Lin, R. Method for Remaining Useful Life Prediction of Turbofan Engines Combining Adam Optimization-Based Self-Attention Mechanism with Temporal Convolutional Networks. Applied Sciences. 14, 7723–7723 (2024). <https://doi.org/10.3390/app14177723>

32. Shang, Z., Zhang, B., Li, W., Qian, S., Zhang, J. Machine remaining life prediction based on multi-layer self-attention and temporal convolution network. *Complex & Intelligent Systems*. 8, 1409–1424 (2021). <https://doi.org/10.1007/s40747-021-00606-4>
33. Jayasinghe, L., Tharaka Samarasinghe, Yuen, C., Chen, J., Ge, S.S. Temporal Convolutional Memory Networks for Remaining Useful Life Estimation of Industrial Machinery. *arXiv (Cornell University)*. 915–920 (2019). <https://doi.org/10.1109/icit.2019.8754956>
34. You, K., Qiu Guangqi, Gu, Y. A 3D Attention-enhanced Hybrid Neural Network for Turbofan Engine Remaining Life Prediction Using CNN and BiLSTM Models. *IEEE Sensors Journal*. 1–1 (2023). <https://doi.org/10.1109/jsen.2023.3296670>
35. Kıymet Ensarioğlu, Tülin İnkaya, Emel, E. Remaining Useful Life Estimation of Turbofan Engines with Deep Learning Using Change-Point Detection Based Labeling and Feature Engineering. *Applied Sciences*. 13, 11893–11893 (2023). <https://doi.org/10.3390/app132111893>
36. Sun, J., Zheng, L., Huang, Y., Ge, Y. Remaining Useful Life Prediction Based on CNN-BGRU-SA. *Journal of Physics: Conference Series*. 2405, 012007 (2022). <https://doi.org/10.1088/1742-6596/2405/1/012007>
37. Boujamza, A., Lissane Elhaq, S. Attention-based LSTM for Remaining Useful Life Estimation of Aircraft Engines. *IFAC-PapersOnLine*. 55, 450–455 (2022). <https://doi.org/10.1016/j.ifacol.2022.07.353>
38. Song, Y., Gao, S., Li, Y., Jia, L., Li, Q., Pang, F. Distributed Attention-Based Temporal Convolutional Network for Remaining Useful Life Prediction. *IEEE Internet of Things Journal*. 8, 9594–9602 (2021). <https://doi.org/10.1109/jiot.2020.3004452>
39. Y. Xin, S. Hu, G. Yang. DA-TCN Based Temperature Prediction Algorithm for Heating Furnace. 2024 IEEE 13th Data Driven Control and Learning Systems Conference (DDCLS), Kaifeng, China, 2024, pp. 611-617, doi: 10.1109/DDCLS61622.2024.10606591.

References:

1. Tsui, K.L., Chen, N., Zhou, Q., Hai, Y., Wang, W. (2015) “Prognostics and Health Management: A Review on Data Driven Approaches”. *Mathematical Problems in Engineering*. Vol.6, pp. 1–17. <https://doi.org/10.315/2015/793161>
2. Ran, Y., Zhou, X., Lin, P., Wen, Y., Deng, R. (2019) “A Survey of Predictive Maintenance: Systems, Purposes and Approaches”. *arXiv*. <https://doi.org/10.48550/arXiv.1912.07383>
3. Riccio, C., Menanno, M., Zennaro, I., Savino, M.M. (2024) “A New Methodological Framework for Optimizing Predictive Maintenance Using Machine Learning Combined with Product Quality Parameters”. *Machines*. 12, 443. <https://doi.org/10.3390/machines12070443>
4. Yildirim, C., Franco-Pereira, A.M., Lillo, R.E. (2025) “Condition monitoring and multi-fault classification of hydraulic systems using multivariate functional data analysis”. *Heliyon*. 11, e41251. <https://doi.org/10.1016/j.heliyon.2024.e41251>
5. A. Parida, P. Tretten. (2017) “Condition monitoring and diagnosis of modern dynamic complex systems using criticality aspect of key performance indicators”. *International Journal of COMADEM*. 20, 35–39

