

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет навчально-науковий центр заочної форми навчання
(повна назва)

Кафедра електронних обчислювальних машин
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

Рівень вищої освіти другий (магістерський)

Модель прогнозування споживання енергії на основі
штучних нейронних мереж

(тема)

Виконав:

студент II курсу, групи КСМзм-23-1
Грибовська В.А.
(прізвище, ініціали)

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

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

Освітня програма Комп'ютерні системи та мережі
(повна назва освітньої програми)

Керівник: Ст.викл. Знайдюк В.Г.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри ЕОМ

(підпис)

Коваленко А.А.

(прізвище, ініціали)

2025 р.

Харківський національний університет радіоелектроніки

Факультет навчально-науковий центр заочної форми навчання

Кафедра електронних обчислювальних машин

Рівень вищої освіти другий (магістерський)

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

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

Освітня програма Комп'ютерні системи та мережі
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

“ _____ ” _____ 20__ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

студенту Грибовській Віолеті Андріївні
(прізвище, ім'я, по батькові)

1. Тема роботи Модель прогнозування споживання енергії на основі штучних нейронних мереж

затверджена наказом по університету від “ 13 ” листопада 2024 р. № 189 Стз

2. Термін подання студентом роботи до екзаменаційної комісії 20 січня 2025 р.

3. Вхідні дані до роботи Штучний інтелект, нейронні мережі, прогнозування, часові ряди, методи валідації, електроспоживання.

4. Перелік питань, що потрібно опрацювати у роботі _____

1. Аналіз предметної області

2. Набори даних і методологія

3. Результати експрементів

Висновки

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) _____

Слайд-презентація – 15 слайдів _____

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	Термін виконання етапів роботи	Примітка
1	Отримання завдання	13.11.24	
2	Аналіз літератури	14.11.24-01.12.24	
3	Дослідження обраних методів ШІ	02.12.24-12.12.24	
4	Програмна реалізація обраних моделей	13.12.24-20.12.24	
5	Аналіз результатів експериментів	21.12.24-23.12.24	
6	Оформлення пояснювальної записки	24.12.24-29.12.24	
7	Проходження перевірки на плагіат	30.12.24-02.01.25	
8	Отримання рецензії	03.01.25-13.01.25	
9	Подача роботи в ЕК	14.01.25-15.01.25	

Дата видачі завдання 13 листопада 2024 р.

Студент _____
(підпис)

Керівник роботи _____
(підпис)

Ст.викл. Знайдюк В.Г. _____
(посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 60 с., 25 рис., 6 табл., 1 дод., 41 джерел.

ШТУЧНИЙ ІНТЕЛЕКТ, НЕЙРОННІ МЕРЕЖІ, ПРОГНОЗУВАННЯ,
ЧАСОВІ РЯДИ, МЕТОДИ ВАЛІДАЦІЇ, ЕЛЕКТРОСПОЖИВАННЯ.

Метою кваліфікаційної роботи є побудова моделі на базі штучних нейронних мереж для прогнозування споживання енергії.

У ході виконання кваліфікаційної роботи створено три прогнозні моделі для прогнозування навантаження електроенергії на короткостроковий період (тобто від 24 годин до одного тижня) для задоволення рівноваги попиту та пропозиції, що дуже корисно для планування технічного обслуговування. У роботі використовуються DNN, штучна нейронна мережа та прогнозування на основі дерева рішень.

ABSTRACT

Master's thesis: 60 pages, 25 figures, 6 tables, 1 appendices, 41 sources.

ARTIFICIAL INTELLIGENCE, NEURAL NETWORKS,
FORECASTING, TIME SERIES, VALIDATION METHODS, ELECTRICITY
CONSUMPTION.

The major goal of this thesis is to build a model based on artificial neural networks for forecasting energy consumption.

During the qualification work, three forecasting models were created to forecast the electricity load for a short-term period (i.e. from 24 hours to one week) to meet the balance of demand and supply, which is very useful for maintenance planning. The work uses DNN, artificial neural network and decision tree forecasting.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ	7
ВСТУП	8
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ	10
1.2 Вибір змінних	13
2 НАБОРИ ДАНИХ І МЕТОДОЛОГІЯ	16
2.1 Коротка інформація про набори даних для експериментальної демонстрації.....	17
2.2 Методи прогнозування навантаження	24
2.2.1 Глибока нейронна мережа (DNN)	24
2.2.2 Штучна нейронна мережа (ШНМ)	25
2.2.3 Дерево рішень (DT).....	28
2.3 Критерії ефективності моделі	30
3 РЕЗУЛЬТАТИ ЕКСПРЕМЕНТІВ	32
3.1 Прогнозування на основі DNN та його перевірка	32
3.2 Прогнозування на базі ANN.....	40
3.3 Прогнозування на основі DT	42
3.4 Порівняння та підтвердження результатів	43
ВИСНОВКИ.....	45
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	47
ДОДАТОК А Графічний матеріал кваліфікаційної роботи.....	52

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ
І ТЕРМІНІВ

ДР – дерево рішень

НМ – нейронна мережа

ШНМ – штучна нейронна мережа

CNN – згорткова НМ

DNN – глибока нейронна мережа

FL – нечітка логіка

GA – генетичний алгоритм

LSTM – довга короткочасна пам'ять

MAE – середня абсолютна похибка

MAR – середній абсолютний залишок

MLP – багатошаровий перцептрон

MMRE – відносна похибка середньої величини

R^2 – регресія

RNN – рекурентна нейронна мережа

ВСТУП

Попит на електроенергію можна передбачити за допомогою різних математичних і статистичних моделей; однак вибір моделі, яка забезпечує узгоджені результати, є критичною діяльністю в цьому процесі. Декілька зовнішніх факторів можуть впливати на споживання електроенергії, і їх потрібно розглядати як вхідні дані в цих моделях [1]. Використання незалежних факторів може допомогти зменшити помилки, і, з іншого боку, процес прогнозування стає більш складним, оскільки вимагає більш детального вивчення взаємозв'язків між змінними, що передбачає визнання критеріїв та рівня важливості [2], оскільки ці критерії різні в кожному випадку [1, 2].

Щоб зрозуміти ці зв'язки, різні метеорологічні, соціально-економічні та екологічні змінні були включені в значну кількість досліджень, пов'язаних з прогнозуванням попиту на електроенергію. Однак література показує, що вибір незалежних змінних в основному здійснюється на основі знань дослідників, і це не гарантує, що це найкраща процедура для вирішення задач прогнозування. Таким чином, розробка інтегрованої моделі для вибору незалежних змінних і значення їх разом із штучними нейронними мережами для попиту на електроенергію все ще залишається актуальною прогалиною.

Країни стикаються з проблемами в енергетичному секторі, і щоб система залишалася в роботі, необхідно покращити вже прийняті рішення та включити майбутні цілі, такі як розширення енергетичної матриці, гарантування енергетичної безпеки та досягнення цілей сталого розвитку [3]. У цьому контексті вивчення моделей прогнозування, які інтегрують багатокритеріальний аналіз, створює можливість включити інші критерії, які не враховуються існуючими моделями. Цей крок включає економічні, соціальні та екологічні аспекти, а також ефективність процесів виробництва енергії.

Споживання електроенергії зростає в глобальному масштабі. За даними Центрального розвідувального управління, розвинені країни споживають 43,26% від загального світового споживання електроенергії. Значна частина цього споживання відбувається в житловому, комерційному та державному секторах, і промисловий сектор є найбільшим споживачем.

Електроенергія не може зберігатися, а дисбаланс між попитом і пропозицією необхідно ефективно моделювати, щоб уникнути витрат, які зазвичай перекладаються на користувачів. Як надлишок, так і скорочення виробництва електроенергії завдають шкоди економіці країни. У цьому випадку рішення повинні бути економічно життєздатними, і важливо визнати поведінку та вплив усіх залучених змінних, що дає змогу визначити теперішні та майбутні тенденції для правильного розподілу інвестицій у сектор електроенергії.

Прогнозування попиту в енергосистемі є критично важливим завданням у галузі енергосистеми. 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 статті використовуються три техніки для короткострокового прогнозування навантаження. Ці методи включають глибоку нейронну мережу (DNN), багат шарову штучну нейронну мережу на основі персептрона (ШНМ) і прогнозування на основі дерева рішень (DT). Додано нові прогнозні змінні, щоб покращити загальне прогнозування та впоратися з труднощами, викликаними деякими категоріальними предикторами. Порівняння між цими трьома методами виконується на основі коефіцієнтів детермінації R^2 і середньої абсолютної похибки (MAE). Статистичні тести проводяться, щоб перевірити результати та перевірити, чи ці моделі статистично відрізняються чи ні. Результати показують, що модель DNN перевершила інші моделі та статистично відрізнялася від них.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

Прогнозування навантаження є важливим компонентом планування та експлуатації системи розподілу [1]. За допомогою прогностичних моделей досліджується структура попиту, і деякі електричні генератори призначені для задоволення цього попиту в мережах передачі та розподілу, тому будь-яке велике відхилення в прогнозуванні може спричинити технічні та економічні проблеми [2]. Крім того, у маркетингу дерегульованої енергосистеми всі стратегії торгів як від виробника енергії, так і від споживача безпосередньо залежать від прогнозованого попиту [2]. Часто існує затримка між усвідомленням збільшення попиту на навантаження та виникненням цього збільшення. Цей час дозволяє інженерам-електрикам виконувати завдання планування та прогнозування для задоволення очікуваного зростання попиту. Прогноз навантаження потрібен, щоб визначити, коли відбудеться збільшення навантаження, щоб можна було вжити відповідних заходів.

Необхідний горизонт прогнозу визначає тип прогнозування, довгострокове, середньострокове або короткострокове. У короткостроковому прогнозуванні часовий проміжок передбачається на 1 годину вперед до 1 тижня, включаючи щоденне прогнозування (24 години). Протягом цього короткого періоду виконується багато операційних заходів, таких як диспетчеризація генераторів, зобов'язання одиниць, регулювання напруги, ціноутворення в режимі реального часу на енергетичному ринку тощо. Таким чином, методи точного короткострокового прогнозування навантаження вимагають даних, які в основному пов'язані з часовим виміром: історичне навантаження, історичні погодні умови, прогнозовані погодні умови, а також характер дня та сезону є прикладами необхідних даних для короткого - строковий прогноз електричного навантаження. Нижче наведено узагальнені важливі фактори для належного дослідження прогнозу навантаження:

- історичні дані про навантаження в мегаватах (МВт) і мегавольт-амперах (MAVR);
- погодні умови (температура, точка роси, тиск, покрив неба, видимість, швидкість вітру тощо);
- економічні показники (ціни на енергоносії, місцеве промислове виробництво, забудова будівництва тощо);
- фактор часу (пора року, день тижня, година доби);
- класи клієнтів (житлові, комерційні, промислові, лікарні тощо).

