

DOI: <https://doi.org/10.33216/1998-7927-2025-295-9-81-90>

УДК 621.316.92:004.89:004.94

ІНТЕЛЕКТУАЛЬНІ МЕТОДИ ПРОГНОЗУВАННЯ ВІДМОВ СИЛОВОГО ЕЛЕКТРОТЕХНІЧНОГО ОБЛАДНАННЯ НА ОСНОВІ БАГАТОРІВНЕВИХ ЦИФРОВИХ ДВІЙНИКІВ

Цвєтков О.В.

INTELLIGENT METHODS FOR PREDICTING FAILURES OF POWER ELECTROTECHNICAL EQUIPMENT BASED ON MULTILEVEL DIGITAL TWINS

Tsvietkov O.V.

Стаття досліджує питання використання інтелектуальних підходів до передбачення несправностей силового електрообладнання з використанням багаторівневих цифрових двійників, які інтегрують фізичне моделювання, технології машинного навчання та аналіз великих масивів даних з метою підвищення надійності функціонування енергетичних мереж. Дослідження спрямоване на розробку та експериментальне підтвердження комплексної цифрової моделі, що синтезує *physics-informed* математичні рівняння з інтелектуальними алгоритмами глибокого навчання для досягнення вищої точності прогнозування залишкового експлуатаційного ресурсу та мінімізації кількості технічних несправностей у трансформаторному обладнанні та асинхронних електродвигунах. Методологічна основа дослідження базується на формуванні багатошарової архітектури цифрового двійника, що охоплює: сенсорний рівень агрегації даних, рівень фізичного моделювання електромагнітних, термічних та механічних явищ, аналітичний рівень застосування алгоритмів машинного навчання та рівень прийняття управлінських рішень із залученням елементів нечіткої логіки. Здобуті наукові результати засвідчили, що застосування гібридної моделі може дозволити досягти зниження середньоквадратичного відхилення похибок RMSE до рівня 0,031, скорочення MAPE до 2,8 % та зростання коефіцієнта F1-score до 0,93, що значно переважає результативність класичних діагностичних методик. Встановлено визначальний вплив повноти сенсорної інформації та періодичності актуалізації моделей на прогностичну точність, а також підтверджено спроможність системи до автоматичної адаптації при варіації режимів навантаження. Створена архітектура

продемонструвала резистентність до дефіциту даних і високий рівень узагальнювальної здатності ($CV < 0,06$). Прикладне значення дослідження виявляється у скороченні аварійних зупинок на 30-40 %, оптимізації експлуатаційних витрат і трансформації до ризик-орієнтованої стратегії керування технічним станом обладнання. Напрями подальших наукових пошуків включають стандартизацію технологій цифрових двійників, розвиток методів *explainable AI* та впровадження базових систем кібербезпеки для промислових цифрових платформ нового покоління.

Ключові слова: цифровий двійник, інтелектуальне прогнозування, машинне навчання, залишковий ресурс, технічна діагностика, енергетичне обладнання.

Вступ. Поточна фаза еволюції енергетичного сектору визначається масштабною цифровою трансформацією та зміщенням парадигми від конвенційних методів експлуатації до інтелектуалізованих систем управління, що реалізують неперервний моніторинг, аналітичне оброблення та прогностичне моделювання технічного стану об'єктів енергетичної інфраструктури. Інтенсифікація навантажень на силове електротехнічне обладнання, ускладнення архітектури енергосистем і підвищення критеріїв надійності актуалізують потребу у впровадженні інноваційних методів технічної діагностики та обслуговування, що ґрунтуються на концепції цифрових двійників та інтелектуальних алгоритмах передбачення

аварійних станів [9]. Застосування віртуальних репрезентацій фізичних об'єктів уможливило не тільки симуляцію фізико-технічних процесів, а й побудову предикативної моделі експлуатаційної поведінки у режимі реального часу через інтеграцію потоків сенсорних даних, моделей машинного навчання та аналітичних описів механізмів деградації. Практична значущість дослідження визначається необхідністю розроблення адаптивних самонавчальних систем, орієнтованих на забезпечення стабільності енергопостачання, редукцію позапланових простоїв та оптимізацію життєвого циклу електротехнічних активів.

Аналіз наукових публікацій демонструє інтенсивне дослідження синергії технологій цифрових двійників та штучного інтелекту у контексті технічної діагностики й прогностичного обслуговування. Дослідження [2], [7] систематизують архітектурні концепції формування цифрових двійників енергетичних систем, де інтеграція моделей фізичних явищ з алгоритмами машинного навчання сприяє підвищенню достовірності прогнозування технічних аномалій. Дослідники [11], [13] обґрунтовують ефективність глибоких нейронних архітектур (CNN, LSTM, Autoencoder) для ідентифікації латентних дефектів та оцінювання залишкового експлуатаційного ресурсу (RUL). Праці [4] та [6] ілюструють результативність імплементації цифрових двійників у системи енергетичного менеджменту, тоді як [5] і [8] наголошують на доцільності гібридизації physics-informed підходів з методами пояснювального штучного інтелекту. Узагальнення наукового дискурсу підтверджує консолідовану тенденцію трансформації від реактивних стратегій технічного обслуговування до превентивно-предикативних систем, здатних гарантувати операційну стійкість енергетичної інфраструктури.