- 6.** Salinas-Camus, M., Goebel, K., Eleftheroglou, N. (2025) "A comprehensive review and evaluation framework for data-driven prognostics: Uncertainty, robustness, interpretability, and feasibility". *Mechanical Systems and Signal Processing*. 237, 113015. <https://doi.org/10.1016/j.ymsp.2025.113015>
- 7.** Lei, L., Li, W., Zhang, S., Wu, C., Yu, H. (2025) "Research Progress on Data-Driven Industrial Fault Diagnosis Methods". *Sensors*. 25, 2952–2952. <https://doi.org/10.3390/s25092952>
- 8.** Al Farizi, W.S., Hidayah, I., Rizal, M.N. (2021) "Isolation Forest Based Anomaly Detection: A Systematic Literature Review". *8th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE)*, Semarang, Indonesia. pp. 118-122, doi: 10.1109/ICITACEE53184.2021.9617498
- 9.** Mian, Z., Deng, X., Dong, X., Tian, Y., Cao, T., Chen, K., Tareq Al Jaber. (2024) "A literature review of fault diagnosis based on ensemble learning". *Engineering applications of artificial intelligence*. 127, 107357–107357. <https://doi.org/10.1016/j.engappai.2023.107357>
- 10.** Ahmad, S., Styp-Rekowski, K., Sasho Nedelkoski, Kao, O. (2021) "Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines". *arXiv* (Cornell University). <https://doi.org/10.48550/arxiv.2101.3139>
- 11.** Ndao, M.L., Youness, G., Niang, N., Saporta, G. (2025) "Improving predictive maintenance: Evaluating the impact of preprocessing and model complexity on the effectiveness of eXplainable Artificial Intelligence methods". *Engineering Applications of Artificial Intelligence*. 144, 110144. <https://doi.org/10.1016/j.engappai.2025.110144>
- 12.** Syed, M.A.B., Hasan, M.R., Chowdhury, N.I., Rahman, M.H., Ahmed, I. (2025) "A systematic review of time series algorithms and analytics in predictive maintenance". *Decision Analytics Journal*. 15, 100573. <https://doi.org/10.1016/j.dajour.2025.100573>
- 13.** V. V. Donets, V. Y. Strilets, M. L. Ugryumov, D. O. Shevchenko, S. V. Prokopovych, L. O. Chagovets. (2023) Methodology of the countries' economic development data analysis. *System Research and Information Technologies*, vol. 2023, no. 4, pp. 21–36.
- 14.** Donets V., Strilets V., Shevchenko D., Shmatkov S. (2022) "Agent-oriented method of clustering the wholesale distributor data". *Bulletin of V.N. Karazin Kharkiv National University, series «Mathematical modeling. Information technology. Automated control systems»*. Vol. 55, pp. 6-18.
- 15.** Shevchenko, D., Ugryumov, M. and Artiukh, S. (2023) "Monitoring data aggregation of dynamic systems using information technologies". *Innovative technologies and scientific solutions for industries*, 1 (23), pp. 123–131. doi: 10.30837/ITSSI.2023.23.123.
- 16.** Yang, Y., Wang, H. (2025) "Random Forest-Based Machine Failure Prediction: A Performance Comparison". *Applied Sciences*. 15, 8841–8841. <https://doi.org/10.3390/app15168841>
- 17.** Donets, V., Shevchenko, D., Holikov, M., Strilets, V., Shmatkov, S. (2024). "Application of a data stratification approach in computer medical monitoring systems". *Eastern-European Journal of Enterprise Technologies*, 2(9 (128)), 6–16.
- 18.** Lyhach O., Ugryumov M., Shevchenko D., Shmatkov S. (2022) "Methods for detecting emissions in test samples when managing processes in condition-based systems". *Bulletin of*

V.N. Karazin Kharkiv National University, series «Mathematical modeling. Information technology. Automated control systems». Vol. 53, pp. 21-40.

19. D.O. Shevchenko, M. L. Ugryumov, I. S. Kholmohortseva. (2023) “Anomaly detection methods in data processing using computational intelligence methods”. Collection of scientific papers of the XII Ukrainian International Scientific Conference with international participation “Academic and Scientific Challenges in the 21st Century: CLIL in Action”. Kharkiv, Karazin University. P. 342.

20. Saxena A., Goebel K. (2008) Turbofan Engine Degradation Simulation Data Set, NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field, CA.