У дослідженнях прогнозу електричного навантаження слід ретельно враховувати часові фактори та погодні умови, окрім історичного попиту на навантаження. Фактор часу враховує різні масштаби, такі як місяці в році, дні в тижні та години в добі. Крім того, індекс можна використовувати в дослідженнях прогнозування навантаження, які розрізняють будні та вихідні дні. Другим важливим фактором короткострокового прогнозу попиту на електроенергію є те, як погодні умови впливають на поведінку навантаження. Різні комунальні служби та інженери-дослідники розглядають різні змінні погоди, щоб зафіксувати вплив погодних умов (температура, вітер, вологість) на прогноз електричного навантаження. Комунальні підприємства широко використовують два фактори для визначення цих ефектів: перший фактор пов'язаний з індексами температури та вологості та зазвичай використовується влітку для визначення впливу тепла та вологості на споживання електроенергії. Взимку використовуються інші показники, пов'язані зі швидкістю вітру, температурою та швидкістю льодопаду. Класи споживачів також відіграють важливу роль для визначення схеми прогнозованого навантаження. Кожен окремий набір даних слід перевіряти вручну. Однак, коли є великі набори даних для аналізу, ручне очищення кожного файлу даних окремо потребуватиме значного часу та зусиль, і автоматизована перевірка може бути найкращою альтернативою з використанням деяких добре відомих статистичних методів.

Різноманітність методів, таких як наївні підходи, простий регресійний аналіз, аналіз часових рядів і методи, засновані на програмних обчисленнях, були застосовані для прогнозування короткочасного електричного навантаження [4, 5]. Короткострокове прогнозування навантаження було представлено за допомогою множинної лінійної регресії, що включає поліноміальні терміни в [4]. В [5] запропонував лінійну регресійну модель, що включає функції нагріву та охолодження, а також двійкові змінні. Короткостроковий прогноз навантаження SA представлений у довідці [6] із застосуванням непараметричної регресії, натхненної функцією розподілу ймовірностей для навантаження та деяких впливаючих змінних.

В роботі [7] використовував нечіткий регресійний аналіз для короткострокового прогнозування попиту, який охоплював вплив свят на прогнозну модель. Прогнозування навантаження було використано у [8] з використанням регресійного аналізу з урахуванням двох компонентів навантажень: температурочутливого навантаження та нетемпературно чутливого навантаження. Адаптивне короткострокове прогнозування погодинних навантажень за допомогою багатовимірної регресії застосовано в [11]. В [12] комбінована регресія з інтегрованою ковзною середньою авторегресії для забезпечення онлайн-прогнозування навантаження. Штучна нейронна мережа (ШНМ) використовується для прогнозування попиту на електроенергію в [13, 14]: єдині дані, які беруть участь у моделі, це дані про температуру та навантаження. Короткострокове прогнозування навантаження реалізується з використанням каскадних методів навчання паралельно із записами навантаження та температури [15], і цей метод називається каскадними штучними нейронними мережами (CANN). Для короткострокового прогнозу навантаження запропоновано нечітку нейронну мережу [16, 17]. В дослідженні [18] використовували неповністю підключену ШНМ для короткострокового прогнозування, щоб мінімізувати час навчання. У [19] було змодельовано схему навантаження на основі робочих і вихідних днів. Активний відбір для навчальних даних, k-найближчі сусіди та пілотне

моделювання включені в ШНМ для прогнозування короткострокового попиту [20]. В [21] розроблено багат шарову нейронну мережу з адаптивним алгоритмом навчання для короткострокового прогнозу навантаження. Автори в [22] використовували дерево рішень ID3 для прогнозування навантаження в довгостроковій перспективі, тоді як автори в [23] застосовували експертні системи крім дерева рішень ID3 для прогнозування короткострокового попиту.

1.2 Вибір змінних

Основні змінні, перелічені в таблиці 1.1, вважалися незалежними змінними з різних досліджень.

Таким чином, незалежні змінні розглядалися як альтернативи для включення в процес багатокритеріального відбору. Ці альтернативи були відфільтровані на цьому етапі на основі застосування методу ELECTRE I, який вибирає ядро («ядро») альтернатив із кращим компромісом щодо мети дослідження. Наступним кроком було визначення критеріїв (таблиця 1.2), що відповідають основним характеристикам, знайденим до виконання прогнозу попиту. Тим не менш, на цьому етапі особи, які приймають рішення, повинні виконати перевірку критеріїв шляхом порівняння запропонованої літератури та/або зазначення нових відповідних критеріїв, якщо необхідно.

Ваги критеріїв було визначено, щоб відобразити важливість кожного критерію. У цьому дослідженні критеріальні ваги були встановлені методом аналітичного ієрархічного процесу (АНП) у попарному порівнянні, проведеному двома фахівцями щодо поведінки попиту на енергію. Наступним етапом цього етапу був вибір багатокритеріального методу для процесу відбору. Цей крок мав на меті вибрати єдину групу альтернатив (таблиця 1.2) на основі зібраних даних щодо кожної альтернативи для кожного критерію.

Таблиця 1.1 – Незалежні змінні були обрані при огляді літератури

Тип змінних	Незалежні змінні	Альтернативи
Соціально-економічні змінні	Національний дохід (NI)	a1
	Населення	a2
	Валовий внутрішній продукт (ВВП)	a3
	Індекс споживчих цін (CPI)	a4
	Інвестиції в основні засоби (FAI)	a5
	Прямі іноземні інвестиції (ПІІ)	a6
	Вартість промислової продукції	a7
	Рівень урбанізації	a8
Кліматичні змінні	температура	a9
	Сонячна радіація	a10
	Відносна вологість	a11
	Опади	a12
	Середній напрямок вітру	a13
	Середня швидкість вітру	a14
	Тиск	a15
	Випаровування	a16
	Дощові дні	a17
Змінна середовища	Викиди вуглецю	a18

Таблиця 1.2 – Критерії, наведені в літературі

Параметри	Критерії	Особливості
1	2	3
Ступінь складності	g1 – Доступність даних	Кількість інформації, числові дані, нечислові дані та числовий аналіз
	g2 – Кореляція з незалежною змінною	Кореляція попиту на електроенергію з незалежними змінними

Продовження таблиця 1.2

1	2	3
Схема споживання	g3 – Структура споживання за секторами	Промисловий, комерційний, житловий, сільський та інші сектори
	g4 – Структура споживання за регіонами	Географічна, економічна та соціальна характеристика регіону
	g5 – Схема споживання за календарем	Свята, вихідні, особливі дні

На цьому етапі підхід надмірної класифікації, заснований на сімействі ELECTRE (ÉLimination Et Choix Traduisant la REalité -Elimination and Choice Translating Reality), точніше ELECTRE I, був обраний для виконання вибору альтернативи (незалежних змінних). Метод ELECTRE I використовує поняття випереджаючих порівнянь та індекс узгодженості та неузгодженості (узгодженості та розбіжності).

2 НАБОРИ ДАНИХ І МЕТОДОЛОГІЯ

Пропонований підхід показано рисунку 2.1, який є комбінацією 7 основних кроків. Ці кроки: (1) онлайн/офлайн збір набору даних, (2) попередня обробка даних, (3) виділення ознак, (4) вибір найбільш релевантних функцій, (5) розробка моделі ШІ, (6) вилучення прогнозних значень і (7) порівняння результатів. Зібраний набір даних може бути онлайн або офлайн, який вибирається відповідно до програми користувача. Після збору набору даних виконується попередня обробка даних, щоб усунути стрибки та заповнити відсутні значення, якщо такі є. Як правило, стрибки та відсутні значення в наборі даних виникають через кілька проблем/причин, як-от небажані погодні умови та/або інструментальна/операційна/технічна помилка чи помилка людини. Після попередньої обробки набору даних виконується виділення ознак, що включає кілька можливих комбінацій ознак, таких як статистичні ознаки (середнє значення, SD, дисперсія, ексцес тощо), функції часової області, функції частотної області та частотно-часові характеристики. особливості домену. Вибір функцій виконується для вибору найбільш релевантних вхідних змінних/функцій, які впливають на продуктивність моделі ШІ/машинного навчання для прогнозування. Після цього виконується розробка моделі прогнозування, яка може включати різні типи моделей, такі як лінійна модель часових рядів (AR, MA, ARMA, ARIMA, ARFIMA, SARIMA тощо), нелінійна модель часових рядів (ARCH, GARCH, EGARCH, TAR, NAR, NMA тощо) і модель на основі AI/ML (ANN, SVM, ELM, PSO, GA, ACO, дерево рішень, тощо). Після розробки моделі проводяться навчання та тестування для перевірки продуктивності моделі, а врешті отримані результати порівнюються, щоб отримати найкращу модель для майбутніх програм прогнозування. Для отримання більш детальної інформації щодо демонстрації покрокової процедури реалізації вилучення та вибору ознак можна звернутися до [24-30] відповідно.

