

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет комп'ютерної інженерії та управління  
(повна назва)

Кафедра електронних обчислювальних машин  
(повна назва)

**КВАЛІФІКАЦІЙНА РОБОТА**  
**Пояснювальна записка**

Рівень вищої освіти другий (магістерський)

Гібридна модель автокодувальника LSTM для аналізу  
даних системи SCADA вітрових турбін

(тема)

Виконав:

здобувач 2 року навчання,

групи СПм-23-3

Дмитро МІШЕНІН

(власне ім'я, прізвище)

Спеціальність

123 «Комп'ютерна інженерія»

(код і повна назва спеціальності)

Тип програми освітньо-наукова

(освітньо-професійна або освітньо-наукова)

Освітня програма

Системне програмування

(повна назва освітньої програми)

Керівник: доцент Олексій ЛЯШЕНКО

(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ЕОМ

(підпис)

Андрій КОВАЛЕНКО

(власне ім'я, прізвище)

2025 р.

Харківський національний університет радіоелектроніки

Факультет \_\_\_\_\_ комп'ютерної інженерії та управління \_\_\_\_\_

Кафедра \_\_\_\_\_ електронних обчислювальних машин \_\_\_\_\_

Рівень вищої освіти \_\_\_\_\_ другий (магістерський) \_\_\_\_\_

Спеціальність \_\_\_\_\_ 123 «Комп'ютерна інженерія» \_\_\_\_\_  
(код і повна назва)

Тип програми \_\_\_\_\_ освітньо-наукова \_\_\_\_\_  
(освітньо-професійна або освітньо-наукова)

Освітня програма \_\_\_\_\_ Системне програмування \_\_\_\_\_  
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

“ \_\_\_\_\_ ” \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**

**НА КВАЛІФІКАЦІЙНУ РОБОТУ**

здобувачеві \_\_\_\_\_ Мішеніну Дмитру Олександровичу \_\_\_\_\_  
(прізвище, ім'я, по батькові)

1. Тема роботи Гібридна модель автокодувальника LSTM для аналізу даних системи SCADA вітрових турбін

затверджена наказом по університету від “ 21 ” квітня 2025 р. № 296 Ст

2. Термін подання здобувачем роботи до екзаменаційної комісії 16 червня 2025 р.

3. Вхідні дані до роботи \_\_\_\_\_

вітрова турбіна, перетворювач, SCADA, виявлення несправностей

аномалії, автокодувальник, LSTM, нейронні мережі

4. Перелік питань, що потрібно опрацювати у роботі \_\_\_\_\_

Теоретичні основи дослідження

Методи дослідження

Результати та тестування системи

Висновки

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій 14

---

---

---

---

---

---

---

---

---

---

6. Консультанти розділів роботи (заповнюється за наявності консультантів згідно з наказом, зазначеним у п.1 )

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / терміни виконання етапів роботи	Примітка
1	Отримання теми кваліфікаційної роботи	21.04	
2	Аналіз літератури	22.04-1.05	
3	Побудова гібридної моделі	2.05-15.05	
4	Тестування системи та отримання результатів	16.05-30.05	
5	Формування пояснювальної записки	31.05-04.06	
6	Перевірка на плагіат	05.06-06.06	
7	Рецензування роботи	07.06	
8	Подача роботи в ЕК	12.06	
9	Захист роботи		

Дата видачі завдання “ 21 ” квітня 2025 р.

Здобувач \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_  
(підпис)

Доцент Олексі ЛЯШЕНКО  
(посада, власне ім'я, прізвище)

## РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 55 с., 14 рис., 4 табл., 1 дод., 33 джерел.

ВІТРОВА ТУРБІНА, ПЕРЕТВОРЮВАЧ, SCADA, ВИЯВЛЕННЯ  
НЕСПРАВНОСТЕЙ, АНОМАЛІЇ, АВТОКОДУВАЛЬНИК, LSTM

Метою кваліфікаційної роботи є розробка моделі автокодувальника LSTM для аналізу даних системи SCADA вітрових турбін

У ході виконання кваліфікаційної роботи запропоновано методологію прогнозування несправностей. Розглянуто компоненти запропонованої моделі (LSTM, автоенкодера та ін.). Розроблено архітектуру моделі для аналізу даних системи на базі LSTM, а також проведено тестування системи щодо прогнозування несправностей

## ABSTRACT

Master's thesis: 55 pages, 14 figures, 4 tables, 1 appendices, 331 sources.

WIND TURBINE, CONVERTER, SCADA, FAULT DETECTION, ANOMALIES, AUTOENCODER, LSTM.

The major goal of this thesis is to develop an LSTM autoencoder model for data analysis of the SCADA system of wind turbines

In the course of the qualification work, a methodology for forecasting malfunctions was proposed. The components of the proposed model (LSTM, autoencoder, etc.) were considered. The architecture of the model for analyzing system data based on LSTM was developed, and the system was tested for predicting faults.

## ЗМІСТ

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ .....	7
ВСТУП .....	8
1 ТЕОРЕТИЧНІ ОСНОВИ ДОСЛІДЖЕННЯ.....	9
1.1 Огляд літературних джерел.....	9
1.2 Теоретичні основи моделі .....	12
2 МЕТОДИ ДОСЛІДЖЕННЯ .....	16
2.1 Методологія прогнозування несправностей .....	16
2.2 Обробка даних .....	17
2.3 Цільовий компонент .....	18
2.4 Вибір функції.....	19
2.5 LSTM .....	21
2.6 Автоенкодер.....	23
2.7 Multi-Head Attention .....	24
2.8 Позиційне кодування.....	26
2.9 Гібридна модель LSTM-MA-AE.....	27
2.10 Система прогнозування несправностей.....	29
2.11 Метрики оцінювання моделі.....	31
3 РЕЗУЛЬТАТИ ТА ТЕСТУВАННЯ СИСТЕМИ.....	33
3.1 Оцінювання моделі .....	33
3.2 Прогнозування несправностей.....	39
ВИСНОВКИ.....	43
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ .....	44
ДОДАТОК А Графічний матеріал кваліфікаційної роботи.....	48

## СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

SCADA – диспетчерське управління та збір даних

BT – вітряна турбіна

LSTM – довготривала та короткочасна пам'ять

F1 – F1-оцінка (метрика якості класифікації)

AE – автокодувальник

ReLU – лінійна функція активації

MSE – середньоквадратична помилка

## ВСТУП

Неминуче виснаження нафтових ресурсів і збільшення забруднення навколишнього середовища спонукали до використання чистої енергії, зокрема енергії вітру. Однак вітряні турбіни (ВТ) стикаються зі значними проблемами, наприклад, збоями критичних компонентів, які можуть спричинити несподівані зупинки та вплинути на виробництво енергії. Щоб вирішити цю проблему, ми проаналізували дані диспетчерського контролю та збору даних (SCADA), щоб виявити значні відмінності між співвідношенням змінних на основі помилок реконструкції даних між фактичними та прогнозованими значеннями. У цьому дослідженні пропонується гібридна модель автокодувальника короткочасної та довгострокової пам'яті (LSTM) для виявлення несправностей перетворювача ВТ. Запропонована модель ідентифікує аномалії в даних шляхом порівняння помилок реконструкції залучених змінних. Щоб усунути це обмеження моделі, ми запропонували систему прогнозування несправностей, яка використовує адаптивне порогове значення з експоненціально зваженим ковзним середнім і фіксованим пороговим значенням. Ця система аналізує аномалії кількох змінних і завчасно генерує попередження про несправності. Таким чином, ми пропонуємо метод виявлення викидів за допомогою попередньої обробки даних і неконтрольованого навчання, використовуючи дані SCADA, зібрані з вітрової електростанції, розташованої на складній місцевості, включаючи реальні несправності в перетворювачі. Показано, що LSTM здатний передбачити вихід з ладу перетворювача за 3,3 місяці наперед і з F1, що перевищує 90% у проведених тестах. Результати свідчать про потенціал запропонованої моделі для покращення діагностики несправностей перетворювача за допомогою даних SCADA в складних середовищах, підкреслюючи її здатність підвищувати надійність і ефективність ВТ.

# 1 ТЕОРЕТИЧНІ ОСНОВИ ДОСЛІДЖЕННЯ

## 1.1 Огляд літературних джерел

Зараз суспільство в світі стикається з виснаженням традиційних енергетичних ресурсів, таких як нафта та вугілля, і проблемами зміни клімату. У той же час глобальний попит на енергію продовжує зростати для задоволення економічних і соціальних потреб. Як відповідь, можна розглядати відновлювальну енергетику, яка є альтернативним рішенням, вивільняючи менше вуглекислого газу та пропонуючи необмежені джерела енергії для стимулювання сталого розвитку [1].

Використання енергії вітру, є життєздатною альтернативою виробництву електроенергії з палива з використанням природних джерел для виробництва електроенергії. Вартість виробництва енергії за допомогою цієї технології щороку знижується, і ця тенденція, як очікується, продовжиться [2]. Крім того, очікується, що продовження розвитку вітряних турбін (ВТ) завдяки інтеграції передових технологій значно підвищить їх ефективність і генеруючу потужність.

Однак виробництво вітрової енергії стикається з проблемами щодо доступності, надійності та терміну служби ВТ. З цієї причини виробники зосередили свої зусилля на подовженні терміну служби електричних і механічних систем, що призвело до зменшення кількості відмов під час експлуатації та постійного виробництва високоякісної електроенергії [3].

Несподівані збої в цих системах можуть негативно вплинути на доступність і продуктивність. Такі компоненти, як лопасті, генератори, перетворювачі електроенергії і коробки передач, особливо вразливі до поломки через суворі умови навколишнього середовища та експлуатації, що призводить до тривалого простою для технічного обслуговування. Якщо їх не вирішити, ці проблеми можуть суттєво вплинути на галузь відновлюваної

енергетики.