21. Ensarioglu, K. (2025) “Hierarchical RUL Prediction for Turbofan Engines Based on Health Stage Classification and Change Point-Guided Data Augmentation”. *IEEE Access*. 13, 134241–134260. <https://doi.org/10.1109/access.2025.3593206>

22. Wu, Z., Wu, K. (2022) “Prognostic classification based on random convolutional kernel”. *arXiv* (Cornell University). <https://doi.org/10.48550/arxiv.2204.04527>

23. Fan, Y., Dang, Y., Guo, Y. (2025) “Fault Identification Model Using Convolutional Neural Networks with Transformer Architecture”. *Sensors*. 25, 3897–3897. <https://doi.org/10.3390/s25133897>

24. Wang, Y., Zhao, Y. (2022) “Multi-Scale Remaining Useful Life Prediction Using Long Short-Term Memory”. *Sustainability*. 14, 15667. <https://doi.org/10.3390/su142315667>

25. Yıldırım, U., Afşer, H. (2025) “Linear Methods for Predictive Maintenance: The Case of NASA C-MAPSS Datasets”. *Applied Sciences*. 15, 9945. <https://doi.org/10.3390/app15189945>

26. Xia, T., Song, Y., Zheng, Y., Pan, E., Xi, L. (2020) “An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation”. *Computers in Industry*. 115, 103182. <https://doi.org/10.1016/j.compind.2019.103182>

27. Zhang, C., Lim, P., Qin, A.K., Tan, K.C. (2017) “Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics”. *IEEE Transactions on Neural Networks and Learning Systems*. 28, 2306–2318. <https://doi.org/10.1109/tnnls.2016.2582798>

28. Li, S., Zhang, C., Liu, L., Zhang, X. (2024) “Gated Transient Fluctuation Dual Attention Unit Network for Long-Term Remaining Useful Life Prediction of Rotating Machinery Using IIoT”. *IEEE Internet of Things Journal*. 11, 18593–18604. <https://doi.org/10.1109/jiot.2024.3363837>

29. Chen, Z., Wu, M., Zhao, R., Guretno, F., Yan, R., Li, X. (2021) “Machine Remaining Useful Life Prediction via an Attention-Based Deep Learning Approach”. *IEEE Transactions on Industrial Electronics*. 68, 2521–2531. <https://doi.org/10.1109/tie.2020.2972443>

30. Amin, U., Kumar, K.D. (2021) “Remaining Useful Life Prediction of Aircraft Engines Using Hybrid Model Based on Artificial Intelligence Techniques”. *2021 IEEE International Conference on Prognostics and Health Management (ICPHM)*, Detroit (Romulus), MI, USA, pp. 1-10, doi: 10.1109/ICPHM51084.2021.9486500.

31. Wang, H., Li, D., Li, Y., Zhu, G., Lin, R. (2024) “Method for Remaining Useful Life Prediction of Turbofan Engines Combining Adam Optimization-Based Self-Attention Mechanism with Temporal Convolutional Networks”. *Applied Sciences*. 14, 7723–7723. <https://doi.org/10.3390/app14177723>

32. Shang, Z., Zhang, B., Li, W., Qian, S., Zhang, J. (2021) "Machine remaining life prediction based on multi-layer self-attention and temporal convolution network". *Complex & Intelligent Systems*. 8, 1409–1424. <https://doi.org/10.1007/s40747-021-00606-4>
33. Jayasinghe, L., Tharaka Samarasinghe, Yuen, C., Chen, J., Ge, S.S. (2019) "Temporal Convolutional Memory Networks for Remaining Useful Life Estimation of Industrial Machinery". *arXiv (Cornell University)*. 915–920. <https://doi.org/10.1109/icit.2019.8754956>
34. You, K., Qiu Guangqi, Gu, Y. (2023) "A 3D Attention-enhanced Hybrid Neural Network for Turbofan Engine Remaining Life Prediction Using CNN and BiLSTM Models". *IEEE Sensors Journal*. 1. <https://doi.org/10.1109/jsen.2023.3296670>
35. Kıymet Ensarioğlu, Tülin İnkaya, Emel, E. (2023) "Remaining Useful Life Estimation of Turbofan Engines with Deep Learning Using Change-Point Detection Based Labeling and Feature Engineering". *Applied Sciences*. 13, 11893–11893. <https://doi.org/10.3390/app132111893>
36. Sun, J., Zheng, L., Huang, Y., Ge, Y. (2022) "Remaining Useful Life Prediction Based on CNN-BGRU-SA". *Journal of Physics: Conference Series*. 2405, 012007. <https://doi.org/10.1088/1742-6596/2405/1/012007>
37. Boujamza, A., Lissane Elhaq, S. (2022) "Attention-based LSTM for Remaining Useful Life Estimation of Aircraft Engines". *IFAC-PapersOnLine*. 55, 450–455. <https://doi.org/10.1016/j.ifacol.2022.07.353>
38. Song, Y., Gao, S., Li, Y., Jia, L., Li, Q., Pang, F. (2021) "Distributed Attention-Based Temporal Convolutional Network for Remaining Useful Life Prediction". *IEEE Internet of Things Journal*. 8, 9594–9602. <https://doi.org/10.1109/jiot.2020.3004452>
39. Y. Xin, S. Hu, G. Yang. (2024) "DA-TCN Based Temperature Prediction Algorithm for Heating Furnace". *2024 IEEE 13th Data Driven Control and Learning Systems Conference (DDCLS)*, Kaifeng, China, pp. 611-617, doi: 10.1109/DDCLS61622.2024.10606591.