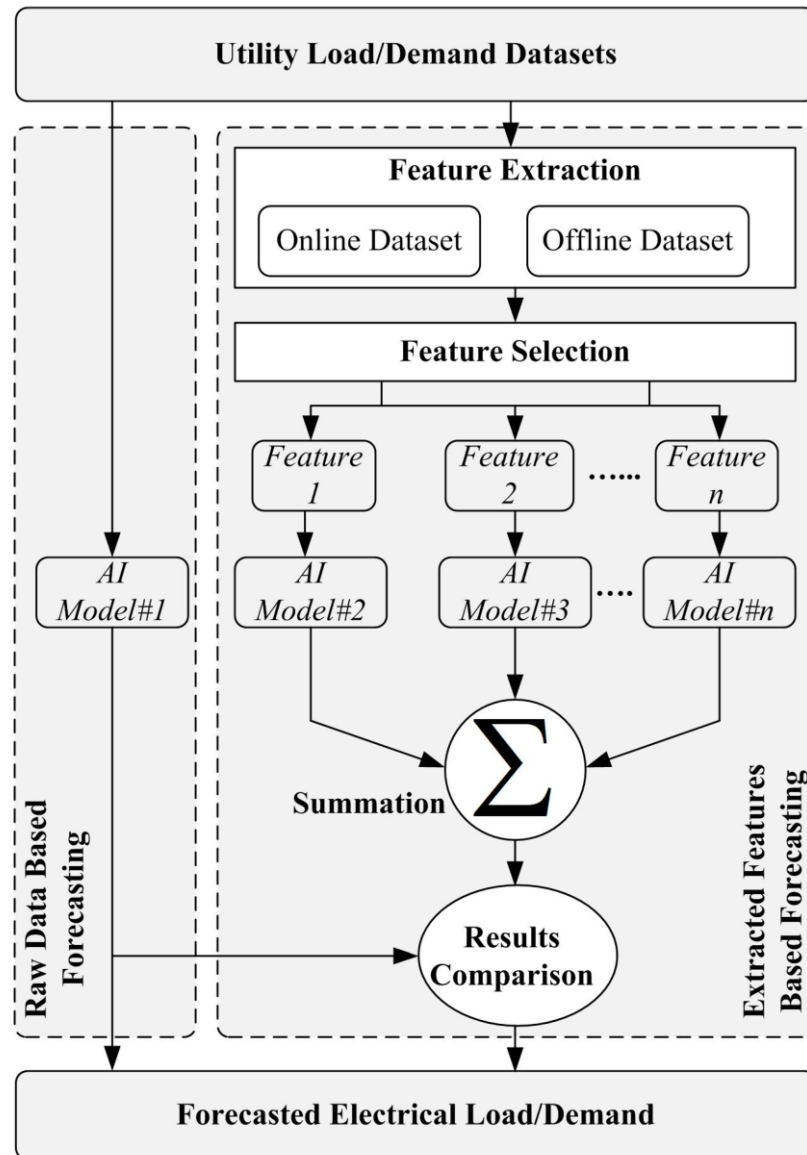


Рисунок 2.1 – Пропонований підхід для прогнозування навантаження

2.1 Коротка інформація про набори даних для експериментальної демонстрації

Прогноз короткого навантаження в основному залежить від погодних умов і попередніх історичних даних попиту. У цій роботі використано три набори даних. Перший набір даних, пов'язаний із історичним зареєстрованим попитом на електроенергію, отримано від незалежного оператора системи електроенергії (IESO) [31]. Ці показники попиту представляють попит на

електроенергію в Канаді. Другий набір даних пов'язаний із погодними умовами, отриманий від Canadian Climate Data – Environment Canada [32]. Величезні зареєстровані дані, включаючи температуру, температуру точки роси, вологість та інші, отримані в наборі даних 2. Третій набір даних також був отриманий від незалежного оператора електроенергетичної системи [33], і він містить погодинні ціни на енергію Онтаріо (НОЕР). Ціни на енергоносії відіграють ключову роль у впливі на моделі навантаження [34]. Оскільки набір даних для запиту досить великий, генерується випадкова вибірка, що містить 200 щогодинних показань із набору даних 1. Потім інші змінні в решті наборів даних відображаються в цій погодинній вибірці. Для ілюстрації, якщо 50-ту годину вибрано випадковим чином із набору даних 1, тоді всі змінні прогнозів у кожному наборі даних у 50-й годині будуть вибрані та зіставлені з цією годиною, щоб представити перше показання в новому наборі даних і так далі. Таким чином, новий набір даних, який використовуватиметься в аналізі, містить 200 вимірювань, випадково вибраних як об'єктивні. Ця вибірка була відібрана випадковим чином за допомогою пакета RStat [35]. Оскільки модель збирається спрогнозувати навантаження на короткий проміжок часу, погодинна потреба в електроенергії вибирається як залежна змінна (вихід моделі), тоді як інші змінні, показані в таблиці 2.1, є незалежними змінними (вхідні дані моделі). Усі змінні є числовими. Варто зазначити, що предиктор PW (навантаження попереднього тижня за той самий час) неявно включає в себе, чи буде ця година в будні чи вихідні. Таким чином, це дало перевагу моделі для перенесення категоріальних предикторів у числові предиктори, що полегшило реалізацію моделі. Крім того, характеристика набору даних наведена в таблиці 2.2 і представлена графічно на рисунках 2.2-2.7.




Рисунок 2.2 – Інформація про дані навантаження в МВт

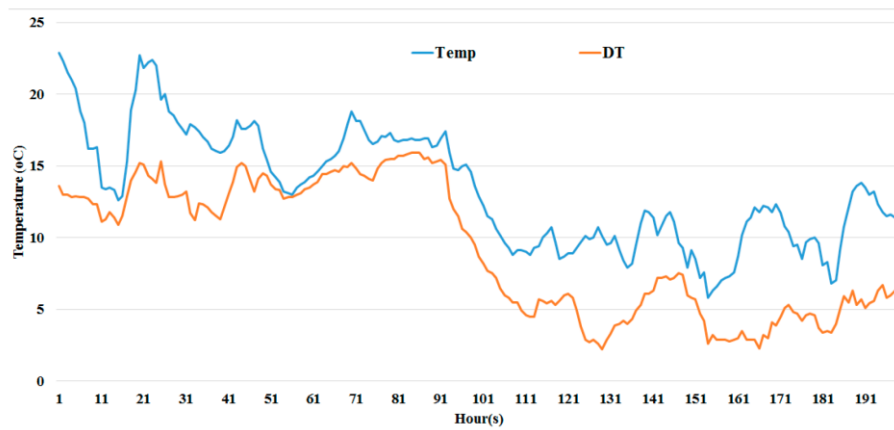


Рисунок 2.3 – Інформація про температуру (°C)




Рисунок 2.4 – Дані про вологість (%)




Рисунок 2.5 – Інформація про швидкість вітру (км/год)




Рисунок 2.6 – Інформація про тиск зовнішнього повітря (кПа)




Рисунок 2.7 – Інформація про погодинну ціну на електроенергію

Таблиця 2.1 – 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)
ONEP	Погодинна ціна електроенергії (центи/кВт-год)

Таблиця 2.2 – Характеристики набору даних

Змінні	Статистична інформація для даних			
	Мін	Середній	Макс	STD
1	2	3	4	5
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

Продовження таблиці 2.2

1	2	3	4	5
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
ONER: погодинна ціна електроенергії (цент/кВт-год)	9.8	34,62302	103,39	12,51388

Підготовка даних і кореляційний аналіз

Процедура підготовки даних для прогнозних моделей є звичайною на більшості етапів, особливо на етапі підготовки. Необхідно чітко розрізняти незалежні змінні та залежні змінні. Всі дані в цій роботі числові. Потім викиди перевіряються перед застосуванням будь-яких методів на основі машинного навчання. Q-тест Діксона [36] застосовується для виявлення викидів у наборі даних. У тесті Dixon Q передбачається, що всі значення даних походять від однієї нормальної популяції. Альтернативна гіпотеза полягає в тому, що найменші чи найбільші значення викидаються на рівні 5% значущості.

Для множинної лінійної регресії спочатку застосовується ступінчаста регресія, щоб враховувати лише статистично значущі предиктори з

достовірністю 95%. Необхідно провести описовий аналіз, особливо коефіцієнта асиметрії (КА) і коефіцієнта ексцесу (КЕ). Коли CS коливається від -0,5 до 0,5, це означає, що дані є відносно симетричними. Умови застосування множинної лінійної регресії слід перевірити перед застосуванням MLR, як зазначено раніше. Було виявлено, що умови для застосування моделі MLR, такі як нормальність розподілу змінних і лінійний зв'язок між вихідною змінною та предикторами, не виконуються, тому ми використовували MLR з логарифмічним перетворенням. Нарешті, у розробці моделі використовувалась перехресна перевірка з відпусткою (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 пояснюється тим, що предиктор, який не вважався значущим у моделі регресії, може бути значущим у моделях на основі машинного навчання.

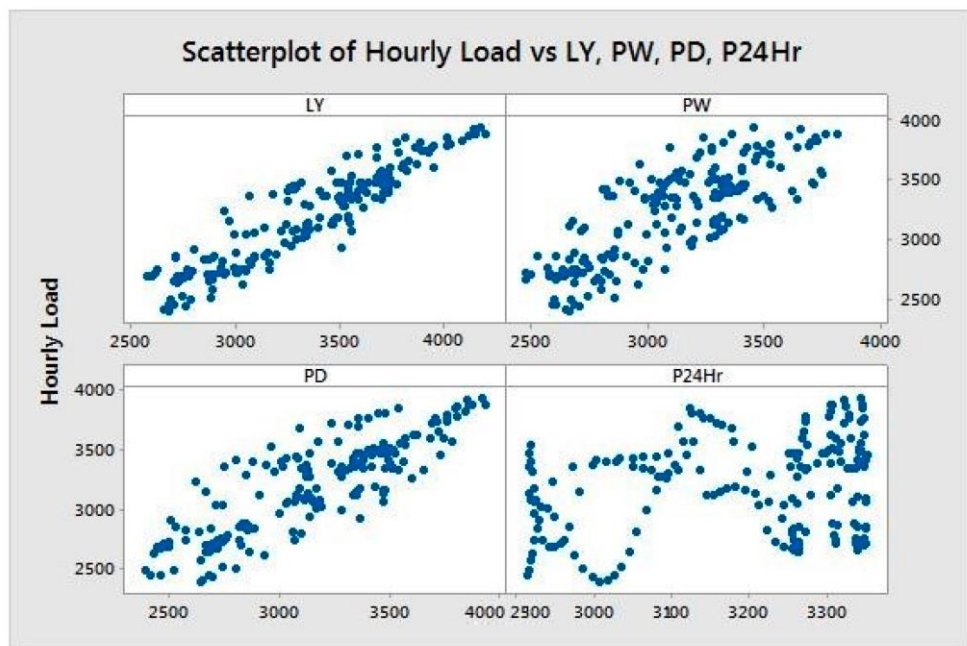


Рисунок 2.8 – Зв'язки між погодинним навантаженням і незалежними змінними LY, PW, PD і P24Hr

Варто зазначити, що три 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 2.8 показано зв'язки між погодинним навантаженням і незалежними змінними LY, PW, PD і P24Hr.