Виявлення несправностей є критичною проблемою з двома основними аспектами: точністю та вартістю [4]. Високий рівень вібрації та шуму генераторів ускладнює точне вимірювання несправностей. Крім того, різноманітність несправностей залежно від умов зовнішнього середовища вимагає точної класифікації кожної ситуації [5]. Впровадження кількох датчиків і складних алгоритмів коштує дорого, особливо для великомасштабних вітрових електростанцій, і складно застосовувати в невеликих установках. Оскільки ВТ збільшуються в розмірах і кількості, потреба в зниженні витрат на моніторинг і ремонт стає більш актуальною [6].

Одним з основних компонентів ВТ є перетворювач. Перетворювачі в ВТ відіграють вирішальну роль у полегшенні контролю та ефективного використання енергії, особливо на складній місцевості та з меншими вимогами до обслуговування [7]. Перетворювач є критично важливим компонентом у роботі ВТ, оскільки він перетворює змінну частоту та вихідну напругу від генератора в стабільний, сумісний із мережею змінний струм із постійною частотою та напругою, забезпечуючи придатність виробленої електроенергії для передачі та використання [8]. Відповідно до [9], перетворювачі є одними з компонентів, які найчастіше виходять з ладу в ВТ, відповідаючи приблизно за 23% відмов; автори вказують на те, що вологість, забруднення та інші фактори відіграють істотну роль у частоті цих несправностей. Крім того, у зв'язку з розвитком електроприводів із прямим приводом перетворювач є одним із компонентів, які найбільше схильні до поломок. Цей аспект стає особливо критичним у складних місцевостях, де умови навколишнього середовища та експлуатації є значно складнішими, ніж у менш вимогливих місцевостях [10].

У рамках виконання кваліфікаційної роботи пропонується вдосконалений підхід до виявлення несправностей за допомогою даних системи диспетчерського контролю та збору даних (SCADA). Мета полягає в тому, щоб виявити несправності в перетворювачі ВТ, розташованих на

складній місцевості. Цей підхід спрямований на оптимізацію надійності та зниження витрат, пов'язаних з експлуатацією та обслуговуванням. Кінцевою метою є забезпечення більшої довгострокової життєздатності та стійкості вітрової енергії.

Два загальних підходи до виявлення несправностей ВТ – це алгоритми класифікації (контрольовані) і моделі реконструкції (неконтрольовані) [11]. Алгоритми класифікації навчають моделі машинного навчання (ML), такі як дерева рішень і k-найближчі сусіди, використовуючи позначені дані та тестуючи їх на нових даних. Однак маркування даних може бути складним і дорогим процесом. Прикладом недавньої роботи в цій галузі є робота [12], який запропонував новий класифікатор під назвою AdaBoost, k-найближчі сусіди та ансамбль стекування на основі логістичної регресії (AKL-SE) для класифікації несправностей у системах моніторингу ВТ, отримавши гарні результати.

Метою моделей реконструкції, навпаки, є розуміння часових рядів і реконструкція змінних для виявлення аномалій, використовуючи помилку реконструкції як міру для виявлення викидів. Яскравим прикладом цього підходу є дослідження [13], який пропонує метод виявлення несправностей ВТ. Цей метод, який поєднує в собі згортову нейронну мережу (CNN) з мережею довго- та короткочасної пам'яті (LSTM), засновану на механізмі уваги (MU), призначений для сповіщення про несправності генератора та коробки передач, що робить його дуже актуальним для сфери ВТ систем.

Крім того, у цій сфері також використовувалися мережі глибокого навчання (DL). В [14] пропонують нову глибоку залишкову мережу (DRN) для виявлення несправностей ВТ. У їхньому методі необроблені дані із системи SCADA безпосередньо використовуються як вхідні дані для DRN, який включає залишковий будівельний блок згортки (CRBB) із згортковими шарами та блоками стиснення та збудження. Цей підхід виконує розпізнавання та класифікацію несправностей лише тоді, коли несправності виникають або є неминучими, хоча на практиці бажано надавати ранні

попередження до того, як несправність виникне.

Помітним обмеженням є те, що більшість досліджень зосереджено на виявленні несправностей механічних або електричних компонентів [15, 16], тоді як лише деякі вирішують проблеми електронних компонентів за допомогою даних SCADA [17]. У цьому контексті одним із досліджень, присвяченим дослідженню перетворювачів, є робота [18], які пропонують покращену структуру під назвою «октавна згортка уваги» (AOctConv), застосовану до магістралі ResNet50 (називається АОС–ResNet50) для виявлення несправностей у перетворювачах ВТ за допомогою даних SCADA з 10-хвилинними інтервалами. Згідно з цим дослідженням, вивчаємо цей компонент на предмет його періодичних збоїв.

Між тим, гібридні моделі є більш надійними, ніж їхні базові моделі, як свідчать останні дослідження [19, 20]. Однак обмеженням цих підходів є те, що вони, як правило, виявляють сигнали тривоги і не намагаються передбачити збої.

Новим підходом у цьому контексті є використання механізмів уваги, як представлено в роботі [21]. Автори пропонують новий метод із використанням інтегрованого МУ із шаблоном багатоваріантного запиту для виявлення аномалії та ідентифікації основної причини. Запропонована модель виявлення аномалій містить кілька каскадних кодерів і декодерів із багатоголовковим механізмом самоконтролю для вилучення кореляцій між змінними. Пропонуємо інтегрувати подібний механізм у нашу модель архітектури.

## 1.2 Теоретичні основи моделі

Метою реалізації моделі автокодувальника є реконструкція вхідних даних. Однак огляд літератури показав, що гібридні моделі дають чудову продуктивність. З цієї причини ця робота реалізує рівні LSTM і Multihead Attention (MA) в архітектурі AE, зокрема на рівнях кодування та

декодування, щоб охопити складніші часові зв'язки.

Запропоновано архітектуру для передбачення несправностей у перетворювачах ВТ з використанням даних SCADA з метою підвищення надійності та конфігурації за допомогою передбачення несправностей. У цій роботі реалізовано підхід до неконтрольованого навчання з використанням LSTM-AE з багатоголовою увагою (LSTM-MA-AE), який включає часові характеристики з даних SCADA.

Ця модель оцінюється на основі реального набору даних вітрової електростанції, розташованої на складному рельєфі. Проводимо оцінювання його з різними конфігураціями архітектури, щоб виміряти його продуктивність у виявленні аномалій.

Основні цілі цього дослідження:

- розробка моделі DL, яка інтегрує автокодери, мережі LSTM і MA для виявлення несправностей у перетворювачах ВТ;
- виявлення несправності перетворювача за допомогою даних SCADA з вітрової електростанції на складній місцевості;
- система прогнозування відмов перетворювача в реальних умовах роботи ВТ з використанням неконтрольованого навчання.

### 1.3 Актуальність використання моделі

У [22] повідомляється про кілька методів виявлення несправностей у ВТ, які можна класифікувати на підходи на основі моделі, обробки сигналів і підходи на основі даних. Крім того, в [23] подано огляд літератури про несправності перетворювача; автори включають методи на основі моделі, на основі сигналу та на основі даних та роблять висновок, що метод на основі даних має високу здатність діагностики несправностей.

Крім того, в [23] представлено дослідження для виявлення несправностей у перетворювачах ВТ з даних SCADA за допомогою CNN; Ефективність дослідження перевірено шляхом порівняльного дослідження.

Крім того, в роботі [24] – це дослідження, в якому детально описуються найпоширеніші несправності перетворювача ВТ і представлено метод, заснований на навчанні передачі (TL); результати демонструють точність та ефективність методу TL у діагностиці несправностей ВТ.

Стратегія з використанням вейвлет-перетворення, аналізу характеристик і нейронної мережі зворотного поширення (BPNN) для точного визначення несправностей розімкнутого ланцюга в перетворювачах ВТ представлена в [25]; результати показують, що запропонована стратегія може успішно класифікувати несправності перетворювача. Крім того, в [26] описує підхід на основі даних для виявлення несправностей перетворювача ВТ за допомогою LSTM; Результати показують, що запропонований метод має потужні можливості обробки даних і більш високу діагностичну точність. Подібним чином, раннє виявлення аномалій та аналіз першопричин у ВТ з використанням даних SCADA запропоновано в [27]. Для цієї мети використовується гібридна модель, що використовує асиметричну варіаційну модель суміші Гауса з автокодуванням на основі LSTM (LSTM-AVAGMM). Надійність і конкурентоспроможність моделі продемонстровано в двох прикладах.

Крім того, гібридна модель DL, що поєднує рекурентні нейронні мережі (RNN) і LSTM для моніторингу стану WT, представлена в [28]. LSTM-AE використовується для обробки даних і виділення ознак у запропонованій моделі. Дані SCADA та змодельовані дані потім використовуються для забезпечення повної навчальної моделі поведінки ВТ. Результати експерименту однозначно демонструють, що запропонована модель перевершує існуючі алгоритми ML за точністю прогнозування несправностей.

Подібним чином підхід, запропонований [29], базується на керованій реалізації варіаційної моделі AE, яка дозволяє проектувати систему ВТ у просторі представлення низької розмірності для раннього прогнозування несправності. Інша подібна робота представлена в [30], де глибокий EA

(DAE), покращений випадками несправностей, розроблений для виявлення аномалій у ВТ. За допомогою випадків несправностей DAE може отримувати шаблони даних нормальної роботи та отримувати функції глибокого вбудовування. Експериментальні результати показують, що метод перевершує поточні методи на основі АЕ у виявленні аномалії ВТ з використанням кількох оціночних метрик.

У [31] представлена методика моніторингу старіння модулів біполярних транзисторів з ізольованим затвором (IGBT) у морських перетворювачах ВТ з використанням даних SCADA та гібридної моделі LSTM (AT-LSTM), заснованої на АЕ та уваги. Модель AT-LSTM використовується для вивчення даних SCADA та встановлення прогнозу температури. АЕ використовується для виявлення аномалій. Результати експерименту підтверджують ефективність запропонованої моделі.

