

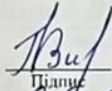
КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

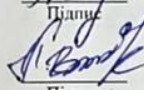
на тему Метод прогнозування залишкового ресурсу літій-іонних акумуляторів
з використанням методів машинного навчання

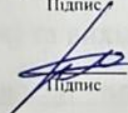
Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань

Спеціальність 122 – Комп'ютерні науки
Шифр і назва спеціальності

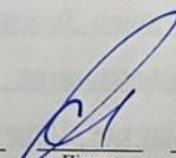
Освітня програма Комп'ютерні науки
Назва освітньої програми

Виконав: студентка групи КН-21-1  Вікторія ГОНЧАРУК
Група виконавця Підпис Ім'я, ПРІЗВИЩЕ

Керівник: асистент кафедри КН  Леонід ВОЗНЮК
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

Нормоконтроль: к.т.н., доц. каф. КН  Руслан БАГРІЙ
Науковий ступінь, посада Підпис Ім'я, ПРІЗВИЩЕ

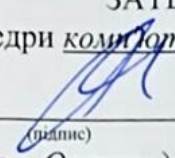
До захисту допускаю:

Зав. кафедри КН, д.т.н., професор  Олександр БАРМАК
Підпис Ім'я, ПРІЗВИЩЕ

19 06 2025 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
 Факультет інформаційних технологій
 Кафедра комп'ютерних наук
 Освітній ступінь бакалавр
 Галузь знань 12 – Інформаційні технології
 Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ
 Завідувач кафедри комп'ютерних наук


 (підпис)
д.т.н., професор Олександр БАРМАК
 « 10 » 02 2025 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ БАКАЛАВРА

1. Тема кваліфікаційної роботи бакалавра: «Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання»
2. Завдання видано студентці Вікторії ГОНЧАРУК
(Ім'я, прізвище)
3. Керівник роботи асистент кафедри КН Леонід ВОЗНІЮК
(посада, ім'я, прізвище)
4. Затверджено наказом університету від « 07 » 02 2025 р. № 23
5. Дата видачі завдання студенту: « 10 » 02 2025 р.
6. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Метою роботи є підвищення точності прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання. Задачі роботи: дослідити сучасний стан та проблеми в галузі оцінювання деградації та прогнозування залишкового ресурсу літій-іонних акумуляторів; провести аналіз існуючих методів та алгоритмів прогнозування залишкового ресурсу акумуляторів, визначити їх переваги та обмеження; розробити метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням нейронної мережі; спроектувати архітектуру інформаційної системи для збору, обробки даних та прогнозування залишкового ресурсу акумуляторів; експериментально дослідити розроблений метод прогнозування.

7. Календарний план виконання кваліфікаційної роботи бакалавра:

№	Назва етапів (розділів) кваліфікаційної роботи бакалавра	Термін виконання	Примітка
1	Вибір напрямку дослідження та узгодження тематики кваліфікаційної роботи бакалавра з керівником, складання календарного графіка виконання роботи	січень 2025	виконано
2	Ознайомлення з предметною областю, формулювання мети та задач дослідження, визначення об'єкта та предмета дослідження	лютий 2025	виконано
3	Проектування та розробка загальної архітектури системи, вибір засобів реалізації програмного забезпечення	березень 2025	виконано
4	Розробка інформаційної системи	квітень 2025	виконано
5	Написання пояснювальної записки, урахування зауважень керівника, оформлення згідно вимог	травень 2025	виконано
6	Розробка презентаційних матеріалів та попередній захист кваліфікаційної роботи	травень 2025	виконано
7	Отримання відгуку керівника, рецензії, перевірка на плагіат, нормоконтроль	червень 2025	виконано
8	Підготовка до захисту та захист кваліфікаційної роботи бакалавра	червень 2025	виконано

Виконавець: студентка групи КН-21-1


Група виконавця


Підпис
Вікторія ГОНЧАРУК

Ім'я, ПРІЗВИЩЕ

Керівник: асистент кафедри КН

Науковий ступінь, посада


Підпис
Леонід ВОЗНІЮК

Ім'я, ПРІЗВИЩЕ

Анотація

Тема кваліфікаційної роботи бакалавра: Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання.

Виконавець кваліфікаційної роботи бакалавра: студентка групи КН-21-1 Вікторія ГОНЧАРУК.

Керівник кваліфікаційної роботи бакалавра: асистент кафедри КН Леонід ВОЗНЮК.

Кваліфікаційна робота бакалавра містить:

Пояснювальна записка				Кількість додатків
Сторінок	Рисунків	Таблиць	Джерел інформації	
61	14	2	41	2

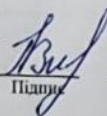
У кваліфікаційній роботі успішно реалізовано актуальне завдання підвищення точності прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання..

Запропонований метод прогнозування залишкового ресурсу літій-іонних акумуляторів охоплює етапи попередньої обробки часових рядів, виокремлення інформативних ознак та формування прогнозу деградації.

Розроблений метод може застосовуватись у системах управління батареями для своєчасного виявлення акумуляторів із ризиком швидкої деградації та формування оптимальних режимів експлуатації.

Ключові слова: літій-іонні акумулятори, прогнозування залишкового ресурсу, часові ряди, нейронна мережа LSTM, машинне навчання.