2.2 Методи прогнозування навантаження

Прогноз короткого завантаження в основному залежить від погодних умов і попередніх історичних даних попиту. У цьому документі використано три набори даних. Перший набір даних, пов'язаний із історичним зареєстрованим попитом на електроенергію, отримано від незалежного оператора системи електроенергії (IESO) [35].

2.2.1 Глибока нейронна мережа (DNN)

У DNN CNN є типом ANN, який є найбільш реалізованою технікою. Але CNN обмежується потоком спільного використання параметрів і даних послідовності. Після цього для подолання цих проблем вводиться RNN. У той же час RNN має обмежену пам'ять для зберігання операцій кожного етапу та страждає від проблем градієнта [25-27], таких як зникнення або вибух тощо. Щоб вирішити ці проблеми, була сформульована вдосконалена версія RNN, LSTM, 1997 р. [32]. LSTM також працює на основі послідовної структури з 4 станів. У цьому дослідженні розроблено модифікований LSTM, який може адаптувати індуктивне зміщення для компенсації відсутніх випадків. Модифікована LSTM разом із стандартною архітектурою LSTM представлена на рисунку 2.9. Можна звернутися до [25] для математичної реалізації для більш детальної інформації. Реалізація прогнозування часових рядів на основі DNN включає наступні кроки:

- завантаження набору даних;
- формулювання файлу даних для навчання та тестування;
- стандартизація набору даних для навчання та тестування для кращої

відповідності розбіжностям;

- визначити мережеву архітектуру DNN (тобто прихований блок, рівні, параметр навчання, поріг, швидкість навчання, метод пошуку, кількість епох тощо);
- навчання моделі DNN (за допомогою функції `trainNetwork`);
- прогноз майбутніх кроків у часі (за допомогою функції `predictAndUpdateState`);
- оновлення стану мережі DNN за допомогою спостережуваних значень.

Для отримання більш детальної інформації про реалізацію LSTM можна звернутися до [25, 37].




Рисунок 2.9 – Модифіковане представлення архітектури LSTM разом зі стандартною архітектурою LSTM

2.2.2 Штучна нейронна мережа (ШНМ)

Штучна нейронна мережа – це тип машинного навчання, який використовує біологічну нейронну мережу як джерело натхнення для навчання [38, 39]. Критичною точкою використання ШНМ є оцінка математичної функції, яка спирається на величезну кількість даних із неописаною поведінкою. Він складається з достатньої кількості взаємопов'язаних нейронів, які фіксують вхідні параметри та направляють їх

у алгоритм навчання для обчислення вихідних значень. Багатошаровий перцептрон (MLP) є механізмом прямої дії і є найбільш часто використовуваною моделлю серед моделей ШНМ [40, 41]. Основною функцією моделі MLP є призначення номеру групи входів відповідним вихідним вузлам. Судячи з назви, MLP має багато рівнів, які повністю пов'язані між собою в спрямованому графічному представленні. Функція активації потрібна для роботи всіх вузлів, за винятком вузла введення, ця функція є здебільшого нелінійною функцією, а в деяких випадках є функція лінійної активації. Важливо зазначити, що техніку зворотного поширення, один із алгоритмів навчання під наглядом, можна використовувати для навчання мережі в багатошаровій перцептрон ШНМ.

Як правило, N шарів вказує на те, що існує N невихідних рівнів блоків обробки та N шарів ваг, оскільки вхідний рівень виключено, як зазначено раніше. Рисунок 2.10 є прикладом багаторівневого MLP. Взаємозв'язки між цими шарами описуються такими рівняннями:

$$out_n^{(2)} = f^{(2)} \left(\sum_{j=1}^z out_j^{(1)} w_{jn}^{(2)} \right), \quad (2.1)$$

$$out_j^{(1)} = f^{(1)} \left(\sum_{i=1}^t out_i^{(0)} w_{ij}^{(1)} \right), \quad (2.2)$$

$$out_i^{(0)} = in_i, \quad (2.3)$$

де f – функція активації, w – ваговий коефіцієнт, z – кількість нейронів у прихованому шарі, а t – загальна кількість входів у першому шарі.

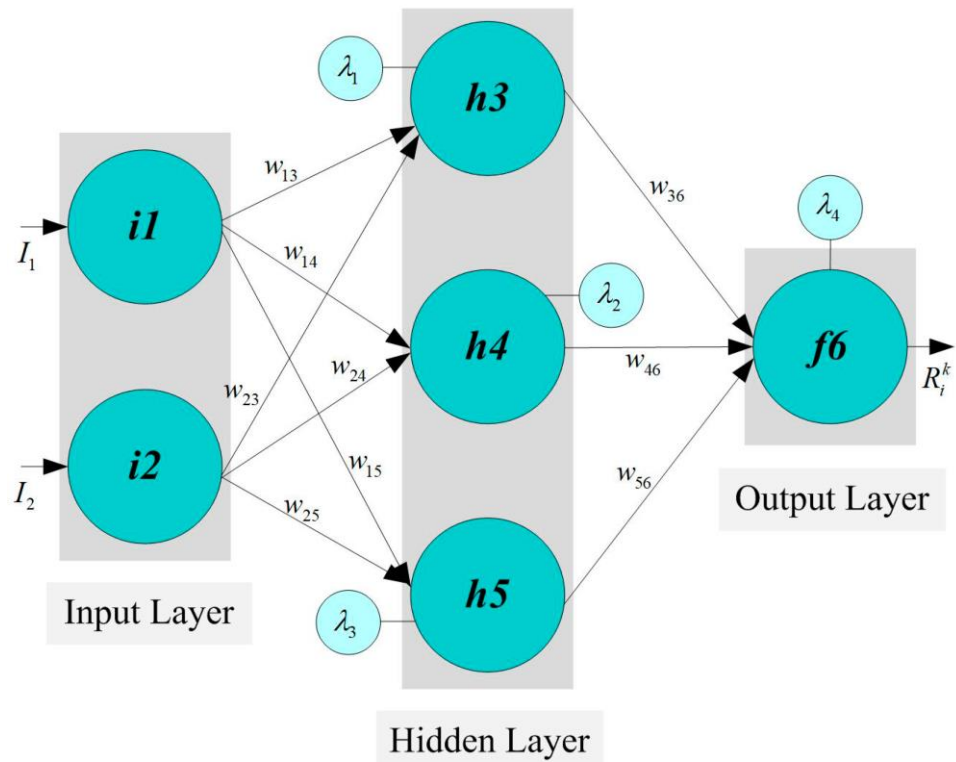


Рисунок 2.10 – Архітектура ШНМ

Нелінійні функції активації в MLP забезпечують гнучкість моделі для того, щоб фіксувати 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). Гіперболічний тангенс коливається від -1 до 1, а логістична функція – від 0 до 1. Кожен вузол з'єднується з іншим вузлом на наступному рівні за допомогою вагового коефіцієнта, і ці коефіцієнти підсумовуються за такою формулою:

$$w_{in} = \sum_{j=1}^z w_{ij}^{(1)} w_{jn}^{(2)} \quad (2.4)$$

Навчання моделей нейронної мережі прогнозуванню споживання електроенергії можна проводити офлайн або онлайн. Офлайн-навчання нейронної мережі залежить від набору вводу-виводу, підготовленого для вивчення нейронної мережі, і використання нейронної мережі з даними поза діапазоном навчання може призвести до помилкових результатів. Використання онлайн-навчання змушує мережу адаптуватися до змін у динаміці системи. Дані, зібрані для онлайн-навчання, можуть містити неправильні дані через помилки датчика. Мережа реагує на погані дані та виробляє вихід, який ставить під загрозу роботу всієї системи, і це головний фактор, який обмежує використання нейронної мережі онлайн-додатками на практиці. У цій роботі ШНМ використовується як офлайн-додаток для прогнозування наступних 24-годинних навантажень і погодинних навантажень наступного тижня.

2.2.3 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 [22, 27]. Насправді дерево рішень — це шаблон класифікації для навчених підмножин або об'єктів, у яких перевіряються значення властивостей цих об'єктів [22]. Структура дерева рішень починається з першого або початкового вузла і закінчується на наступних вузлах. Властивість кожного вузла в дереві рішень оцінюється за допомогою методології посилення нижче. Процедури дерева рішень можна підсумувати такими етапами:

А – Початковий вузол вибрано та присвоєно значенню дискреційного атрибута А.

В – Визначається граничне значення А і обчислюється ентропія розподілу, викликана значенням А; після цього буде обрано мінімальний.

С – 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.

