

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет
Кафедра

Комп'ютерної інженерії та управління
Комп'ютерних інтелектуальних технологій та систем

КВАЛІФІКАЦІЙНА РОБОТА

Пояснювальна записка

рівень вищої освіти

другий (магістерський)

Інтелектуальна комп'ютерна система аналізу та прогнозування
енергоспоживання
(тема)

Виконав:

студент II курсу, групи КІТМ-22-1

Владислав ПОЛОУС

(власне ім'я, прізвище)

Спеціальність 123 Комп'ютерна інженерія

(код і повна назва спеціальності)

Тип програми освітньо-професійна

(освітньо-професійна або освітньо-наукова)

Освітня програма Комп'ютерні
інтелектуальні технології

(повна назва освітньої програми)

Керівник проф. каф. КІТС Микола КОРАБЛЬОВ

(посада, власне ім'я, прізвище)

Допускається до захисту

Зав. кафедри

(підпис)

Олег РУДЕНКО

(власне ім'я, прізвище)

2023 р.

Харківський національний університет радіоелектроніки

Факультет	Комп'ютерної інженерії та управління
Кафедра	Комп'ютерних інтелектуальних технологій та систем
Рівень вищої освіти	другий (магістерський)
Спеціальність	123 Комп'ютерна інженерія
Тип програми	освітньо-професійна
Освітня програма	Комп'ютерні інтелектуальні технології

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

« _____ » _____ 202_ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові _____ Полоусу Владиславу Юрійовичу
(прізвище, ім'я, по батькові)

1. Тема роботи Інтелектуальні комп'ютерна система аналізу та прогнозування енергоспоживання

затверджена наказом по університету від " 03 " листопада 2023 р. № 1290Ст

2. Термін подання студентом роботи до екзаменаційної комісії 13.01.2024

3. Вхідні дані до роботи

1) історичний набір даних енергоспоживання;

2) побудова моделі для прогнозування енергоспоживання;

3) мова програмування – Python.

4. Перелік питань, що потрібно опрацювати в роботі

1) огляд предметної області;

2) аналіз предмету дослідження;

3) дослідження інтелектуальних систем прогнозування енергоспоживання;

4) дослідження традиційних методів прогнозування;

5) дослідження інтелектуальних методів прогнозування;

6) розробка інтелектуальної моделі прогнозування;

7) висновки.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій 16 слайдів

6. Консультанти розділів роботи и (п.6 включається до завдання за наявності консультантів згідно до наказу, зазначеному 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	Видача та узгодження теми проєкту	6.11-8.11	Виконано
2	Огляд стану проблеми та постановка задачі	9.11-23.11	Виконано
3	Аналіз літератури за напрямком роботи	23.11-30.11	Виконано
4	Аналіз інтелектуальних систем прогнозування	30.11-3.12	Виконано
5	Розробка інтелектуальної моделі	3.12-19.12	Виконано
6	Експериментальні дослідження	19.12-31.12	Виконано
7	Підготовка графічного матеріалу	31.01-15.01	Виконано
8	Перевірка виконаного проєкту керівником	15.01-22.01	Виконано
9	Захист проєкту	25.01	Виконано

Дата видачі завдання 06 листопада 2023 р.

Студент _____
(підпис)

Керівник роботи _____
(підпис) _____
(посада, ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 75 с., 23 рис., 8 табл., 1 дод., 27 джерел.

ПРОГНОЗУВАННЯ, ІНТЕЛЕКТУАЛЬНІ МОДЕЛІ, ІНТЕРВАЛИ ПРОГНОЗУВАННЯ, ЕНЕРГОСПОЖИВАННЯ, ІНТЕЛЕКТУАЛЬНА СИСТЕМА, РЕКУРЕНТНІ НЕЙРОННІ МЕРЕЖІ, ДОВГА КОРОТКОЧАСНА ПАМ'ЯТЬ, АВТОРЕГРЕСІЙНЕ ІНТЕГРОВАНЕ КОВЗНЕ СЕРЕДНЄ, PYTHON

Метою кваліфікаційної роботи є розробка інтелектуальної комп'ютерної системи аналізу та прогнозування енергоспоживання, що дозволить створити надійну та точну систему, яка допоможе покращити прогнозування споживання та збалансувати енергетичну систему країни.

Об'єктом дослідження є процеси енергоспоживання.

Предметом дослідження є методи та моделі аналізу та прогнозування енергоспоживання.

У роботі проведено комплексний аналіз предметної області, існуючих методів та підходів до прогнозування енергоспоживання. Розглянуто класифікацію інтервалів прогнозування, традиційні та інтелектуальні методи, проаналізовано сучасні системи прогнозування. Для вирішення поставленої задачі було проаналізовано та обрано LSTM метод прогнозування. Він може застосовуватися енергопостачальними компаніями для оптимізації процесів та підвищення ефективності енергосистеми.

ABSTRACT

Master's thesis: 75 pages, 23 figures, 8 tables, 1 appendice, 27 sources.

FORECASTING, INTELLIGENT MODELS, FORECASTING INTERVALS, ENERGY CONSUMPTION, INTELLIGENT SYSTEM, RECURRENT NEURAL NETWORKS, LONG SHORT-TERM MEMORY, AUTOREGRESSIVE INTEGRATED MOVING AVERAGE, PYTHON

The qualification work aims to develop an intelligent computer system for analysing and forecasting energy consumption, which will create a reliable and accurate system that will help improve consumption forecasting and balance the country's energy system.

The object of research is energy consumption processes.

The subject of the study is methods and models for analysing and forecasting energy consumption.

The paper provides a comprehensive analysis of the subject area and existing methods and approaches to forecasting energy consumption. The paper considers the classification of forecasting intervals and traditional and intelligent methods and analyses modern forecasting systems. To solve this problem, the LSTM forecasting method was analysed and selected. Energy supply companies can use it to optimise processes and improve the efficiency of the power system.

АНОТАЦІЯ

Полоус В. Ю. Інтелектуальна комп'ютерна система аналізу та прогнозування енергоспоживання. – Магістерська кваліфікаційна робота.

У магістерській кваліфікаційній роботі вирішену актуальну задачу прогнозування енергоспоживання.

Метою кваліфікаційної роботи є розробка інтелектуальної комп'ютерної системи аналізу та прогнозування енергоспоживання, що дозволить створити надійну та точну систему, яка допоможе покращити прогнозування споживання та збалансувати енергетичну систему країни.

Об'єктом дослідження є процеси енергоспоживання.

Предметом дослідження є методи та моделі аналізу та прогнозування енергоспоживання.

Наукова новизна полягає у тому, що у роботі представлено аналіз сучасних методів прогнозування енергоспоживання, що включає як традиційні статистичні, так і новітні інтелектуальні підходи. На основі цього аналізу було проаналізовано гібридні моделі, які поєднують різні методи для підвищення точності прогнозів. Розроблено інтелектуальну комп'ютерну систему для комплексного аналізу даних та прогнозування енергоспоживання. У магістерській роботі досліджується науково-прикладна задача створення інтелектуальної комп'ютерної системи прогнозування енергоспоживання.

Практична цінність отриманих результатів полягає у створенні програмного забезпечення на Python для автоматизації аналізу даних і прогнозування, що дозволяє підвищити точність прогнозів енергоспоживання та оптимізувати планування в енергетичній сфері.

У першому розділі було зроблено аналіз предметної області та літератури пов'язаних з цією роботою.

Детально розглянуто поняття інтелектуальної системи та проаналізовано її застосування в контексті аналізу і прогнозування енергоспоживання. Інтелектуальні

системи дозволяють ефективно обробляти великі обсяги даних, виявляти приховані закономірності та прогнозувати майбутні тенденції.

Також було здійснено класифікацію інтервалів прогнозу енергоспоживання. Для кожного типу прогнозування проаналізовано його переваги, недоліки та сфери застосування. Особливу увагу приділено аналізу традиційних методів прогнозування енергоспоживання, серед яких розглянуто регресійний аналіз, метод ковзного середнього, експоненційне згладжування. Висвітлено їхні можливості та обмеження.

Досліджено сучасні інтелектуальні методи прогнозування – штучні нейронні мережі, нечітку логіку, метод опорних векторів. Проаналізовано ключові особливості цих методів та їхні переваги порівняно з традиційними підходами.

Було розглянуто вплив зміни клімату на споживання енергії в житловому секторі, зокрема збільшення потреби в охолодженні та зменшення споживання енергії на опалення. Зазначається, що зміни в споживанні вимагають удосконалення методів прогнозування енергоспоживання з урахуванням динаміки клімату, а поєднання різних моделей може бути ефективним інструментом для довгострокового прогнозування, об'єднуючи кліматичні та соціально-економічні фактори. Особливий підрозділ присвячено аналізу існуючих комп'ютерних систем прогнозування енергоспоживання, зокрема EnergyPlus та SAS Energy Forecasting. Висвітлено їхні можливості, сфери застосування та обмеження.

На основі проведеного аналізу сформульовано чітку постановку задачі дослідження – розробити інтелектуальну комп'ютерну систему для аналізу і прогнозування енергоспоживання.

У другому розділі було описано процес проектування інтелектуальної комп'ютерної системи для аналізу та прогнозування енергоспоживання. Архітектура системи включає такі основні модулі, як набір даних, підготовка та аналіз даних, прогнозування за допомогою інтелектуальної моделі, аналіз результатів та результат прогнозування. Кожен модуль виконує конкретні функції, такі як збір необхідної інформації, підготовка та аналіз даних, використання алгоритмів машинного та глибокого навчання для прогнозування, оцінка продуктивності моделі та генерація прогнозів.

Першим кроком є вивчення початкового набору даних для отримання огляду структури. Далі проводиться конвертація даних до єдиної структури з встановленням часового індексу. Отриманий набір даних є основою для вивчення та аналізу динаміки споживання електроенергії в часі, що дозволяє виявити довгострокові тенденції та вплив факторів на енергетичні показники.

Після цього проводиться обробка даних, включаючи нормалізацію для забезпечення консистентності та однорідності. Важливим етапом є візуальна інтерпретація даних, за допомогою побудови графіків для виявлення ключових патернів та тенденцій у споживанні електроенергії.

Далі висвітлюється модуль прогнозування, де проводиться аналіз різних алгоритмів машинного та глибокого навчання. Для об'єктивного порівняння моделей використовуються параметри, такі як середньоквадратична похибка, середня абсолютна похибка, середня абсолютна відсоткова похибка та коефіцієнт детермінації.

Також було описано різні гібридні моделі прогнозування. Перший підхід використовує гібридні моделі, які комбінують багат шарові нейронні мережі й системи адаптивного нейронечіткого виводу. У цьому підході ШНМ навчаються моделювати нелінійні залежності між вхідними даними (погода, енергоспоживання) та використовуються для генерації вхідно-вихідних даних. ANFIS об'єднує нечіткі правила та нейромережеву архітектуру, покращуючи точність прогнозування.

Другий підхід об'єднує моделі авторегресійного інтегрованого ковзного середнього та штучних нейронних мереж. Гібридна методологія використовує ARIMA для моделювання лінійної автокореляційної структури, а потім використовує багат шарові нейронні мережі для моделювання нелінійних компонентів, таких як погода та інші фактори.

Третій підхід поєднує методи SARIMA та довготривалої короткострокової пам'яті. Цей підхід призначений для короткострокового прогнозування навантаження та враховує як лінійні, так і нелінійні закономірності у даних.

Модель SARIMA використовується для моделювання лінійної автокореляційної структури та сезонності. Параметри моделі оцінюються для вибору

оптимальної SARIMA моделі, яка дозволяє робити лінійний прогноз споживання енергії. Залишки від цієї моделі вводяться в мережу LSTM, що є типом рекурентної нейронної мережі, спроектований для обробки послідовностей даних. LSTM моделює нелінійні зв'язки та довгострокові часові залежності.

Третій розділ присвячений моделюванню інтелектуальної комп'ютерної системи для аналізу та прогнозування енергоспоживання. Спочатку обґрунтовується вибір мови програмування Python для розробки системи через її переваги в аналізі даних та машинному навчанні. Далі описується попередня обробка даних про енергоспоживання, що включає завантаження, візуалізацію, нормалізацію тощо.

Потім реалізуються та порівнюються три моделі машинного навчання для прогнозування: рекурентна нейронна мережа, мережа з довгою короткочасною пам'яттю та штучна нейронна мережа. За допомогою різних метрик оцінюється точність цих моделей, а результати візуалізуються на графіках. Робиться висновок, що модель з довгою короткочасною пам'яттю показала найкращі результати для задачі прогнозування енергоспоживання.

ПРОГНОЗУВАННЯ, ІНТЕЛЕКТУАЛЬНІ МОДЕЛІ, ІНТЕРВАЛИ
ПРОГНОЗУВАННЯ, ЕНЕРГОСПОЖИВАННЯ, ІНТЕЛЕКТУАЛЬНА СИСТЕМА,
РЕКУРЕНТНІ НЕЙРОННІ МЕРЕЖІ, ДОВГА КОРОТКОЧАСНА ПАМ'ЯТЬ,
АВТОРЕГРЕСІЙНЕ ІНТЕГРОВАНЕ КОВЗНЕ СЕРЕДНЄ, PYTHON

Публікації здобувача за темою роботи:

1. Полоус В. Ю. Проблема прогнозування споживання енергоресурсів. Наука сьогодні: від досліджень до стратегічних рішень : V Міжнар. студент. наук. конф., м. Київ, 2 груд. 2022 р. / Наук. керівник Н. Г. Аксак. Київ, 2022. С. 148–150.

2. Полоус В. Ю., Власов В. І. Основні інструменти для реалізації нейромережного підходу в задачах прогнозування. Радіоелектроніка та молодь у XXI столітті : XXVII Міжнар. молодіж. форум, м. Харків, 12 трав. 2023 р. / Наук. керівник Н. М. Сердюк. Харків, 2023. С. 11–12.