Можна зазначити, що наукова література про використання даних SCADA для прогнозування збоїв у перетворювачах ВТ, розташованих на складній місцевості, обмежена.

У сучасних ВТ перетворювач контролює швидкість і крутний момент генератора на додаток до передачі потужності в мережу [32]. Крім того, вивчення перетворювача є актуальною темою дослідження на даний момент, оскільки збій цього компонента може спричинити несподіване відключення ВТ, що призведе до зниження виробництва енергії. Ця ситуація ще більш критична на ВТ, розташованих на складному рельєфі, що може призвести до тривалих простоїв ВТ.

Крім того, раннє виявлення несправностей має вирішальне значення для технічного обслуговування ВТ, оскільки це значно економить час і кошти. Впровадження гібридних моделей і ефективне використання даних SCADA може підвищити надійність і ефективність прогнозного технічного обслуговування, що призведе до зниження витрат на експлуатацію та технічне обслуговування вітрових електростанцій.

## 2 МЕТОДИ ДОСЛІДЖЕННЯ

### 2.1 Методологія прогнозування несправностей

На рисунку 2.1 показано методологічний процес прогнозування несправностей, який використовується в цьому дослідженні. На рисунку описано процес від отримання необроблених даних до очищення та вибору функцій, запропонованої розробки моделі та прогнозування несправностей. Необроблені дані проходять процес очищення та фільтрації, а потім вибираються змінні, пов'язані з цільовим компонентом. Ці змінні є вхідними даними для моделі LSTM-MA-AE, яка реконструює вихідний сигнал для кожної змінної. Згодом передбачені сигнали потрапляють у систему прогнозування несправності, де вони порівнюються з кожним фактичним сигналом, а помилка реконструкції використовується для обчислення показника аномалії. Ця система генерує сигнал тривоги, коли виявляється значна невідповідність, що дозволяє передбачити й попередити про можливість збою.



Рисунок 2.1 – Загальна блок-схема методологічного процесу

## 2.2 Обробка даних

Для обробки даних необроблені файли у форматі .txt і .tmp спочатку були взяті з системи SCADA, оброблені та об'єднані в єдиний файл. Кроки, які виконуються для очищення та фільтрації даних для забезпечення цілісності даних, описані нижче.

Змінні з нульовими значеннями, що перевищують 10000 записів, було видалено з набору даних, оскільки вони потенційно могли спотворити аналіз.

Змінні, які, ґрунтуючись на знаннях домену, не вносять суттєвих характеристик в аналіз, були виключені.

Було враховано нульові значення на повний рядок, що представляло максимум 7 незначущих записів у змінних ВТ.

Дані були відфільтровані, щоб включити лише ті з активною потужністю більше 0 і менше 1600, гарантуючи, що ВТ знаходиться в межах гарантованого робочого діапазону.

Режим роботи ВТ має бути 5, що в цьому випадку вказує на те, що він не перебуває в режимі обмеження потужності або обслуговування.

Діапазон швидкості вітру було встановлено між 3 м/с і 25 м/с, оскільки це початкові та граничні значення GOLDWIND GW70/1500 WT, що гарантує, що дані відображають типові умови експлуатації.

Температурні відхилення були усунені: зокрема, температури IGBT вище 120°C, враховуючи середнє значення 60 °C.

Температури повинні бути вище 0 °C, оскільки в досліджуваній області не було зареєстровано мінусових температур, середня історична температура яких становить приблизно 15 °C.

Цей підхід гарантує послідовність і високу якість даних, які використовуються для аналізу та навчання моделі, що важливо для отримання точних і надійних результатів.

Після обробки даних остаточний набір було скорочено до 317323 записів і 55 змінних. Тобто вилучено 17,85% даних.

### 2.3 Цільовий компонент

Аналіз несправності перетворювача проводився відповідно до рекомендацій операторів ВТ. Перегляд записів про технічне обслуговування та сигналів тривоги SCADA підтвердив, що перетворювач має найвищий рівень відмов – 89,3%, рисунок 2.2 а). Цей відсоток відрізняється від 23%, для несправностей конвертера, оскільки несправності інших компонентів ВТ, таких як генератор, коробка передач, система кроку, серед інших. У нашому випадку ВТ є відносно новим, тому жодних збоїв у цих інших компонентах не було зафіксовано, що призвело до більш високого відсотка збоїв, пов'язаних з перетворювачем.

Крім того, сигнали тривоги системи SCADA на конвертері складають 86,4% від загальної кількості, значно перевищуючи кількість сигналів на системі кроку, рисунок 2.2 б). У цьому дослідженні були проаналізовані лише компоненти перетворювача та кроку, оскільки обидва вимагали заміни як критичні частини ВТ.




Рисунок 2.2 – Відсоток відмов і тривог усіх вітряних турбін на станції, де: а) – показові несправності з протоколу технічного обслуговування; б) – сигнали тривоги SCADA, пов'язані з компонентом несправності

Крім того, варто відзначити концептуальну різницю між

несправностями та сигналами тривоги. Несправність передбачає відключення ВТ і, як правило, вимагає заміни пошкодженого компонента, тоді як сигнал тривоги може призвести до тимчасового відключення вітрової турбіни, але не обов'язково призводить до заміни компонента. Збої можуть зупинити виробництво та спричинити значні збитки. Тому важливо передбачити, коли станеться збій, дозволяючи вжити превентивних заходів для мінімізації впливу на виробництво.

## 2.4 Вибір функції

Як згадувалося вище, набір даних SCADA, використаний у цьому дослідженні, складається з 55 змінних. Змінні були зменшені, щоб запобігти тому, щоб модель стала надто складною, і таким чином покращити вивчення функцій, пов'язаних із цільовим компонентом. Для цього змінні були обрані на основі кореляції Пірсона.




Рисунок 2.3 – Вибір ознак за кореляцією

На рисунку 2.3 зображено кореляційну матрицю для кількох змінних, пов'язаних з роботою вітряних турбін та їх компонентів, зокрема

перетворювача та IGBT. Ця матриця показує силу та напрямок зв'язків між парами змінних, представлених кольорами, де червоний колір вказує на високу позитивну кореляцію, а синій має високу негативну кореляцію.

Змінна `igbt_temperature_max` демонструє сильну позитивну кореляцію з кількома іншими змінними, такими як `wind_speed_avg`, `grid_active_power_avg`, `generator_speed_avg` і `ambient_temperature_avg`. Це свідчить про те, що температура IGBT тісно пов'язана із загальною роботою ВТ та умовами навколишнього середовища.

Під час попереднього аналізу було виявлено три несправності перетворювача, що завадило нам спостерігати значні кореляції між змінною несправності IGBT та іншими змінними. Щоб вирішити цю проблему, 10000 даних перед кожною несправністю були позначені відповідно до припущення, що компонент погіршується з часом і в таких даних можуть існувати ознаки несправності. Це дозволило збалансувати набір даних і спостерігати кореляції. Крім того, хоча спостережувані кореляції невеликі, вони дають змогу зрозуміти змінні, які можуть бути залучені до несправностей.

Незважаючи на низьку пряму кореляцію між відмовами IGBT та іншими змінними, включення тегів до даних перед відмовою забезпечує цінне розуміння умов, які можуть сприяти відмові перетворювача.

Підводячи підсумок, це дослідження вибрало змінні на основі їх кореляції з цільовою змінною, кореляції з відмовами конвертера, кореляції з сигналами тривоги конвертера та знань авторів про домен. Таким чином, було вибрано дев'ять змінних, пов'язаних із цільовим компонентом, які наведені в таблиці 2.1.

Цей вибір гарантує, що модель ефективно фіксує умови роботи цільового компонента, передбачає можливі збої та мінімізує виявлення збоїв в інших компонентах, підвищуючи надійність і ефективність ВТ.

Таблиця 2.1 – Змінні, вибрані для аналізу відмови перетворювача

№	Змінні	Опис
1	grid_active_power_avg	Вказує на продуктивність ВТ і умови роботи перетворювача.
2	generator_speed_avg	Це тісно пов'язане з продуктивністю ВТ і може впливати на поведінку перетворювача.
3	ambient_temperature_avg	Температура навколишнього середовища впливає на кілька компонентів ВТ, включаючи перетворювач.
4	grid_U1_avg	Середня напруга в мережі може вплинути на поломку перетворювача.
5	grid_I1_avg	Це ключовий показник робочого стану ВТ і може впливати на збої конвертера.
6	topbox_temperature_max	Це може свідчити про термічні проблеми, що впливають на перетворювач.
7	igbt_temperature_max	Безпосередньо пов'язані з цільовим компонентом.
8	rectifier_temperature_max	Індикатор критичного стану конвертера.
9	step_up_igbt_temperature_max	Контролює температуру IGBT.

## 2.5 LSTM

Мережі LSTM можуть покращити злиття часових характеристик із стану різних частин. У цьому дослідженні наша модель поєднується з LSTM для вилучення часових особливостей із даних WT. LSTM містить вхідний вентиль, вихідний вентиль і пропускний вентиль. Його структуру показано на рисунку 2.4.




Рисунок 2.4 – Принципова діаграма архітектури LSTM

Інформація, яку потрібно забути, контролюється шлюзом забуття  $f_t$ , визначається як:

$$f_t = \sigma (W_f x_t + W_h h_{t-1} + b_f)$$

де  $\sigma$  є сигмоїдною функцією, і  $W_f$  та  $b_f$  являють собою вагову матрицю та зсув пропуску, відповідно. На наступному кроці входні шлюзи  $i_t$  отримує  $h_{t-1}$  і  $x_t$  щоб визначити нові дані, які слід зберігати в стані комірки. При цьому вектор значень кандидатів  $C_t$  створюється гіперболічним дотичним шаром ( $\tanh$ ), який повертає значення від -1 до 1. Попередній стан клітинки  $C_{t-1}$  потім оновлюється до нового стану комірки  $C_t$ , як описано в наступних рівняннях

$$i_t = \sigma (W_i x_t + W_h h_{t-1} + b_i)$$

$$\tilde{C}_t = \tanh (W_c x_t + W_h h_{t-1} + b_c)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

Нарешті вихідні шлюзи  $o_t$  визначає прихований стан  $h_t$  наступним чином:

$$o_t = \sigma (W_o x_t + W_h h_{t-1} + b_o)$$

$$h_t = o_t \odot \tanh (C_t)$$

де  $W_o$  і  $b_o$  є ваговою матрицею та зміщенням вихідного вентиля відповідно. Вихід  $h_t$  отримано відповідно до оновленого стану комірки  $C_t$ .