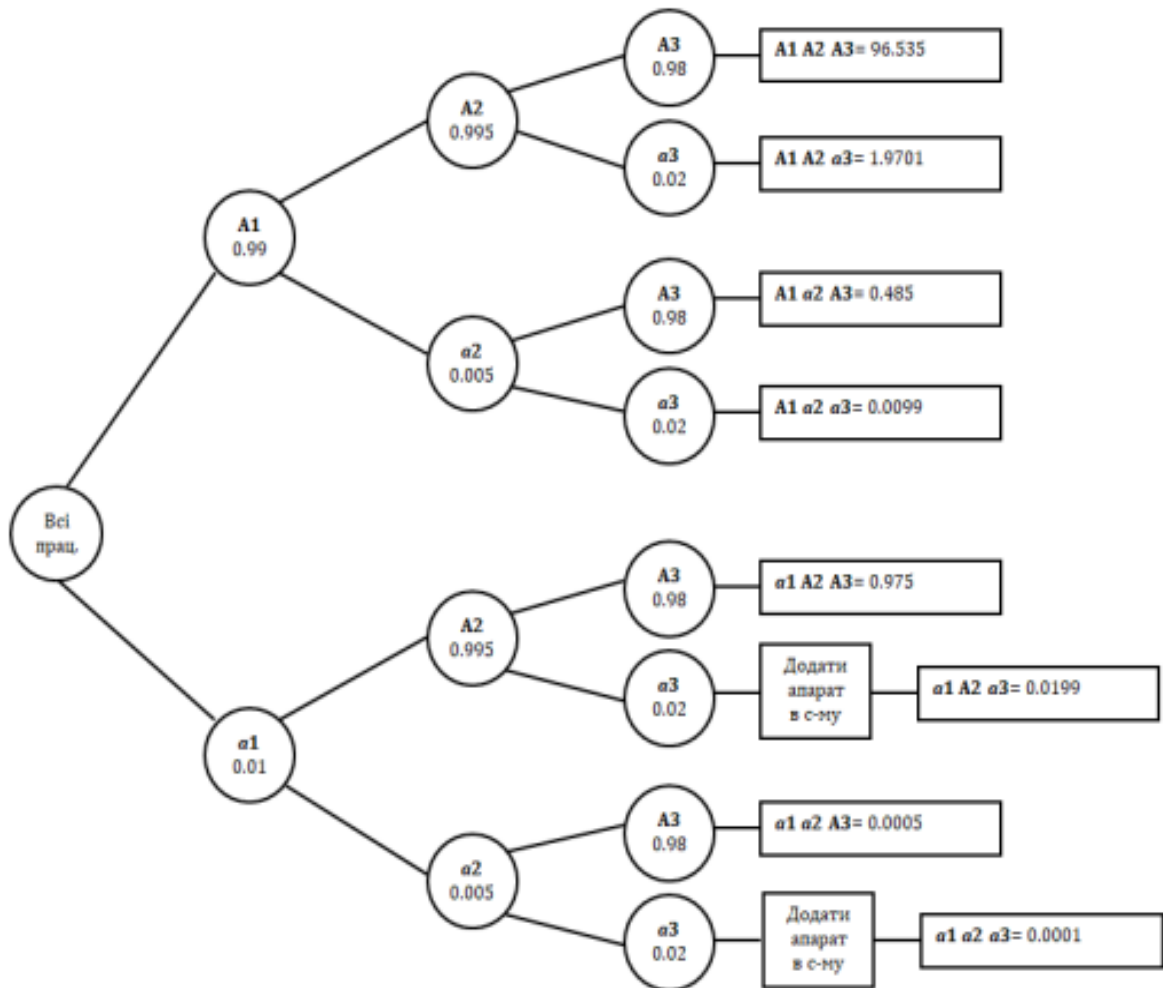


Рисунок 2.11 – Дерево рішень

2.3 Критерії ефективності моделі

Під час аналізу літературних джерел було розглянуто кілька критеріїв ефективності для оцінки ефективності прогнозних моделей.

Відносна похибка середньої величини (Mean magnitude relative error MMRE), яка є середнім значенням залишкової похибки за фактичним значенням, є дуже популярним критерієм ефективності, але його критикували, оскільки він упереджений і підходить для моделей, які недооцінюють. Для цього 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.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i(t) - \hat{y}_i(t))^2}{\sum_{i=1}^n (y_i(t) - \bar{y}_i(t))^2}, \quad (2.5)$$

$$MAR = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i(t) - \hat{y}_i(t)| \quad (2.6)$$

Щоб перевірити, чи ці три моделі статистично відрізняються чи ні, реалізовано статистичні тести (тобто ARIMA та метод Монте-Карло). Спочатку перевіряється, чи виконуються такі умови, як розподіл даних і значення дисперсії для використання параметричних тестів. Якщо результати випробувань виявляють, що ці умови не були виконані, автор використовував непараметричний критерій Крускала-Уолліса для порівняння різних моделей. Крім того, результати порівняння моделей аналізуються за допомогою пост-хок тестів, які дозволяють ідентифікувати відмінності між конкретними парами моделей. Це забезпечує більш глибокий аналіз продуктивності моделей за обраними показниками.

3 РЕЗУЛЬТАТИ ЕКСПРЕМЕНТІВ

Дані відфільтровуються від викидів за допомогою Q-тесту Діксіона, і використовуються чисті набори даних. Лише дев'ять точок даних виявляються як викиди. Рисунок 2.8 (діаграма кореляції) показує зв'язок між деякими предикторами та відповіддю. З цих цифр можна чітко побачити, що залежність між погодинним навантаженням і минулорічним навантаженням за той самий час (LY) є лінійною. Крім того, навантаження за попередній тиждень (PW), навантаження за попередній день (PD) і середнє навантаження за 24 години до цього часу (P24H) знаходяться в лінійній залежності від погодинного навантаження (змінна відповіді).

3.1 Прогнозування на основі DNN та його перевірка

На основі моделі DNN, представленої в розділі 2, у цьому розділі було проаналізовано три окремі приклади. Ці приклади: прогнозування на годину, прогнозування на день і прогнозування на тиждень. Рисунки 3.1-3.12 показують аналіз продуктивності DNN для прикладу 1, прикладу 2 та приклад 3 відповідно. Представлення прогресу навчання для погодинного, денного та тижневого прогнозування з використанням DNN на основі LSTM представлено на рисунку 3.1, рисунку 3.5 та рисунку 3.9 відповідно, де показано всі індекси ефективності (наприклад, межа перевірки, тип навчання, час початку) , час закінчення, епоха, ітерація, максимальна ітерація, тип обробки, швидкість навчання тощо) DNN. У цьому дослідженні для моделі DNN використовуються такі параметри: numFeatures = 1; numResponses = 1; numHiddenUnits = 200; шари = [...sequenceInputLayer (numFeatures), lstmLayer (numHiddenUnits), fullyConnectedLayer (numResponses), regressionLayer]; trainingOptions ('adam', ...'MaxEpochs', 250, ...'GradientThreshold', 1, ...'InitialLearnRate', 0,005, ...'LearnRateSchedule', 'piecewise',

...'LearnRateDropPeriod', 125, ...'LearnRateDropFactor', 0,2, ... 'Verbose', 0, ...'Plots', 'training-progress').




Рисунок 3.1 – Представлення прогресу навчання для погодинного прогнозування за допомогою DNN на основі LSTM

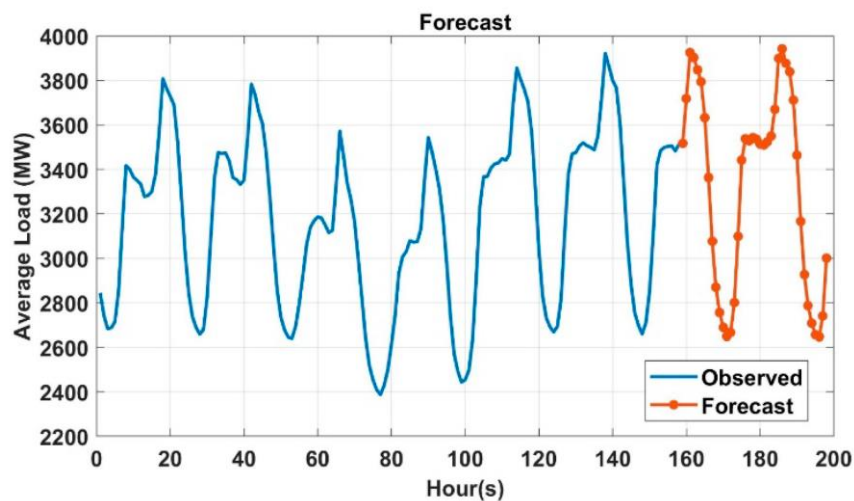


Рисунок 3.2 – Погодинний прогноз майбутніх часових рядів

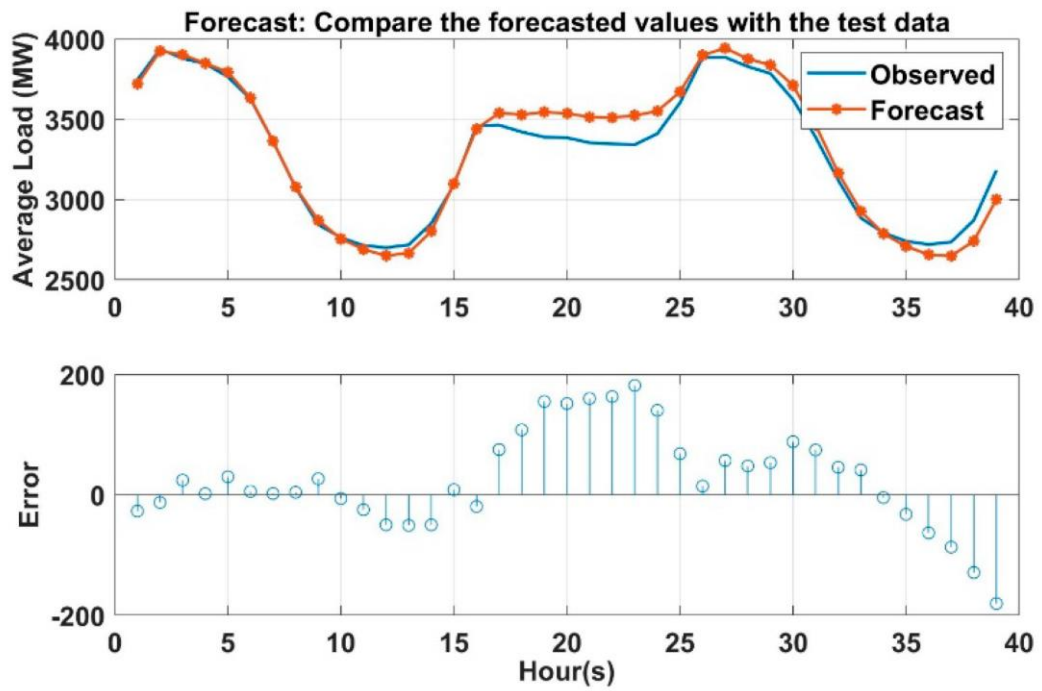


Рисунок 3.3 – Порівняння погодинного прогнозу майбутнього часового ряду з тестовими даними (спостережене значення)