3. Полоус В. Ю., Власов В. І. Використання контейнерних застосунків для

задачі прогнозування. Радіоелектроніка та молодь у ХХІ столітті : ХХVІІ Міжнар. молодіж. форум, м. Харків, 12 трав. 2023 р. / Наук. керівник Н. М. Сердюк. Харків, 2023. С. 13–14.

4. Полоус В. Ю. Особливості застосування штучних нейронних мереж. Пріоритетні напрямки та вектори розвитку світової науки : ІІ Міжнар. студент. наук. конф., м. Черкаси, 31 берез. 2023 р. / Наук. керівник Н. М. Сердюк. Черкаси, 2023. С. 154–155.

5. Korablyov M.M., Polous V.Y. Analysis of methods for forecasting energy consumption. Intelligent Solutions-S: Proceedings of the International Symposium, September 28, 2023, Kyiv-Uzhorod, Ukraine / Ministry of Education and Science of Ukraine, Taras Shevchenko National University of Kyiv. Kyiv: Publishing House «Caravela», 2023, pp. 34-36.

Використані публікації керівника та співробітників кафедри, що становлять теоретичну базу роботи:

1. Mykola Korablyov, Oleksandr Fomichov, Sergey Lutskyu, Ihor Ivanisenko, Danylo Antonov, Stanislav Dykyi. Hybrid stock analysis model for financial market forecasting // 18th International Scientific and Technical Conference on Computer Science and Information Technology, CSIT 2023, October 19-21, 2023, Lviv Ukraine.

ЗМІСТ

Скорочення та умовні позначки	14
Вступ	15
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ	17
1.1 Поняття інтелектуальної системи	17
1.2 Аналіз інтервалів прогнозування енергоспоживання	18
1.2.1 Короткострокове прогнозування	19
1.2.2 Середньострокове прогнозування	20
1.2.3 Довгострокове прогнозування	21
1.3 Прогнозування споживання енергії в контексті зміни клімату	23
1.4 Аналіз методів прогнозування енергоспоживання	24
1.4.1 Регресійний аналіз.....	24
1.4.2 Ковзне середнє.....	25
1.4.3 Експоненційне згладжування.....	27
1.5 Інтелектуальні методи прогнозування енергоспоживання	28
1.5.1 Штучні нейронні мережі	28
1.5.2 Нечітка логіка	30
1.5.3 Метод опорних векторів	31
1.6 Аналіз сучасних систем прогнозування енергоспоживання	32
1.6.1 EnergyPlus.....	33
1.6.2 SAS Energy Forecasting	34
1.7 Постановка задачі	36
2 ПРОЄКТУВАННЯ ІНТЕЛЕКТУАЛЬНОЇ КОМП'ЮТЕРНОЇ СИСТЕМИ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ	37
2.1 Архітектура та загальна структура системи	37
2.1.1 Набір даних	38
2.1.2 Аналіз та підготовка даних	39
2.1.3 Прогнозування.....	40

2.1.4 Аналіз результатів	41
2.1.5 Результат прогнозування	43
2.2 Моделі прогнозування енергоспоживання	43
2.2.1 Прогнозування енергоспоживання з використанням нейронних мереж та нейронечіткої системи	44
2.2.2 Прогнозування енергоспоживання за допомогою моделі нейронної мережі та моделі ARIMA	46
2.2.3 Прогнозування енергоспоживання за допомогою моделі ARIMA та мережі LSTM	48
3 МОДЕЛЮВАННЯ ІНТЕЛЕКТУАЛЬНОЇ КОМП'ЮТЕРНОЇ СИСТЕМИ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ	51
3.1 Аналіз та вибір програмного забезпечення для розробки	51
3.2 Попередня обробка даних	52
3.3 Процес нормалізації	54
3.4 Реалізація моделей прогнозування	55
3.4.1 Рекурентна нейронна мережа.....	55
3.4.2 Довга короткочасна пам'ять	56
3.4.3 Штучна нейронна мережа	58
3.5 Порівняння отриманих результатів	59
Висновки	62
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ	64
Додаток А Графічний матеріал кваліфікаційної роботи	67

СКОРОЧЕННЯ ТА УМОВНІ ПОЗНАКИ

ШНМ – Штучна нейронна мережа

ІАЦ – інформаційно-аналітичний центр

ARIMA – бездротова розподільча система (англ., Autoregressive integrated moving average)

МОВ – Метод опорних векторів

ІС – Інтелектуальна система

ОВР – Опорна векторна регресія

ВЛ – Випадковий ліс

HVAC – Heating, Ventilation, & Air Conditioning

ANFIS – адаптивні системи нейронечіткого виводу (англ., Adaptive neuro-fuzzy inference systems)

FIS – системи нечіткого виводу (англ., Fuzzy inference systems)

LSTM – довга короткочасна пам'ять (англ., Long short-term memory)

SARIMA – сезонна авторегресійна інтегрована ковзна середня (англ., Seasonal autoregressive integrated moving average)

ES – експоненційне згладжування (англ., Exponential smoothing)

RNN – рекурентна нейронна мережа (англ., Recurrent neural networks)

ВСТУП

Енергетичний сектор має вирішальне значення для економічного розвитку та соціального добробуту, оскільки він забезпечує енергією, необхідною для різних видів діяльності. Однак енергопостачання часто є нестабільним й існує потреба у точному прогнозуванні споживання енергії для збалансування енергетичної системи.

Немає ефективного способу збереження великої кількості електричної енергії. Недостатнє її вироблення може призвести до запуску електростанцій в піковому режимі, що може призвести до несправностей в системі. Тому загальна кількість спожитої електроенергії має бути збалансована з виробленою. На промислових підприємствах, які використовують електроенергію як основну сировину, може відбуватись нестача потужностей у разі, якщо споживання електроенергії перевищує встановлені норми. У такому випадку, їм доведеться купувати електроенергію за завищеним тарифом. З іншого боку, коли споживання електроенергії менше встановлених норм, може мати місце марне споживання коштів.

Протягом останнього року українська енергосистема серйозно постраждала від постійних ракетних обстрілів енергетичних об'єктів з боку росії. Такі терористичні ракетні удари викликали неминучі наслідки для усієї енергосистеми країни. Скорочення виробництва енергоресурсів та водночас сезонне збільшення їх споживання створило певний колапс енергетичної системи. Входячи з цього, енергетики почали почергові від'єднання споживачів від електромережі, особливо у вечірнє пікове споживання, бо чітко не можуть спрогнозувати кількість необхідної енергії для країни в цей тяжкий момент. Таке нелегке становище вимагає та стимулює розвиток прогнозувальних інтелектуальних технологій у різних сферах людської діяльності.

Дане дослідження спрямоване на розв'язання вищезгаданих проблем та створення інтелектуальної системи обліку, аналізу та прогнозування споживання енергоресурсів. Інтелектуальна система буде призначена для моніторингу та аналізу звичок енергоспоживання побутових споживачів з урахуванням різних факторів,

таких як місцевість, температура повітря, вологість, сила та напрямок вітру.

Метою цього дослідження є створення надійної та точної системи прогнозування енергоспоживання, яка допоможе збалансувати енергетичну систему України. Інтелектуальна система надасть уявлення про структуру енергоспоживання домогосподарств, що дозволить енергетичним компаніям приймати обґрунтовані рішення щодо попиту та пропозиції на енергоресурси.

Таким чином, дане дослідження присвячене критично важливому питанню для України. Саме тому, актуальність та важливість цього дослідження неможливо переоцінити, особливо враховуючи поточну ситуацію з постійними ракетними обстрілами з боку РФ. Управління енергоспоживанням має вирішальне значення для забезпечення комфортного, якісного, надійного та безпечного майбутнього для народу України. Точне прогнозування енергоспоживання є більш важливим, ніж будь-коли раніше, для балансування енергетичної системи України та забезпечення енергопостачання домогосподарств і підприємств. Це дослідження також сприятиме розвитку енергетичного сектору в Україні, зробивши його більш стійким до майбутніх атак і забезпечивши стабільне енергопостачання для населення.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Поняття інтелектуальної системи

Інтелектуальні системи являють собою складний комп'ютерний механізм, що використовує адаптивні алгоритми для прийняття рішень і розроблення стратегій успішного розв'язання проблем в конкретних діапазонах, і керується загальними принципами та правилами. Вони об'єднують значну кількість технологій штучного інтелекту, включаючи машинне навчання, нейронні мережі, експертні системи та генетичні алгоритми.

Сполучаючи ці різноманітні технології, інтелектуальні системи можуть ефективно обробляти та інтерпретувати дані, встановлювати зв'язки між ними, розглядати можливі сценарії та враховувати глибокі взаємозв'язки в обраному контексті.

Ключовою областю застосування інтелектуальних систем є аналіз даних і прийняття на основі них інформованих рішень. Штучний інтелект та машинне навчання використовуються для того, щоб система змогла сама вивчати шаблони поведінки та прогнозувати майбутні тенденції.

У контексті прогнозування енергоспоживання, інтелектуальні системи можуть бути використані для аналізу великих об'ємів даних, включаючи метеорологічні зміни, ціни на енергію, коефіцієнт енергоефективності та інші важливі параметри системи. Засновуючись на цих даних, система може виявити потенційні шаблони та напрямки, що на свою чергу допоможуть у прийнятті більш інформованих рішень, що стосуються управління та використання енергії.

Узагальнюючи вищесказане, можна виокремити ключові характеристики інтелектуальних систем:

- здатність до навчання – система на основі даних самостійно виявляє закономірності та залежності між змінними, будує моделі процесів;
- адаптивність – система може пристосовуватися до змін зовнішнього

середовища, нових даних, вдосконалювати свої моделі;

- здатність до узагальнення – на основі обмеженої навчальної вибірки система може робити узагальнені висновки про властивості даних;

- виявлення знань – інтелектуальна система може самостійно виявляти приховані залежності, закономірності, причинно-наслідкові зв'язки в даних;

- прийняття рішень в умовах невизначеності – за наявності неповних даних система може оцінювати ймовірності та приймати обґрунтовані рішення.

1.2 Аналіз інтервалів прогнозування енергоспоживання

Прогнозування споживання енергії відіграє вирішальну роль в ефективному управлінні енергетичними ресурсами, особливо в епоху, коли попит на енергію постійно зростає. Точні прогнози дозволяють постачальникам електроенергії оптимізувати свою діяльність, зменшити витрати та впровадити стратегії управління попитом. Це, своєю чергою, веде до більш сталої та надійної енергетичної системи.



Рисунок 1.1 – Приклади застосування інтервалів прогнозування

Прогнозування споживання енергії є складним завданням через численні фактори, які впливають на попит на енергію. Ці фактори включають погодні умови, сезонність, економічні умови та поведінку споживачів. Крім того, тривалість інтервалу прогнозу може значно вплинути на точність і застосовність прогнозу. Далі буде проаналізовано різну довжину інтервалів прогнозування, підкреслюючи їх переваги, недоліки та найкращі випадки використання (рисунок 1.1).

1.2.1 Короткострокове прогнозування

Короткострокове прогнозування споживання енергії – це тип прогнозування споживання енергії, який передбачає кількість енергії, яка буде використана за дуже короткий проміжок часу, як правило, від кількох годин до декількох днів наперед. Він широко використовується в різних галузях промисловості, таких як управління електромережами, торгівля енергією та енергоменеджмент будівель [1].

Основна перевага короткострокового прогнозування споживання енергії полягає в тому, що воно може допомогти оптимізувати виробництво, передачу та споживання енергії в режимі реального часу. Прогнозуючи моделі споживання енергії, постачальники енергії можуть регулювати свої постачання для більш ефективного задоволення попиту, що може зменшити втрати енергії, знизити витрати та підвищити стабільність електромережі. Крім того, короткострокове прогнозування споживання енергії також може бути використано для реалізації програм реагування на попит, які стимулюють споживачів енергії зменшувати споживання енергії в години пік, щоб збалансувати енергосистему та уникнути відключень.

З іншого боку, короткострокове прогнозування споживання енергії має деякі обмеження. Наприклад, воно дуже чутливий до раптових змін погоди, поведінки людини та інших зовнішніх факторів, які можуть вплинути на моделі споживання енергії та призвести до неточних прогнозів. Крім того, точність короткострокового прогнозування споживання енергії залежить від якості даних, що використовуються для навчання, і вибору моделей прогнозування.

Існують різні методи та алгоритми, які використовуються для реалізації

короткострокового прогнозування споживання енергії. Один із найпопулярніших методів заснований на нейронних мережах, які є алгоритмами машинного навчання, натхненними структурою та функціями людського мозку. Нейронні мережі можуть вловлювати складні закономірності в даних про споживання енергії та вчитися робити точні прогнози на основі історичних даних. Деякі типи нейронних мереж, які використовуються для короткострокового прогнозування споживання енергії, включають рекурентні нейронні мережі, мережі довгострокової короткочасної пам'яті та згорткові нейронні мережі [2].

На додаток до нейронних мереж існують інші методи, які використовуються для короткострокового прогнозування споживання енергії, такі як статистичні моделі, наприклад, моделі авторегресійної інтегрованої ковзної середньої (ARIMA), моделі нечіткої логіки та метод опорних векторів (МОВ). Їх можна комбінувати з нейронними мережами для підвищення точності прогнозів і зменшення помилок [3].

1.2.2 Середньострокове прогнозування

Середньострокове прогнозування енергоспоживання є важливим для енергетичного планування та управління, яке передбачає прогнозування енергоспоживання на часовому горизонті від кількох тижнів до кількох місяців. Цей вид прогнозування може допомогти енергетичним компаніям приймати обґрунтовані рішення щодо виробництва, передачі та розподілу енергоресурсів.