Метою статті є дослідження особливостей формування багаторівневої цифрової моделі силового електротехнічного обладнання, яка поєднує фізично-інформовані підходи та інтелектуальні алгоритми машинного навчання для підвищення точності прогнозування відмов і залишкового ресурсу

Виклад основного матеріалу дослідження. Архітектура багаторівневого цифрового двійника силового електротехнічного обладнання розглядається як комплексна динамічна система, що поєднує фізичний об'єкт, віртуальну математичну

модель і аналітичний інтелектуальний шар управління, між якими встановлюється двосторонній обмін даними в реальному часі, що забезпечує не лише імітацію, але й адаптивне прогнозування розвитку технічного стану об'єкта. Структура багаторівневої моделі включає чотири основні рівні функціонування: рівень даних, рівень цифрового моделювання, рівень аналітики та рівень керування. На рівні даних здійснюється сенсорний моніторинг параметрів електротехнічного обладнання за допомогою систем SCADA, IoT-вузлів і вбудованих датчиків струму, напруги, температури, вібрації та частоти, які формують безперервний потік сигналів $x_i(t)$, що є вхідними змінними для цифрового двійника [15]. Цей потік обробляється у вигляді матриці часових рядів:

$$X(t) = \begin{bmatrix} x_1(t_1) & x_1(t_2) & \dots & x_1(t_n) \\ x_2(t_1) & x_2(t_2) & \dots & x_2(t_n) \\ \dots & \dots & \dots & \dots \\ x_m(t_1) & x_m(t_2) & \dots & x_m(t_m) \end{bmatrix} \quad (1)$$

де: m – кількість сенсорів;

n – кількість вимірів за проміжок часу.

Для усунення шумів застосовується ковзне середнє або фільтр Калмана, а нормалізація проводиться за формулою:

$$x_i'(t) = \frac{x_i(t) - \min(x_i)}{\max(x_i) - \min(x_i)}. \quad (2)$$

На рівні цифрового моделювання формується віртуальний образ обладнання, який відтворює електромагнітні, теплові та механічні процеси з урахуванням матеріальних характеристик і експлуатаційних режимів. Математична модель електричної підсистеми виражена системою диференціальних рівнянь:

$$L \frac{d_i(t)}{dt} + R_i(t) + e(t) = 0, \quad (3)$$

де: L – індуктивність обмоток;

R – активний опір;

$e(t)$ – електрорушійна сила, що залежить від збурень у мережі.

Теплова підсистема описується рівнянням теплопередачі [14]:

$$C \frac{dT(t)}{dt} = P_{\text{втрат}}(t) - hA[T(t) - T_{\text{ср}}], \quad (4)$$

де: C – теплоємність;
 $P_{\text{втрат}}$ – потужність втрат;
 h – коефіцієнт тепловіддачі;
 A – площа охолодження;
 $T_{\text{ср}}$ – температура середовища.

Механічні коливання системи описуються рівнянням:

$$M \frac{d^2\theta}{dt^2} + c \frac{d\theta}{dt} + k\theta = M_{\text{ел}}, \quad (5)$$

де: M – момент інерції ротора;
 c – коефіцієнт демпфування;
 k – жорсткість валу;
 $M_{\text{ел}}$ – електромагнітний момент.

Представлені три підсистеми поєднуються у спільній симуляційній платформі цифрового двійника, що відтворює повну динаміку процесів деградації елементів. На рівні аналітики цифровий двійник перетворюється на інтелектуальний аналітичний модуль, де застосовуються методи машинного навчання та глибоких нейромереж для розпізнавання закономірностей і прогнозування відмов. У моделі прогнозування залишкового ресурсу використовується рекурентна нейромережа LSTM, яка отримує на вхід часові ряди параметрів $\{x_1(t), x_2(t), \dots, x_m(t)\}$ і дає наступну оцінку функції стану $f(t)$, яка апроксимується як [12]:

$$f(t + \Delta t) = LSTM(x(t), h, c), \quad (6)$$

де: ht – прихований стан;
 tc – контекстна пам'ять, що забезпечує врахування попередніх спостережень. Для виявлення аномалій у багатовимірних даних застосовується автоенкодер з функцією втрат:

$$L = \|X - \hat{X}\|^2, \quad (7)$$

де: X – вхідні дані;
 $\hat{X}$ – реконструйовані дані;
відхилення $L > L_{\text{кр}}$ сигналізує про потенційну відмову.

Для виділення просторових закономірностей у сигналах струму, напруги та температури використовується згорткова нейромережа (CNN), що реалізує операцію згортки:

$$s(t) = (x \cdot w)(t) = \sum_i x(i)w(t-i), \quad (8)$$

де: w – ядро фільтра.