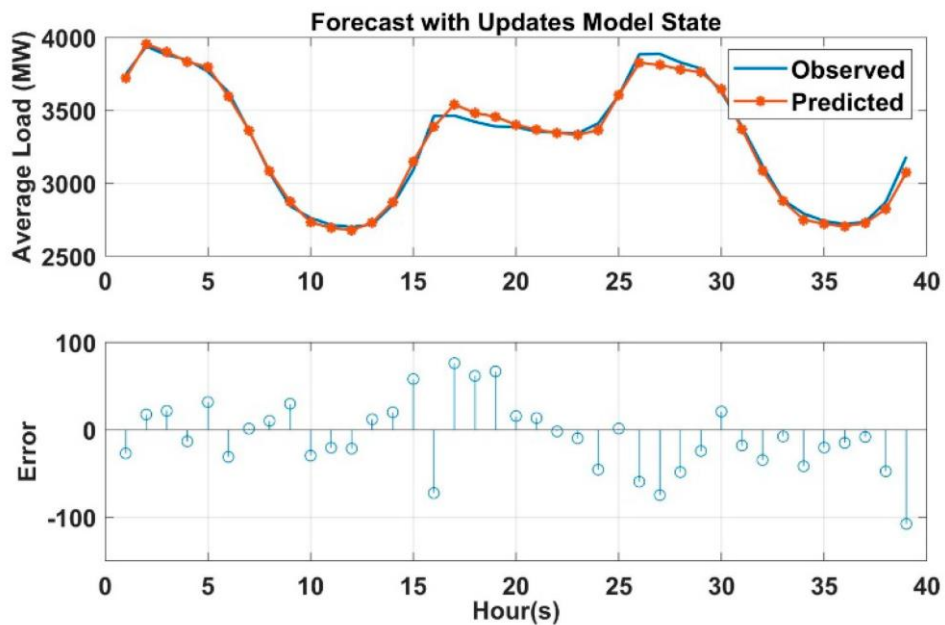


Рисунок 3.4 – Порівняння годинного прогнозу майбутніх часових рядів з використанням оновленої моделі DNN з тестовими даними (спостережуване значення)




Рисунок 3.5 – Представлення прогресу навчання для щоденного прогнозування за допомогою DNN на основі LSTM




Рисунок 3.6 – Денний прогноз майбутніх часових рядів




Рисунок 3.7 – Порівняння денного прогнозу майбутніх часових рядів із тестовими даними (спостережене значення)




Рисунок 3.8 – Порівняння щоденних прогнозних майбутніх часових рядів з використанням оновленої моделі DNN із тестовими даними (спостережуване значення)

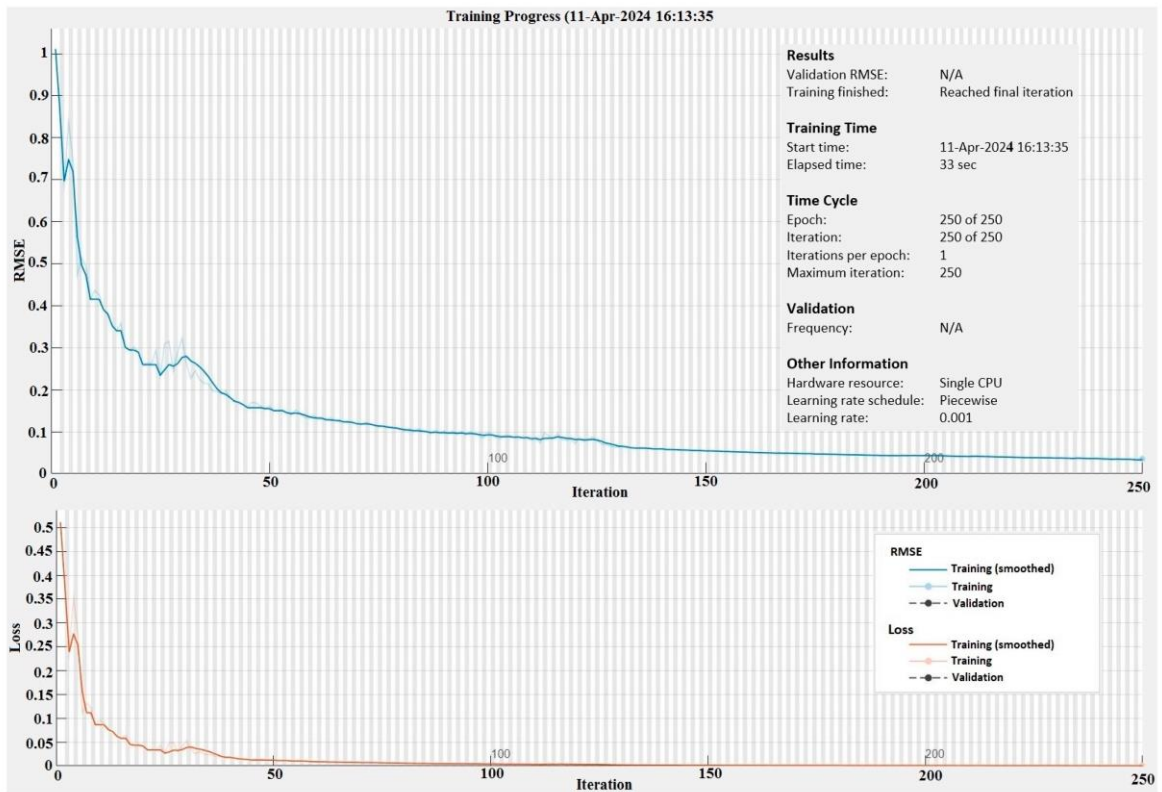


Рисунок 3.9 – Представлення прогресу навчання для тижневого прогнозування за допомогою DNN на основі LSTM




Рисунок 3.10 – Тижневий прогноз майбутніх часових рядів

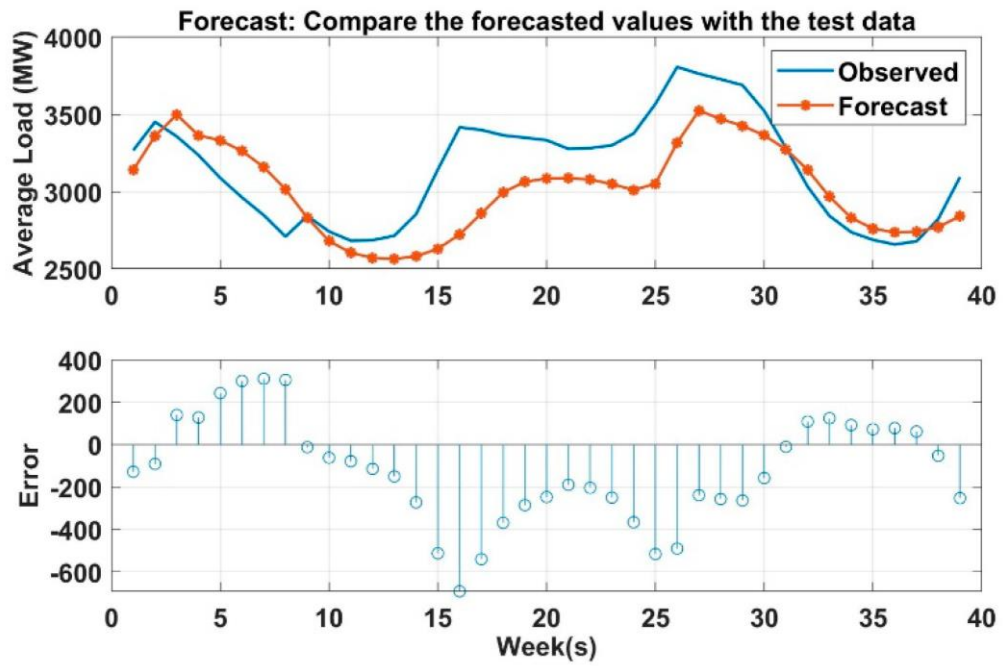


Рисунок 3.11 – Порівняння тижневого прогнозу майбутніх часових рядів із тестовими даними (спостережене значення)

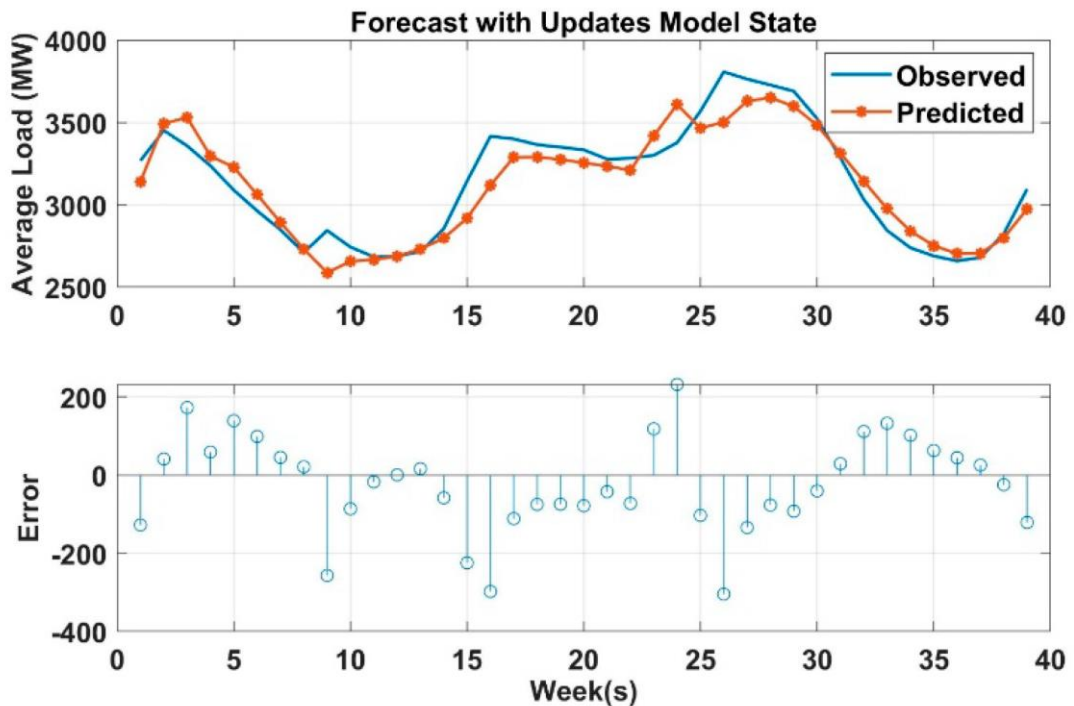


Рисунок 3.12 – Порівняння тижневого прогнозу майбутніх часових рядів з використанням оновленої моделі DNN з тестовими даними (спостережуване значення)

Правильне завершення процесу навчання для прогнозування майбутніх часових рядів за допомогою моделі DNN на основі LSTM представлено на рисунку 3.2, рисунку 3.6 і рисунку 3.10 для погодинних, щоденних і тижневих, відповідно. На цих рисунках сині лінії представляють прогнозовані (спостережувані) значення, а червоні лінії – прогнозовані майбутні значення. Порівняння прогнозованих майбутніх часових рядів за годину, день і тиждень із тестовими даними (спостережене значення) представлено на рисунку 3.3, рисунку 3.7 та рисунку 3.11 відповідно, які демонструють високу кореляцію між собою та значення помилки дуже мінімальне для всіх точок даних: лише від -200 до 200 .