Одним з найпоширеніших методів середньострокового прогнозування є ARIMA [4]. Ця модель широко використовується для прогнозування часових рядів і базується на припущенні, що майбутні значення є лінійною комбінацією минулих значень і помилок. Іншим популярним методом є модель штучної нейронної мережі (ШНМ), яка має здатність вловлювати нелінійні зв'язки в даних [5]. Модель ШНМ навчається на історичних даних і може бути використана для прогнозування майбутніх значень на основі вивчених закономірностей у даних.

В останні роки методи машинного навчання, такі як опорно-векторна регресія (ОВР) та випадковий ліс (ВЛ), набули популярності у середньостроковому

прогнозуванні енергетики. Ці методи базуються на статистичних алгоритмах та алгоритмах машинного навчання і мають здатність вловлювати складні взаємозв'язки між вхідними та вихідними змінними. ОВР – це тип алгоритму машинного навчання, який може вивчати складні нелінійні зв'язки між вхідними та вихідними змінними. ВЛ – деревоподібний алгоритм машинного навчання, який може обробляти дані високої розмірності та є стійким до перенавчання.

Окрім вищезгаданих методик, для середньострокового енергетичного прогнозування запропоновано також гібридні моделі, які поєднують різні методи прогнозування. Наприклад, показано, що комбінація моделей ARIMA та ШНМ підвищує точність прогнозування споживання енергії [6]. Гібридні моделі поєднують сильні сторони різних моделей і можуть надавати точніші прогнози порівняно з окремими моделями.

До переваг середньострокового прогнозування енергоспоживання можна віднести можливість прогнозувати попит на енергію на кілька тижнів або місяців, що дозволяє енергетичним компаніям ефективно планувати та управляти своїми ресурсами. Крім того, середньострокове прогнозування може допомогти знизити витрати на виробництво енергії шляхом оптимізації використання ресурсів. Однак у цього виду прогнозування також є деякі недоліки. Наприклад, середньострокові прогнози схильні до невизначеності та можуть неточно відображати раптові зміни попиту чи пропозиції.

1.2.3 Довгострокове прогнозування

Довгострокове прогнозування споживання енергії стосується передбачення споживання енергії протягом тривалого періоду часу, зазвичай охоплювальним кілька років або навіть десятиліть. Цей тип прогнозування особливо важливий для енергетичного планування та розробки політики, оскільки він дозволяє особам, які приймають рішення, передбачити майбутні потреби в енергії та відповідно розподілити ресурси.

Довгострокове прогнозування споживання енергії використовується в

різноманітних напрямленнях, таких як планування енергетичної політики, розвиток інфраструктури та інвестиційні рішення. Точне прогнозування тенденцій споживання енергії протягом більш тривалого періоду часу може допомогти урядам і енергетичним компаніям приймати обґрунтовані рішення щодо інвестицій в енергетичну інфраструктуру та інтеграції відновлюваних джерел енергії. Наприклад, точне довгострокове прогнозування споживання енергії може допомогти енергетичним компаніям передбачити зростання попиту, визначити потенційні прогалини в постачанні та спланувати нові потужності з виробництва електроенергії.

Одна з головних переваг довгострокового прогнозування споживання енергії полягає в тому, що воно дозволяє зацікавленим сторонам у сфері енергетики планувати наперед і більш ефективно розподіляти ресурси. Передбачаючи майбутній попит на енергію, вони можуть уникнути надмірного будівництва енергетичної інфраструктури або застати зненацька раптові стрибки споживання енергії. Крім того, довгострокове прогнозування споживання енергії може допомогти визначити можливості для підвищення енергоефективності та інтеграції відновлюваних джерел енергії, що призведе до більш стійких енергетичних систем [7].

Однак довгострокове прогнозування споживання енергії також має деякі обмеження. Однією з головних проблем є складність точного прогнозування довгострокових тенденцій споживання енергії, оскільки на це впливає багато факторів, таких як економічне зростання, демографічні показники населення, технологічний прогрес і урядова політика. Крім того, довгострокове прогнозування споживання енергії вимагає значних даних і обчислювальних ресурсів, а також досвіду статистичного моделювання та енергетичних систем.

Для реалізації довгострокового прогнозування енергоспоживання використовуються різні методи та техніки, такі як аналіз часових рядів, економетричні моделі та алгоритми машинного навчання. Аналіз часових рядів – це статистичний метод, який вивчає тенденції споживання енергії в минулому, щоб визначити закономірності та спрогнозувати споживання в майбутньому. Економетричні моделі використовують економічні змінні, такі як ВВП і зростання населення, для прогнозування споживання енергії. Алгоритми машинного навчання,

такі як ШНМ, ВЛ та МОВ, можна використовувати для аналізу складних моделей споживання енергії та визначення тенденцій.

Одним із популярних підходів до довгострокового прогнозування споживання енергії є сценарне планування, який передбачає створення різних сценаріїв на основі різних припущень щодо майбутнього, таких як темпи економічного зростання та енергетична політика. Ці сценарії можна використовувати для передбачення потенційних тенденцій споживання енергії та інформування про енергетичне планування та розробку політики [8].

1.3 Прогнозування споживання енергії в контексті зміни клімату

Зміна клімату є важливим фактором, який впливає на споживання енергії в цілому. Підвищення температури повітря викликане глобальним потеплінням збільшує навантаження на системи кондиціонування та охолодження будівель. Водночас зменшуються опалювальні потреби в зимовий період. Ці зміни мають бути враховані при довгостроковому прогнозуванні попиту на енергію [15].

Дослідження які були проведені в рамках Програми досліджень і розробок під керівництвом лабораторії в Тихоокеанській північно-західній національній лабораторії, багатoprogramній національній лабораторії, що працює під керівництвом компанії Battelle на замовлення Міністерства енергетики США [15] показують, що для житлових будівель США до 2080 року очікується збільшення річного енергоспоживання на 5-15% через зростання потреби в охолодженні. При цьому споживання енергії на опалення зменшиться на 34-53%. Загальне збільшення попиту буде відбуватися переважно в літній період.

Дослідження Карлссона Й. [16] для Європи також прогнозує зростання енергоспоживання на охолодження до 2050 року на 200-400% у Південній Європі та 50-120% у Центральній і Східній Європі.

Такі зміни попиту вимагають удосконалення методів прогнозування енергоспоживання з урахуванням динаміки клімату. Довгострокові прогнозні моделі повинні враховувати як зростання температур, так і соціально-економічні фактори,

що впливають на енергоспоживання. Гібридні нейронечіткі моделі дозволяють ефективно поєднувати вплив кліматичних та соціально-економічних факторів для довгострокового прогнозування.

Отже, зміна клімату суттєво впливатиме на структуру та обсяги споживання енергії в житловому секторі. Адаптація моделей прогнозування енергоспоживання до нових кліматичних умов є важливим завданням для забезпечення надійного енергопостачання та планування розвитку енергосистеми.

1.4 Аналіз методів прогнозування енергоспоживання

Традиційні методи прогнозування енергоспоживання – це математичні та статистичні методи, що використовуються для прогнозування майбутнього енергоспоживання на основі історичних даних. Ці методи ґрунтуються на припущенні, що майбутнє відбудуватиметься за аналогічною схемою, як і минуле, тому їх зазвичай називають «аналізом часових рядів». Метою традиційних методів є пошук закономірностей і тенденцій у даних, які можуть бути використані для точного прогнозування енергоспоживання. Існує кілька традиційних методів, що використовуються для прогнозування енергоспоживання, включаючи регресійний аналіз, ковзне середнє та експоненціальне згладжування.

1.4.1 Регресійний аналіз

Регресійний аналіз – це широко використовуваний статистичний метод для прогнозування майбутнього споживання енергії на основі історичних даних. Він ґрунтується на принципі, що минулі моделі споживання можуть бути використані для виявлення та кількісної оцінки взаємозв'язків між різними факторами, які впливають на споживання енергоресурсів [9].

Регресійний аналіз припускає, що існує лінійний зв'язок між енергоспоживанням та незалежними змінними, які використовуються в аналізі. Він також припускає, що історичні дані, які використовуються в аналізі, є

репрезентативними для майбутніх моделей споживання. Точність прогнозів залежить від надійності історичних даних і того, наскільки зв'язки між змінними залишаються стабільними в часі.

$$Y = b_1 \times X + c, \quad (1.1)$$

де b_1 – кутовий коефіцієнт регресії,

X – значення ознаки-фактору,

c – вільний член, константа.

Однією з основних переваг регресійного аналізу є те, що він забезпечує чітке і кількісне розуміння факторів, які впливають на споживання енергії. Визначаючи та кількісно оцінюючи взаємозв'язки між різними факторами, він дозволяє енергетичним компаніям приймати обґрунтовані рішення щодо попиту та пропозиції. Регресійний аналіз також може допомогти виявити тенденції та закономірності в енергоспоживанні, які можуть бути використані для довгострокового планування та прийняття інвестиційних рішень.

Одним з основних обмежень регресійного аналізу є те, що він передбачає лінійний зв'язок між споживанням енергії та незалежними змінними. Насправді ж зв'язок між енергоспоживанням та змінними може бути нелінійним або складним, що може призвести до неточностей у прогнозах. Іншим обмеженням є те, що регресійний аналіз базується на історичних даних, які можуть неточно відображати майбутні моделі споживання. Це може призвести до помилок і неточностей у прогнозах, особливо якщо відбудуться зміни на ринку або в регуляторному середовищі.

Отже, регресійний аналіз є корисним методом прогнозування енергоспоживання на основі історичних даних. Однак його точність залежить від надійності історичних даних та стабільності зв'язків між змінними в часі. Хоча він дає чітке і кількісне розуміння факторів, що впливають на енергоспоживання, важливо усвідомлювати його обмеження і потенційні недоліки.

1.4.2 Ковзне середнє

Ковзне середнє – це традиційний метод, який використовується для

прогнозування енергоспоживання. Цей метод базується на середньому значенні попередніх показників енергоспоживання і передбачає, що майбутнє енергоспоживання буде таким же, як і в минулому. У цьому методі ковзне середнє розраховується як середнє значення фіксованої кількості послідовних історичних точок даних. Отримане значення потім використовується як прогноз на наступний період часу [10].

Однією з переваг методу ковзного середнього є його простота. Його легко зрозуміти та реалізувати, і не вимагає складного статистичного аналізу. Він також корисний для згладжування коливань у даних і виявлення тенденцій у часі. Це може бути особливо корисно для виявлення сезонних коливань у споживанні енергії, що може допомогти у плануванні попиту та пропозиції енергії.

$$y_t = \sum_{r=-q}^{+s} \alpha_r x_{t+r}, \quad (1.2)$$

де x_t – часовий ряд,

α_r – сума ваг.

Однак, у методу ковзного середнього також є обмеження. Одне з них полягає в тому, що він сильно залежить від довжини інтервалу ковзного середнього. Якщо воно занадто коротке, прогноз може бути занадто волатильним і не відображати довгострокові тенденції. З іншого боку, якщо інтервал занадто довгий, прогноз може бути занадто гладким і не врахувати короткострокові коливання. Тому визначення відповідного розміру періоду для певного набору даних може бути складним завданням.

Ще одним обмеженням методу ковзного середнього є те, що він передбачає постійний характер споживання енергії в часі. Це може не відповідати дійсності у випадках, коли відбуваються значні зміни в структурі енергоспоживання через зміни в економіці, технологічний прогрес або зміни в політиці. У таких випадках метод ковзного середнього може бути неточним, і його необхідно поєднувати з іншими методами прогнозування.

Таким чином, метод ковзного середнього є простим і корисним інструментом для прогнозування енергоспоживання, але він має свої обмеження. Важливо ретельно продумати відповідний розмір вікна та врахувати всі фактори, які можуть вплинути

на структуру енергоспоживання в часі. Поєднуючи метод ковзного середнього з іншими методами прогнозування, можна розробити більш точний і надійний прогноз енергоспоживання.

1.4.3 Експоненційне згладжування

Експоненційне згладжування – це широко використовуваний метод прогнозування часових рядів, в якому прогнози робляться на основі середньозваженого значення минулих спостережень. Він особливо корисний, коли мають випадкові коливання, що ускладнює використання традиційних методів, таких як регресійний аналіз.

Експоненційне згладжування припускає, що майбутні значення ряду базуються на минулих спостереженнях і що останні спостереження є більш важливими, ніж попередні. Це означає, що ваги, присвоєні попереднім значенням, експоненціально зменшуються зі старішанням спостережень.

Однією з головних переваг експоненційного згладжування є його простота, що робить його легким у використанні навіть для неспеціалістів. Воно також не вимагає великої кількості історичних даних, що робить його корисним для короткострокового прогнозування. Крім того, воно є достатньо гнучким, щоб бути адаптованим до широкого спектра даних часових рядів.

Експоненційне згладжування має кілька обмежень, зокрема, воно найкраще підходить для даних з плавним трендом, сезонними закономірностями або циклами та обмеженими випадковими коливаннями. Він також передбачає, що помилки прогнозу є нормально розподіленими та незалежними одна від одної, що не завжди може бути так на практиці. Нарешті, він може бути чутливим до викидів, тому важливо видаляти їх або відповідно коригувати ваги.

Експоненційне згладжування працює шляхом обчислення прогнозу на основі попереднього спостереження та експоненціально зваженого середнього значення минулих спостережень. Вага, присвоєна кожному спостереженню, експоненціально зменшується зі старішанням спостережень. Формула експоненціального

згладжування виглядає наступним чином:

$$F_{t+1} = \alpha \gamma_t + (1 - \alpha)F_t, \quad (1.3)$$

де F_{t+1} – прогноз на наступний період,

α – константа згладжування,

γ_t – спостережуване значення ряду за період t ,

F_t – старий прогноз на період t .

Отже, експоненціальне згладжування є популярним методом прогнозування часових рядів, який є простим у використанні та адаптується до широкого спектра даних. Хоча він має свої обмеження, він може бути потужним інструментом для короткострокового прогнозування при правильному використанні.