У гібридних моделях CNN-LSTM забезпечується як просторово-часовий, так і кореляційний аналіз ознак.

На рівні керування результати прогнозу перетворюються у рішення щодо технічного обслуговування, що реалізується як функція прийняття рішень:

$$D(t) = \begin{cases} 1, & \text{якщо } RUL(t) < R_{\text{min}}, \\ 0, & \text{інакше} \end{cases} \quad (9)$$

де: $RUL(t)$ – прогнозований залишковий ресурс;
 R_{min} – порогове значення ресурсу, нижче якого ініціюється ремонт або заміна вузла.

Математичне представлення процесів деградації елементів обладнання базується на рівняннях старіння ізоляції, теплових навантажень і вібраційних збурень [16]. Для електроізоляційних матеріалів модель зносу визначається за експоненціальним законом:

$$L(t) = L_0 e^{-\alpha T(t)}, \quad (10)$$

де: $L(t)$ – залишковий строк служби;
 α – температурний коефіцієнт старіння.

Теплова деградація описується моделлю Арреніуса:

$$k(T) = A e^{\frac{-RT}{Ea}}, \quad (11)$$

де: Ea – енергія активації процесу;
 R – універсальна газова стала;
 A – передекспоненціальний множник.

Вібраційні дефекти описуються через спектральну густину коливань:

$$S(f) = \frac{1}{T} \left| \int_{-T/2}^{T/2} s(t) e^{-j2\pi f t} dt \right|^2 \quad (12)$$

де аномальні піки у спектрі сигналізують про пошкодження підшипників або дисбаланс ротора. Гібридна модель прогнозування об'єднує physics-informed і data-driven підходи у єдину структуру, де фізична частина формує апіорні обмеження для навчання ШІ-моделі [5]. У загальному вигляді така модель описується як:

$$y(t) = f_{phys}(x(t), \theta_p) + f_{ML}(x(t), \theta_m), \quad (13)$$

де: f_{phys} – фізична модель;

f_{ML} – навчена неймережа;

θ_p і θ_m – вектори параметрів, що коригуються під час інтеграції моделей.

Таблиця 1

Структура багаторівневої цифрової моделі прогнозування відмов (сформовано автором)

Рівень системи	Джерела даних / моделі	Алгоритмічні методи	Функціональний результат
1. Рівень даних (сенсорика, SCADA)	Датчики струму, напруги, температури, вібрацій, SCADA-архіви	Калманів фільтр, moving average	Очищені та синхронізовані часові ряди параметрів
2. Рівень цифрового моделювання	Електромагнітна, теплова, механічна підсистеми	MATLAB/Simulink, Ansys Twin Builder	Віртуальне відтворення поведінки обладнання та процесів деградації
3. Рівень аналітики (AI-моделі)	Ознаки, отримані з моделі й сенсорів	LSTM, CNN, Autoencoder, PINN	Прогноз технічного стану, виявлення аномалій, оцінка RUL
4. Рівень керування	Результати прогнозу, граничні стани	Decision rules, fuzzy logic	Автоматичне прийняття рішень про ремонт або заміну
5. Інтеграційний рівень (cloud-edge)	Промислові мережі, стандарти зв'язку	Модуль інтеграції та синхронізації даних	Взаємодія цифрового двійника з системою діагностики підприємства

Інтеграція моделі у систему технічної діагностики підприємства реалізується за допомогою cloud-edge архітектури, де обчислення з високими вимогами до швидкодії виконуються на рівні периферійних вузлів (edge computing), а довгострокові аналітичні задачі, тренування моделей і візуалізація виконуються у хмарному середовищі. Такий підхід

забезпечує баланс між швидкістю реакції та аналітичною глибиною [13]. Стандартизовані інтерфейси, як-от IEC 61850, OPC UA або MQTT, забезпечують взаємодію між цифровими двійниками різних виробників і рівнів – від окремого агрегату до системи підстанції.

Апробація проводилася на реальних промислових об'єктах, зокрема на прикладі силових трансформаторів типу ТМ-400/10 та асинхронних двигунів серії АІР132М, що функціонують у системах електроприводу гірничо-збагачувального виробництва. Для кожного типу об'єкта створювався окремий цифровий двійник, який реалізовував багаторівневу архітектуру: фізичний рівень із сенсорними каналами, віртуальну симуляційну модель електромагнітних і теплових процесів, аналітичний рівень неймережевого прогнозування та рівень керування, який формував рішення щодо технічного обслуговування [1]. Основною метою апробації було визначення точності, стабільності та швидкодії запропонованої системи прогнозування у порівнянні з традиційними підходами технічної діагностики, що базуються на фіксованих інтервалах оглядів і статистичних моделях без самонавчання [10]. Для кількісного оцінювання ефективності прогнозування використовувалися чотири ключові метрики:

1) Root Mean Square Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

2) Mean Absolute Percentage Error (MAPE):

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (15)$$

3) F1-score:

$$Precision = \frac{TP}{TP + FP} \quad (16)$$

$$Recall = \frac{TP}{TP + FN} \quad (17)$$

$$F1-score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (18)$$

4) Area Under Curve (AUC):

$$AUC = \int_0^1 TPR(FPR)d(FPR), \quad (19)$$

де: TP – істинно позитивні;

FP – хибно позитивні;

FN – хибно негативні класифікації;

PR та FP – показники істинно-позитивної та хибно-позитивної частот відповідно.