Після цього аналізу модель DNN оновлюється спостережуваними новими значеннями, а результати порівнюються між прогнозом з оновленим станом моделі та спостережуваним значенням. На рисунках 3.4, 3.8, 3.12 показано порівняння прогнозованих майбутніх часових рядів за годину, день і тиждень з використанням оновленої моделі DNN із тестовими даними (спостережуване значення), що є більш прийнятним для обмеження продуктивності.

Таблиця 3.1 – Демонстрація результатів на основі DNN з оновленням моделей DNN і без нього

Тип прогнозування	Демонстрація результатів фази тестування	
	Модель DNN	Оновлена модель DNN
Погодинний прогноз	11,58186	4,08530
Подобове прогнозування	16,93268	4,22537
Тижневе прогнозування	29,62043	15,00319

Відповідно до наведеного вище пояснення щодо отриманих результатів з використанням DNN та його оновленої версії, порівняльна демонстрація наведена в таблиці 3.1, яка показує демонстрацію результатів під час умов фази тестування для всіх випадків прогнозування навантаження. З

порівняння зрозуміло, що запропоновані результати на основі DNN прийнятні для подальшого впровадження на фактичному сайті.

3.2 Прогнозування на базі ANN

Для ШНМ використовується багат шаровий перцептрон. Є один прихований шар. Теоретично один прихований шар, а також два шари з достатньою кількістю прихованих нейронів здатні апроксимувати будь-яку безперервну функцію, і вони широко використовуються та працюють дуже добре. Що стосується оптимального вибору прихованих нейронів, то немає певної узгодженої формули, і більшість дослідників в основному покладаються на експерименти. Однак існує кілька методів або емпіричних правил для вибору кількості прихованих нейронів [41]. Одне з них, яке було використано в цій роботі, стверджує, що кількість прихованих нейронів є сумою кількості входів і виходів, поділених на два. Інше емпіричне правило стверджує, що залежно від проблеми кількість прихованих нейронів становить від однієї третини кількості вхідних нейронів до, можливо, двох або трьох разів більше кількості вхідних нейронів. На основі цих методологій ми перевірили проблему двічі, з одним прихованим шаром і з двома прихованими шарами. Для одного прихованого шару було встановлено, що оптимальна кількість нейронів в одному прихованому шарі становить сім. Коли кількість прихованих нейронів перевищує сім, MAE збільшується. На рисунку 3.13 показана зміна MAE залежно від кількості прихованих вузлів. Швидкість навчання та імпульс становлять 0,3 та 0,2 відповідно. Перехресна перевірка Leave-one-out також використовується в нейронних мережах. Середній абсолютний залишок для одного прихованого шару становить 0,0558 кВт, а коефіцієнт детермінації R^2 покращено до 0,958. Крім того, продуктивність зі зміною прихованих шарів представлена на рисунку 3.14

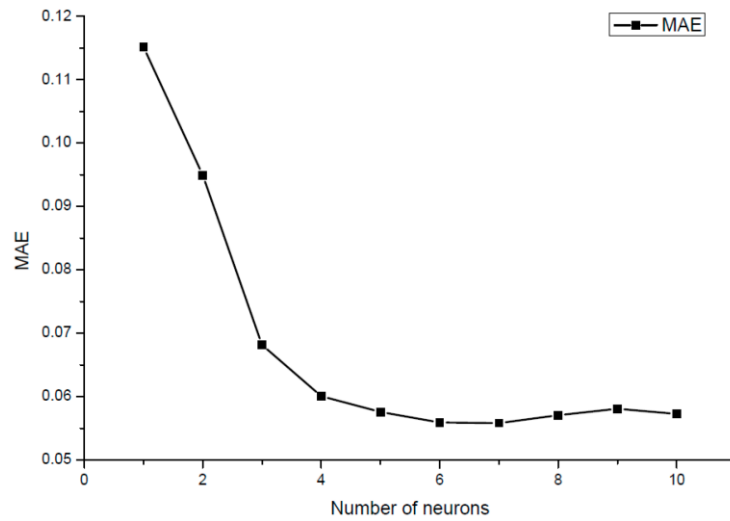


Рисунок 3.13 – Крива продуктивності МЕА в залежності від нейронів прихованого шару




Рисунок 3.14 – Крива продуктивності МЕА проти прихованих шарів

У випадку подвійних прихованих шарів експерименти показали, що оптимальна кількість прихованих нейронів, яка дає мінімальний МЕА, становить вісім нейронів у першому шарі та шість нейронів у другому шарі, як показано на рисунку 2.6. Середня абсолютна похибка становить 0,051 кВт, а коефіцієнт детермінації R^2 становить 0,966.

3.3 Прогнозування на основі DT

Для тих самих даних, що використовуються в DNN, ШНМ, інструмент прогнозування на основі дерева рішень використовується для прогнозування погодинного навантаження. Оптимальною кількістю правил, які мінімізують середню абсолютну похибку, виявилось 12 правил. Таким чином, дерево рішень має 12 правил, що означає, що ми маємо 12 лінійних моделей, які можуть прогнозувати або представляти поведінку короткострокового попиту на електроенергію. Кожне правило описано в таблиці 3.2. Коефіцієнти кожного предиктора в кожному правилі зведені в таблицю 3.3. Середній абсолютний залишок, отриманий з моделі дерева рішень, становить 0,091 кВт, що краще, ніж лінійна регресія. Коефіцієнт детермінації R^2 становить 0,904.

Таблиця 3.2 – Характеристики правила

Правило №	Характеристики правила
1	$LY \leq 2889, P24Hr \leq 3039,3, Temp \leq 18$
2	$LY \leq 2889, P24Hr \leq 3039,3, Temp > 18$
3	$LY \leq 2889, P24Hr > 3039,3$
4	$LY > 2889, AP \leq 100, PD \leq 2758,2$
5	$LY > 2889, AP \leq 100, PD > 2758,2$
6	$LY > 2889, AP > 100, P24Hr \leq 3017,2$
7	$LY > 2889, AP > 100, P24Hr > 3017,2$
8	$LY \leq 3584, AP \leq 99,9$
9	$LY \leq 3584, AP > 99,9$
10	$LY > 3584, AP \leq 100$
11	$LY > 3584, AP > 100$
12	$LY > 3742$

Таблиця 3.3 – Коефіцієнти кожного предиктора в кожному правилі

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

3.4 Порівняння та підтвердження результатів

З таблиці 3.4 видно, що модель DNN перевершує інші моделі на основі критеріїв MAR і R^2 .

Таблиця 3.4 – Порівняння між DNN, ШНМ і дерево рішень

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

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. Усі дослідження проводилися в середовищі WEKA на ноутбучі з процесором Intel (R) Core i5 і 4 ГБ оперативної пам'яті.

ВИСНОВКИ

Прогнозування навантаження в енергосистемі є дуже важливим повсякденним обов'язком у відділі експлуатації. Багато видів діяльності в енергосистемі (або плануванні енергосистеми) використовували вихідні дані моделей прогнозування навантаження як вхідні дані для своєї роботи. Наприклад, LF (на основі 1 тижня до 1 року) необхідний для планування технічного обслуговування. Подібним чином LF (на основі від 1 хвилини до 1 тижня) необхідний для аналізу зобов'язань одиниць (UCA), економічного аналізу диспетчерського потоку навантаження (ELD-FA) і автоматичного керування генерацією та планування (AGCS). Тому дуже важливо побудувати точну та ефективну прогностичну модель для впорання з невизначеністю, спричиненою коливаннями навантаження. У кваліфікаційній роботі створено три прогностні моделі для прогнозування навантаження електроенергії на короткостроковий період (тобто від 24 годин до одного тижня) для задоволення рівноваги попиту та пропозиції, що дуже корисно для планування технічного обслуговування, UCA, ELD-FA, AGCS і PS динамічний аналіз. Ці моделі доводять свою ефективність і точність прогнозування навантаження. У цій роботі використовуються DNN, штучна нейронна мережа та прогнозування на основі дерева рішень. Продуктивність DNN також перевіряється на основі методу ARIMA та МС. Як показано в результатах, DNN на основі LSTM має вищий коефіцієнт детермінації R^2 серед усіх моделей і має найнижчий середній абсолютний залишок. Однак ANN потребує більше часу для створення та навчання моделей порівняно з іншими. Алгоритм передбачення на основі дерева рішень має R^2 , що дорівнює 0,9, що нижче, ніж ШНМ. Середній абсолютний залишок моделі дерева рішень нижчий за MLR і вищий за ШНМ. Найнижче значення R^2 порівняно з іншим для множинної логарифмічної лінійної регресії, і воно також має вищий MAR. Однак щодо часу, необхідного для розробки моделі,