## 2.6 Автоенкодер

Автоенкодер (АЕ) – це глибока нейронна мережа без учителя, яка реконструює вхідні дані з мінімальною похибкою на основі закодованих даних. Вхідні дані кодуються в цій мережі шляхом відображення їх у низьковимірний простір. Потім вона намагається мінімізувати втрати між вхідними та декодованими даними. Як показано на рисунку 2.5, АЕ зазвичай складається з двох частин: кодера та декодера.




Рисунок 2.5 – Архітектура глибокої АЕ

Кодер перетворює вхідні дані  $x$  у закодоване представлення  $z$  (тобто, кодовий рівень). Відповідно до зображеної архітектури, математичне формулювання процесу кодування кодового рівня задається рівнянням; таким чином,

$$z = \zeta(W_2h + b_2)$$

де  $W$  та  $b$  – це матриця ваг та вектор зміщення мережі відповідно. Далі декодер намагається реконструювати вхідні дані з кодового рівня  $z$ , найменшою розбіжністю між початковими вхідними даними  $x$  і реконструйований вихід  $x'$ , розрахований на основі наступного рівняння:

$$x' = \zeta(W_4h' + b_4)$$

де  $\zeta$  – це функція активації.

## 2.7 Multi-Head Attention

Адміністрування стало життєво важливим компонентом нейронних мереж для обробки довгих послідовних даних. Обчислюючи ваги уваги, мережа вчиться зосереджуватися на найважливіших частинах вхідних даних. Важливе нововведення було введено з Multi-Head Attention (MA). Цей підхід покращує увагу, використовуючи кілька паралельних шарів уваги або «головок» для зосередження на різних сегментах вхідних даних. MA значно покращує моделювання складних залежностей у даних та підвищує продуктивність моделі.

На відміну від традиційних моделей уваги, які обчислюють оцінки уваги між вектором запиту та парами ключ-значення з вхідних даних, самоувага генерує вектори запиту, ключа та значення шляхом перетворення самих вхідних даних. Це дозволяє моделі ефективно витягувати важливі

ознаки та зв'язки в даних за допомогою самопосилання. Зокрема, самоувага порівнює різні елементи в одній вхідній послідовності один з одним. Вона обчислює оцінки взаємодії між матрицею запиту  $Q$ , матрицею ключів  $K$  та матрицями значень  $V$  з вхідних даних за допомогою рівняння

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

де  $d_k$  – розмірність матриці ключів. МА розширює це, використовуючи кілька незалежних головок уваги, причому кожна головка вивчає різні шаблони. Кілька головок по суті дозволяють паралелізацію в межах шару уваги, забезпечуючи багатше представлення вхідних даних.

Як показано на рисунку 2.6, вхідна послідовність лінійно проектується на  $Q$ ,  $K$  та  $V$  за допомогою вивчених вагових матриць  $W_i^Q$ ,  $W_i^K$  та  $W_i^V$ . Потім  $Q$  та  $K$  множаться та масштабуються, щоб отримати бали уваги. Ваги уваги множаться на  $V$ , щоб отримати вихідні значення кожної голови  $Att_h$ . Ці вихідні значення, які становлять увагу кожного керівника  $Att_h$ , об'єднуються та лінійно проектуються за допомогою вивченої матриці  $W^O$  щоб отримати кінцевий результат уваги кількох голів  $Output$ . Цей процес описується рівняннями

$$Att_h = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$$

$$Output(Q, K, V) = \text{Concat}(Att_1, Att_2, \dots, Att_n) W^O$$

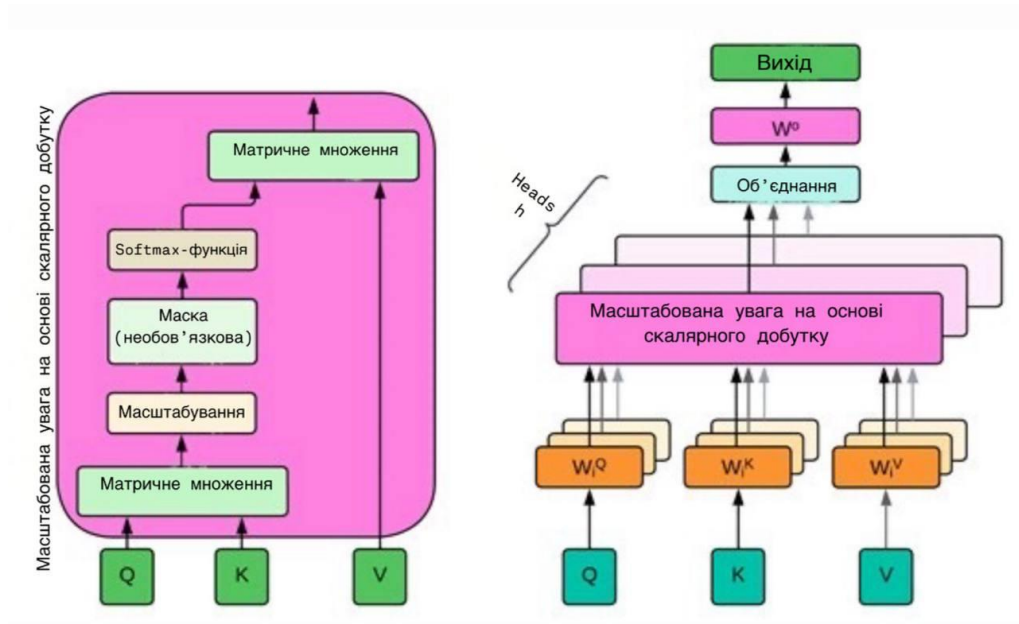


Рисунок 2.6 – Принципова схема механізму МА

Хоча маскування є необов'язковим компонентом, який можна застосовувати до показників уваги перед softmax, щоб запобігти зосередженню певних позицій на інших, воно не використовувалося, оскільки повний контекст послідовності був кращим для охоплення всіх глобальних залежностей і міг виключати закономірності, корисні для виявлення невеликих змін у всій послідовності.

## 2.8 Позиційне кодування

Позиційне кодування – це важлива техніка в Transformers, яка включає інформацію про положення вхідних послідовностей. На відміну від RNN, які обробляють дані послідовностей упорядкованим чином, Transformers з їхньою АМ обробляють послідовності паралельно, що означає, що положення елементів у послідовності не є неявно встановленим у моделі. Щоб вирішити це обмеження, вводиться позиційне кодування, яке додає інформацію про положення до вхідних векторів на рівень уваги. Це кодування виконується за допомогою тригонометричних функцій (синуса та косинуса) для генерації унікального вектора для кожної позиції, що полегшує

для моделі захоплення позиційного зв'язку елементів у послідовності.

У цьому процесі використовуються рівняння

$$PE_{(pos,2i)} = \sin \left( \frac{pos}{10000^{2i/d_{model}}} \right)$$

$$PE_{(pos,2i+1)} = \cos \left( \frac{pos}{10000^{2i/d_{model}}} \right)$$

де  $pos$  – позиція в послідовності,  $i$  – розмірність, а  $d_{model}$  – розмір вектора ознак.

## 2.9 Гібридна модель LSTM-MA-AE

Ця модель ефективно фіксує просторові та часові характеристики даних SCADA, покращуючи можливості прогнозування та діагностики несправностей. Модель LSTM-MA-AE, розроблена в цьому дослідженні, обробляє вхідні сигнали для реконструкції часових рядів та прогнозування несправностей до їх виникнення.

Модель LSTM-MA-AE має дві основні частини: кодер та декодер. Структура моделі представлена на рисунку 2.7. У кодері комбінація шарів LSTM, PE та MA обробляє вхідні послідовності. Декодер використовує структуру, подібну до кодера, для реконструкції часового ряду з закодованих представлень. Це означає, що в кодері використовуються два шари LSTM з 64 прихованими одиницями кожен, які відповідають за захоплення складних короткострокових часових залежностей у послідовності даних, вбудовуючи шаблони, що стосуються завдання реконструкції. За цими шарами слідує нормалізація та відсів 0,1 для запобігання перенаванчання. На виході LSTM інтегровано PE для механізму 8-головного MA, щоб зрозуміти позиції даних часового ряду. Ці ознаки уваги додаються до залишкового зв'язку з

попереднього виходу, щоб уникнути втрати інформації про дані. Кожна головка МА дозволяє моделі одночасно зосереджуватися на різних аспектах вхідної послідовності, покращуючи можливості довгострокового вбудовування ознак та часовості.