Всі вони можуть всебічно оцінювати поведінку моделі як у контексті безперервного прогнозу залишкового ресурсу, так і в задачах класифікації станів (нормальний, передаварійний, аварійний). Порівняння результатів моделювання показало, що впровадження гібридної моделі, яка поєднує фізично-інформовані (physics-informed) рівняння з машинним навчанням, забезпечує істотне зменшення помилки прогнозування залишкового ресурсу обладнання. Для трансформаторів середнє значення RMSE знизилося з 0,087 до 0,031, а MAPE – із 9,4 % до 2,8 %, що вказує на підвищення точності в 3,4 рази у порівнянні з базовими методами. Для асинхронних двигунів показники були дещо нижчими, але все ж істотно поліпшилися: RMSE = 0,046, MAPE = 4,1 %, при цьому F1-score перевищував 0,92, що свідчить про високу надійність класифікації станів. Графічний аналіз ROC-кривих підтвердив стійку роботу системи навіть при обмеженій кількості даних, що демонструє AUC = 0,96 для трансформаторів і AUC = 0,94 для двигунів.

Стабільність роботи моделей оцінювалася методом крос-валідації (k -fold = 10), що дозволило виявити, що варіативність результатів не перевищує 5 %, а коефіцієнт варіації $CV = \sigma/\mu$ для помилки прогнозу залишався нижчим за 0,06, що вказує на високу узагальнювальну здатність моделі. Для порівняння: традиційні моделі, побудовані на регресійних залежностях і експертних правилах, мали значно більшу нестабільність ($CV \approx 0,18$ -0,22).

У процесі експериментів виявлено декілька ключових чинників, що визначають ефективність прогнозу. По-перше, повнота сенсорних даних: відсутність навіть одного з критичних параметрів (наприклад, температури

обмоток трансформатора або осьових вібрацій двигуна) призводила до зростання RMSE на 25-30 %, що свідчить про високу чутливість системи до втрат даних. По-друге, частота оновлення вимірювань: при зменшенні інтервалу збору даних з 10 с до 1 с точність прогнозу RUL (Remaining Useful Life) збільшувалася на 15-18 %, завдяки кращій репрезентативності динаміки деградаційних процесів. По-третє, синхронізація рівнів цифрового двійника – несвоєчасне оновлення аналітичної моделі або симуляційного ядра призводило до накопичення похибок і «зсуву» прогнозу, особливо в умовах змінних навантажень [3]. Нижче наведено узагальнену таблицю з результатами оцінювання ефективності, порівняльним аналізом та головними факторами впливу (табл. 2).

Порівняльний аналіз засвідчив, що запропонована архітектура забезпечує істотне зниження частоти відмов обладнання за рахунок раннього прогнозу деградаційних процесів та своєчасного технічного обслуговування. Для підприємства з трансформаторами середнього класу навіть 25 % скорочення аварійних випадків означає річну економію понад 1,2 млн грн за рахунок зменшення простоїв, витрат на позапланові ремонти та штрафів за порушення графіка енергопостачання. Крім того, система дозволила скоротити час на проведення діагностичних процедур на 30-40 %, оскільки аналітичний рівень автоматично формує пріоритети для технічного персоналу, а алгоритм прогнозу RUL виконує попередню класифікацію станів агрегатів. Додатковим результатом дослідження стало підвищення надійності систем технічної діагностики через автоматичну самооцінку якості моделей. Функція self-validation здійснюється шляхом обчислення показника узгодженості Q_c :

$$Q_c = 1 - \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (20)$$

де: $Q_c > 0,99$ свідчить про високу довіру до результатів. Під час експлуатації цифрового двійника цей коефіцієнт підтримувався на рівні 0,93-0,95, що забезпечує надійність аналітичних прогнозів.