Виконавець: студентка групи КН-21-1
Група виконавця


Підпис

Вікторія ГОНЧАРУК
Ім'я, ПРІЗВИЩЕ

Зміст

Перелік скорочень.....	7
Вступ.....	8
Розділ 1 Характеристика області прогнозування залишкового ресурсу літій-іонних акумуляторів	10
1.1 Аналіз сучасного стану деградації літій-іонних акумуляторів.....	10
1.2 Методи збору та попередньої обробки даних.....	12
1.3 Методи на основі застосування штучного інтелекту	13
1.4 Порівняльний аналіз методів прогнозування	17
1.5 Мета, задачі до реалізації інформаційної системи	18
Розділ 2 Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання.....	19
2.1 Схема методу прогнозування залишкового ресурсу літій-іонних акумуляторів.....	19
2.2 Архітектурне рішення для прогнозування залишкового ресурсу літій-іонних акумуляторів	29
2.3 Структурні складові інформаційної системи.....	32
2.4 Елементи допоміжної архітектури системи	38
2.5 Висновок до розділу 2.....	40
Розділ 3 Експериментальне дослідження методу прогнозування залишкового ресурсу літій-іонних акумуляторів	41
3.1 Характеристика набору даних	41
3.2 Програмні засоби розробки інформаційної системи.....	45
3.3 Структура та функціональне призначення програмних складових	46
3.4 Результати досліджень.....	50
3.5 Висновок до розділу 3.....	56
Висновок.....	58
Перелік посилань	60
ДОДАТКИ	1

Перелік скорочень

Скорочення, термін, позначення	Пояснення
RUL	Remaining Useful Life – залишковий ресурс
КРБ	Кваліфікаційна робота бакалавра
LSTM	Long Short-Term Memory – довга короткочасна пам'ять
SOH	State of Health – стан здоров'я акумулятора
MAE	Mean Absolute Error – середня абсолютна помилка
RMSE	Root Mean Square Error – середньоквадратична помилка
CNN	Convolutional Neural Network – згорткова нейронна мережа
API	Application Programming Interface – програмний інтерфейс додатку
BMS	Battery Management System – система управління батареями

Вступ

Кваліфікаційна робота бакалавра присвячена розробці методу прогнозування залишкового ресурсу літій-іонних акумуляторів на основі машинного навчання з використанням нейронних мереж. У роботі запропоновано підхід, який дозволяє аналізувати часові ряди вимірювань напруги, струму та часу для визначення поточного стану акумулятора та прогнозування його майбутньої деградації.

Актуальність – використання літій-іонних акумуляторів стрімко зростає в різноманітних галузях - від портативної електроніки до електромобілів та систем збереження різного виду енергії. За прогнозами аналітиків, світовий ринок літій-іонних акумуляторів досягне обсягу в 250 мільярдів доларів до 2030 року. При цьому проблема деградації акумуляторів та неочікуваного виходу з ладу залишається критичною для безпеки, надійності систем, що їх використовують.

Деградація літій-іонних акумуляторів значно впливає на тривалість експлуатації та продуктивність електронних пристроїв, викликаючи зниження ємності, підвищення внутрішнього опору, скорочення часу роботи та потенційні ризики безпеки. Фінансові наслідки передчасного виходу з ладу акумуляторів є суттєвими – від вартості заміни до простоїв обладнання та втрати продуктивності. За оцінками експертів, економічні втрати через непередбачуваний вихід з ладу акумуляторних систем складають мільярди доларів щорічно.

Особливу актуальність проблема прогнозування залишкового ресурсу акумуляторів набуває в контексті стрімкого розвитку електромобільності та відновлюваної енергетики. Акумуляторна батарея є найдорожчим компонентом електромобіля, складаючи до 40% його вартості, а системи збереження енергії з використанням літій-іонних акумуляторів стають ключовим елементом енергетичних мереж з високою часткою відновлюваних джерел. Одночасно з цим, механізми деградації акумуляторів є складними, багатofакторними та

залежать від специфічних умов експлуатації конкретного пристрою, що ускладнює прогнозування їх залишкового ресурсу.

Об’єкт дослідження – процес прогнозування залишкового ресурсу літій-іонних акумуляторів засобами машинного навчання.

Предмет дослідження – методи та алгоритми прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням технологій машинного навчання на основі аналізу.

Мета кваліфікаційної роботи бакалавра – підвищення точності прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання.

Завдання кваліфікаційної роботи бакалавра:

- дослідити сучасний стан та проблеми в галузі оцінювання деградації та прогнозування залишкового ресурсу літій-іонних акумуляторів;
- провести аналіз існуючих методів та алгоритмів прогнозування залишкового ресурсу акумуляторів, визначити їх переваги та обмеження;
- розробити метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням нейронної мережі;
- спроектувати архітектуру інформаційної системи для збору, обробки даних та прогнозування залишкового ресурсу акумуляторів;
- експериментально дослідити розроблений метод прогнозування.

Розділ 1 Характеристика області прогнозування залишкового ресурсу літій-іонних акумуляторів

1.1 Аналіз сучасного стану деградації літій-іонних акумуляторів

Літій-іонні акумулятори (ЛІА) є ключовим компонентом сучасних електронних пристроїв, електромобілів та систем накопичення енергії. Точне прогнозування залишкового ресурсу (Remaining Useful Life, RUL) цих акумуляторів має критичне значення для забезпечення безпеки, оптимізації використання та планування технічного обслуговування. Залишковий ресурс визначається як час або кількість циклів заряду-розряду до моменту, коли характеристики акумулятора знизяться до рівня, що не відповідає встановленим критеріям продуктивності.

Значна увага дослідників у галузі прогнозування залишкового ресурсу літій-іонних акумуляторів зосереджена на розвитку методів, заснованих на машинному навчанні. Ця тенденція обумовлена здатністю алгоритмів ШІ виявляти нелінійні співвідношення в даних без необхідності детального моделювання фізико-хімічних процесів, що відбуваються в акумуляторах під час їх експлуатації [1–4].