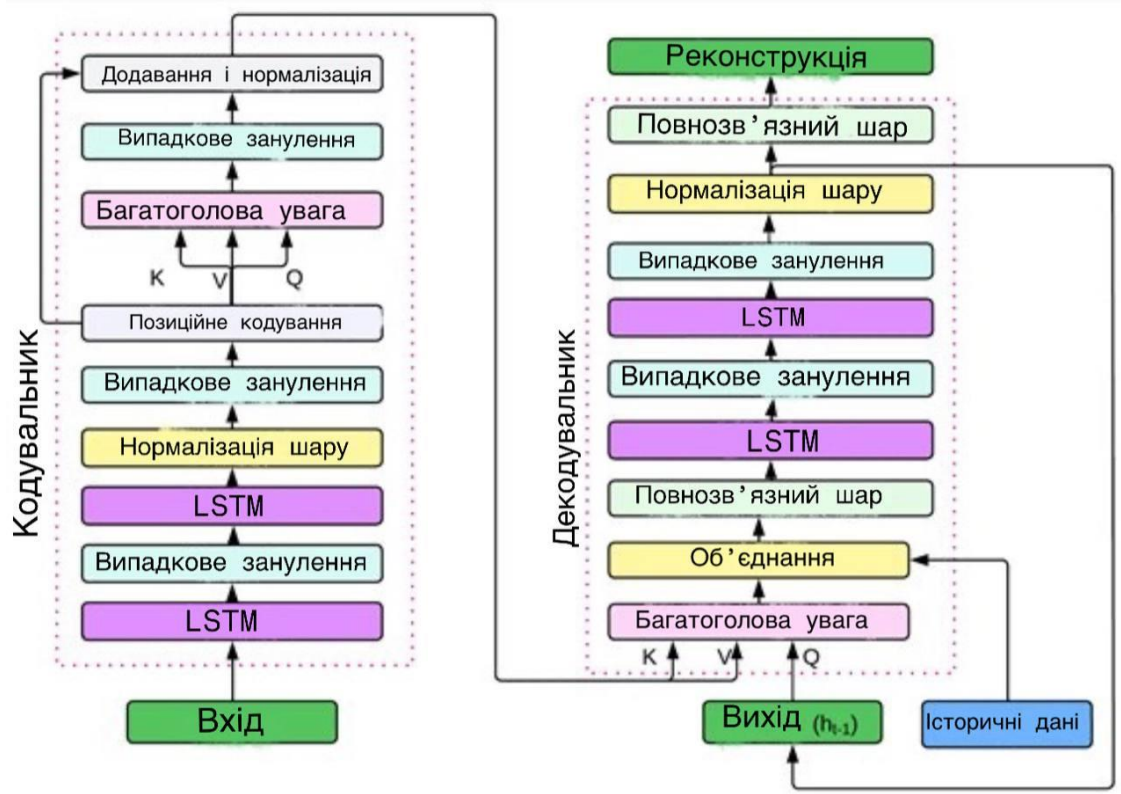


Рисунок 2.7 – Архітектура моделі LSTM-MA-AE

Крім того, в декодері ми ініціюємо вилучення вбудованих ознак кодера за допомогою 8-головного механізму МА, доповненого двома додатковими 64-шаровими прихованими шарами LSTM. Спочатку нульові тензори використовуються як запит у механізмі МА, тоді як вбудовування кодера використовуються як ключ і значення. Потім вони передаються шарам LSTM, які обробляють історичні значення набору даних разом з виходом уваги, що дозволяє вилучити відповідну послідовну структуру та передбачити перше значення за допомогою повністю зв'язаного шару. Цей вихід згодом використовується як зворотний зв'язок у запиті до механізму МА для наступних прогнозів. Прогнози, згенеровані декодером, ітеративно

використовуються як запит, досягаючи точної реконструкції по всій послідовності. Нарешті, ми застосовуємо нормалізацію та виключення для оптимізації навчання та запобігання перенавчанню моделі.

Вхідними даними для моделі є часовий ряд даних довжиною  $T$  з  $d$  характеристиками:

$$X = [x_1, x_2, \dots, x_T] \in \mathbb{R}^{T \times d}$$

Потім часова послідовність кодується за допомогою двох шарів LSTM з випаданням між ними та нормалізаційним шаром LayerNorm в кінці другого шару, щоб отримати кодоване представлення, як показано в наступних рівняннях

$$H_{out} = LSTM_{enc}(X)$$

$$H_{enc} = LayerNorm(LSTM_{enc}(H_{out}))$$

Вихідна серія  $H_{enc}$  нього додано PE, щоб MA міг зрозуміти положення часового ряду, як показано в рівнянні

$$H_{PE} = H_{enc} + PE$$

## 2.10 Система прогнозування несправностей

Спочатку модель реконструює всі вхідні змінні, щоб врахувати відхилення в кожній з них. На рисунку 2.8 поазана система прогнозування несправностей обчислює бал реконструкції для кожної точки даних для кожної змінної. Потім використовується вектор згладжування для

розрізнення аномалій, можливо спричинених деградацією або ситуаціями, коли ВТ працює на межах своєї потужності. Далі цей новий бал пропускається через поріг за допомогою EWMA. Якщо бал перевищує цей поріг, створюється вектор міток, де 1 вказує на те, що поріг перевищено, а 0 вказує на те, що ні.

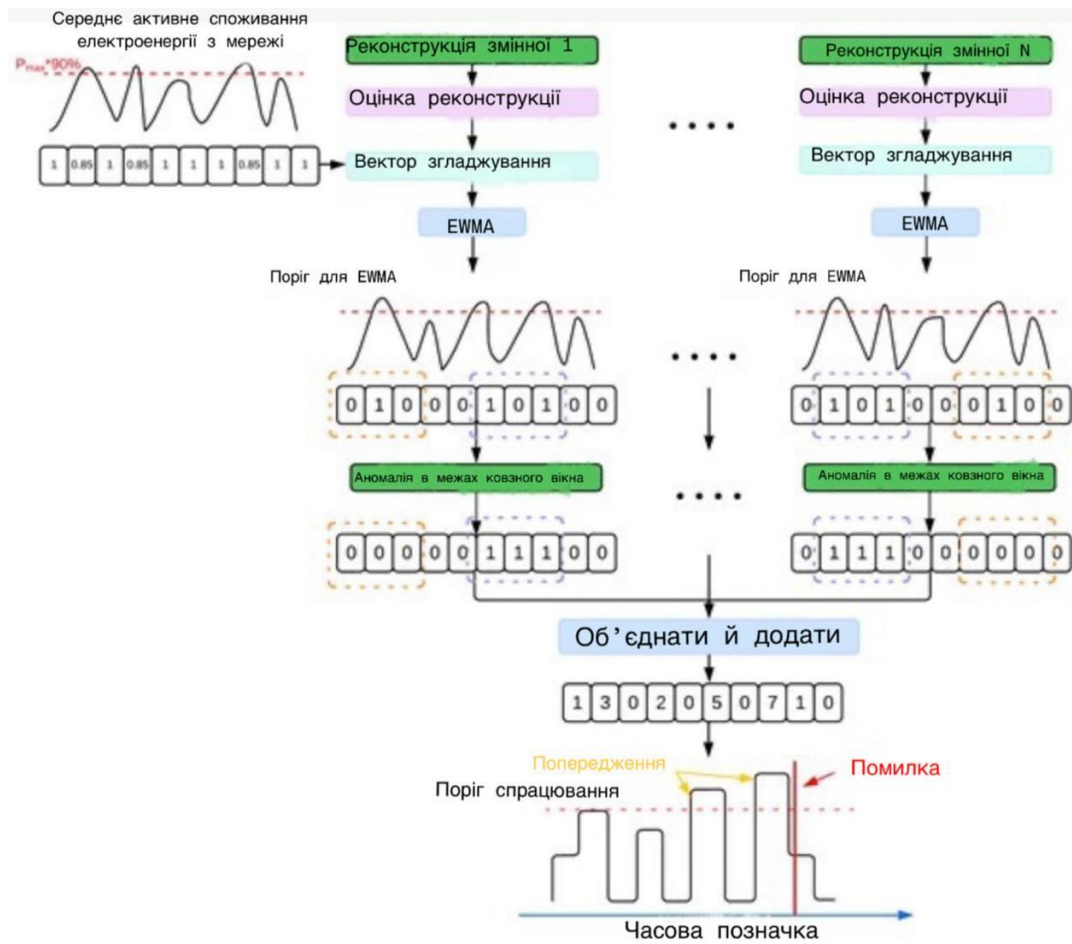


Рисунок 2.8 – Блок-схема системи прогнозування відмов

Символ \* позначає множення на поріг вектора згладжування. Пунктирні лінії використовуються для виділення процесу аномалії ковзного вікна.

Цей вектор міток обробляється детектором аномалій зі ковзним вікном для покращення мічення аномалій. Цей детектор приймає двійковий вектор як вхідні дані та визначає, чи є їх більше ніж  $N_{anomalies}$  аномалій в межах часового вікна  $N_{window}$ , тоді він позначає все вікно між першою та останньою

аномалією у вікні як аномальне (1). Цей метод припускає, що сусідні аномалії в межах максимального розміру вікна  $N_{\text{window } 1}$  може представляти ту саму помилку.

Після отримання остаточного вектора міток кожної змінної, всі вектори об'єднуються та додаються. Цього разу кількість змінних з аномаліями, які вказують на попередження про помилку, визначається за допомогою фіксованого порогу.

## 2.11 Метрики оцінювання моделі

Для оцінки запропонованої моделі ми використовували різні показники похибки, поширені в аналізі прогнозування, такі як середньоквадратична похибка (RMSE), середня абсолютна похибка (MAE) та коефіцієнт детермінації ( $R^2$ ). Рівняння визначають ці показники.

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

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

де  $y_i$  представляє фактичні значення,  $\hat{y}_i$  прогнозовані значення,  $n$  – кількість зразків,  $\bar{y}$  середнє значення  $y_i$ .

Крім того, ми використовуємо функцію Precision ( $Pr$ ), Нагадаємо ( $Re$ ), та F1-оцінка ( $F1$ ) метрики, які зазвичай використовуються для виявлення

аномалій. Ці метрики визначаються рівняннями

$$Pr = \frac{TP}{TP + FP}$$

$$Re = \frac{TP}{TP + FN}$$

$$F1 = \frac{2 \cdot Pr \cdot Re}{Pr + Re}$$

де істиннопозитивний ( $TP$ ) представляє тривоги, які правильно виявили несправність у певному часовому вікні, хибнопозитивний результат ( $FP$ ) відповідає тривогам, які не призводять до фактичної несправності, та хибнонегативним ( $FN$ ) вказує на несправності, які не були виявлені правильно.