Таблиця 2

**Ефективність та фактори впливу на точність прогнозування відмов
електротехнічного обладнання (сформовано автором)**

№	Об'єкт / Методика	RMSE	MAPE (%)	F1-score	AUC	Основні переваги	Основні чинники впливу	Результати впровадження
1	Трансформатор ТМ-400/10, традиційна діагностика (планові вимірювання)	0,087	9,4	0,78	0,85	Простота реалізації, відомі процедури	Низька частота вимірів, відсутність інтеграції даних	Висока кількість хибно позитивних спрацювань, перевитрати часу на обслуговування
2	Трансформатор ТМ-400/10, гібридна DT+AI модель	0,031	2,8	0,93	0,96	Висока точність, адаптивність до навантажень, прогноз RUL	Повнота сенсорних даних, синхронізація моделей	Скорочення відмов на 41 %, зменшення простоїв на 23 %
3	Асинхронний двигун АІР132М, традиційна система віброконтролю	0,081	8,6	0,81	0,88	Визначення грубих дефектів	Обмежена кількість параметрів	Несвоєчасне виявлення передаварійних станів
4	Асинхронний двигун АІР132М, інтелектуальний DT (LSTM+Autoencoder)	0,046	4,1	0,92	0,94	Виявлення прихованих дефектів, прогнозні сценарії	Повнота сигналів, якість синхронізації edge-cloud	Скорочення часу діагностики на 35 %, підвищення надійності на 27 %
5	Узагальнена модель з explainable AI та адаптивною оновлюваністю	0,038	3,3	0,95	0,97	Інтерпретованість рішень, динамічне перенавчання	Частота оновлення, затримка потоків даних	Самооновлення моделей, стабільність прогнозу на 2 роки експлуатації

Дослідження також дозволило сформуванню узагальненої закономірності впливу якості даних і обчислювальних ресурсів на точність прогнозу, що можна описати аналітичним виразом:

$$\eta_{\text{прогн}} = f(\rho_d, \tau_u, \gamma_s) = k_1 \rho_d^{\alpha_1} k_2 \tau_u^{\alpha_2} - k_3 (1 - \gamma_s)^{-\alpha_3}, \quad (21)$$

де: ρ_d – коефіцієнт повноти даних;

τ_u – середній час оновлення моделі;

γ_s – частота синхронізації шарів DT;

α_i – емпіричні показники чутливості. Для трансформаторів отримано $\alpha_1=0,46$, $\alpha_2=0,31$, $\alpha_3=0,27$, що підтверджує перевагу фактору якості даних над швидкістю оновлення.

Серед практичних ефектів упровадження системи слід виділити не лише зменшення простоїв, але й перехід до ризик-орієнтованого технічного обслуговування, коли рішення приймаються не на основі календарного графіка, а залежно від прогнозного ресурсу. Завдяки цій парадигмі підприємство отримує змогу планувати ремонти на основі реального стану, знижуючи експлуатаційні ризики без втрати надійності. Перспективи подальших досліджень у цій сфері охоплюють кілька стратегічних напрямів. Перш за все – стандартизація моделей цифрових двійників, яка потребує розроблення

уніфікованих описів інформаційних потоків, параметрів сенсорів та інтерфейсів взаємодії між підсистемами, відповідно до міжнародних протоколів IEC 61850, ISO/IEC 30182, OPC UA Companion Specifications. Це дозволить створювати взаємодіючі модулі цифрових двійників, які можна буде інтегрувати в єдині промислові екосистеми.

Другим напрямом є розвиток explainable AI (XAI) у прогнозуванні технічного стану, що забезпечить інтерпретованість рішень системи та підвищить довіру до результатів. Для цього доцільно використовувати методи SHAP (Shapley Additive Explanations) і LIME (Local Interpretable Model-Agnostic Explanations), які дозволяють визначити внесок кожного параметра у формування прогнозу, що особливо важливо для критичних об'єктів енергетичної інфраструктури.

Третій напрям стосується кіберзахисту цифрових копій обладнання, адже в умовах зростаючої цифровізації промисловості загроза несанкціонованого втручання у віртуальні моделі або потокові дані може спричинити серйозні наслідки. Запропоновано концепцію «trusted twin», коли цифровий двійник забезпечується блокчейн-підтвердженням цілісності даних, а обмін між вузлами здійснюється через захищені канали з

автентифікацією та шифруванням на рівні протоколу MQTT over TLS (рис.).

Завдяки поєднанню фізичного моделювання, інтелектуальних алгоритмів і децентралізованої обробки даних багаторівневий цифровий двійник стає самонавчальною системою, яка здатна не лише відтворювати поточний стан силового обладнання, але й прогнозувати його деградаційні процеси, оптимізуючи технічне обслуговування на основі об'єктивних аналітичних показників.




Рис. Багаторівнева архітектура цифрового двійника силового електротехнічного обладнання з інтеграцією фізичних моделей та інтелектуальних методів прогнозування (розроблено автором)

Таким чином, створена архітектура здатна буде забезпечити повну циклічність інформаційних потоків – data acquisition → digital modeling → intelligent prediction → decision making → model retraining – що є ключовою передумовою для переходу від реактивного до превентивно-прогностичного управління технічним станом електроенергетичних систем.

Отже, результати проведених досліджень доводять, що створення багаторівневої архітектури цифрових двійників у поєднанні з інтелектуальними алгоритмами прогнозування формує нову якість технічної експлуатації електроенергетичного обладнання, забезпечуючи зменшення аварійності, економію ресурсів та підвищення безпеки енергосистем. Наукова новизна полягає у синергетичному об'єднанні physics-informed modelling і неймережевих методів прогнозу, що дозволяє перейти від постфактум-діагностики до самонавчальних систем превентивного

обслуговування. перспективи розвитку підтверджується розгортанням мережі взаємопов'язаних цифрових двійників, які в майбутньому забезпечуватимуть повну автономність управління технічним станом критичних енергетичних активів.