Традиційні методи прогнозування RUL спираються на фізичні моделі процесів деградації акумуляторів, що вимагає глибокого розуміння електрохімічних процесів та точного моделювання [5, 6]. Однак такі моделі часто недостатньо точні для практичного застосування через складність процесів старіння та залежність від багатьох факторів. У зв'язку з цим, методи ШІ отримали значний розвиток у цій області завдяки здатності працювати зі складними, нелінійними залежностями без необхідності побудови детальних фізичних моделей [7–9].

Розвиток методів машинного навчання для прогнозування RUL супроводжується розробкою нових підходів до збору та обробки даних, вибору інформативних ознак та створення моделей. Значний прогрес досягнуто в галузі

нейронних мереж, ансамблевих методів та гібридних підходів, що поєднують фізичні моделі з алгоритмами машинного навчання [10, 11].

Сучасні дослідження у сфері оцінки стану здоров'я акумуляторів вказують на важливість розробки надійних моделей, що враховують різноманітні фактори деградації [12–14]. Так, у роботі [13] підкреслюється, що традиційні методи не беруть до уваги складність електрохімічних процесів, що обмежує їх точність при довгострокових прогнозах. Застосування глибокого навчання дозволяє подолати це обмеження завдяки здатності виявляти складні залежності в даних. Проте істотним недоліком таких моделей є їх "чорноскринність", що ускладнює інтерпретацію результатів та верифікацію моделі.

Механізми деградації на катоді та аноді, включаючи розростання твердоелектролітного шару (SEI), літійове покриття, втрату активного матеріалу та структурні зміни електродів, детально аналізуються в дослідженнях [15–17]. Автори зазначають, що ці процеси складно моделювати окремо, що робить привабливим використання методів машинного навчання для обґрунтованого прогнозування.

Зміни температури, глибини розряду та швидкості заряду-розряду на швидкість деградації розглянуто в роботах [17–19]. Ці фактори є критичними вхідними параметрами для моделей машинного навчання. Дослідження [19] підтвердило, що поєднання цих факторів має нелінійний вплив на швидкість старіння, що ускладнює традиційне моделювання. Однак недоліком багатьох моделей залишається недостатнє врахування історії експлуатації акумулятора, що може призводити до значних помилок у прогнозах.

Різні підходи до отримання найбільш інформативних параметрів для моделей машинного навчання запропоновано в роботах [20–22]. Для врахування різних аспектів деградації розроблено багаторівневі моделі оцінки стану здоров'я акумуляторів [13, 23]. Ці моделі поєднують дані про зміну ємності, внутрішнього опору та інших параметрів для формування комплексної оцінки стану акумулятора. Проте, як зазначено в [24], подібні підходи часто вимагають

складного та дорогого обладнання для різних даних, що обмежує їх практичне застосування.

1.2 Методи збору та попередньої обробки даних

Якість та репрезентативність даних є визначальними факторами успішного застосування методів ШІ для оцінювання RUL. Сучасні підходи до збору та попередньої обробки даних спрямовані на забезпечення достатнього обсягу інформації для навчання моделей, зниження шумів вимірювань та виділення найбільш інформативних ознак.

У дослідженні [5] та співавтори використали дані про 124 комерційних літій-іонних елементів, які циклували до втрати 20% початкової ємності. Автори продемонстрували можливість точного прогнозування терміну служби лише на основі перших кількох циклів заряду-розряду. Проте для отримання таких результатів потрібні високоточні вимірювальні системи, що не завжди доступні в промислових умовах.

Методи збору даних в реальному часі, включаючи вимірювання напруги, струму, температури та імпедансну спектроскопію, розглянуто в роботах [8, 25, 26]. Однак значна кількість відомих систем збору даних не забезпечують достатньої частоти вимірювань або мають обмежену точність, що негативно впливає на якість прогнозів.

Проблема обмеженості експериментальних даних, особливо для довготривалих випробувань, залишається актуальною. Для її вирішення розробляються методи розширення набору даних [10, 27, 28]. В роботі [27] запропоновано підхід на основі Гаусівських процесів для прогнозування стану здоров'я акумуляторів з урахуванням невизначеності даних. Цей метод дозволяє працювати з обмеженими наборами даних, але вимагає ресурсів обчислення для великих масивів інформації.

Методики нормалізації та стандартизації даних з різних джерел та типів акумуляторів розглянуто в роботах [12, 29].