1.5 Інтелектуальні методи прогнозування енергоспоживання

Інтелектуальні методи привертають значну увагу в останні роки завдяки своїй здатності підвищувати точність прогнозування енергоспоживання. Ці методи, які включають штучні нейронні мережі, нечітку логіку та метод опорних векторів, використовують передові математичні алгоритми для аналізу історичних даних та прогнозування майбутніх моделей енергоспоживання.

На відміну від традиційних методів, які покладаються на статистичні моделі та припущення, інтелектуальні методи можуть виявляти складні закономірності та взаємозв'язки в даних, роблячи їх більш точними та надійними для прогнозування. Вони також можуть адаптуватися до мінливих умов і вчитися на нових даних, що робить їх більш гнучкими та пристосованими до різних сценаріїв прогнозування.

1.5.1 Штучні нейронні мережі

Штучні нейронні мережі (ШНМ) є популярним і потужним методом прогнозування енергоспоживання. ШНМ – це тип алгоритму машинного навчання, натхненний структурою та функціями людського мозку. ШНМ складаються з декількох шарів взаємопов'язаних вузлів, або нейронів, які обробляють інформацію

та вивчають закономірності з історичних даних, щоб робити прогнози щодо майбутнього споживання енергії [11].




Рисунок 1.2 – Структура ШНМ

Однією з ключових переваг ШНМ є їхня здатність обробляти нелінійні зв'язки та складні закономірності в даних. Вони здатні вловлювати тонкі та складні взаємозв'язки, які можуть бути пропущені традиційними методами прогнозування, такими як ковзне середнє та експоненційне згладжування. ШНМ також добре адаптуються і можуть бути легко налаштовані відповідно до конкретних потреб прогнозування енергоспоживання.

Структура складається з вхідного шару, одного або декількох прихованих шарів та вихідного шару. Вхідний шар приймає історичні дані, такі як температура, вологість і час доби, в той час, як вихідний шар прогнозує майбутнє споживання енергії. Приховані шари, які складаються з взаємопов'язаних нейронів, виконують обчислення для виявлення закономірностей і взаємозв'язків у даних.

Процес навчання ШНМ передбачає подачу історичних даних у вхідний шар, а потім коригування ваг і зсувів нейронів, щоб мінімізувати похибку між

прогнозованим виходом і фактичним виходом. Після навчання ШНМ можна використовувати для точного прогнозування майбутнього споживання енергії на основі нових вхідних даних.

Доведено, що ШНМ перевершують традиційні методи прогнозування енергоспоживання, особливо при роботі з великими обсягами даних та складними взаємозв'язками. Однак ШНМ мають певні обмеження, наприклад, потребують великих обсягів історичних даних для навчання та є багато обчислень. Загалом, ШНМ є перспективним методом для точного та ефективного прогнозування енергоспоживання.

1.5.2 Нечітка логіка

Нечітка логіка – це інтелектуальний метод, який все частіше використовується для прогнозування енергоспоживання. Цей метод базується на принципах теорії нечітких множин і має на меті представити невизначені та нечіткі дані у більш гнучкий та природний спосіб. Нечітка логіка дозволяє моделювати складні взаємозв'язки між входами та виходами без необхідності створення точної математичної моделі.

У контексті прогнозування енергоспоживання нечітка логіка може бути використана для моделювання впливу численних факторів, що впливають на енергоспоживання, таких як погодні умови, структура зайнятості та характеристики будівлі. Цей метод особливо корисний, коли має справу з нелінійними та змінними в часі зв'язками між входами й виходами, які часто присутні в даних про енергоспоживання.

Однією з головних переваг нечіткої логіки є її здатність обробляти неточні та неповні дані. Визначаючи функції належності, нечітка логіка дозволяє представляти невизначену та розмиту інформацію у більш природний спосіб. Це може бути особливо корисно в ситуаціях, коли даних мало або вони невизначені.

Нечітка логіка також здатна працювати з декількома входами й виходами, що дозволяє більш комплексно моделювати енергоспоживання. Цей метод може

враховувати широкий спектр факторів, що впливають на енергоспоживання, і може забезпечити більш точні прогнози, ніж традиційні методи, які покладаються на один вхідний параметр.

Для реалізації нечіткої логіки для прогнозування енергоспоживання зазвичай використовується система нечіткого виведення. Ця система складається з набору правил, які визначають взаємозв'язок між входами та виходами, а також набору функцій належності, які визначають ступінь належності кожного входу до кожної нечіткої множини. Потім вихід системи дефазифікується для отримання чіткого значення, яке представляє прогнозоване споживання енергії.

Таким чином, нечітка логіка є потужним і гнучким методом прогнозування енергоспоживання, який може працювати з неточними та невизначеними даними, а також зі складними й нелінійними зв'язками між входами та виходами. Цей метод має потенціал для забезпечення більш точних прогнозів, ніж традиційні методи, особливо в ситуаціях, коли даних недостатньо або вони є невизначеними.

1.5.3 Метод опорних векторів

Метод опорних векторів (МОВ) – це клас алгоритмів керованого навчання, які широко використовуються для прогнозування енергоспоживання. МОВ здатні обробляти дані високої розмірності з нелінійною границею, що робить їх чудовим вибором для прогнозування, де традиційні методи є менш ефективними.

МОВ працюють шляхом побудови гіперплощини або набору гіперплощин у високорозмірному просторі, які можуть бути використані для класифікації або регресії. Мета полягає в тому, щоб знайти гіперплощину, яка розділяє дані на класи або прогнозує цільову змінну у випадку регресії. У прогнозуванні енергоспоживання МОВ можна використовувати для прогнозування майбутнього енергоспоживання на основі історичних даних.




Рисунок 1.3 – Результат роботи методу МОВ

Перевагами МОВ є їхня здатність працювати з великими масивами даних і високорозмірними просторами ознак, стійкість до шуму та здатність обробляти нелінійні зв'язки між змінними. Крім того, МОВ мають потужну теоретичну базу, що робить їх більш надійними, ніж інші алгоритми машинного навчання в деяких випадках.

Порівняно з традиційними методами, МОВ можуть надавати більш точні та надійні прогнози, особливо у випадках, коли зв'язок між вхідними та вихідними змінними є нелінійним. Однак одним з основних обмежень МОВ є їхня обчислювальна складність, що може зробити їх непрактичними для дуже великих наборів даних [12].

Таким чином, МОВ є потужним інструментом для прогнозування енергоспоживання, а їх переваги над традиційними методами роблять їх популярним вибором у цій галузі. Однак слід враховувати їхню обчислювальну складність при розгляді їхнього використання у великомасштабних додатках.

1.6 Аналіз сучасних систем прогнозування енергоспоживання

В останні роки було розроблено численні системи прогнозування енергії для різноманітних реальних застосувань, саме тому вони стали все більш важливими в

останні роки, допомагаючи комунальним службам, енергетичним компаніям і споживачам оптимізувати їх споживання енергії.

1.6.1 EnergyPlus

EnergyPlus, розроблена Міністерством енергетики США – це програма моделювання будівель, яка дозволяє детально аналізувати та оцінювати енергоефективність будівельних систем. EnergyPlus також включає модуль прогнозування, який забезпечує прогнози споживання енергії на основі різних вхідних параметрів і погодних умов [13].

EnergyPlus має застарілий графічний інтерфейс, який дозволяє користувачам визначати характеристики будівлі, такі як геометрія будівлі, будівельні матеріали та системи HVAC (опалення, вентиляція та кондиціонування повітря). Програма використовує механізм моделювання для виконання погодинного моделювання енергії та розрахунку споживання енергії на основі визначених користувачем вхідних даних. Модуль прогнозування в EnergyPlus базується на підході, заснованому на регресії, який використовує історичні дані споживання енергії та погодні умови для прогнозування споживання енергії в майбутньому.

Модуль прогнозування в EnergyPlus надає кілька варіантів прогнозування, наприклад короткострокове, середньострокове та довгострокове прогнозування. Короткострокове прогнозування може передбачити споживання енергії на наступний день, тоді як середньострокове прогнозування може передбачити споживання на наступний тиждень або місяць. Довгострокове прогнозування може передбачити споживання на кілька років у майбутньому. Модуль прогнозування також надає різні варіанти виведення, включаючи графіки споживання енергії та статистичні підсумки.

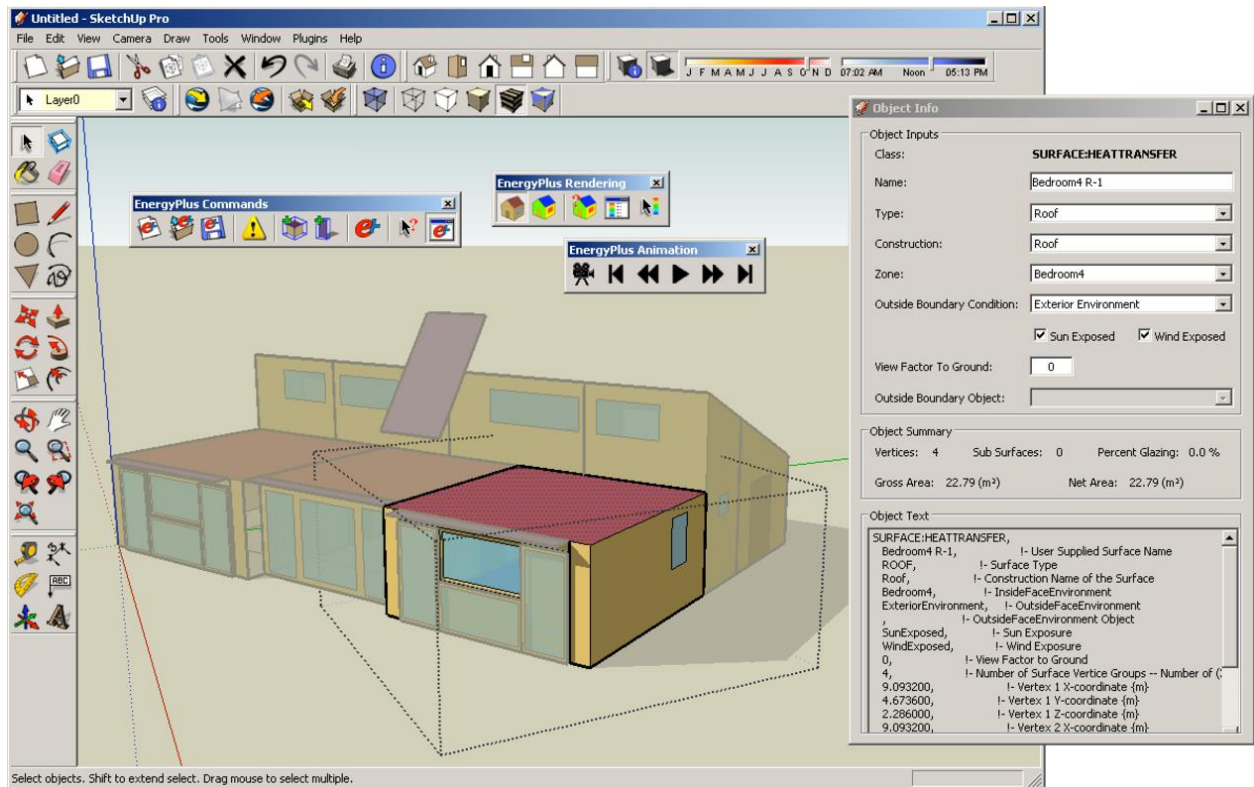


Рисунок 1.4 – Графічний інтерфейс програми

EnergyPlus використовує різні статистичні та математичні методи для прогнозування споживання енергії, такі як регресійний аналіз, аналіз часових рядів і штучні нейронні мережі. Програма також містить модуль даних про погоду, який надає історичні дані про погоду та дозволяє користувачам визначати майбутні сценарії погоди для цілей прогнозування. EnergyPlus зазвичай використовується в дослідницьких дослідженнях та оцінці енергетичної ефективності будівель і набуває популярності в комерційному енергоменеджменті будівель.

1.6.2 SAS Energy Forecasting

SAS Energy Forecasting – потужний програмний інструмент, що використовується для прогнозування енергоспоживання в різних галузях промисловості. Програмне забезпечення використовує різні статистичні алгоритми та алгоритми машинного навчання для прогнозування майбутнього споживання енергії на основі історичних даних [14].

SAS Energy Forecasting використовує різні статистичні алгоритми та алгоритми машинного навчання для прогнозування споживання енергії. Програмне забезпечення підтримує кілька методів прогнозування часових рядів, включаючи ARIMA, експоненціальне згладжування та нейронні мережі. Він також підтримує розширені методи прогнозування, такі як ієрархічне прогнозування та періодичне прогнозування попиту.

SAS Energy Forecasting має кілька переваг перед традиційними методами прогнозування. Головне, він може обробляти великі та складні набори даних, що важливо для точного прогнозування споживання енергії у великих організаціях.