Висновки. Дослідженням встановлено, що інтеграція багатошарової структури цифрового двійника з алгоритмами глибинного навчання і забезпечує принципово вищу якість прогнозування технічного стану силового електрообладнання.

Впровадження комбінованої моделі, яка об'єднує physics-informed математичні співвідношення з неймережевими архітектурами, дозволило досягти зменшення показника RMSE до величини 0,031 та MAPE до 2,8 %, що формує триразове-чотириразове перевищення результативності порівняно з конвенційними діагностичними підходами. Отримані результати підтверджують високу здатність моделі до адаптації при варіативних навантаженнях і її потенціал до автономного навчання під час функціонування.

Встановлено, що результативність інтелектуального передбачення несправностей детермінується комплексом системних чинників — повнотою сенсорної інформації, темпоральністю актуалізації вимірювань та узгодженістю між структурними рівнями цифрового двійника. Сформульована аналітична залежність, яка продемонструвала, що визначальним параметром виступає коефіцієнт інформаційної повноти даних, вплив якого на прогностичну якість переважає над впливом частоти оновлення чи обчислювальної потужності. За умов оптимального інформаційного забезпечення система досягає показника AUC вище 0,96, що забезпечує високу достовірність класифікації експлуатаційних станів і консистентність результатів при тривалому використанні.

Розроблена інтелектуальна система прогнозування на базі технології цифрових двійників генерує практичний ефект у формі скорочення часу простою обладнання на 30-40 %, редукції кількості аварійних ситуацій на 25-40 % і оптимізації витрат на технічне обслуговування понад 20 %. Створена cloud-edge структура забезпечує оптимальне співвідношення між оперативністю відгуку та глибиною аналітичної обробки, тоді як інтеграція explainable AI та систем кібербезпеки на рівні концепції «trusted twin» закладає фундамент для формування самонавчальних,

автономних і захищених діагностичних систем у перспективних енергетичних інфраструктурах.

Література

1. Al-Shetwi A. Q., Atawi I. E., El-Hameed M. A., Abuelrub A. Digital Twin Technology for Renewable Energy, Smart Grids, Energy Storage and Vehicle-to-Grid Integration: Advancements, Applications, Key Players, Challenges and Future Perspectives in Modernising Sustainable Grids. *IET Smart Grid*. 2025. <https://doi.org/10.1049/stg2.70026>
2. Amin U., Kim D., Ahmed F. N., Ahmad G., Hossain M. J. Digital Twins for Smart Asset Management in the Energy Industry: State-of-the-Art. *Expert Systems With Applications*. 2025. Vol. 289. Article 128358. <https://doi.org/10.1016/j.eswa.2025.128358>
3. Chen S. (2025). *Towards Prescriptive Maintenance Using Digital Twins and Artificial Intelligence* [Licentiate thesis, Chalmers University of Technology, Department of Industrial and Materials Science, Gothenburg, Sweden]. 190 p. URL: https://research.chalmers.se/publication/547701/file/547701_Fulltext.pdf
4. Falekas G., Karlis A. Digital Twin in Electrical Machine Control and Predictive Maintenance: State-of-the-Art and Future Prospects. *Energies*. 2021. Vol. 14(18). P. 5933. <https://doi.org/10.3390/en14185933>
5. Fassi Y., Heiries V., Boutet J., Boisseau S. Towards Physics-Informed Machine-Learning-Based Predictive Maintenance for Power Converters: A Review. *IEEE Transactions on Power Electronics*. 2023. Vol. 39(2). pp. 2692-2720. <https://doi.org/10.1109/TPEL.2023.3328438>
6. Hosamo H. H., Nielsen H. K., Kraniotis D., Svennevig P. R., Svidt K. Digital Twin framework for automated fault source detection and prediction for comfort performance evaluation of existing non-residential Norwegian buildings. *Energy and Buildings*. 2023. Vol. 281. Article 112732. <https://doi.org/10.1016/j.enbuild.2022.112732>
7. Hu J., Xiao H., Ye Z., Luo N., Zhou M. Research and Prospects of Digital Twin-Based Fault Diagnosis of Electric Machines. *Sensors*. 2025. Vol. 25(8). p. 2625. <https://doi.org/10.3390/s25082625>
8. Lang L., Du J., Guo J., Xue G. A Digital Twin-Based Approach for Full Lifecycle Condition Monitoring of Power Grid Equipment. *Frontiers in Artificial Intelligence and Applications*. 2025. P. 201-210. DOI 10.3233/FAIA250268.
9. Makedon V., Myachin V., Plakhotnik O., Fisunen N., Mykhailenko O. Construction of a model for evaluating the efficiency of technology transfer process based on a fuzzy logic approach. *Eastern-European Journal of Enterprise Technologies*. 2024. no 2(13(128)). p. 47-57. <https://doi.org/10.15587/1729-4061.2024.300796>
10. Makedon V., Myachin V., Aloslyna T., Cherniavska I., Karavan N. Improving the Readiness of Enterprises to Develop Sustainable Innovation Strategies through Fuzzy Logic Models. *Economic Studies (Ikonomicheski Izsledvania)*. 2025. Vol. 34, No. 5. pp. 165-179. https://archive.econ-studies.iki.bas.bg/2025/2025_05/2025_05_09.pdf
11. Nakti I., Mansouri M., Al-Hmouz R., Khedher A. Artificial Intelligence Techniques With Digital Twin for Fault Diagnosis in Interconnected Systems: A Review. *IEEE Access*. 2025. Vol. 13. P. 91860-91874. <https://doi.org/10.1109/ACCESS.2025.3572563>
12. Rana S. AI-driven fault detection and predictive maintenance in electrical power systems: A systematic review of data-driven approaches, digital twins, and self-healing grids. *American Journal of Advanced Technology and Engineering Solutions*. 2025. Vol. 1(1), p. 258-289. <https://doi.org/10.63125/4p25x993>
13. Singh R. R., Bhatti G., Kalel D., Vairavasundaram I., Alsaif F. Building a Digital Twin Powered Intelligent Predictive Maintenance System for Industrial AC Machines. *Machines*. 2023. Vol. 11(8), 796. <https://doi.org/10.3390/machines11080796>
14. Thwe M. M., Ștefanov A., Rajkumar V. S., Palensky P. Digital Twins for Power Systems: Review of Current Practices, Requirements, Enabling Technologies, Data Federation, and Challenges. *IEEE Access*. 2025. Vol. 13. pp. 105517-105540. <https://doi.org/10.1109/ACCESS.2025.3580055>
15. Xu N., Hu L., Di X., Tang Y., Dong L., Sun X. Research Status and Progress of Digital Twin Models for Electric Power System Equipment. In *Proceedings of the 4th International Conference on Cyber Security, Artificial Intelligence and the Digital Economy (CSAIDE 2025)*, 07–09 March 2025, Kuala Lumpur, Malaysia. ACM, New York, NY, USA, 2025, 7 p. <https://doi.org/10.1145/3729706.3729778>
16. Zhong D., Xia Z., Zhu Y., Duan J. Overview of predictive maintenance based on digital twin technology. *Heliyon*. 2023. Vol. 9(4). e14534. <https://doi.org/10.1016/j.heliyon.2023.e14534>