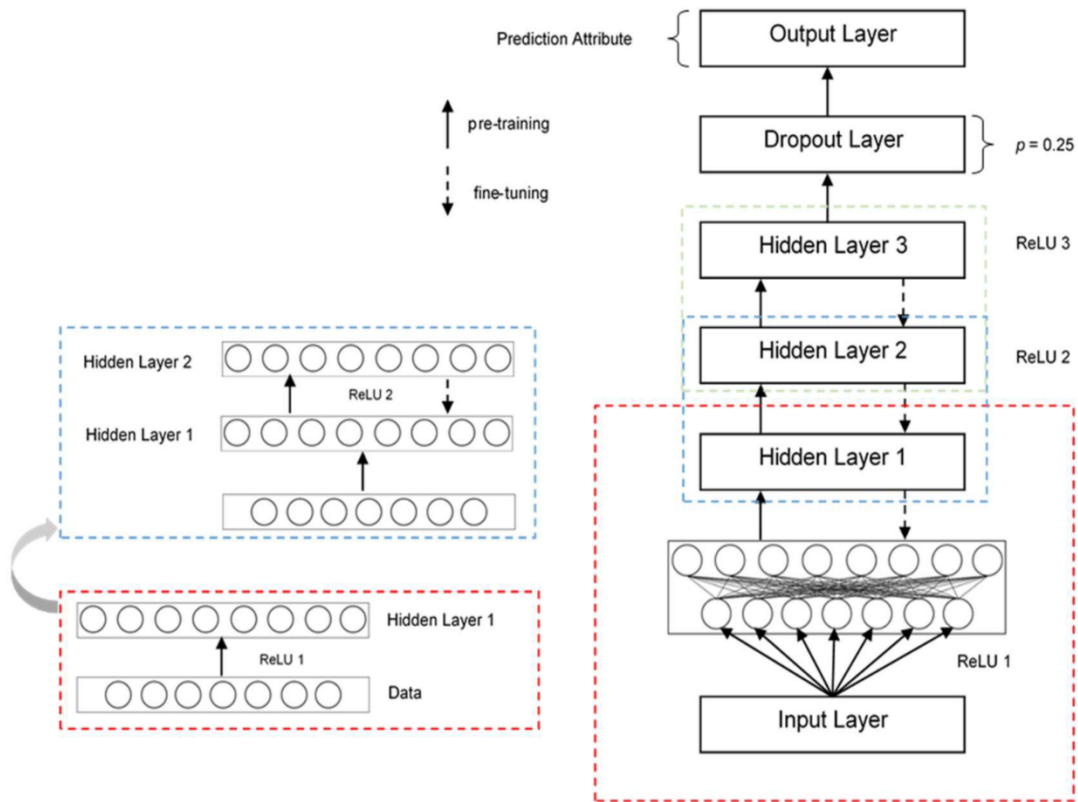


Рисунок 1.1 – Модифікована модель глибокої нейронної мережі [12]

Вплив періодичності вимірювань на точність прогнозування RUL досліджено в роботах [30, 31]. Встановлено, що надто висока частота може призвести до перенавчання, тоді як надто низька — до втрати важливої інформації про динаміку деградації. Новітні підходи до отримання даних включають використання технологій Інтернету речей (IoT) та розподілених систем моніторингу [19, 32–35].

1.3 Методи на основі застосування штучного інтелекту

Штучні нейронні мережі довели свою доцільність у прогнозуванні залишкового ресурсу літій-іонних акумуляторів завдяки здатності виявляти складні нелінійні результати. Серед різноманітних архітектур нейронних мереж

особливу увагу розробників привертають рекурентні нейронні мережі різного виду, згорткові нейронні мережі різного проектування та їх гібридні варіанти.

Високу точність при роботі з даними про деградацію акумуляторів продемонстрували архітектури типу Long Short-Term Memory (LSTM) і Gated Recurrent Unit (GRU) [28, 36]. В роботі [9] запропоновано архітектуру LSTM для прогнозування RUL, яка враховує різні залежності в даних. Модель перевершила традиційні підходи, показавши на 15% вищу точність. Однак ця модель потребує значного обсягу даних для навчання та обчислювальних ресурсів, що ускладнює її реалізацію в системах з обмеженими ресурсами.

В дослідженні [28] представлено підхід на основі онлайн-методу з використанням важливості вибірки та НМ для оцінки залишкового ресурсу літій-іонних акумуляторів. Цей метод показує хорошу точність при роботі з обмеженими даними, але вимагає ретельного налаштування параметрів, що ускладнює його автоматизацію.

Інноваційний підхід на основі мереж для обробки даних імпедансної спектроскопії представлено в роботі [8]. Застосування 2D-згорток для виявлення залежностей у спектрах дозволило виявити ранні ознаки деградації, невидимі для традиційних методів. Але підхід вимагає спеціалізованого обладнання для збору даних та значних обчислювальних ресурсів для навчання моделі.

Перспективним напрямком є розробка гібридних архітектур, що поєднують переваги різних типів нейронних мереж [10, 13, 37]. Так запропоновано метод оцінки ємності літій-іонних акумуляторів на основі машинного навчання з використанням багатоканальних профілів заряду. Цей метод дозволяє використовувати різні ресурси, але його точність значно залежить від якості вимірювань, що не завжди може бути забезпечено в промислових умовах.

Підхід на основі комбінування методу хибних найближчих сусідів з гібридною нейронною мережею представлено в дослідженні [13]. Цей підхід

дозволив досягти високої точності прогнозування, але має обмежену інтерпретованість, що ускладнює його застосування в критичних системах.

Значний інтерес представляє використання автоенкодерів та мереж глибокого переконання (Deep Belief Networks) для зниження розмірності даних та виявлення прихованих ознак деградації [11, 38]. Запропоновано модель на основі мережі глибокого переконання для моделювання деградації літій-іонних акумуляторів. Хоча цей підхід дозволяє результативно отримувати стан акумулятора, він вимагає багато даних для навчання та інтерпретації результатів.

Особливу увагу дослідники приділяють проблемі перенавчання нейронних мереж та їх здатності до узагальнення на нові типи акумуляторів [13, 39]. В роботах запропоновано різні методики регуляризації та валідації моделей для підвищення їх стійкості та надійності. Однак, навіть з використанням передових методів регуляризації, нейромережеві моделі можуть давати значні помилки при екстраполяції за межі діапазону навчальних даних.

Проблема інтерпретованості результатів залишається одним з головних обмежень нейромережевих методів [36, 40, 41]. В роботі [36] зроблено спробу підвищити інтерпретованість моделі через аналіз активації нейронів та їх зв'язку з фізичними процесами деградації. Проте цей підхід потребує подальшого розвитку для забезпечення повної прозорості та зрозумілості отриманих прогнозів.

Серед регресійних методів особливу увагу дослідників привертає Гаусівська регресія (Gaussian Process Regression, GPR) [6, 7]. В роботі [6] запропоновано новий підхід на основі GPR для оцінки стану здоров'я літій-іонних акумуляторів з використанням кривих заряду. Модель демонструє високу точність, але має обмеження при роботі з великими наборами даних через обчислювальну складність. Розвиток цього підходу представлено в роботі [7], де GPR доповнено ядром з автоматичним визначенням релевантності для прогнозування календарного старіння акумуляторів. Цей метод дозволяє

ідентифікувати найбільш інформативні ознаки, але його точність знижується для акумуляторів з нелінійними профілями деградації.