Надійшла (received) 13.01.2026.

Стаття прийнята до друку 05.02.2026

Опублікована 27.02.2026

Представила д-р техн. наук, проф. Харківського національного університета імені В.Н. Каразіна Мірошник М.А.

Shevchenko Dmytro, PhD student, V. N. Karazin Kharkiv National University, Svobody Sq., 6, Kharkiv, Ukraine, 61022, e-mail: dimych24@gmail.com, ORCID ID: 0000-0002-7897-250X

Strilets Viktoriia, Candidate of Technical science, associate professor, V. N. Karazin Kharkiv National University, Svobody Sq., 6, Kharkiv, Ukraine, 61022, e-mail: viktoria.strilets@karazin.ua, ORCID ID: 0000-0002-2475-1496

УДК 004.9:62-044.7

Багаторівнева інформаційна технологія діагностування технічних систем на основі даних моніторингу / Шевченко Д.О., Стрілець В.Є. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2026. – № 1 (15). – С. 134 – 154.

У статті розроблено та досліджено багаторівневу інформаційну технологію технічного діагностування динамічних систем на основі даних моніторингу. Актуальність дослідження зумовлена складністю деградаційних процесів у сучасних промислових об'єктах, таких як турбовентилляторні двигуни, та необхідністю підвищення точності прогнозування їхнього технічного стану для запобігання економічним втратам і ризикам безпеки. Запропонована інформаційна технологія базується на принципах комплементарності діагностичних підходів, багаторівневої організації, модульності, ансамблювання рішень, поєднання прогнозування та класифікації, а також використання диференційованих часових представлень. Експериментальна перевірка проведена на сталонних наборах даних NASA C-MAPSS (FD001 та FD004). Результати продемонстрували високу ефективність. F1-оцінка класифікації стану перевищила 92% для складного багаторежимного набору даних FD004. Порівняльний аналіз показав, що розроблена технологія забезпечує найвищу стійкість до змін операційних режимів робіт. Падіння якості при переході від простих до складних умов експлуатації є мінімальним порівняно з існуючими аналогами. Іл.: 2. Табл.: 3. Бібліогр.: 39 назв.

Ключові слова: технічне діагностування, динамічні системи, багаторівнева інформаційна технологія, дані моніторингу, багатовимірні часові ряди, прогнозування залишкового ресурсу, ансамблювання рішень, глибоке навчання, NASA C-MAPSS.

UDC 004.9:62-044.7

Multi-level information technology for technical system diagnostics based on monitoring data / Shevchenko D., Strilets V. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkiv: NTU "KhPI". – 2026. – № 1 (15). – P. 134 – 154.

The article develops and investigates a multi-level information technology for technical diagnostics of dynamic systems based on monitoring data. The relevance of the research is determined by the complexity of degradation processes in modern industrial facilities, such as turbofan engines, and the need to improve the accuracy of forecasting their technical condition to prevent economic losses and safety risks. The proposed information technology is based on the principles of complementarity of diagnostic approaches, multi-level organization, modularity, ensemble of solutions, combination of forecasting and classification, as well as the use of differentiated time representations. Experimental verification was carried out on NASA C-MAPSS reference datasets (FD001 and FD004). The results demonstrated high efficiency. The F1-score of the state classification exceeded 92% for the complex multi-mode FD004 dataset. A comparative analysis showed that the developed technology provides the highest resistance to changes in operating modes. The drop in quality when transitioning from simple to complex operating conditions is minimal compared to existing analogues. Fig.: 2. Tabl.: 3. Refs.: 39 items.

Keywords: technical diagnostics, dynamic systems, multi-level information technology, monitoring data, multidimensional time series, residual resource forecasting, decision ensemble, deep learning, NASA C-MAPSS.