Експерименти були проведені з використанням мови програмування Python у бібліотеці PyTorch у середовищі Google Colab. Середовище мало процесор Intel(R) Xeon(R) з частотою 2,22 ГГц, 51,00 ГБ оперативної пам'яті, прискорювач Tesla K80 та 12 ГБ відеопам'яті GDDR5.

## 3 РЕЗУЛЬТАТИ ТА ТЕСТУВАННЯ СИСТЕМИ

### 3.1 Оцінювання моделі

Результати, наведені в таблиці 3.1, були отримані за допомогою гіперпараметрів. Ми оцінили три конфігурації моделі:

- підхід LSTM-MA-AE;
- той самий підхід без AM (LSTM-AE);
- версія без заземлення (PE) та залишкового з'єднання.

Це дозволяє нам підтвердити, що впроваджені покращення ефективно покращують продуктивність запропонованої моделі.

Дані, представлені в таблиці 3.1, вказують на те, що включення MA до підходу LSTM-MA-AE є дуже ефективним для охоплення складнощів у часових даних. Це показує, що AM підвищує продуктивність моделі. MA допомагає моделі зрозуміти широкий діапазон послідовностей, тим самим зберігаючи важливу інформацію, необхідну для ефективної реконструкції часового ряду. Крім того, підхід LSTM-MA-AE без позиційного кодування демонструє нижчу продуктивність порівняно з підходом, який включає PE. Це пояснюється тим, що додавання PE полегшує моделі розуміння позиційних характеристик кожних даних у часовому ряді, покращуючи її здатність до точної інтерпретації та прогнозування.

$R^2$  коефіцієнт показує різницю між рядами; значення  $R^2$  значення, близьке до 1, відображає високу подібність між наборами даних. MAE вимірює втрату між двома точками даних, тоді як RMSE штрафує викиди. Як видно, найкращу продуктивність було отримано за допомогою моделі LSTM-MA-AE.

Таблиця 3.1 – Порівняння результатів реконструкції змінних

Фунція	LSTM-MA-AE			LSTM-AE			LSTM-MA-AE без PE		
	RMSE	MAE	$R^2$	RMSE	MAE	$R^2$	RMSE	MAE	$R^2$
3	0,44	0,33	0,91	1.50	1.22	-0,09	13.12	13.09	-80,65
2	0,52	0,37	0,88	1.71	1.35	-0,23	20.35	20.32	-143,71
6	0,80	0,67	0,84	2.64	2.24	-0,69	36,92	36.18	-19,17
8	1,55	1.17	0,82	3.34	2.68	0,18	58,62	56,84	-13,99
9	1,75	1.38	0,94	6,99	5.86	0,11	70,15	68,15	-15,24
7	3.63	2.60	0,93	16.28	13.15	-0,35	358,37	358,36	-9026,75
4	4.21	3.17	0,93	22.23	16.44	-0,88	1169,89	1052.11	-4.21
5	125,20	96,16	0,92	326,12	260,14	0,51	1094,50	986,58	-4,32
1	137.11	109,85	0,91	453,77	361,64	-0,12	1169,89	1052.11	-4.21

Під час навчання ми встановили максимальну кількість епох на 75. Однак, використовуючи ранню зупинку, модель досягла найкращої продуктивності на епосі 25, коли втрати валідації перестали суттєво покращуватися. Як показано на рисунку 3.1, втрати валідації швидко зменшуються протягом перших 25 епох, а потім стабілізуються. Рання

зупинка діяла з цього моменту, щоб уникнути перенавчання, яке могло б статися, якби навчання продовжувалося до початково налаштованих епох.

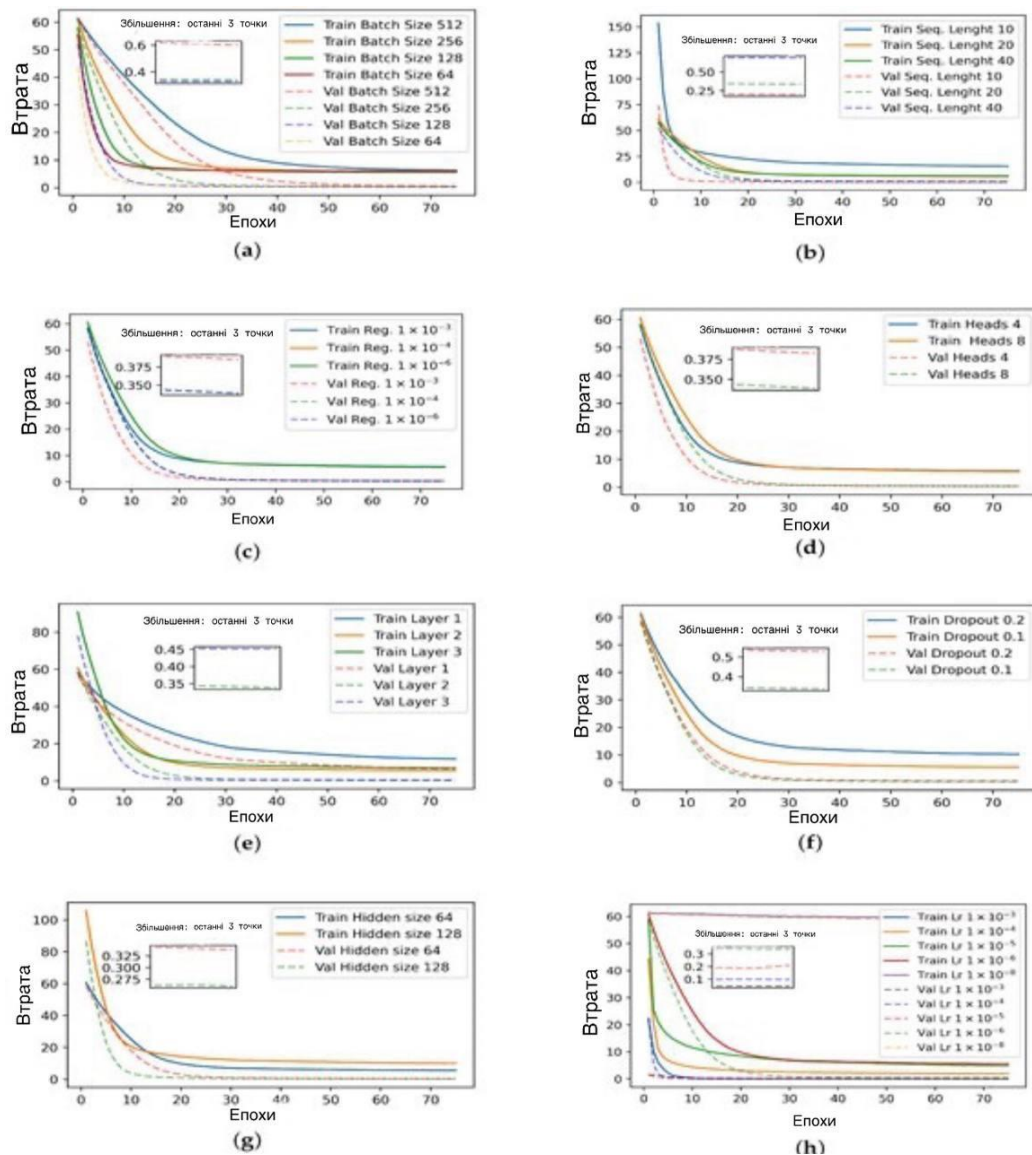


Рисунок 3.1 – Порівняння втрат під час навчання та валідації з різними гіперпараметрами моделі

Порівняння втрат під час навчання та валідації з різними гіперпараметрами моделі. Порівняння втрат з різними розмірами партій (a). втрат з різною довжиною послідовностей (b). Порівняння втрат з різними коефіцієнтами регуляризації (c). Порівняння втрат з різною кількістю головок (d). Порівняння втрат з різною кількістю шарів (e). Порівняння втрат з різними значеннями відсіву (f). Порівняння втрат з різними розмірами

прихованих шарів (g). Порівняння втрат з різними значеннями швидкості навчання (h).

Цей аналіз є критично важливим для визначення оптимальної точки, де модель найкраще узагальнюється без перенавчання, тим самим забезпечуючи надійну продуктивність на невидимих даних. На рисунку 3.1 (a) зображено поведінку втрат протягом епох навчання, що підкреслює важливість ранньої зупинки в оптимізації моделі.

Крім того, як видно на рисунку 3.1 (a), розмір партії 256 було обрано через його порівнянну продуктивність з точки зору втрат з меншими розмірами партій, такими як 128, але з меншим обчислювальним часом, як показано на рисунку 3.2. На рисунку 3.1 (b) проаналізовано довжину послідовності, і хоча довжина послідовності 10 демонструє дещо кращу продуктивність, ніж довжина послідовності 20, було обрано останню, оскільки вона надає моделі більше історії, що дозволяє більш загальне вивчення часових рядів. На рисунку 3.1 (c) показано, що коефіцієнти регуляризації  $1 \times 10^{-4}$  та  $1 \times 10^{-6}$  дають подібні результати, тому значення  $1 \times 10^{-4}$  було обрано. На рисунку 3.1 (d) показано, що збільшення кількості головок покращує захоплення довгострокових закономірностей у часових рядах. На рисунку 3.1 (e) показано, що один шар має низьку продуктивність, тоді як більша кількість шарів, така як два або три, зменшує втрати, але збільшує обчислювальні витрати. На рисунку 3.1 (f) показано, що більший відсів впливає на здатність моделі до узагальнення, причому значення 0,1 є найбільш доцільним у цьому випадку. На рисунку 3.1 (g) показано, що розмір прихованого шару 128 покращує відповідність реальним значенням, хоча це збільшує обчислювальні витрати та час, як показано на рисунку 3.2. Нарешті, на рисунку 3.1 (h) показано, що початкове значення швидкості навчання разом із планувальником суттєво впливає на відповідність моделі. Ми прагнемо узагальнити часові ряди з хорошою відповідністю, без перенавчання, щоб виявити аномальні закономірності з часом. Хоча вища швидкість навчання була б адекватною для завдань прогнозування, у цьому

випадку нам потрібна така, яка дозволяє нам узагальнити часові ряди та отримати адекватні результати, як представлено в таблиці 3.1




Рисунок 3.2 – Порівняння часу навчання між різними змінами гіперпараметрів

У таблиці 3.2 зазначено, що додавання механізму уваги збільшує час, необхідний для навчання моделі. Це пов'язано зі збільшенням обсягу обчислень та необхідністю вивчення складніших функцій. Підхід LSTM-MA-AE має час на епоху 13,28 с, тоді як підхід LSTM-AE без AM вимагає лише 7,48 с на епоху. Крім того, використання PE у підході LSTM-MA-AE дещо зменшує час навчання порівняно з версією без PE, з часом 13,28 с та 13,40 с на епоху відповідно. Це свідчить про те, що PE та залишковий зв'язок допомагають трохи пришвидшити навчання.