DNN є дуже швидким порівняно з ШНМ і DT. Загалом кажучи, у сфері великих енергосистем прийнятно мати помилки в кілька кіловат у прогнозованому навантаженні, оскільки загальне навантаження вимірюється мегаватами або гігаватами, і можна побачити, що відмінності між MAR є відносно невеликими. Після проведення непараметричного тесту Крускала–Уолліса можна зробити висновок, що існує статистично значуща різниця між усіма моделями на 5% рівні значущості. Ця робота також перевірена за допомогою методів стохастичних часових рядів, таких як ARIMA та моделювання МС, які також дуже корисні для короткострокового прогнозування. Цю роботу можна застосувати для прогнозування роботи мікромережі в енергетичній системі шляхом прогнозування як виробництва відновлюваних ресурсів, так і існуючого обсягу попиту, а також створюючи численні зв'язки між джерелами та попитом. Таким чином, алгоритми машинного навчання та регресійний аналіз забезпечують ефективну та досить точну оцінку попиту енергосистеми.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Корнієнко Є., Ляшенко О., Торба А. Метод керування системою генерації електроенергії з використанням бездротових технологій \\\ Сучасний стан наукових досліджень та технологій в промисловості. – 2023, – №2(24), – с. 80-89. doi: 10.30837/ITSSI.2023.24.080.
2. Грибовська В.А., Знайдюк В.Г. Метод прогнозування споживання електроенергії на основі штучних нейронних мереж. Проблеми інформатизації. Тези доповідей дванадцятої міжнародної НТК. – Баку: ІСУ АР; Харків: НТУ «ХПІ»; Харків: ХНУРЕ; Харків: НАУ «ХАІ»; Бельсько-Бяла: УТІГН, 2024. – 21-22 листопада 2024. – Том 2. – С. 88.
3. Feinberg, E.A.; Genethliou, D. Load forecasting. In Applied Mathematics for Restructured Electric Power Systems; Springer: Berlin/Heidelberg, Germany, 2005; pp. 269–285.
4. Amral, N.; Özveren, C.; King, D. Short term load forecasting using multiple linear regression. In Proceedings of the 42nd International Universities Power Engineering Conference, 2007 (UPEC 2007), Brighton, UK, 4–6 September 2007; pp. 1192–1198.
5. Papalexopoulos, A.D.; Hesterberg, T.C. A Regression-based approach to short-term system load forecasting. IEEE Trans. Power Syst. 1990,5, 1535–1547.
6. Song, K.-B.; Baek, Y.-S.; Hong, D.H.; Jang, G. Short-term load forecasting for the holidays using fuzzy linear regression method. IEEE Trans. Power Syst. 2005, 20, 96–101.
7. Heinemann, G.; Nordmian, D.; Plant, E. The relationship between summer weather and summer loads—A regression analysis. IEEE Trans. Power Appar. Syst. 1966, 11, 1144–1154.
8. Hagan, M.T.; Behr, S.M. The time series approach to short term load forecasting. IEEE Trans. Power Syst. 1987, 2, 785–791.
9. Al-Hamadi, H.; Soliman, S. Short-term electric load forecasting based on

kalman filtering algorithm with moving window weather and load model. *Electr. Power Syst. Res.* 2004, 68, 47–59.

10. Gupta, P.; Yamada, K. Adaptive short-term forecasting of hourly loads using weather information. *IEEE Trans. Power Appar. Syst.* 1972, 5, 2085–2094.

11. Krogh, B.; de Llinas, E.; Lesser, D. Design and implementation of an on-line load forecasting algorithm. *IEEE Trans. Power Appar. Syst.* 1982, 9, 3284–3289.

12. Park, D.C.; El-Sharkawi, M.; Marks, R.; Atlas, L.; Damborg, M. Electric load forecasting using an artificial neural network. *IEEE Trans. Power Syst.* 1991, 6, 442–449.

13. Bakirtzis, A.G.; Petridis, V.; Kiartzis, S.; Alexiadis, M.C. A neural network short term load forecasting model for the greek power system. *IEEE Trans. Power Syst.* 1996, 11, 858–863.

14. AlFuhaid, A.; El-Sayed, M.; Mahmoud, M. Cascaded artificial neural networks for short-term load forecasting. *IEEE Trans. Power Syst.* 1997, 12, 1524–1529.

15. Bakirtzis, A.; Theocharis, J.; Kiartzis, S.; Satsios, K. Short term load forecasting using fuzzy neural networks. *IEEE Trans. Power Syst.* 1995, 10, 1518–1524.

16. Daneshdoost, M.; Lotfalian, M.; Bumroonggit, G.; Ngoy, J. Neural network with fuzzy set-based classification for short-term load forecasting. *IEEE Trans. Power Syst.* 1998, 13, 1386–1391.

17. Chen, S.-T.; Yu, D.C.; Moghaddamjo, A.R. Weather sensitive short-term load forecasting using nonfully connected artificial neural network. *IEEE Trans. Power Syst.* 1992, 7, 1098–1105.

18. Czernichow, T.; Piras, A.; Imhof, K.; Caire, P.; Jaccard, Y.; Dorizzi, B.; Germond, A. Short term electrical load forecasting with artificial neural networks. *Eng. Intell. Syst. Electr. Eng. Commun.* 1996, 4, 85–99.

19. Drezga, I.; Rahman, S. Short-term load forecasting with local ann predictors. *IEEE Trans. Power Syst.* 1996, 14, 844–850.

20. Ho, K.-L.; Hsu, Y.-Y.; Yang, C.-C. Short term load forecasting using a multilayer neural network with an adaptive learning algorithm. *IEEE Trans. Power Syst.* 1992, 7, 141–149.

21. Ding, Q. Long-term load forecast using decision tree method. In *Proceedings of the 2006 IEEE PES Power Systems Conference and Exposition (PSCE'06)*, Atlanta, GA, USA, 29 October 2006; pp. 1541–1543.

22. Salgado, R.M.; Lemes, R.R. A hybrid approach to the load forecasting based on decision trees. *J. Control. Autom. Electr. Syst.* 2013, 24, 854–862.

23. Stensrud, E.; Myrtveit, I. Human performance estimating with analogy and regression models: An empirical validation. In *Proceedings of the Fifth International Software Metrics Symposium*, Metrics, Bethesda, MD, USA, 20–21 November 1998; pp. 205–213.

24. Malik, H.; Fatema, N.; Iqbal, A. *Intelligent Data-Analytics for Condition Monitoring: Smart Grid Applications*, 1st ed.; Elsevier: Amsterdam, The Netherlands, 2021; ISBN 978-0-323-85510-5.

25. Iqbal, A.; Malik, H.; Joshi, P.; Agrawal, S.; Bakhsh, F.I. *Meta Heuristic and Evolutionary Computation: Algorithms and Applications*, 1st ed.; Springer Nature: Berlin/Heidelberg, Germany, 2020; ISBN 978-981-15-7571-6.

26. Malik, H.; Chaudhary, G.; Srivastava, S. Digital transformation through advances in artificial intelligence and machine learning. *J. Intell. Fuzzy Syst.* 2021, 42, 615–622.

27. Fatema, N.; Malik, H. Data-Driven Occupancy Detection Hybrid Model Using Particle Swarm Optimization Based Artificial Neural Network. In *Metaheuristic and Evolutionary Computation: Algorithms and Applications; Studies in Computational Intelligence Series*; Springer: Singapore, 2020; pp. 283–297.

28. Arora, P.; Malik, H.; Sharma, R. Wind Energy Forecasting Model for Northern-Western Region of India Using Decision Tree and MLP Neural Network Approach. *Interdiscip. Environ. Rev.* 2018, 19, 13–20.

29. Fatema, N.; Malik, H.; Abd Halim, M.S. Hybrid Approach Combining EMD, ARIMA and Monte Carlo for Multi-Step Ahead Medical Tourism Forecasting. *J. Intell. Fuzzy Syst.* 2022, 42, 1235–1251.

30. Mykhailichenko, I., Ivashchenko, H., Barkovska, O., & Liashenko, O. (2022), "Application of Deep Neural Network for Real-Time Voice Command Recognition", In 2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek), P. 1–4. DOI: <https://doi.org/10.1109/KhPIWeek57572.2022.9916473>

31. Srivastava, S.; Malik, H.; Sharma, R. Intelligent tools and techniques for signals, machines and automation. *J. Intell. Fuzzy Syst.* 2018, 35, 4895–4899.

32. Saad, S.; Ishtiyaque, M.; Malik, H. Selection of Most Relevant Input Parameters Using WEKA for Artificial Neural Network Based Concrete Compressive Strength Prediction Model. In Proceedings of the 2016 IEEE 7th Power India International Conference (PIICON), Bikaner, India, 25–27 November 2016; pp. 1–6.

33. Martovytskyi V., Sievierinov O., Liashenko O., Koltun Y., Liashenko S., Kis V., Sukhoteplyi V., Nosyk A., Konov D., Yevstrat D. (2022). Devising an approach to the identification of system users by their behavior using machine learning methods // *EasternEuropean Journal of Enterprise Technologies*, 3 (117), 2022, pp. 23–34.

34. Filimonchuk T.V. Development of information technology of tasks distribution for GRID-systems using the GRASS simulation environment / T.V. Filimonchuk, M.O. Volk, I.V. Ruban, V.M. Tkachov // *Eastern-European Journal of Enterprise Technologies*. - Vol 3, No 9(81). - 2016. - Pp. 45-53.

35. Phstat Package. Available online: <http://wps.aw.com/phstat/>

36. Dean, R.; Dixon, W. Simplified statistics for small numbers of observations. *Anal. Chem.* 1951, 23, 636–638.

37. Malik, H.; Savita. Application of Artificial Neural Network for Long Term Wind Speed Prediction. In Proceedings of the 2016 Conference on Advances in Signal Processing (CASP), Pune, India, 9–11 June 2016; pp. 217–222

38. Malik, H.; Ahmad, W.; Kothari, D.P. *Intelligent Data-Analytics for Power and Energy Systems: Advances in Models and Applications*, 1st ed.; Springer Nature: Berlin/Heidelberg, Germany, 2022; ISBN 978-981-16-6080-1.

39. Yadav, A.K.; Malik, H.; Chandel, S.S. Application of Rapid Miner in ANN Based Prediction of Solar Radiation for Assessment of Solar Energy Resource Potential of 76 Sites in Northwestern India. *Renew. Sustain. Energy Rev.* 2015, 52, 1093–1106.

40. Chen, H.; Canizares, C.A.; Singh, A. Ann-based short-term load forecasting in electricity markets. In *Proceedings of the Power Engineering Society Winter Meeting, Columbus, OH, USA, 28 January–1 February 2001*; pp. 411–415.

41. M. Hunko, V. Tkachov, O. Liashenko and J. Rabčan, "Application Architecture For Obtaining Data From Scientometric Databases," 2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek), Kharkiv, Ukraine, 2022, pp. 1-4, doi: 10.1109/KhPIWeek57572.2022.9916398.