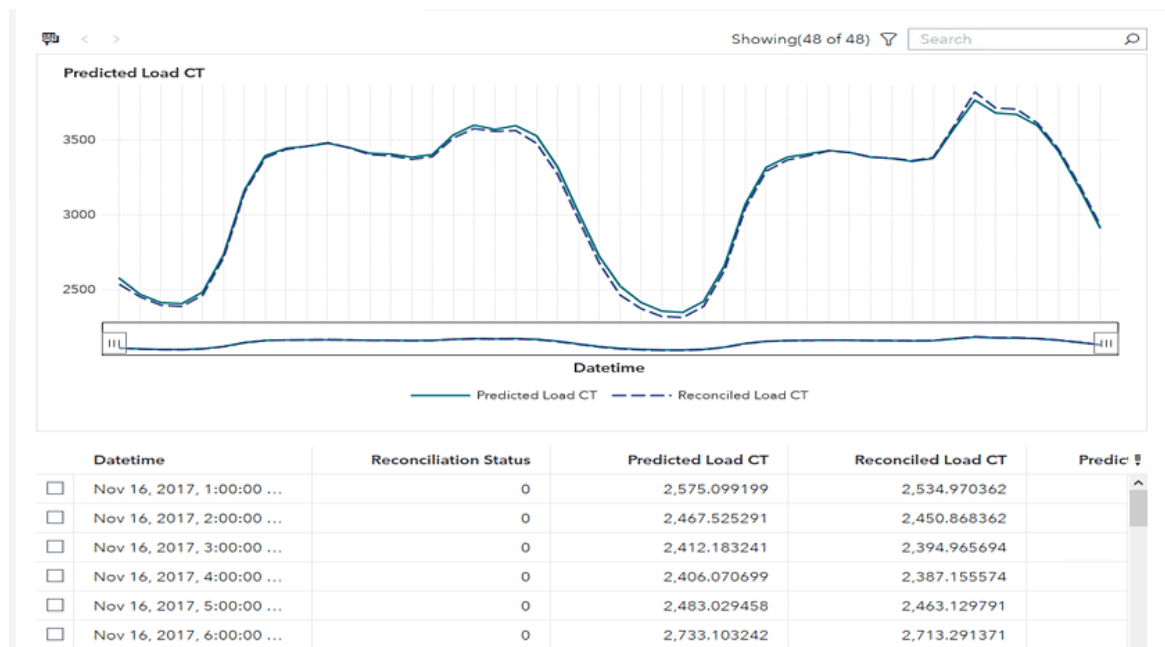


Рисунок 1.5 – Графічний інтерфейс програми

Попри свої переваги, SAS Energy Forecasting має деякі обмеження. По-перше, програмне забезпечення може бути дорогим, що може стати перешкодою для невеликих організацій з обмеженим бюджетом. По-друге, для ефективного використання потрібні спеціальні знання та досвід, що може вимагати додаткового навчання або найму аналітиків даних. Точність прогнозу все ще залежить від якості історичних даних, на які можуть впливати помилки вимірювання, прогалини в даних або зміни в базовій системі.

1.7 Постановка задачі

Нині важливо розробити та впровадити інтелектуальну комп'ютерну систему, яка забезпечує аналіз та прогнозування енергоспоживання з метою оптимізації використання енергетичних ресурсів. З урахуванням зростання попиту на проблеми енергоефективності та необхідності збереження ресурсів, створення саме інтелектуальної системи стає актуальною та необхідною задачею.

При якісному підході до розробки комп'ютерних систем треба визначити головні вимоги до проєкту. Для розробки інтелектуальної комп'ютерної системи аналізу та прогнозування енергоспоживання необхідно виділити, які завдання ставляться перед нею, яким чином виконувати аналіз і прогнозування та які ресурси потрібні на проєктування та підтримку. З ростом складності енергомереж і розвитком нових технологій, вимоги до функціонала системи можуть зростати. Інтелектуальні системи повинні адаптуватися до цих змін, пропонуючи нову функціональність.

Головні завдання перед розробкою інтелектуальної комп'ютерної системи включають:

- збір та акумуляція даних;
- аналіз та обробка даних;
- висока точність прогнозування;
- безпека даних;
- масштабованість.

З врахуванням комплексності завдань та вимог до розробки інтелектуальної комп'ютерної системи для аналізу та прогнозування енергоспоживання, детальне вивчення та виконання вищезгаданих завдань відіграє ключову роль у досягненні успішного результату. Така система може допомогти ефективно використовувати енергетичні ресурси задля сталого розвитку та оптимізації енергетичного сектору.

2 ПРОЄКТУВАННЯ ІНТЕЛЕКТУАЛЬНОЇ КОМП'ЮТЕРНОЇ СИСТЕМИ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ

2.1 Архітектура та загальна структура системи

Для розробки комп'ютерної інтелектуальної системи потрібно спочатку спроектувати її структуру:

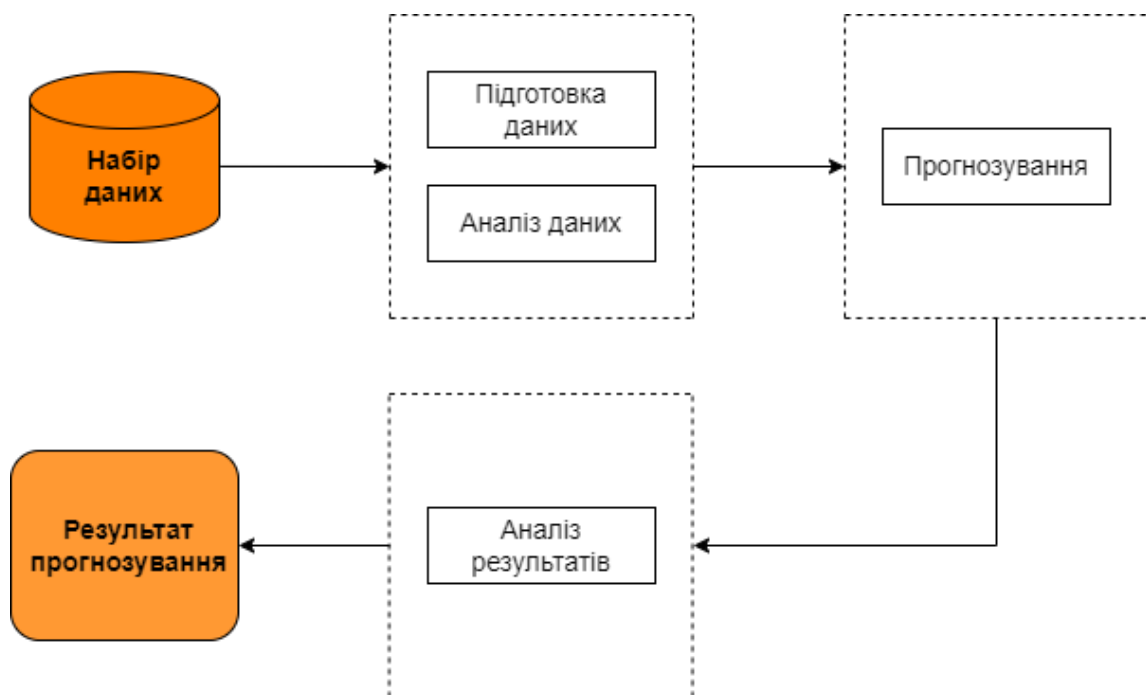


Рисунок 2.1 – Структура комп'ютерної інтелектуальної системи

Архітектура запропонованої комп'ютерної інтелектуальної системи прогнозування енергоспоживання, яка наведена в рисунку 2.1, складається з таких основних модулів:

- набір даних – цей модуль складається з необхідної інформації для навчання та тестування моделей прогнозування. Набір даних включає історичні дані про споживання енергії, а також змінні прогнозування, такі як погодні параметри (температура, вологість, вітер тощо), календарні дані (година, день, місяць, свята) та інші потенційні фактори, що впливають на споживання. Також виконується перевірка

якості даних і попередня обробка;

- підготовка та аналіз даних – у цьому модулі зібрані необроблені дані проходять комплексну підготовку та аналіз. Вони форматуються, узгоджуються, обробляються та готуються до аналізу та моделювання. Статистичний та візуальний аналіз дає уявлення про властивості даних, тенденції та взаємозв'язки. Дані розбиваються на відповідні навчальні та тестові набори даних для розробки та оцінки моделей;

- прогнозування за допомогою інтелектуальної моделі – у цьому модулі буде проаналізовано різні алгоритми машинного навчання та глибокого навчання для навчання надійних моделей, які відображають складні взаємозв'язки між змінними та цілями прогнозування та обрано найкращу поміж них. Використовуються найсучасніші методи, засновані на штучному інтелекті;

- аналіз результатів – у цьому модулі навчена модель прогнозування аналітично оцінюється на тестовому наборі даних для вимірювання її продуктивності. Для кількісної оцінки помилок моделі обчислюються різні метрики точності, такі як: середньоквадратична похибка, середня абсолютна похибка, середня абсолютна відсоткова похибка та коефіцієнт детермінації. Інформаційні панелі аналізу продуктивності візуалізують результати;

- результат прогнозування – згенеровані прогнози дають можливість енергоменеджерам та комунальним підприємствам оптимізувати операції, ресурси та надійність. Модульна архітектура дозволяє безперервне перенавчання моделі в міру надходження нових даних.

Таким чином, така архітектура забезпечує надійну й адаптивну основу для розробки та розгортання інтелектуальних систем прогнозування енергоспоживання на основі даних з використанням найсучасніших інтелектуальних методів.

2.1.1 Набір даних

Для прогнозування енергоспоживання було обрано набір даних «Hourly Energy Consumption» [25] з онлайн-ресурсу Kaggle. Це онлайн-спільнота науковців з даних і

фахівців з машинного навчання під егідою Google.

Набір складається з даних компанії PJM Interconnection, яка є регіональною організацією з передачі електроенергії. Вона є частиною мережі Eastern Interconnection, що управляє системою передачі електроенергії, яка обслуговує всі або частину штатів Делавер, Іллінойс, Індіана, Кентуккі, Мериленд, Мічиган, Нью-Джерсі, Північна Кароліна, Огайо, Пенсильванія, Теннессі, Вірджинія, Західна Вірджинія та Округ Колумбія.

Погодинні дані про споживання електроенергії взяті вказані в мегаватах (МВт)(рисунок 2.2).




Рисунок 2.2 – Візуалізація даних з набору

2.1.2 Аналіз та підготовка даних

Початковий етап підготовки даних передбачає вивчення набору, яка дозволить надати початковий огляд структури. Далі, для забезпечення ефективного аналізу на основі часу, буде конвертовано дані до єдиної структури, де стовпчик з часом буде встановлено як індекс.

Отриманий набір даних із встановленим індексом часу є фундаментальним для вивчення та аналізу динаміки споживання електроенергії в часі. Це створює можливість докладного розгляду довгострокових тенденцій та виявлення факторів, що впливають на енергетичні показники.

Наступним етапом обробки даних є використання методів для забезпечення консистентності та однорідності. Важливим елементом цього підходу є нормалізація, яка дозволяє створити стандартизований формат даних, полегшуючи їхнє подальше порівняння та аналіз.

У завершенні даного етапу враховано важливість візуальної інтерпретації даних. За допомогою побудови графіків досягається не лише ілюстрація змін у споживанні електроенергії, але й виокремлення ключових патернів та тенденцій. Це сприяє глибшому розумінню, що лежать в основі динаміки енергетичного споживання.

У цьому модулі системи використано систематичний та науковий підхід до обробки та аналізу даних, створюючи стійку основу для подальшого вивчення та розуміння динаміки споживання електроенергії в широкому контексті енергетичної галузі.

2.1.3 Прогнозування

У цьому модулі інтелектуальної системи буде проведено практичний аналіз різних алгоритмів машинного та глибокого навчання для вибору найкращої прогнозування. Для справедливого порівняння моделей, була обрана однакова структура моделей, що включає в себе: один вхідний шар, один прихований шар та один вихідний шар. Загальна структура моделей представлена на рисунку 1.2.

Алгоритми які будуть проаналізовані:

а) Штучна нейронна мережа (ШНМ) є моделлю машинного навчання, яка відтворює структуру та функції нейронних мереж у людському мозку. Вона складається зі штучних нейронів, які з'єднані між собою імітуючи зв'язки між нейронами у біологічних системах.

б) Рекурентна нейронна мережа (RNN)

Рекурентні нейронні мережі (RNN) являють собою клас нейронних мереж, розроблених для роботи з послідовними часовими рядами або послідовностями даних. Однією з ключових особливостей RNN є їх здатність зберігати та

використовувати інформацію з попередніх кроків для обробки нових вхідних даних. Це робить їх ефективними для аналізу та моделювання часових залежностей в даних, таких як часові ряди або текстові послідовності.

Основна ідея полягає в тому, що кожен елемент послідовності обробляється мережею, а її внутрішній стан час від часу оновлюється залежно від попередніх обчислень. Така здатність "пам'ятати" попередні стани дозволяє RNN виявляти складні залежності в даному контексті, що робить їх особливо корисними для прогнозування та аналізу часових даних.

в) Довга короткочасна пам'ять (LSTM)

Довга короткочасна пам'ять є рекурентною нейронною мережею, призначеною для розв'язання проблеми зникаючого градієнта, яка присутня в традиційних RNN. Відносна нечутливість до довжини проміжку є її перевагою над іншими RNN, прихованими марковськими моделями та іншими методами послідовного навчання.

2.1.4 Аналіз результатів

В умовах постійної еволюції технологій та вимог сучасного світу, визначення точності моделі стає важливим завданням. Для об'єктивного аналізу моделей, будуть використовуватися наступні параметри:

а) Середньоквадратична похибка (MSE):

MSE вимірює середню квадратичну різницю між прогнозованими та фактичними значеннями. Вона дає повне уявлення про помилки прогнозування, але чутлива до похибок, оскільки більші помилки зводяться до квадрату. MSE є особливо корисна, коли точна величина помилки є критично важливою, оскільки вона більш суттєво показує більші відхилення від прогнозу.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (2.1)$$

де n – кількість спостережень,

y_i – фактичне значення i -го спостереження,

\hat{y}_i – прогнозоване значення i -го спостереження.

б) Середня абсолютна похибка (MAE):

MAE обчислює середню абсолютну різницю між прогнозованими та фактичними значеннями. Вона менш чутлива до відхилень, ніж MSE, і дає чіткіше уявлення про середню величину помилки. MAE є ефективним, коли потрібно зосередитися на величині помилок, не підкреслюючи їхній конкретний напрямок.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2.2)$$

де n – кількість спостережень,

y_i – фактичне значення i -го спостереження,

\hat{y}_i – прогнозоване значення i -го спостереження.

в) Середня абсолютна відсоткова похибка (MAPE):

MAPE виражає середню різницю у відсотках між прогнозованими та фактичними значеннями. Вона дає змогу оцінити точність моделі у відсотках, що робить її придатною для інтерпретації в різних масштабах. MAPE є особливо цінним при оцінці точності у відносному вираженні і менше залежить від масштабу даних.