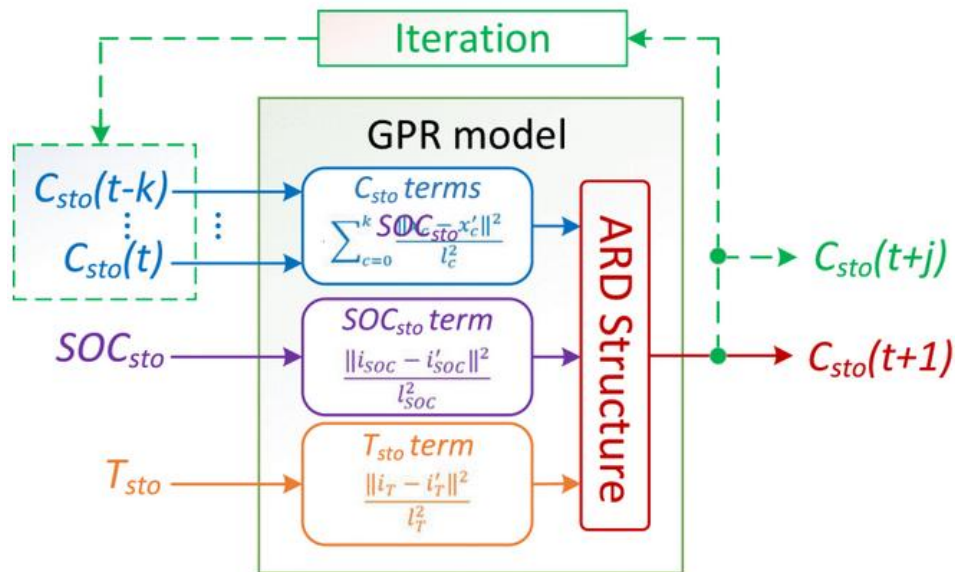


Рисунок 1.2 – Модель для прогнозування старіння [7]

Багатомасштабний фреймворк для прогностичного стану здоров'я літій-іонних акумуляторів з використанням модифікованої GPR та нелінійної регресії представлено в роботі [23]. Цей підхід дозволяє враховувати різні часові масштаби процесів деградації, але вимагає ретельного налаштування параметрів для конкретних типів акумуляторів.

Інший хороший напрямок використання регресії на основі опорних векторів (Support Vector Regression, SVR) [20, 21, 24]. В роботі [20] запропоновано гібридну модель на основі SVR та диференціальної еволюції для прогнозування RUL. Ансамблеві методи, такі як Random Forest, Gradient Boosting та AdaBoost, також активно застосовуються для прогнозування RUL [22, 27]. Так запропоновано підхід із застосуванням ШІ та часткової фільтрації для оцінки стану літій-іонних акумуляторів. Взаємодіючу множинну модель з частковим фільтром для прогнозування стану літій-іонних акумуляторів представлено в дослідженні [29]. В роботі [35] запропоновано новий показник здоров'я для онлайн-прогнозування залишкового ресурсу літій-іонних

аккумуляторів. Незважаючи на високий потенціал гібридних методів, вони мають ряд обмежень, зокрема, складність інтеграції різних типів моделей та високі вимоги до обчислювальних ресурсів [13, 15]. Ці аспекти детально розглянуто в зазначених роботах, де запропоновано різні підходи до оптимізації гібридних моделей. Проте, існуючі методи оптимізації часто призводять до компромісу між точністю та обчислювальною складністю, що вказує на необхідність розробки нових підходів.

1.4 Порівняльний аналіз методів прогнозування

Для об'єктивної оцінки різних методів прогнозування RUL необхідно порівняти їх за спільними критеріями. В сучасних дослідженнях особлива увага приділяється таким аспектам, як точність прогнозування, інтерпретованість результатів та здатність до узагальнення на нові типи аккумуляторів або умови експлуатації.

Комплексне порівняння різних методів машинного навчання представлено в ряді робіт [12, 15]. Так проведено порівняння результатів роботи ШІ з відомими підходами для прогнозування RUL. Результати показують, що глибокі нейронні мережі забезпечують вищу точність при достатній кількості даних, але поступаються більш простим моделям при обмежених наборах даних. Крім того, нейромереві моделі мають низьку інтерпретованість, що робить складним їх застосування в різних системах.

В дослідженні [7] показано, що методи із використанням регресії демонструють найкращі результати при обмеженій кількості даних завдяки здатності оцінювати невизначеність прогнозів. Але методи мають високу обчислювальну складність, що обмежує їх застосування в повсякденних часу. В дослідженні [15] підкреслюють, що гібридні методи, які поєднують фізичні моделі з машинним навчанням, забезпечують найкращий баланс між точністю та інтерпретованістю. Проте ці методи вимагають детального знання фізичних

процесів деградації, що може бути проблематичним для нових типів акумуляторів.

Порівняння точності різних підходів до прогнозування RUL на основі аналізу реальних даних представлено в роботах [12, 13]. Для практичних застосувань з обмеженими ресурсами більш придатними є спрощені моделі з невеликим зниженням точності.

1.5 Мета, задачі до реалізації інформаційної системи

Відповідно до проведеного аналізу метою роботи є підвищення точності прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання.

Для цього потрібно реалізувати такі завдання:

- дослідити сучасний стан та проблеми в галузі оцінювання деградації та прогнозування залишкового ресурсу літій-іонних акумуляторів;
- провести аналіз існуючих методів та алгоритмів прогнозування залишкового ресурсу акумуляторів, визначити їх переваги та обмеження;
- розробити метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням нейронної мережі;
- спроектувати архітектуру інформаційної системи для збору, обробки даних та прогнозування залишкового ресурсу акумуляторів;
- експериментально дослідити розроблений метод прогнозування.