Ці результати підкреслюють важливість балансування точності моделі з часом навчання. Хоча механізм уваги може збільшити час навчання, він може значно покращити продуктивність моделі, фіксуючи складні ознаки та зберігаючи важливу інформацію в послідовних даних.

Таблиця 3.2 – Порівняння швидкості навчання за епохами

Підхід	Час за епохами
LSTM-AE	7,48 с
LSTM-MA-AE без PE	13,40 с
LSTM-MA-AE	13,28 с

Крім того, було оцінено вплив обсягу навчальних даних на загальну продуктивність моделі, як показано таблиці 3.3. Модель для змінної *ambient\_temperature\_avg* точно реконструює дані навіть зі зменшеним набором даних, що дає багатообіцяючі результати.

Таблиця 3.3 – Продуктивність моделі для різних відсотків набору даних

Відсоткові дані	Змінна 3 (MAE)
90%	0,35
50%	1.45
25%	3.62

На рисунку 3.3 (а) показано реконструкцію максимальної температурної змінної IGBT. На цьому рисунку показано підвищення температури з початку травня до кінця червня 2018 року. Ця тенденція збігається з відмовою перетворювача, задокументованою в журналі технічного обслуговування. Ця несправність може бути пов'язана з прискореною деградацією перетворювача, оскільки протягом цього періоду, згідно з журналом вихідної потужності, вітровий трансформатор працював на максимальній потужності більшу частину часу.




Рисунок 3.3 – Реконструкція температурної змінної IGBT

На рисунку 3.3 видно, що справжні часові ряди та реконструкція моделі відображають це підвищення температури. Однак, під час дослідження втрат (помилки) реконструкції, показаних на рисунку 3.3 (b), було виявлено, що кілька аномалій перевищили поріг, встановлений до події відмови. Хоча ці втрати реконструкції не є значними в абсолютному вираженні, вони заслуговують на увагу порівняно з нормальними значеннями.

### 3.2 Прогнозування несправностей

Виявлення несправностей у компонентах вітрового перетворювача може залежати від аномалій в одній або кількох змінних, пов'язаних з

цільовим компонентом. Крім того, наявність ознак несправностей у змінних SCADA може бути не очевидною, особливо в електронних компонентах. Тому була розроблена система прогнозування несправностей для точнішого виявлення та передбачення цих аномалій.

Після впровадження системи прогнозування відмов ми отримали на рисунку 3.4, який демонструє, що система прогнозування може надавати сповіщення про потенційні відмови до двох місяців наперед. На рисунку 3.4 також показано дві події сповіщень, які передували відмовам, зареєстрованим у файлі технічного обслуговування: одна 10 червня та інша 24 червня 2018 року. Ці сповіщення виникли послідовно, що свідчить про ефективність системи у виявленні неминучих відмов.




Рисунок 3.4 – Прогнозування відмов з фіксованим порогом та обмеженими даними

На рисунку 3.5, який є збільшеним вікном, показаним на рисунку 3.4, видно, що модель із системою прогнозування несправностей з додатковим ковзним вікном аномалій наприкінці етапу може попереджати про наявність аномалій із середнім випередженням приблизно на чотири місяці для несправностей, що сталися 10 та 24 червня 2018 року, а також 2 березня 2021 року. Однак важливо зазначити, що модель також попереджала про аномалії

наприкінці листопада 2018 року, хоча згідно з журналом технічного обслуговування не було жодної несправності.

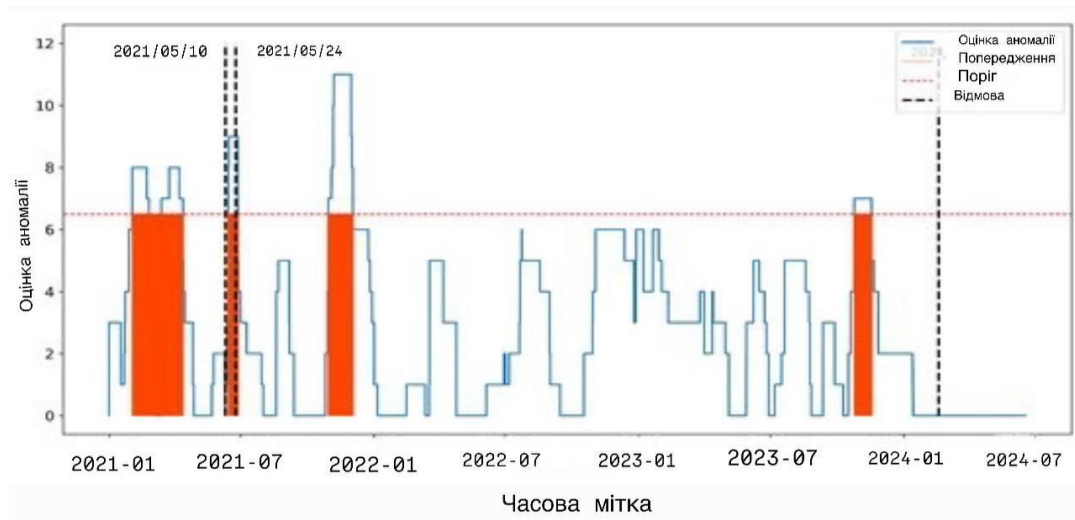


Рисунок 3.5 – Результати роботи системи прогнозування відмов без EWMA для WT2

Для зменшення шуму, що генерується фіксованим порогом, використовувалися фіксований поріг та адаптивний поріг з EWMA. Обмеженням використання фіксованого порогу є те, що він може вловлювати аномалії лише тоді, коли спостерігається тенденція до втрати реконструкції. Тому в цьому дослідженні, оскільки необхідно визначати аномалії в роботі ВТ у всьому його робочому діапазоні, використовується адаптивний поріг з EWMA.

На рисунку 3.6 показано ефективність адаптивного порогу з EWMA, застосованим до кожної помилки реконструкції кожної змінної, що покращило виявлення помилок та зменшило кількість хибнопозитивних результатів.

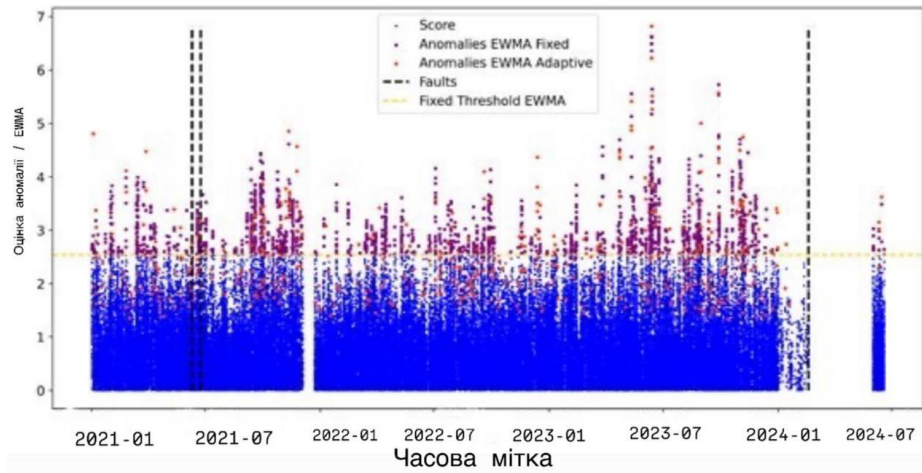


Рисунок 3.6 – Адаптивний поріг EWMA

На рисунку 3.7 показано кінцевий результат роботи системи прогнозування відмов. Модель правильно виявила відмови перетворювача приблизно за 2,5 та 4,2 місяці до їх виникнення. Це демонструє здатність запропонованої моделі до раннього виявлення несправностей.

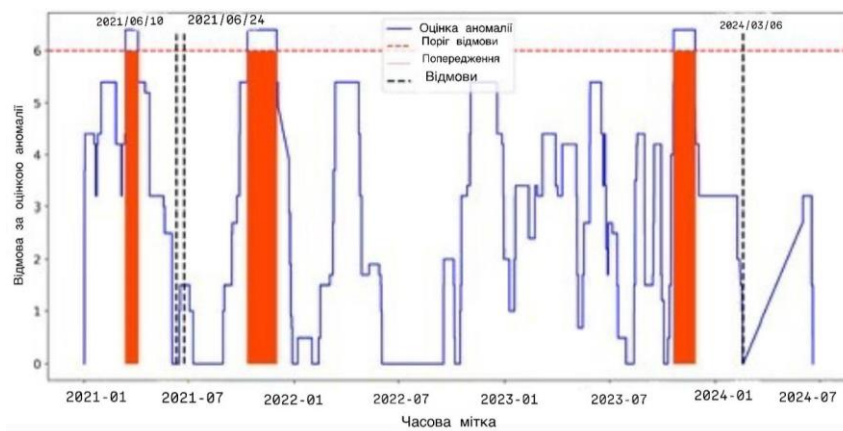


Рисунок 3.7 – Результати роботи системи прогнозування відмов для WT2

## ВИСНОВКИ

Оскільки електронні перетворювачі є критично важливими компонентами, здатність прогнозувати відмови за кілька місяців наперед має вирішальне значення для зниження витрат на експлуатацію та обслуговування. Тому це дослідження стосується прогнозування відмови перетворювачів у ветрогенераторах, розташованих на складному рельєфі місцевості.