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100, \quad (2.3)$$

де n – кількість спостережень,

y_i – фактичне значення i -го спостереження,

\hat{y}_i – прогнозоване значення i -го спостереження.

г) Коефіцієнт детермінації (R2):

Цей показник, який застосовується в статистичних моделях, вимірює, якою мірою зміни в незалежних змінних впливають на залежну змінну. Інакше, він пояснює, наскільки точно модель пояснює варіацію у залежній змінній. Цей коефіцієнт може приймати значення від 1 до 0 в умовах класичної лінійної множинної регресії, де більший коефіцієнт вказує на кращу адаптацію моделі до спостережень.

Усі ці параметри надають змогу здійснити аналіз точності моделей в умовах постійної технологічної еволюції. Враховуючи як аспекти абсолютної точності, так і відсоткові відхилення, ми можемо отримати повний образ ефективності прогнозування. Використання MSE, MAE та MAPE дозволяє більш глибоко вивчати різні аспекти помилок та їхній вплив на модель. Коефіцієнт детермінації R2, у свою

чергу, стає ключовим показником у визначенні того, наскільки добре модель адаптується до даних.

Загалом, враховуючи ці параметри, ми можемо здійснити об'єктивний аналіз та прийняти обґрунтоване рішення щодо ефективності та придатності моделі.

2.1.5 Результат прогнозування

У цьому останньому модулі інтелектуальної системи висвітлені результати прогнозування, які були зроблені системою. Вони подаються у формі деталізованих графіків та таблиць.

Представлене візуальне відображення прогнозів є не лише структурованим, але й максимально зручним для сприйняття та аналізу. Графіки виконують роль візуальних інструментів, які надають користувачам можливість швидко та чітко оцінити динаміку та зміни в прогнозованих даних. Таблиці ж допомагають в створенні структурованого контексту для числових значень, що робить аналіз більш деталізованим та зорієнтованим на конкретні цифри.

Сприйняття результатів стає більш ефективним завдяки цьому підходу, що дозволяє не лише розпізнавати загальні тенденції, але й зосереджуватися на деталях, виявляючи ключові аспекти прогнозів. Взаєморозуміння між користувачами системи покращується, оскільки вони отримують доступ до інформації, яка представлена зрозуміло та лаконічно.

Такий візуально насичений підхід не лише дозволяє реагувати на зміни в ситуації оперативно, але і сприяє активній взаємодії з результатами прогнозування, забезпечуючи користувачам можливість приймати обґрунтовані та обдумані рішення в галузі енергоменеджменту.

2.2 Моделі прогнозування енергоспоживання

У прогнозуванні енергоспоживання поява гібридних інтелектуальних моделей прогнозування є значним проривом. Ці моделі поєднують дві або більше підсистем,

кожна з яких має окреме представлення та методологію виведення даних, щоб сформувати комбіновану, семантично узгоджену систему. Термін «гібридна», таким чином, вказує на комплексну систему, в якій різноманітні компоненти гармонійно поєднуються, сприяючи збагаченню взаємодії та інтеграції.

До того ж сучасний розвиток штучного інтелекту прокладає шлях до інтелектуальних систем з гібридними моделями. Ці системи являють собою комбіновані моделі штучного інтелекту, призначені для імітації складної динаміки взаємодії, адаптації та самоорганізації, характерної для систем, що включають природу, технології та людину. З огляду на складність завдань, які вирішують системи підтримки прийняття рішень, моделі та методології, що застосовуються в цих гібридних інтелектуальних системах, набувають все більшої актуальності та виявляються критично важливими.

Таким чином, гібридна інтелектуальна система розуміється як комплексна обчислювальна модель, яка використовує декілька методологій, що імітують інтелектуальну діяльність людини для розв'язання проблем. Вона часто включає такі підходи, як аналітичні моделі, штучні нейронні мережі, нечіткі системи, генетичні алгоритми, експертні системи та статистичні імітаційні моделі. Комплексний характер цих систем, в яких співіснують декілька інтелектуальних методологій, пропонує кращі еволюційні можливості порівняно з системами, які використовують єдиний метод, що робить їх надійним, достатнім та ефективним рішенням для аналізу та прогнозування енергоспоживання.

2.2.1 Прогнозування енергоспоживання з використанням нейронних мереж та нейронечіткої системи

Моделі, що поєднують ШНМ та адаптивні системи нейронечіткого виводу (ANFIS), є перспективним підходом для точного прогнозування енергоспоживання будівель [17]. Цей тип гібридних систем використовує можливості ШНМ щодо апроксимації нелінійних функцій та інтерпретацію систем нечіткого виводу (FIS) для досягнення вищої продуктивності.

У цьому гібридному підході багатoshарова нейронна мережа спочатку навчається на вхідних даних, що складаються з відповідних змінних погоди та енергоспоживання. ШНМ навчається моделювати складні нелінійні взаємозв'язки між вхідними даними та споживанням енергії шляхом ітеративного налаштування синаптичних ваг та зсувів [18].

Після навчання ШНМ використовується для генерації набору вхідних-вихідних даних, що відображають різні вхідні умови у відповідні значення енергоспоживання. Цей набір числових даних потім використовується для автоматичної генерації початкової ШНМ [17].

ANFIS об'єднує FIS у нейромережеву архітектуру з багаторівневими вузлами та зваженими зв'язками. Він налаштовує функції належності та нечіткі правила за допомогою гібридного алгоритму навчання, що поєднує в собі зворотне поширення та оцінку за методом найменших квадратів [17]. Зворотне розповсюдження дозволяє налаштовувати початкові параметри функцій належності, тоді як метод найменших квадратів допомагає оптимізувати подальші параметри.

Архітектура ANFIS має п'ять рівнів (рисунок 2.3) [18]:

- вхідний рівень: обробляє вхідні дані;
- рівень нечіткості: визначає ступінь приналежності входів до нечітких множин;
- рівень правил: генерує виходи правил шляхом нечіткого І з антецедентів правил;
- рівень нормалізації: обчислює відносну силу правил;
- рівень дефазифікації: обчислює результати роботи моделі.

Ця гібридна інтеграція ШНМ та ANFIS поєднує можливості нелінійного моделювання ШНМ з інтерпретацією нечітких правил, згенерованих ANFIS. ANN забезпечує чудову здатність навчатися на основі даних, тоді як ANFIS генерує зрозумілу систему правил, що пояснює прогнози.

Дослідження показали, що гібридні ШНМ-ANFIS моделі забезпечують кращу точність у порівнянні з окремими ШНМ або ANFIS моделями при прогнозуванні енергоспоживання. Ключові переваги цього гібридного підходу включають [19]:

- ефективний при моделюванні нелінійних залежностей;
- швидкий процес навчання;
- генерує інтерпретовані правила «якщо-то» ;
- досягає високої точності прогнозування;
- добре обробляє зашумлені та неповні дані;
- може використовувати ієрархічну структуру, щоб уникнути проблем розмірності.




Рисунок 2.3 – Архітектура моделі ANFIS, два входи, два правила.

2.2.2 Прогнозування енергоспоживання за допомогою моделі нейронної мережі та моделі ARIMA

Перспективним підходом для точного прогнозування часових рядів енергоспоживання є інтеграція моделей авторегресійного інтегрованого ковзного середнього (ARIMA) та штучних нейронних мереж (ANN) [20]. Математичне представлення моделі показано у формулі 2.5. Це дозволяє використовувати унікальні можливості обох методів для моделювання лінійних та нелінійних закономірностей у прогноз даних про споживання.

У гібридній методології ARIMA моделювання спочатку застосовується для виявлення лінійної автокореляційної структури. Вона припускає лінійний зв'язок між запізнілими значеннями ряду та помилками прогнозу. Оцінювання параметрів

здійснюється для того, щоб підібрати оптимальну ARIMA модель. Діагностична перевірка підтверджує адекватність моделі. Нова модель визначається, якщо в залишках залишається значна автокореляція. Підібрана ARIMA модель дає лінійний прогноз.

$$Y_t = \theta_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}, \quad (2.4)$$

де Y_t та ε_t – це фактичне значення та випадкова помилка в момент часу t відповідно;

φ_i ($i=1,2,\dots,p$) та θ_j ($j=1,2,\dots,q$) – це параметри моделі.

p та q – це порядки AR та MA відповідно.

Залишки від цієї моделі потім вводяться в багат шарову ШНМ для моделювання решти нелінійних моделей. ШНМ може апроксимувати складні нелінійні зв'язки між вхідними даними, такими як погода, економічні фактори, минулі значення споживання та майбутнє споживання. Мережа навчається на навчальних даних шляхом ітеративного коригування вагових коефіцієнтів та зсувів. Різні архітектури мережі оцінюються, щоб запобігти надмірному пристосуванню.

Загальне математичне представлення гібридної моделі має вигляд [20]:

$$YF_t = LF_t + NF_t, \quad (2.5)$$

де YF_t – комбінований прогноз,

LF_t – ARIMA прогноз,

NF_t – ШНМ прогноз залишків.

Прогнозування залишків за допомогою ШНМ поєднується з прогнозом за допомогою ARIMA для отримання гібридного прогнозу. Окремо моделюючи лінійні та нелінійні компоненти, гібридний підхід забезпечує комплексне прогнозування. Компонент ARIMA обробляє лінійну автокореляцію, в той час, як ШНМ моделює складні взаємозв'язки між погодою та споживанням.

Дослідження підтвердили вищу продуктивність гібридної моделі порівняно з окремими ARIMA та ШНМ моделями в задачах прогнозування енергоспоживання [21]. Гібридна модель є особливо корисною, коли присутні як лінійні, так і нелінійні зв'язки, що часто зустрічається у даних про споживання. Цей підхід може врахувати складну динаміку, яку не можуть врахувати окремі моделі. Належний дизайн та

поєднання компонентів ARIMA та ШНМ є ключовим для повного використання їхніх взаємодоповнюючих переваг. Загалом, гібридна модель ARIMA-ШНМ є перспективною і все більш популярною технікою для точного короткострокового і довгострокового прогнозування енергоспоживання.

2.2.3 Прогнозування енергоспоживання за допомогою моделі ARIMA та мережі LSTM

Багатонадійним підходом для короткострокового прогнозування навантаження є інтеграція моделей нейронних мереж сезонної ARIMA (SARIMA) та довготривалої короткострокової пам'яті (LSTM) [22]. Структура моделі зображена на рисунку 2.4. Вона поєднує можливості статистичних методів та методів машинного навчання для моделювання як лінійних, так і нелінійних закономірностей у даних про навантаження.

LSTM – це тип рекурентної нейронної мережі, який використовується для обробки послідовностей даних. Він включає в себе чотири основні компоненти: вхідний клапан, забувальний клапан, клапан виходу та внутрішній стан. Формули для кожного з цих компонентів наведені нижче:

$$\begin{aligned}
 f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\
 i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\
 o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\
 h_t &= o_t \odot \sigma_h(c_t),
 \end{aligned} \tag{2.6}$$

де x_t – вхідні дані в момент часу t ,

h_{t-1} – вихідні дані з попереднього кроку,

c_{t-1} – комірка пам'яті з попереднього часового кроку,

W , U , та b – це вагові матриці та параметри вектора зміщення, які ми вивчимо під час навчання,

σ_g , σ_c , та σ_h є функціями активації, такими як сигмоїдна функція або функція гіперболічного тангенса,

⊙ – позначає поелементне множення, яке використовується для застосування значення стробу до комірки пам'яті.

У гібридній методології для врахування лінійної автокореляції та сезонності спочатку застосовується моделювання SARIMA. Вона передбачає лінійний зв'язок між запізнілими значеннями та помилками прогнозу. Параметри оцінюються для того, щоб підібрати оптимальну модель SARIMA, яка перевіряється за допомогою діагностичної перевірки. Підібрана модель дає лінійний прогноз споживання.

Залишки від моделі SARIMA вводяться в мережу LSTM для моделювання решти нелінійних зв'язків, пропущених SARIMA. LSTM може вивчати довгострокові часові залежності та добре підходить для прогнозування послідовностей. Мережа вивчає складні зв'язки між вхідними даними, такими як погода, цикли попиту та навантаження, регулюючи коефіцієнти шляхом зворотного розповсюдження.