Розділ 2 Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання

2.1 Схема методу прогнозування залишкового ресурсу літій-іонних акумуляторів

Розроблений метод прогнозування залишкового ресурсу літій-іонних акумуляторів призначений для одержання прогнозованого значення залишкового ресурсу (RUL - Remaining Useful Life) акумулятора шляхом аналізу часових рядів вимірювань напруги, струму та часу під час зарядно-розрядних циклів. Основна концепція методу полягає у виконанні послідовності взаємопов'язаних етапів, спрямованих на перетворення первинних даних вимірювань у високорівневі інформативні ознаки, які потім використовуються для побудови прогностичної моделі на базі нейронної мережі архітектури LSTM.

Особливо важливою перевагою розробленого методу є можливість прогнозування залишкового ресурсу акумуляторів без необхідності прямого вимірювання ємності. Сучасні підходи до оцінки стану літій-іонних акумуляторів найчастіше базуються на вимірюванні ємності, яке потребує спеціального обладнання та зупинки експлуатації акумулятора, що робить такі підходи непрактичними для систем реального часу та вбудованої діагностики. Запропонований метод спирається виключно на параметри, які можуть бути отримані безпосередньо під час звичайної експлуатації акумулятора, що значно розширює сферу його практичного застосування.

Метод прогнозування залишкового ресурсу літій-іонних акумуляторів поділяється на чотири логічно пов'язані етапи, кожен з яких виконує специфічні завдання в рамках загального алгоритму прогнозування.

Перший етап – попередня обробка даних спрямований на підготовку часових рядів вимірювань до подальшого аналізу. Другий етап полягає у створенні інформативних ознак на основі оброблених даних. Третій етап присвячений розробці архітектури LSTM-мережі, яка враховує специфіку задачі

прогнозування деградаційних процесів в акумуляторах. Четвертий етап – це навчання та валідація розробленої моделі для отримання надійних прогнозів залишкового ресурсу акумулятора.