Ми розробили гібридну модель з використанням даних SCADA, яка поєднує LSTM, механізм багатоголової уваги та автокодування, використовуючи їхні сильні сторони для вивчення часових та просторових характеристик між змінними. LSTM забезпечує краще узагальнення, тоді як механізм багатоголової уваги фіксує складні закономірності, властиві даним. Механізм автокодування дозволяє моделі реконструювати ознаки за допомогою просторової та часової інформації, що полегшує виявлення несправностей у змінних, пов'язаних з цільовим компонентом.

Модель LSTM-MA-AE може передбачати відмови в середньому приблизно на 3,3 місяці наперед та із середнім значенням F1 90% в оцінених WT, що демонструє низький рівень хибнопозитивних результатів. Ці середньострокові відмови можуть свідчити про деградацію перетворювача.

Цей метод може сприяти ранньому виявленню несправностей і забезпечує надійний механізм прогнозного обслуговування вітрових електростанцій, забезпечуючи більшу надійність та ефективність виробництва. Більше того, ми впевнені, що розроблений нами методологічний процес можна успішно відтворити на інших вітрових електростанціях. Фактично, ми вважаємо, що його можна застосувати навіть до інших компонентів вітрової електростанції, а не лише до перетворювача, що ще більше розширить межі наших досліджень.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Sun, T.; Yu, G.; Gao, M.; Zhao, L.; Bai, C.; Yang, W. Fault Diagnosis Methods Based on Machine Learning and its Applications for Wind Turbines: A Review. *IEEE Access* 2021, 9, 147481–147511
2. Корнієнко, Є., Ляшенко, О. і Торба, А. (2023) «Метод керування системою генерації електроенергії з використанням бездротових технологій», *Сучасний стан наукових досліджень та технологій в промисловості*, (2(24)), с. 80–89. doi: 10.30837/ITSSI.2023.24.080.
3. Kouadri, A.; Hajji, M.; Harkat, M.F.; Abodayeh, K.; Mansouri, M.; Nounou, H.; Nounou, M. Hidden Markov model based principal component analysis for intelligent fault diagnosis of wind energy converter systems. *Renew. Energy* 2020, 150, 598–606.
4. Ляшенко, О., Стародубцев, М., Макаренко, Г. і Пашенко, О. (2024) «Керування електромеханічними системами конвеєрних ліній», *Сучасний стан наукових досліджень та технологій в промисловості*, (4(30)), с. 85–96. doi: 10.30837/2522-9818.2024.4.085.
5. Gao, Z.; Liu, X. An Overview on Fault Diagnosis, Prognosis and Resilient Control for Wind Turbine Systems. *Processes* 2021, 9, 300.
6. Liu, Z.; Zhang, L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. *Measurement* 2020, 149, 107002.
7. Hossain, M.L.; Abu-Siada, A.; Muyeen, S.M. Methods for Advanced Wind Turbine Condition Monitoring and Early Diagnosis: A Literature Review. *Energies* 2018, 11, 1309.
8. Liang, J.; Zhang, K.; Al-Durra, A.; Muyeen, S.; Zhou, D. A state-of-the-art review on wind power converter fault diagnosis. *Energy Rep.* 2022, 8, 5341–5369.
9. Yang, Z.; Chai, Y. A survey of fault diagnosis for onshore grid-

connected converter in wind energy conversion systems. *Renew. Sustain. Energy Rev.* 2016, 66, 345–359.

10. Qiao, W.; Lu, D. A Survey on Wind Turbine Condition Monitoring and Fault Diagnosis—Part I: Components and Subsystems. *IEEE Trans. Ind. Electron.* 2015, 62, 6536–6545.

11. Ляшенко, О. і Михайліченко, І. (2025) «Модель автономної системи моніторингу та оптимізації ІТ-інфраструктури з використанням трансформерів», *Сучасний стан наукових досліджень та технологій в промисловості*, (1(31), с. 73–82. doi: 10.30837/2522-9818.2025.1.073.

12. López, G.; Arboleya, P. Short-term wind speed forecasting over complex terrain using linear regression models and multivariable LSTM and NARX networks in the Andes Mountains, Ecuador. *Renew. Energy* 2022, 183, 351–368.

13. Daniil Vyshnivsky, Oleksii Liashenko, Nataliia Yeromina. Human pose estimation system using deep learning algorithms / Vol. 2 No. 72 (2023): *Control, Navigation and Communication Systems, Information Technology*, P. 75-79. <https://doi.org/10.26906/SUNZ.2023.2.075>

14. Waqas Khan, P.; Byun, Y.C. Multi-Fault Detection and Classification of Wind Turbines Using Stacking Classifier. *Sensors* 2022, 22, 6955.

15. Xiang, L.; Wang, P.; Yang, X.; Hu, A.; Su, H. Fault detection of wind turbine based on SCADA data analysis using CNN and LSTM with attention mechanism. *Measurement* 2021, 175, 109094.

16. Liu, J.; Wang, X.; Wu, S.; Wan, L.; Xie, F. Wind turbine fault detection based on deep residual networks. *Expert Syst. Appl.* 2023, 213, 119102.

17. Zhang, K.; Tang, B.; Deng, L.; Yu, X. Fault Detection of Wind Turbines by Subspace Reconstruction-Based Robust Kernel Principal Component Analysis. *IEEE Trans. Instrum. Meas.* 2021, 70, 1–11.

18. Liu, Z.; Xiao, C.; Zhang, T.; Zhang, X. Research on Fault Detection for Three Types of Wind Turbine Subsystems Using Machine Learning. *Energies* 2020, 13, 460.

19. Xiao, C.; Liu, Z.; Zhang, T.; Zhang, X. Deep Learning Method for Fault

Detection of Wind Turbine Converter. *Appl. Sci.* 2021,11, 1280.

20. Ghazimoghadam, S.; Hosseinzadeh, S. A novel unsupervised deep learning approach for vibration-based damage diagnosis using a multi-head self-attention LSTM autoencoder. *Measurement* 2024, 229, 114410.

21. Wang, A.; Pei, Y.; Zhu, Y.; Qian, Z. Wind turbine fault detection and identification through self-attention-based mechanism embedded with a multivariable query pattern. *Renew. Energy* 2023, 211, 918–937.

22. Aksan, F.; Janik, P.; Suresh, V.; Leonowicz, Z. Review of the application of deep learning for fault detection in wind turbine. In *Proceedings of the 2022 IEEE International Conference on Environment and Electrical Engineering and 2022 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)*, Prague, Czech Republic, 28 June–1 July 2022; pp. 1–6.

23. Zhang, G.; Li, Y.; Jiang, W.; Shu, L. A fault diagnosis method for wind turbines with limited labeled data based on balanced joint adaptive network. *Neurocomputing* 2022, 481, 133–153.

24. Zhang, J.; Sun, H.; Sun, Z.; Dong, W.; Dong, Y. Fault Diagnosis of Wind Turbine Power Converter Considering Wavelet Transform, Feature Analysis, Judgment and BP Neural Network. *IEEE Access* 2019, 7, 179799–179809.

25. Xue, Z.Y.; Xiahou, K.S.; Li, M.S.; Ji, T.Y.; Wu, Q.H. Diagnosis of Multiple Open-Circuit Switch Faults Based on Long Short-Term Memory Network for DFIG-Based Wind Turbine Systems. *IEEE J. Emerg. Sel. Top. Power Electron.* 2020, 8, 2600–2610.

26. Zhang, C.; Hu, D.; Yang, T. Research of artificial intelligence operations for wind turbines considering anomaly detection, root cause analysis, and incremental training. *Reliab. Eng. Syst. Saf.* 2024, 241, 109634.

27. Rama, V.S.B.; Hur, S.H.; Yang, J.M. Short-Term Fault Prediction of Wind Turbines Based on Integrated RNN-LSTM. *IEEE Access* 2024, 12, 22465–22478.

28. Oliveira-Filho, A.; Zemouri, R.; Cambron, P.; Tahan, A. Early Detection and Diagnosis of Wind Turbine Abnormal Conditions Using an Interpretable

Supervised Variational Autoencoder Model. *Energies* 2023, 16, 4544.

29. Liu, J.; Yang, G.; Li, X.; Wang, Q.; He, Y.; Yang, X. Wind turbine anomaly detection based on SCADA: A deep autoencoder enhanced by fault instances. *ISA Trans.* 2023, 139, 586–605.

30. Zhong, Y.; Lakshminarayan, S.; Ran, L.; Mawby, P.; Jia, C.; Ng, C. Detecting Power Module Thermal Resistance Change in Wind Turbine Converters with an Attention-based LSTM-Autoencoder Architecture. In *Proceedings of the 2023 IEEE Energy Conversion Congress and Exposition (ECCE)*, Nashville, TN, USA, 29 October–2 November 2023; pp. 314–320.

31. Ayala, M.; Maldonado, J.; Paccha, E.; Riba, C. Wind Power Resource Assessment in Complex Terrain: Villonaco Case-study Using Computational Fluid Dynamics Analysis. *Energy Procedia* 2017, 107, 41–48.

32. Zhang, J.; Sun, H.; Sun, Z.; Dong, W.; Dong, Y.; Gong, S. Reliability Assessment of Wind Power Converter Considering SCADA Multistate Parameters Prediction Using FP-Growth, WPT, K-Means and LSTM Network. *IEEE Access* 2020, 8, 84455–84466.

33. Ляшенко О.С., Знайдюк В.Г., Цветков К.О., Мішенін Д.О. (2025) Методи машинного навчання для аналізу даних SCADA-систем // Вісник Херсонського національного технічного університету, 3(94).