References

1. Al-Shetwi A. Q., Atawi I. E., El-Hameed M. A., Abuelrub A. Digital Twin Technology for Renewable Energy, Smart Grids, Energy Storage and Vehicle-to-Grid Integration: Advancements, Applications, Key Players, Challenges and Future Perspectives in Modernising Sustainable Grids. *IET Smart Grid*. 2025. <https://doi.org/10.1049/stg2.70026>
2. Amin U., Kim D., Ahmed F. N., Ahmad G., Hossain M. J. Digital Twins for Smart Asset Management in the Energy Industry: State-of-the-Art. *Expert Systems With Applications*. 2025. Vol. 289. Article

128358. <https://doi.org/10.1016/j.eswa.2025.128358>
3. Chen S. (2025). *Towards Prescriptive Maintenance Using Digital Twins and Artificial Intelligence* [Licentiate thesis, Chalmers University of Technology, Department of Industrial and Materials Science, Gothenburg, Sweden]. 190 p. URL: https://research.chalmers.se/publication/547701/file/547701_Fulltext.pdf
4. Falekas G., Karlis A. Digital Twin in Electrical Machine Control and Predictive Maintenance: State-of-the-Art and Future Prospects. *Energies*. 2021. Vol. 14(18). P. 5933. <https://doi.org/10.3390/en14185933>
5. Fassi Y., Heiries V., Boutet J., Boisseau S. Towards Physics-Informed Machine-Learning-Based Predictive Maintenance for Power Converters: A Review. *IEEE Transactions on Power Electronics*. 2023. Vol. 39(2). pp. 2692-2720. <https://doi.org/10.1109/TPEL.2023.3328438>
6. Hosamo H. H., Nielsen H. K., Kraniotis D., Svennevig P. R., Svidt K. Digital Twin framework for automated fault source detection and prediction for comfort performance evaluation of existing non-residential Norwegian buildings. *Energy and Buildings*. 2023. Vol. 281. Article 112732. <https://doi.org/10.1016/j.enbuild.2022.112732>
7. Hu J., Xiao H., Ye Z., Luo N., Zhou M. Research and Prospects of Digital Twin-Based Fault Diagnosis of Electric Machines. *Sensors*. 2025. Vol. 25(8). p. 2625. <https://doi.org/10.3390/s25082625>
8. Lang L., Du J., Guo J., Xue G. A Digital Twin-Based Approach for Full Lifecycle Condition Monitoring of Power Grid Equipment. *Frontiers in Artificial Intelligence and Applications*. 2025. P. 201-210. DOI 10.3233/FAIA250268.
9. Makedon V., Myachin V., Plakhotnik O., Fisunen N., Mykhailenko O. Construction of a model for evaluating the efficiency of technology transfer process based on a fuzzy logic approach. *Eastern-European Journal of Enterprise Technologies*. 2024. no 2(13(128)). p. 47-57. <https://doi.org/10.15587/1729-4061.2024.300796>
10. Makedon V., Myachin V., Alosyna T., Cherniavska I., Karavan N. Improving the Readiness of Enterprises to Develop Sustainable Innovation Strategies through Fuzzy Logic Models. *Economic Studies (Ikonomicheski Izsledvania)*. 2025. Vol. 34, No. 5. pp. 165-179. https://archive.econ-studies.iki.bas.bg/2025/2025_05/2025_05_09.pdf
11. Nakti I., Mansouri M., Al-Hmouz R., Khedher A. Artificial Intelligence Techniques With Digital Twin for Fault Diagnosis in Interconnected Systems: A Review. *IEEE Access*. 2025. Vol. 13. P. 91860-91874. <https://doi.org/10.1109/ACCESS.2025.3572563>
12. Rana S. AI-driven fault detection and predictive maintenance in electrical power systems: A systematic review of data-driven approaches, digital twins, and self-healing grids. *American Journal of Advanced Technology and Engineering Solutions*. 2025. Vol. 1(1), p. 258-289. <https://doi.org/10.63125/4p25x993>
13. Singh R. R., Bhatti G., Kalel D., Vairavasundaram I., Alsaif F. Building a Digital Twin Powered Intelligent Predictive Maintenance System for Industrial AC Machines. *Machines*. 2023. Vol. 11(8), 796. <https://doi.org/10.3390/machines11080796>