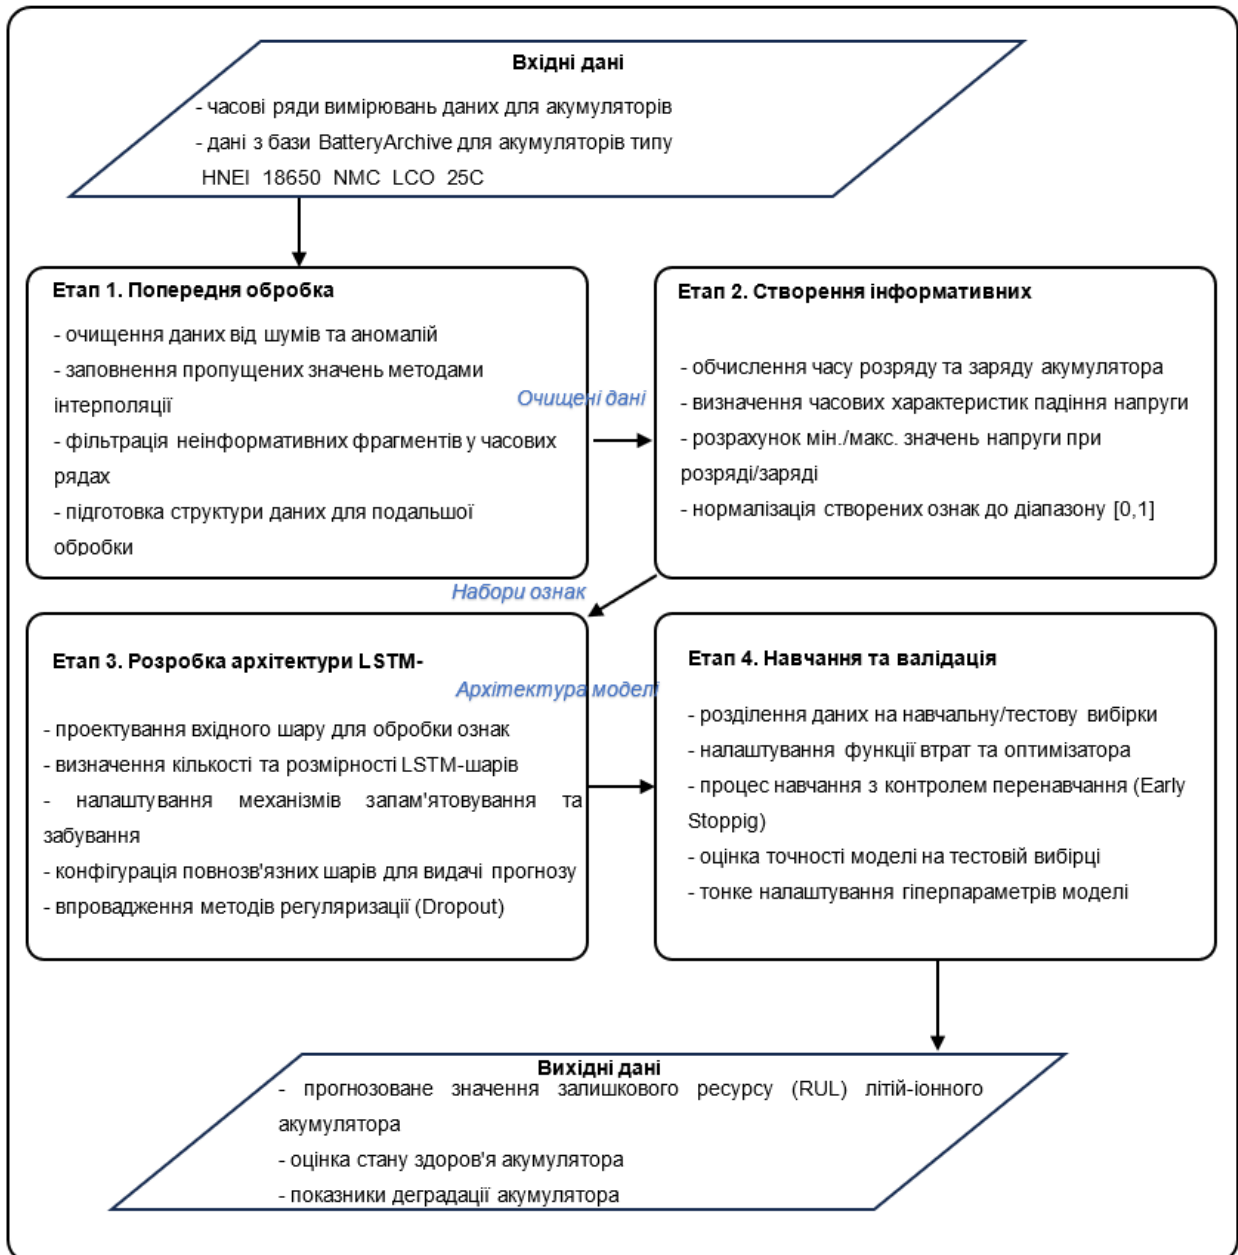


Рисунок 2.1 – Схема методу прогнозування залишкового ресурсу літій-іонних акумуляторів

За вхідні дані для роботи методу використовуються часові ряди вимірювань параметрів літій-іонних акумуляторів з бази даних BatteryArchive

для акумуляторів типу HNEI_18650_NMC_LCO_25C. База даних містить результати експериментів, проведених Гавайським інститутом природної енергії, де досліджувались акумулятори під час численних циклів заряду-розряду. Ці дані включають записи про напругу, струм, час та інші параметри, що характеризують процеси в акумуляторах протягом їх життєвого циклу.

Вхідними даними для першого етапу є необроблені часові ряди вимірювань напруги, струму та часу. Важливо відзначити, що якість та обсяг вхідних даних дуже впливають на прогнозування. Чим більша кількість даних і циклів заряду-розряду доступна для аналізу, тим кращими будуть результати прогнозування залишкового ресурсу. В ідеальному випадку, бажано мати дані з початку експлуатації акумулятора до його деградації до неприйняттого рівня продуктивності.

Розглянемо детально кожен з етапів розробленого методу прогнозування залишкового ресурсу літій-іонних акумуляторів. Перший етап методу – попередня обробка даних часових рядів включає різні заходи, які ідуть на підвищення якості та інформативності вхідних даних. Цей етап надзвичайно важливий, оскільки від якості оброблених даних значною мірою залежить точність прогнозування. Процес попередньої обробки даних складається з деяких пов'язаних кроків.

На першому кроці виконується очищення даних від шумів та аномалій. Вимірювання напруги та струму можуть містити випадкові шуми, викиди та аномальні значення, які виникають внаслідок нестабільної роботи вимірювальної апаратури, електромагнітних завад або інших чинників, що впливають на точність вимірювань. Для видалення шумів застосовуються методи фільтрації сигналів, такі як медіанна фільтрація та фільтр ковзного середнього. Для виявлення та видалення аномальних значень використовуються статистичні методи, зокрема метод Z-оцінки та метод межквартильного розмаху. Очищені від шумів та аномалій дані дають більш точне уявлення про реальні процеси, що відбуваються в акумуляторі.

Другий крок першого етапу полягає у заповненні пропущених значень методами інтерполяції. У вхідних даних можуть бути пропуски, спричинені тимчасовими збоями вимірювальної апаратури або іншими технічними проблемами. Для забезпечення безперервності даних та можливості їх подальшого аналізу необхідно заповнити ці пропуски. В розробленому методі для цього використовуються методи інтерполяції, такі як лінійна інтерполяція та інтерполяція сплайнами. Вибір конкретного методу інтерполяції залежить від характеру даних та розміру пропусків.

Третій крок – фільтрація неінформативних фрагментів у часових рядах. Не всі фрагменти часових рядів однаково інформативні для прогнозування залишкового ресурсу акумуляторів. Наприклад, дані, зібрані під час перехідних процесів або нестабільних режимів роботи, можуть містити шуми та викривлення, які не відображають реальний стан акумулятора. Тому важливо відфільтрувати такі фрагменти та зосередитися на найбільш інформативних частинах циклів заряду-розряду. Для цього застосовуються методи сегментації часових рядів та аналізу характерних точок кривих заряду-розряду.

Четвертий крок першого етапу – підготовка структури даних для подальшої обробки. На цьому кроці оброблені дані організуються у формат, зручний для подальшого аналізу та вилучення ознак. Це включає нормалізацію даних за часом, вирівнювання кривих заряду-розряду та створення уніфікованої структури даних, яка забезпечує роботу алгоритмів на наступних етапах.

Результатом першого етапу є очищені, безперервні та структуровані часові ряди, які точно відображають процеси, що відбуваються в акумуляторі протягом циклів заряду-розряду.

Другий етап методу – створення інформативних ознак на основі оброблених даних – є ключовим для прогнозування залишкового ресурсу акумуляторів. На цьому етапі з очищених та структурованих часових рядів вилучаються високорівневі ознаки, які характеризують стан акумулятора та можуть бути застосовні для прогнозування його роботи .

