

## ДОДАТОК А

Графічний матеріал кваліфікаційної роботи



Харківський національний університет  
радіоелектроніки

каф. ЕОМ

## Модель прогнозування споживання енергії на основі штучних нейронних мереж

СТ. ГРУПИ КСМзм-23-1

КЕРІВНИК

ГРИБОВСЬКА В. А.

СТ. ВИКЛАДАЧ ЗНАЙДУК В. Г.

## Актуальність роботи

- Прогнозування попиту в енергосистемі є критично важливим завданням у галузі. Це пов'язано з тим, що більшість системного планування та операційної діяльності в основному покладаються на належні моделі прогнозування.
- Вся енергетична інфраструктура побудована, по суті, для забезпечення та обслуговування споживання енергії. Таким чином, дуже необхідно побудувати надійні та ефективні прогнозні моделі, щоб забезпечити точне прогнозування навантаження. У цій роботі використовуються три техніки для короткострокового прогнозування навантаження. Ці методи включають глибоку нейронну мережу, багатoshарову штучну нейронну мережу на основі персептрона і прогнозування на основі дерева рішень.

## Мета та завдання роботи

**Мета кваліфікаційної роботи** побудувати моделі на базі штучних нейронних мереж для прогнозування споживання енергії.

### Завдання:

- Провести аналіз набору даних на основі якого будуть навчатися моделі
- Розглянути сучасні моделі які використовуються для прогнозування
- Обрати критерії ефективності моделі
- Побудувати моделі та провести аналіз результатів

24.01.2023 3

## Опис залежних і незалежних змінних.

Змінна	Опис—Тип
Hourly Load	Розрахункове годинне навантаження на систему (МВт)
LY	Навантаження минулого року на той самий час (МВт)
PW	Навантаження попереднього тижня за той самий час (МВт)
PD	Навантаження попереднього дня за той самий час (МВт)
P24Hr	Середнє навантаження за 24 години до цього часу (МВт)
Temp	Зовнішня температура (°C)
DT	Температура точки роси (°C)
Hum	Реальна вологість (%)
WS	Середня швидкість вітру (км/год)
AP	Тиск зовнішнього повітря (кПа)
ONER	Погодинна ціна електроенергії (центи/кВт-год)

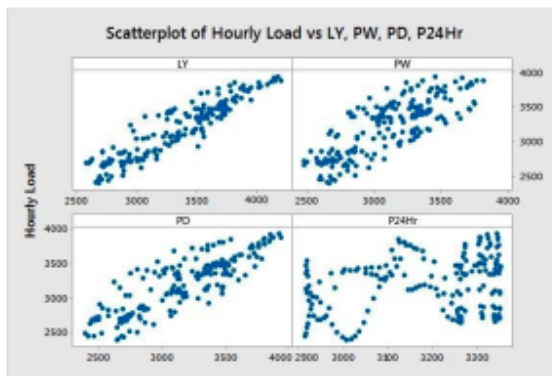
24.01.2023 4

## Характеристики набору даних.

Змінні	Статистична інформація для даних			
	Мін	Середній	Макс	STD
Погодинна навантаження	2387,356	3198,982	3937,756	396,3217
LY: навантаження минулого року в той самий час (МВт)	2574,196	3359,433	4197,332	408,688
PW: навантаження попереднього тижня за той самий час (МВт)	2473,032	3089,212	3807,772	329,1408
PD: Навантаження попереднього дня за той самий час (МВт)	2387,356	3151,728	3937,756	395,8146
P24Hr: Середнє навантаження за 24 години до цього часу (МВт)	2912,799	3188,113	3351,651	149,6213
Temp: зовнішня температура (°C)	5.8	13,40905	22.9	3,995968
DT: температура точки роси (°C)	2.2	9,210553	15.9	4,57159
Hum: справжня вологість (%)	46	81,96985	99	12,01837
WS: Середня швидкість вітру (км/год)	0	14,15578	35	6,852418
AP: тиск зовнішнього повітря (кПа)	98,94	100,0777	101,34	0,568973
ONEP: погодинна ціна електроенергії (цент/кВт-год)	9.8	34,62302	103,39	12,51388

24.01.2023 5

## Підготовка даних і кореляційний аналіз




При розробці моделі використовувалась перехресна перевірка з відпусткою (leave-one-out LOO). Для методів машинного навчання моделі були навчені та протестовані за допомогою техніки LOO. Важливо зазначити, що в техніках машинного навчання всі предиктори розглядалися як вхідні дані. Це тому, що предиктор, який не вважався значущим у регресійній моделі, може бути значущим у моделях на основі машинного навчання.

