

## ДОДАТОК А

Графічний матеріал кваліфікаційної роботи

Харківський національний університет радіоелектроніки

каф. ЕОМ

Гібридна модель автокодувальника LSTM для аналізу  
даних системи SCADA вітрових турбін

Ст. групи СПм-23-3  
Мішенін Д.О.

Керівник  
Ляшенко О.С.

2025

## Актуальність роботи

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 роботі пропонується гібридна модель автокодувальника короткочасної та довгострокової пам'яті (LSTM) для виявлення несправностей перетворювача ВТ.

## Мета та задачі кваліфікаційної роботи

- Мета роботи розробити модель автокодувальника LSTM для аналізу даних системи SCADA вітрових турбін

Задачі які поставлені в роботі:

- Запропонувати методологію прогнозування несправностей
- Розглянути компоненти запропонованої моделі (LSTM, автоенкодера та ін.)
- Розробити архітектуру моделі для аналізу даних системи на базі LSTM
- Провести тестування системи щодо прогнозування несправностей

3

## Методологія прогнозування несправностей

На рисунку показано методологічний процес прогнозування несправностей, який використовується в роботі.

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.




4



## 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 вітрових турбін.


LSTM містить вхідний вентиль, вихідний вентиль і пропускний вентиль. Його структуру показано на рисунку.



7

## Автоенкодер

Автоенкодер (AE) – 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, AE зазвичай складається з двох частин: кодера та декодера.



8

## Multi-Head Attention (MA)

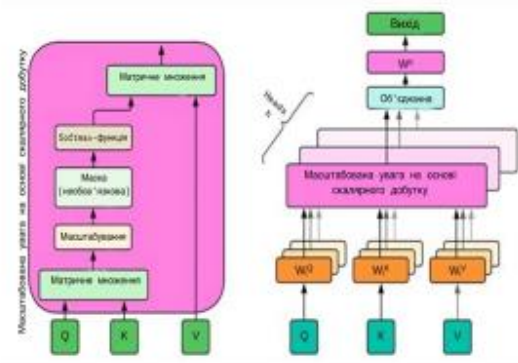
Адміністрування стало життєво важливим компонентом нейронних мереж для обробки довгих послідовних даних. Обчислюючи ваги уваги, мережа вчиться зосереджуватися на найважливіших частинах вхідних даних. Важливе нововведення було введено з Multi-Head Attention (MA). Цей підхід покращує увагу, використовуючи 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 рисунку, вхідна послідовність лінійно проєктується на Q, K та V за допомогою вивчених вагових матриць  $W_1^Q$ ,  $W_1^K$  та  $W_1^V$ .

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 проєктується за допомогою вивченої матриці  $W^O$  щоб отримати кінцевий результат уваги кількох голів Output. Цей процес описується рівняннями

$$Att_h = \text{Attention}(QW_1^Q, KW_1^K, VW_1^V)$$

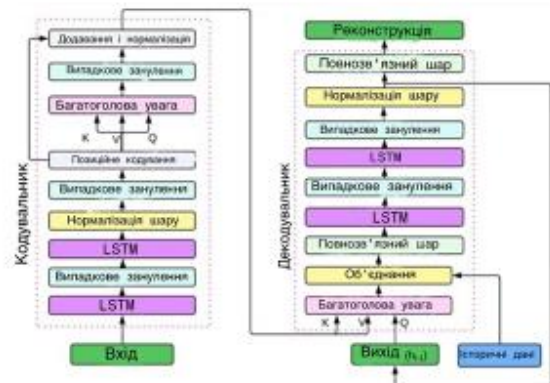
$$\text{Output}(Q, K, V) = \text{Concat}(Att_1, Att_2, \dots, Att_n) W^O$$



9

## Архітектура моделі LSTM-MA-AE

- Модель LSTM-MA-AE має дві основні частини: кодер та декодер. Структура моделі представлена на рисунку.
- У кодері комбінація шарів LSTM, AE 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 AE 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.



10

## 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.

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

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

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

Крім того, ми використовуємо функцію Precision ( $Pr$ ), Recall ( $Re$ ), та F1-оцінка ( $F1$ ) метрики, які зазвичай використовуються для виявлення аномалій. Ці метрики визначаються рівняннями

$$Pr = \frac{TP}{TP + FP} \quad Re = \frac{TP}{TP + FN} \quad F1 = \frac{2 \cdot Pr \cdot Re}{Pr + Re}$$


Всі 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.

11

### Порівняння втрат під час навчання та валідації з різними гіперпараметрами моделі.

Під час навчання ми встановили максимальну кількість епох на 75. Однак, використовуючи ранню зупинку, модель досягла найкращої продуктивності на епісі 25, коли втрати валідації перестали суттєво покращуватися.


Як показано на рисунку, 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.



12

## 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. Ми використовували набір даних Wind Turbine Scada Dataset від Kaggle за 2018 рік.
- Після впровадження системи прогнозування відмов можна побачити на рисунку, що система прогнозування може надавати сповіщення про потенційні відмови до двох місяців наперед.
- На рисунку 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.



13

## ВИСНОВКИ

Розроблено 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 MA 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.

Також в роботі було:

- Запропоновано методологію прогнозування несправностей
- Розглянуто компоненти запропонованої моделі
- Розроблено архітектуру моделі для аналізу даних системи на базі LSTM
- Проведено тестування системи щодо прогнозування несправностей.

Результати дослідження подані в фаховий журнал категорії Б «Вісник Херсонського національного технічного університету» у вигляді наукової статті  
Ляшенко О.С., Знайдок В.Г., Цвєтков К.О., Мішенін Д.О. Методи машинного навчання для аналізу даних SCADA-систем.

14