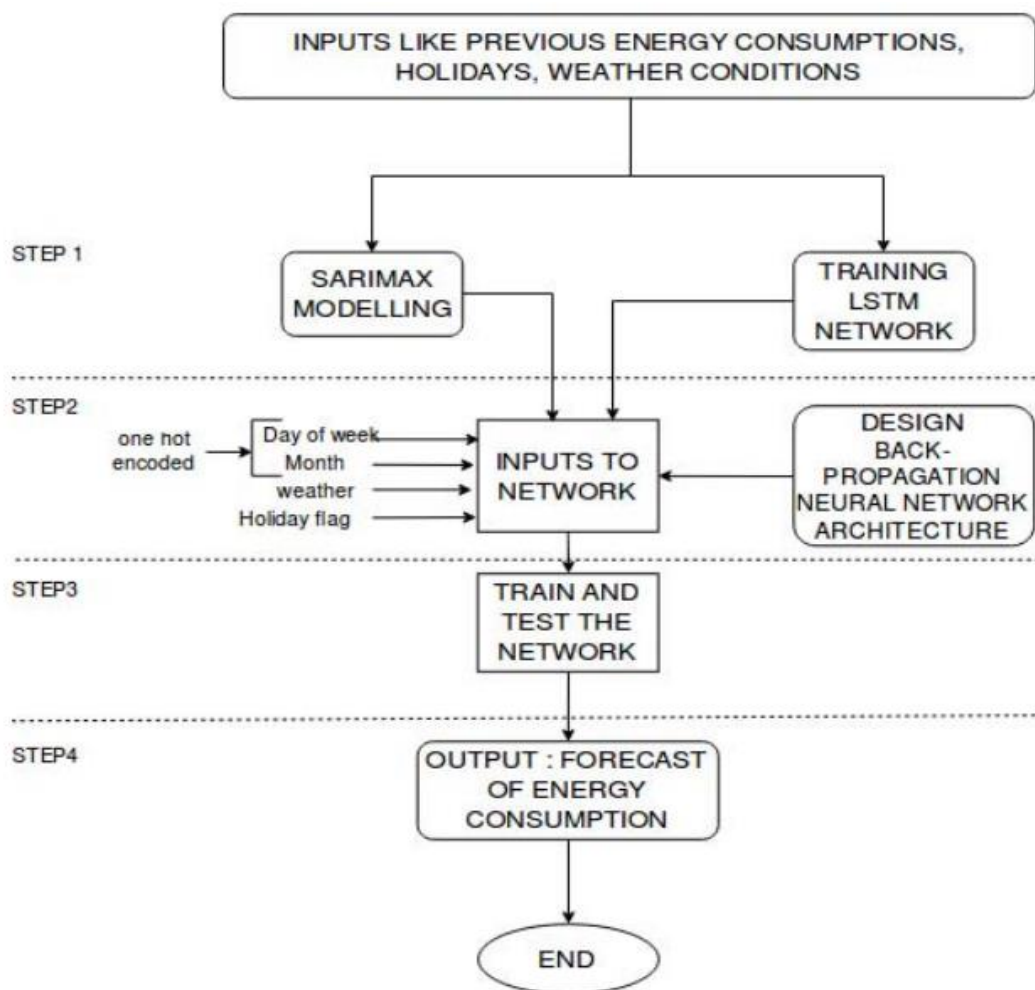


Рисунок 2.4 – Процес створення гібридної моделі

Прогноз залишків за допомогою LSTM поєднується з прогнозом SARIMA для отримання результатів гібридної моделі. Окремо моделюючи лінійні та нелінійні компоненти, гібридний підхід забезпечує комплексне прогнозування. SARIMA обробляє лінійні моделі, в той час, як LSTM фіксує складні взаємодії між погодою та споживанням.

Запропонована методика використовує сильні сторони статистичних моделей і моделей машинного навчання за допомогою простої інтеграції.

3 МОДЕЛЮВАННЯ ІНТЕЛЕКТУАЛЬНОЇ КОМП'ЮТЕРНОЇ СИСТЕМИ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ

3.1 Аналіз та вибір програмного забезпечення для розробки

Python — інтерпретована об'єктноорієнтована мова програмування високого рівня зі суворою динамічною типізацією [26]. Вона вважається основним інструментом для розробки програмного забезпечення для прогнозування енергоспоживання завдяки своїй універсальності та широкій підтримці у сферах науки про дані та машинного навчання. Відома своєю зрозумілістю та простотою у використанні, Python пропонує безліч бібліотек та фреймворків, пристосованих для надійного аналізу та моделювання даних, що робить її ідеальним вибором для вирішення складних завдань, пов'язаних із моделюванням енергоспоживання.

Її бібліотеки, орієнтовані на дані, зокрема NumPy та pandas, сприяють ефективному управлінню даними, а фреймворки машинного навчання, такі як scikit-learn та TensorFlow, дають змогу впроваджувати складні моделі прогнозування. Особливої уваги заслуговує вміння Python у машинному навчанні, завдяки багатій екосистемі, яка включає найсучасніші алгоритми для прогнозування часових рядів, що є критично важливим аспектом прогнозування тенденцій енергоспоживання.

Інструменти візуалізації Python, такі як Matplotlib та Plotly, допомагають створювати змістовні графіки для виявлення складних тенденцій. Ці інструменти не лише покращують розуміння даних про енергоспоживання. Універсальність Python ще більше підкреслюється його здатністю легко інтегруватися з іншими мовами, що дозволяє додавати важливі для продуктивності компоненти, коли це необхідно.

Завдяки активній та розгалуженій спільноті, Python забезпечує вільний доступ до безлічі ресурсів, що сприяє безперешкодному процесу розробки. Спільна робота спільноти Python сприяє інноваціям і гарантує, що мова залишається на передовій технологічного прогресу. Ця широка підтримка суспільства також виражається у великій кількості навчальних посібників, форумів та документації, що полегшує

розв'язання проблем та забезпечує розробникам можливість бути в курсі останніх тенденцій та найкращих практик у сфері прогнозування енергоспоживання.

До того ж відкритий код Python не лише відповідає принципам доступності, але й дозволяє модифікувати вихідний код відповідно до конкретних потреб проєкту. Це сприяє інноваціям та гнучкості в процесі розробки, що має вирішальне значення для адаптації рішень до унікальних викликів, пов'язаних з прогнозуванням енергоспоживання.

Крім того, застосування Python виходить за рамки аналізу та моделювання даних. Вона є чудовим вибором для розробки вебінтерфейс, використовуючи такі фреймворки, як Django та Flask, для створення інтерактивних та зручних для користувача додатків. Інтеграція Python з Jupyter Notebooks надає додаткову перевагу, дозволяючи створювати та ділитися документами, що містять живий код, візуалізації та описовий текст. Це може бути неоціненним для представлення та документування тонкощів аналізу енергоспоживання.

Отже, Python — це не просто мова програмування, а динамічна екосистема, яка відповідає багатогранним потребам прогнозування енергоспоживання. Широкий набір інструментів у поєднанні з активною спільнотою та адаптованістю до різноманітних потреб робить Python чудовим вибором для створення ефективних, точних та масштабованих рішень у сфері енергоменеджменту та прогнозування.

3.2 Попередня обробка даних

Початковим кроком на етапі попередньої обробки даних є імпорт та перевірка набору даних. У цьому випадку набір даних представляє погодинне споживання енергії в мегаватах. Дані зберігаються у файлі CSV, а для читання та дослідження набору даних використовується бібліотека Pandas (рисунок 3.1).

Функція `head()` застосовується для відображення перших кількох рядків набору даних, надаючи початковий огляд структури (таблиця 3.1).

Далі стовпчик «Datetime» конвертується у формат часу, а сам стовпчик встановлюється як індекс для кращого аналізу на основі часу (рисунок 3.2).

```
import pandas as pd

df = pd.read_csv("/kaggle/input/hourly-energy-consumption/DOM_hourly.csv")
df.head()
```

Рисунок 3.1 – Завантаження даних

Таблиця 3.1 – Результат роботи функції head()

	Datetime	DOM_MW
0	2020-12-31 01:00:00	9389.0
1	2020-12-31 02:00:00	9070.0
2	2020-12-31 03:00:00	9001.0
3	2020-12-31 04:00:00	9042.0

```
df['Datetime'] = pd.to_datetime(df['Datetime'])

df.set_index('Datetime', inplace=True)
```

Рисунок 3.2 – Встановлення стовпчика, як індекс

Отриманий набір даних тепер має індекс часу, що дозволяє проводити хронологічне дослідження та аналіз (таблиця 3.2).

Таблиця 3.2 – Дані після змін індексу

Datetime	DOM_MW
2020-12-31 01:00:00	9389.0
2020-12-31 02:00:00	9070.0
2020-12-31 03:00:00	9001.0
2020-12-31 04:00:00	9042.0
2020-12-31 05:00:00	9132.0

Далі розраховується середнє споживання енергії за рік і представляється в табличному форматі (рисунок 3.3, таблиця 3.3).

```
df_yearly_avg = df['DOM_MW'].resample('Y').mean()
df_yearly_avg.to_frame()
```

Рисунок 3.3 – Знаходження середньоарифметичного споживання енергії

Нище згадана таблиця відображає середнє споживання енергії за кожен рік, надаючи цінну інформацію про довгострокові тенденції (таблиця 3.3). Цей аналіз надає всебічний огляд часових закономірностей набору даних.

Таблиця 3.3 – Результати виконання коду

Datetime	DOM_MW
2018-12-31	10833.524668
2019-12-31	10457.146951
2020-12-31	10991.015871
2021-12-31	10786.751765
2022-12-31	10696.930235

3.3 Процес нормалізації

Для візуального огляду набору даних створюється графік, який ілюструє тенденції енергоспоживання в часі (рисунок 3.4).

Нормалізація є важливим кроком для забезпечення однорідності даних. MinMaxScaler застосовується для нормалізації стовпця «DOM_MW», масштабуючи значення між 0.0 та 1.0 (рисунок 3.5).




Рисунок 3.4 – Візуалізація даних

```

def normalize_data(df):
    scaler = MinMaxScaler()
    normalized_data = scaler.fit_transform(df['DOM_MW'].values.reshape(-1,1))
    df['DOM_MW'] = normalized_data
    return df, scaler

df_norm, scaler = normalize_data(df)

```

Рисунок 3.5 – Нормалізація даних

Виводиться нормалізований набір даних, що показує перетворені значення «DOM_MW» (рисунок 3.6).

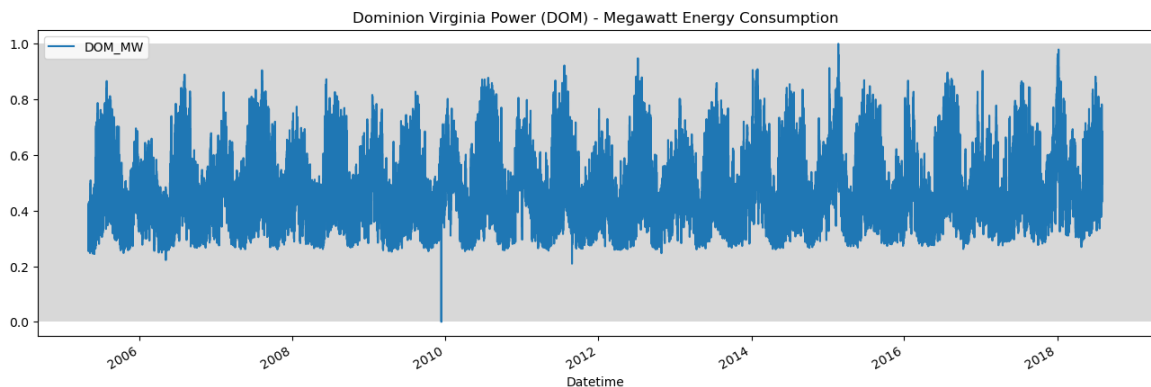


Рисунок 3.6 – Графік даних після нормалізації

3.4 Реалізація моделей прогнозування

На цьому етапі розглянемо результати роботи різних інтелектуальних моделей прогнозування для аналізу, порівняння та визначення найкращої з них. Загальна архітектура моделей була описана та використана в розділі 2.

3.4.1 Рекурентна нейронна мережа

Рекурентна нейронна мережа (RNN) представляє собою архітектуру нейронної мережі, яка здатна працювати з послідовними даними. Вона використовує механізм повторного входу, що дозволяє враховувати попередні стани та використовувати їх при обробці нових вхідних даних.

```

R2 Score of RNN model = 0.965
MSE Score of RNN model = 188859.748
MAE Score of RNN model = 238.079
MAPE of RNN model = 0.025%

```

Рисунок 3.7 – Результати підрахунку параметрів точності оцінювання

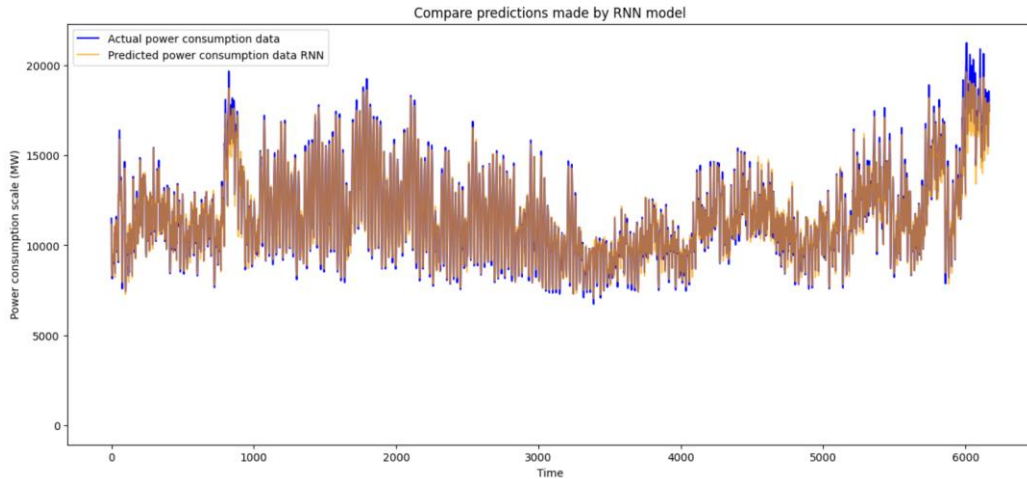


Рисунок 3.8 – Графік прогнозування RNN моделі

Таблиця 3.4 – Порівняння результатів прогнозування

Дата	Фактичні дані	Прогнозовані дані RNN
2022-01-01 18:00:00	17801.0	16914.4
2022-01-01 19:00:00	18249.0	17911.2
2022-01-01 20:00:00	18418.0	18143.0
2022-01-01 21:00:00	18567.0	18110.0
2022-01-01 22:00:00	18307.0	18241.7
2022-01-01 23:00:00	17814.0	18027.2
2022-01-02 00:00:00	17428.0	17416.8

3.4.2 Довга короткочасна пам'ять

Довга короткочасна пам'ять (LSTM) є розширенням RNN, спроектованим для подолання проблем втрати та зсуву градієнтів. Вона використовує спеціальні блоки

пам'яті, які дозволяють зберігати та оновлювати інформацію на тривалий термін.