Варто зазначити, що моделі були навчені/тестовані з використанням тих самих наборів даних із перевіркою LOO. Це робиться для того, щоб порівняння між цими трьома моделями було чесним і неупередженим. На рисунку показано зв'язки між погодинним навантаженням і незалежними змінними LY, PW, PD і P24Hr.

24.01.2023 6

## Глибока нейронна мережа (DNN)

В рамках дослідження було розроблено модифіковану LSTM, яка може адаптувати індуктивне зміщення для компенсації відсутніх випадків. Модифікована LSTM разом із стандартною архітектурою LSTM представлена на рисунку.




Реалізація прогнозування часових рядів на основі DNN включає наступні кроки:

- 1) завантаження набору даних,
- 2) формулювання файлу даних для навчання та тестування,
- 3) стандартизація набору даних для навчання та тестування для кращої відповідності розбіжностям,
- 4) визначити мережеву архітектуру DNN (тобто прихований блок, рівні, параметр навчання, поріг, швидкість навчання, метод пошуку, кількість епох тощо),
- 5) навчання моделі DNN (за допомогою функції trainNetwork),
- 6) прогноз майбутніх кроків у часі (за допомогою функції predictAndUpdateState)
- 7) оновлення стану мережі DNN за допомогою спостережуваних значень.

24.01.2023 7

## Штучна нейронна мережа (ШНМ)



Нелінійні функції активації в MLP забезпечують гнучкість моделі, щоб зафіксувати варіації потенціалів дії біологічних нейронів. Функція активації повинна бути нормалізована та мати можливість математично диференціюватись.

Існує дві основні функції активації, які широко використовуються в області ШНМ. Ці функції є гіперболічним тангенсом і логістичною функцією, і обидві є функціями S-кривої (сигмоподібна функція).

24.01.2023 8

## Дерево рішень (DT)

Дерево рішень — це ефективний алгоритм у машинному навчанні, заснований на ідентифікації певного шаблону в даних для сортування або прогнозування подій таким чином, що метою є оптимальна побудова дерева рішень з мінімальною помилкою узагальнення.

Процедури дерева рішень можна підсумувати такими етапами:

A - Початковий вузол вибрано та присвоєно значенню дискретного атрибута A.  
B - Визначається граничне значення A і обчислюється ентропія розподілу, викликана значенням A; після цього буде обрано мінімальний.

C - Для всіх атрибутів буде розраховано наведений нижче приріст і буде розглянуто атрибут, який має найбільший приріст. Вибраний атрибут буде основою сортування для дерева, а дерево рішень буде розгорнуто на цьому конкретному вузлі.

D- Наведені вище процедури повторюватимуться, доки не буде досягнуто двох основних моментів:

1 - у кожного вузла залишився лише один вузол, і цей вузол називається листовим вузлом, де більше немає розширення.

2 - коефіцієнт підсилення досягає критерію зупинки, коли більше немає процесу сортування.



24.01.2023 9

## Критерії ефективності моделі


- В якості критеріїв оцінки використовуються коефіцієнт детермінації  $R^2$  і середній абсолютний залишковий (mean absolute residual - MAR). Крім того, враховується час, який витрачається на навчання кожної моделі. Коли  $R^2$  наближається до 1, а MAR наближається до нуля, точність моделі дуже висока. MAR залежить від одиниці прогнозованого значення. Наприклад, якщо одиниця прогнозованого значення в мегаватах (106 ват), доцільно мати кілька кіловат як помилку.
- $R^2$  (коефіцієнт детермінації) — це число (дорівнює або менше 1), яке описує, наскільки добре дані відповідають моделі регресії. Він варіюється від 1 (коли лінія регресії проходить через усі дані) до 0 (коли немає кореляції — погана кореляція).
- MAR вимірює, наскільки віддалені прогнозовані значення від фактичних значень. Зрозуміло, що модель точна, коли MAR стає нижчим.

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

$$MAR = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i(t) - \hat{y}_i(t)|$$

24.01.2023 10

## Прогнозування на основі DNN



Порівняння годинного прогнозу майбутніх часових рядів з використанням оновленої моделі DNN з тестовими даними

Порівняння щоденних прогнозних майбутніх часових рядів з використанням оновленої моделі DNN із тестовими даними

Порівняння тижневого прогнозу майбутніх часових рядів з використанням оновленої моделі DNN з тестовими даними

24.01.2023 11

## Прогнозування на основі ШНМ (MLP)




Рисунок 1. Крива продуктивності MEA в залежності від нейронів прихованого шару.