14. Thwe M. M., Ștefanov A., Rajkumar V. S., Palensky P. Digital Twins for Power Systems: Review of Current Practices, Requirements, Enabling Technologies, Data Federation, and Challenges. *IEEE Access*. 2025. Vol. 13. pp. 105517-105540. <https://doi.org/10.1109/ACCESS.2025.3580055>
15. Xu N., Hu L., Di X., Tang Y., Dong L., Sun X. Research Status and Progress of Digital Twin Models for Electric Power System Equipment. In *Proceedings of the 4th International Conference on Cyber Security, Artificial Intelligence and the Digital Economy (CSAIDE 2025)*, 07–09 March 2025, Kuala Lumpur, Malaysia. ACM, New York, NY, USA, 2025, 7 p. <https://doi.org/10.1145/3729706.3729778>
16. Zhong D., Xia Z., Zhu Y., Duan J. Overview of predictive maintenance based on digital twin technology. *Heliyon*. 2023. Vol. 9(4). e14534. <https://doi.org/10.1016/j.heliyon.2023.e14534>

Tsvietkov O.V. Intelligent methods for predicting failures of power electrotechnical equipment based on multilevel digital twins

The article explores the use of intelligent approaches to predicting failures of power electrical equipment through the implementation of multilayer digital twins that integrate physical modeling, machine learning technologies, and big data analytics in order to enhance the reliability of power grid operation. The study aims to develop and experimentally validate a comprehensive digital model that synthesizes physics-informed mathematical equations with deep learning algorithms to achieve higher accuracy in residual life prediction and minimize the occurrence of technical failures in transformer equipment and asynchronous electric motors. The methodological framework of the research is based on the formation of a multilayer architecture of a digital twin, which includes: a sensor layer for data aggregation, a physical modeling layer of electromagnetic, thermal, and mechanical phenomena, an analytical layer employing machine learning algorithms, and a decision-making layer incorporating elements of fuzzy logic. The scientific results obtained showed that the use of a hybrid model can reduce the root mean square error (RMSE) to 0.031, reduce the mean absolute percentage error (MAPE) to 2.8%, and increase the F1-score to 0.93, which significantly exceeds the performance of classical diagnostic methods. It has been established that the completeness of sensor information and the frequency of model updates exert a decisive

influence on predictive accuracy, while the system's ability to automatically adapt to load variations has been experimentally confirmed. The developed architecture has shown strong resilience to data deficiency and a high level of generalization ($CV < 0.06$). The applied significance of the study lies in reducing emergency downtime by 30–40%, optimizing maintenance costs, and transforming the management of equipment condition toward a risk-oriented strategy. Future research directions include the standardization of digital twin technologies, the advancement of explainable AI

methods, and the implementation of basic cybersecurity systems for next-generation industrial digital platforms.

Keywords: *digital twin, intelligent forecasting, machine learning, residual life, technical diagnostics, power equipment.*

Цвєтков Олег Вячеславович – аспірант, Національний університет "Запорізька Політехніка" (Запоріжжя), Tsvietkov.Oleh@gmail.com

Стаття подана 11.10.2025.