Рисунок 3.9 – Графік прогнозування LSTM моделі

```
R2 Score of LSTM model = 0.985
MSE Score of LSTM model = 125571.092
MAE Score of LSTM model = 169.54
MAPE of LSTM model = 0.015%
```

Рисунок 3.10 – Результати підрахунку параметрів точності оцінювання

Таблиця 3.5 – Порівняння результатів прогнозування

Дата	Фактичні дані	Прогнозовані дані LSTM
2022-01-01 18:00:00	17801.0	17581.7
2022-01-01 19:00:00	18249.0	18326.5
2022-01-01 20:00:00	18418.0	18130.5
2022-01-01 21:00:00	18567.0	18360.3
2022-01-01 22:00:00	18307.0	18117.9
2022-01-01 23:00:00	17814.0	17958.2
2022-01-02 00:00:00	17428.0	17195.6

3.4.3 Штучна нейронна мережа

Штучна нейронна мережа представляє собою модель, яка вивчає статичні зв'язки в даних без врахування часових залежностей.

```
R2 Score of ANN model = 0.954
MSE Score of ANN model = 224770.549
MAE Score of ANN model = 275.259
MAPE of ANN model = 0.029%
```

Рисунок 3.11 – Результати підрахунку параметрів точності оцінювання




Рисунок 3.12 – Графік прогнозування ШНМ моделі

Таблиця 3.6 – Порівняння результатів прогнозування

Дата	Реальні дані	Прогнозовані дані ШНМ
2022-01-01 18:00:00	17801.0	16979.4
2022-01-01 19:00:00	18249.0	18205.3
2022-01-01 20:00:00	18418.0	18201.4
2022-01-01 21:00:00	18567.0	18098.1
2022-01-01 22:00:00	18307.0	18166.3
2022-01-01 23:00:00	17814.0	17763.4
2022-01-02 00:00:00	17428.0	17221.7

3.5 Порівняння отриманих результатів

Для кращого сприйняття та деталізації отриманих результатів, вони будуть занесені до порівняльної таблиці (таблиця 3.7, 3.8). Ці таблиці стануть необхідним інструментом для систематичного та зрозумілого порівняння різних аспектів точності кожної моделі. Вони дозволять визначити переваги та недоліки кожної моделі, забезпечуючи повний огляд їхньої ефективності в різних умовах.

Таблиця 3.7 – Порівняння результатів прогнозування різних моделей

Дата	Фактичні дані	RNN модель	LSTM модель	ШНМ модель
2022-02-14 00:00:00	11494.0	11196.5	11509.6	11366.0
2022-02-12 01:00:00	8728.0	9983.2	8691.0	10398.2
2022-02-12 02:00:00	8390.0	8393.5	8394.4	7870.7
2022-02-12 03:00:00	8283.0	7972.0	8279.3	8363.8
2022-02-12 04:00:00	8195.0	8243.5	8222.8	8601.4
2022-02-12 05:00:00	8150.0	8365.9	8312.2	8587.6
2022-02-12 06:00:00	8308.0	8628.6	8351.3	8640.2
2022-02-12 07:00:00	8588.0	9061.6	8671.2	8962.3
2022-02-12 08:00:00	9000.0	9138.3	8969.4	9261.0
2022-02-12 09:00:00	9290.0	9580.7	9385.9	9520.2

Таблиця 3.8 – Порівняння результатів параметрів оцінювання моделей

	MSE	MAE	MAPE	R ²
RNN	188859.748	238.079	0.025%	0.965
LSTM	125571.092	169.54	0.015%	0.985
ANN	224770.549	275.259	0.029%	0.954

Для найкращого візуального аналізу та порівняння результатів прогнозування енергоспоживання, було створено декілька детальних графіків. На них були нанесені фактичні дані щодо споживання енергії поряд із прогнозованими значеннями, отриманими різними моделями (рисунок 3.13 та рисунок 3.14). На ньому чітко видно, що прогнозування LSTM моделі майже постійно знаходиться біля лінії фактично споживання або навіть ці значення накладаються один на одне.

Кожен графік представляє собою наглядний порівняльний аналіз, де чітко видно відхилення між реальними та прогнозованими значеннями для кожної моделі. Це дозволяє здійснити оцінку точності та ефективності кожної моделі на різних етапах часового ряду.

Такий візуальний підхід сприяє кращому розумінню тенденцій, аномалій та загальної адаптованості моделей до змін у часовому споживанні енергії. Ці графіки стануть важливим інструментом для прийняття обґрунтованих висновків та визначення найефективнішої моделі для використання в прогнозуванні.

Під час аналізу та порівняння результатів у межах цього дослідження виявлено, що модель LSTM, виявилася найбільш ефективною у прогнозуванні енергоспоживання. Її високий рівень точності, відображений у низьких значеннях середньої квадратичної помилки, середньої абсолютної похибки та високому коефіцієнті детермінації, свідчать про виняткову адаптованість до динаміки енергетичного споживання.




Рисунок 3.13 – Деталізований графік порівняння прогнозування

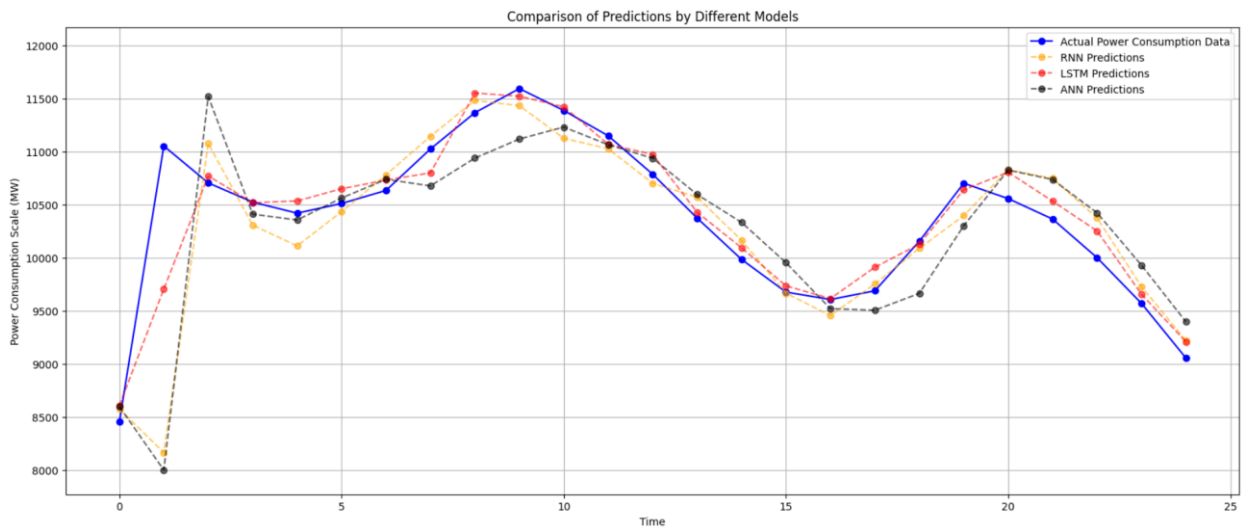


Рисунок 3.14 – Деталізований графік порівняння прогнозування

Враховуючи ретельні порівняння з іншими моделями, LSTM видається не лише найточнішою, але й найбільш універсальною у різних умовах. Її здатність впевнено адаптуватися до змін у часових рядах і висока точність роблять її незамінною для точного прогнозування енергоспоживання.

Цей висновок підкріплюється як кількісними даними з таблиць і графіків, так і висновками, отриманими з візуального аналізу. Усі ці фактори роблять модель на основі LSTM перспективним вибором для подальших застосувань у сфері прогнозування енергетичного споживання

ВИСНОВКИ

Ефективне управління енергоспоживанням є важливим завданням для забезпечення сталого розвитку енергетичної системи будь-якої країни. Точне та надійне прогнозування попиту на енергію дозволяє оптимізувати розподіл ресурсів, уникнути дефіцитів та підвищити ефективність постачання енергії споживачам.

У ході роботи було розглянуто актуальну задачу розробки інтелектуальної комп'ютерної системи для аналізу та прогнозування енергоспоживання.

У першому розділі проведено детальний аналіз предметної області та наявних методів прогнозування енергоспоживання. Розглянуто поняття інтелектуальної системи, класифікацію інтервалів прогнозування, вплив зміни клімату на енергоспоживання. Проаналізовано як традиційні, так і інтелектуальні методи прогнозування. Розглянуто сучасні системи прогнозування енергоспоживання.

У другому розділі запропоновано архітектуру інтелектуальної системи, що включає модулі для збору даних, їх аналізу та підготовки, прогнозування за допомогою інтелектуальних моделей, аналізу результатів. Розглянуто різні гібридні моделі прогнозування на основі нейронних мереж, нейронечітких систем, моделей ARIMA та LSTM.

У третьому розділі наведено реалізацію інтелектуальної системи з використанням мови Python. Виконано попередню обробку даних, побудовано та порівняно за метриками точності моделі прогнозування: рекурентну нейронну мережу, мережу LSTM та штучну нейронну мережу.

Однією з ключових пунктів цієї роботи є обґрунтований вибір моделі довгої короткочасної пам'яті (LSTM) як інтелектуальної моделі, яка продемонструвала найвищу точність у прогнозуванні енергоспоживання порівняно з іншими методами. Її високі показники ефективності вказують на можливість успішного впровадження в енергетичні системи та покликані покращити управління ресурсами та попитом на енергію.

Обрана інтелектуальна модель продемонструвала високу точність

прогнозування енергоспоживання, перевершивши за показниками інші методи прогнозування. Створена система може застосовуватися енергопостачальними компаніями для оптимізації розподілу ресурсів, управління попитом та підвищення ефективності енергосистеми. Подальші дослідження можуть бути спрямовані на розширення функціональності та практичному впровадженні.

ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Probabilistic energy forecasting: Global Energy Forecasting Competition 2014 and beyond / T. Hong та ін. *International Journal of Forecasting*. 2016. Т. 32, № 3. С. 896–913.
2. Short-term power load forecasting based on LSTM neural network optimized by improved PSO / T. Wei та ін. *Journal of System Simulation*. 2021. Т.33, № 8. С. 1866.
3. Short-Term Load Forecasting: Based on Hybrid CNN-LSTM Neural Network / A. Agga та ін. 2021 6th International Conference on Power and Renewable Energy (ICPRE), м. Shanghai, China, 17–20 верес. 2021 р. 2021.
4. Hyndman R. J., Khandakar Y. Automatic Time Series Forecasting: The forecastPackage for R. *Journal of Statistical Software*. 2008. Т. 27, № 3.
5. Wang X., Meng M. A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting. *Journal of Computers*. 2012. Т. 7, № 5.
6. Pooniwala N., Sutar R. Forecasting Short-Term Electric Load with a Hybrid of ARIMA Model and LSTM Network. 2021 International Conference on Computer Communication and Informatics (ICCCI), м. Coimbatore, India, 27–29 січ. 2021 р. 2021.
7. Hafezi R., Alipour M. Energy Security and Sustainable Development. *Encyclopedia of the UN Sustainable Development Goals*. Cham, 2020.
8. Scenario-based prediction of climate change impacts on building cooling energy consumption with explainable artificial intelligence / D. Chakraborty та ін. *Applied Energy*. 2021. Т. 291. С. 116807.
9. Seber G. A., Lee A. J. *Linear Regression Analysis*. Wiley & Sons, Incorporated, John, 2012.
10. Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and practice*. OTexts, 2018. 382 с.
11. Lu C., Li S., Lu Z. Building energy prediction using artificial neural networks: A literature survey. *Energy and Buildings*. 2022. Т. 262. С. 111718.
12. Modelling the energy performance of residential buildings using advanced

computational frameworks based on RVM, GMDH, ANFIS-BBO and ANFIS-IPSO / N. Kardani та ін. *Journal of Building Engineering*. 2021. Т. 35. С. 102105.

13. EnergyPlus. Energy.gov. URL:

<https://www.energy.gov/eere/buildings/articles/energyplus> (дата звернення: 15.11.2023).

14. SAS Energy Forecasting. URL: https://www.sas.com/en_us/software/energy-forecasting.html (дата звернення: 15.11.2023).

15. Impacts of climate change on energy consumption and peak demand in buildings: A detailed regional approach / J. A. Dirks та ін. *Energy*. 2015. Т. 79. С. 20–32.

16. Jakubcionis M., Carlsson J. Estimation of European Union residential sector space cooling potential. *Energy Policy*. 2017. Т. 101. С. 225–235.

17. Jang J. S. R. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. 1993. Т. 23, № 3. С. 665–685.

18. Li K., Su H., Chu J. Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study. *Energy and Buildings*. 2011. Т. 43, № 10. С. 2893–2899.

19. Seydi Ghomsheh V., Aliyari Shoorehdeli M., Teshnehlab M. Training ANFIS structure with modified PSO algorithm. 2007 Mediterranean Conference on Control & Automation, м. Athens, Greece, 27–29 черв. 2007 р. 2007.

20. Wang X., Meng M. A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting. *Journal of Computers*. 2012. Т. 7, № 5.

21. Li K., Su H., Chu J. Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study. *Energy and Buildings*. 2011. Т. 43, № 10. С. 2893–2899.

22. Pooniwala N., Sutar R. Forecasting Short-Term Electric Load with a Hybrid of ARIMA Model and LSTM Network. 2021 International Conference on Computer Communication and Informatics (ICCCI), м. Coimbatore, India, 27–29 січ. 2021 р. 2021.

23. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Т. 9, № 8. С. 1735–1780.

24. Graves A., Jaitly N., Mohamed A.-r. Hybrid speech recognition with Deep Bidirectional LSTM. 2013 IEEE Workshop on Automatic Speech Recognition &

Understanding (ASRU), м. Olomouc, Czech Republic, 8–12 груд. 2013 р. 2013.

25. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/robikscube/hourly-energy-consumption> (дата звернення: 15.11.2023).

26. Python. URL: <https://www.python.org/> (дата звернення: 01.11.2023).

27. Wikiwand – Коефіцієнт детермінації. Wikiwand. URL: https://www.wikiwand.com/uk/Коефіцієнт_детермінації (дата звернення: 15.11.2023).