Рисунок 2. Крива продуктивності MEA проти прихованих шарів

24.01.2023 12

## Прогнозування на основі Дерева рішень

Атрибути/номер правила	LY	PW	PD	P24Hr	Temp	DT	Hum	WS	AP	ONEP	Constant
1	0,58	0,17	-0,26	0,19	16,53	-7,14	5,91	-0,91	11,24	-1,77	-1127,98
2	0,70	0,17	-0,26	0,19	23,81	-7,14	6,66	-0,91	11,24	-1,77	-1588,60
3	0,75	0,17	-0,26	0,19	17,57	-7,14	3,67	-0,91	11,24	-2,80	-1317,36
4	0,54	0,30	-0,23	-0,01	11,49	-7,14	—	-0,49	11,24	-1,98	-133,78
5	0,54	0,30	-0,22	0,20	11,49	-7,14	—	-0,91	11,24	-1,98	-797,84
6	0,76	0,34	-0,46	0,08	11,49	-7,14	—	-0,91	11,24	-1,98	-449,59
7	0,72	0,34	-0,43	0,08	11,49	-7,14	—	-0,91	11,24	-1,98	-426,06
8	1,14	0,12	-0,23	-0,18	16,73	-24,59	3,57	-0,87	-9,02	-1,97	964,80
9	0,93	0,08	-0,28	-0,18	28,95	-47,47	1,22	-0,87	24,24	-1,97	-1053,00
10	0,54	0,03	-0,21	-0,22	11,68	-18,37	0,72	-0,87	28,96	-9,37	289,99
11	0,54	0,03	-0,43	-0,22	11,68	-18,37	0,72	-0,87	28,96	-6,18	937,13
12	1,06	0,03	-0,34	-0,22	10,35	-16,88	0,72	-1,48	29,61	-0,39	-1526,00

Коефіцієнти кожного предиктора в кожному правилі.

24.01.2023 13

## Порівняння та підтвердження результатів

З таблиці видно, що модель DNN перевершує інші моделі на основі критеріїв MAR і  $R^2$ . Модель ШНМ має найнижчий MAR в одинарному та подвійному шарах, який становить 0,0558 та 0,051 відповідно. Крім того, моделі DNN мають найвищі значення  $R^2$ .

Модель	$R^2$	MAR	Час створення моделі	Час навчання
DNN	0,985	0,014	0,0002 с	32–33 с
ШНМ (1)	0,958	0,0558	0,42 с	1 хв., 17 с
ШНМ (2)	0,966	0,051	0,42 с	3 хв., 13 с
Дерево рішень	0,904	0,091	0,16 с	15,2 с

24.01.2023 14

## Висновки

---

В рамках кваліфікаційної роботи було створено три прогнозні моделі для прогнозування навантаження електроенергії на короткостроковий період (тобто від 24 годин до одного тижня) для задоволення рівноваги попиту та пропозиції. Ці моделі доводять свою ефективність і точність прогнозування навантаження. У цій роботі використовуються DNN, MLP та прогнозування на основі дерева рішень.

З таблиці видно, що модель DNN перевершує інші моделі на основі критеріїв MAR і  $R^2$ . Модель ШНМ має найнижчий MAR в одинарному та подвійному шарах, який становить 0,0558 та 0,051 відповідно. Крім того, моделі DNN мають найвищі значення  $R^2$ .

Однак DNN також займав найкоротший час для створення та навчання моделі порівняно з іншими методами. Алгоритм дерева рішень має нижче значення MAR, ніж регресія, але вище, ніж ШНМ, а час на створення та навчання моделі менший, ніж ШНМ. З наведених вище результатів усі методи дають дуже хороші результати, оскільки  $R^2$  для них є відносно високим, а MAR малим.

**Апробація результатів роботи:** Грибовська В.А., Знайдок В.Г. Метод прогнозування споживання електроенергії на основі штучних нейронних мереж. Проблеми інформатизації. Тези доповідей дванадцятій міжнародної НТК. – Баку: ІСУ АР; Харків: НТУ «ХПБ»; Харків: ХНУРЕ; Харків: НАУ «ХАІ»; Бельсько-Бяла: УТІГН, 2024. – 21-22 листопада 2024. – Том 2. – С. 88.