Безпосереднє використання змінних напруги, струму та часу як входів для моделі прогнозування не є доцільним з кількох причин. По-перше, розмірність цих даних надзвичайно велика, що ускладнює навчання моделі та може бути перенавчене. По-друге, необроблені дані вимірювань містять багато надлишкової інформації, яка не має прямого відношення до деградаційних процесів в акумуляторі. По-третє, важливі для прогнозування закономірності часто приховані у взаємозв'язках між різними параметрами та їх динамікою протягом циклів заряду-розряду. Тому необхідно створити нові, більш інформативні ознаки, які відображають стан акумулятора та його деградацію з часом.

В розробленому методі формуються сім інформативних ознак, які характеризують різні аспекти роботи акумулятора. Першою ознакою є час розряду – загальний час, необхідний для розряду акумулятора в одному циклі. Ця ознака є прямим індикатором ємності акумулятора, оскільки зі зменшенням ємності внаслідок деградації зменшується і час розряду. Однак, на відміну певного з проміжками часу вимірювання ємності, час розряду можна визначити під час звичайної експлуатації акумулятора без спеціального обладнання.

Другою ознакою є час при нарузі 4,15 В – час, протягом якого напруга акумулятора підтримувалася на рівні 4,15 В під час заряду. Ця ознака відображає здатність акумулятора утримувати заряд на високих рівнях напруги, яка зменшується з деградацією акумулятора.

Третя ознака – час при постійному струмі – час, протягом якого акумулятор заряджався при постійному струмі. Більшість літій-іонних акумуляторів заряджаються за протоколом постійного струму/постійної напруги (CC/CV), і тривалість фази постійного струму може бути індикатором стану акумулятора.

Четверта ознака – час падіння напруги з 3,6 В до 3,4 В – характеризує швидкість розряду акумулятора в середньому діапазоні напруг. Зі старінням

акумулятора цей час зазвичай зменшується, що відображає збільшення внутрішнього опору.

П'ята ознака – максимальна напруга розряду – найвище значення напруги, зареєстроване під час розряду акумулятора. Ця ознака може вказувати на зміни в електрохімічних процесах всередині акумулятора, пов'язані з деградацією.

Шоста ознака – мінімальна напруга заряду – найнижче значення напруги, зареєстроване під час заряду акумулятора. Як і попередня ознака, вона відображає електрохімічні зміни в акумуляторі.

Сьома ознака – час заряду – загальний час, необхідний для повного заряду акумулятора в одному циклі. Зі старінням акумулятора час заряду зазвичай збільшується через збільшення внутрішнього опору та зменшення заряду.

Після створення цих ознак виконується їх нормалізація для забезпечення хорошого навчання нейронної мережі. Нормалізація необхідна для приведення всіх ознак до єдиного масштабу, що запобігає домінуванню одних ознак над іншими в процесі навчання. В розробленому методі використовується мінімакс-нормалізація, яка перетворює значення ознак до діапазону $[0, 1]$. Нормалізація виконується за формулою:

$$X_{norm} = (X - X_{min}) / (X_{max} - X_{min}), \quad (2.1)$$

де X – значення ознаки, X_{min} та X_{max} – значення мінімальне та максимальне у нашій вибірці.

Результатом другого етапу є набір нормалізованих інформативних ознак, які характеризують стан акумулятора та можуть бути використані для прогнозування його залишкового ресурсу.

Третій етап методу – розробка архітектури LSTM-мережі – спрямований на створення моделі для прогнозування залишкового ресурсу акумуляторів на

основі вилучених інформативних ознак. Вибір архітектури LSTM обумовлений специфікою задачі прогнозування деградаційних процесів в акумуляторах.

LSTM-мережі є певним видом рекурентних нейронних мереж, які спеціально розроблені для обробки послідовностей даних та часових рядів. На відміну від звичайних рекурентних мереж, LSTM-мережі здатні вивчати довгострокові залежності між елементами послідовності, що особливо важливо для прогнозування деградаційних процесів, які розвиваються протягом багатьох циклів заряду-розряду. Структура LSTM-комірки включає механізми запам'ятовування та забування, які дозволяють моделі зберігати важливу інформацію протягом довгого часу та ігнорувати неважливу, що робить LSTM-мережі ідеальними для прогнозування залишкового ресурсу акумуляторів.

Архітектура розробленої LSTM-моделі складається з кількох шарів, кожен з яких виконує специфічні функції в процесі прогнозування. Перший шар – вхідний – приймає сформовані на другому етапі інформативні ознаки. Розмірність вхідного шару визначається кількістю ознак та довжиною послідовності, яка відповідає кількості циклів заряду-розряду, що використовуються для прогнозування.

Наступними є один або кілька LSTM-шарів, які обробляють послідовності даних та вивчають залежності між параметрами акумуляторів та їх залишковим ресурсом. Кількість LSTM-шарів та їх розмірність (кількість нейронів) є важливими гіперпараметрами моделі, які впливають на її здатність вивчати складні залежності у даних. Механізми запам'ятовування та забування в LSTM-комірках налаштовуються під час навчання моделі для оптимального виділення інформації, релевантної для прогнозування залишкового ресурсу.

Після LSTM-шарів розміщуються шари регуляризації, такі як Dropout, які запобігають перенавчанню моделі. Перенавчання є серйозною проблемою для нейронних мереж, особливо при обмеженій кількості навчальних даних, що часто є випадком для задач прогнозування деградації акумуляторів. Метод

Dropout випадковим чином вимикає певний відсоток нейронів під час навчання, що змушує мережу бути більш робастною та менш схильною до перенавчання.

Останнім шаром моделі є повнозв'язний шар (Dense), який перетворює вихід LSTM-шарів у прогнозоване значення залишкового ресурсу. Розмірність цього шару дорівнює одиниці, оскільки метою моделі є прогнозування одного скалярного значення – залишкового ресурсу акумулятора.

Важливим аспектом архітектури є правильний вибір кількості LSTM-шарів та їх розмірності, оскільки від цього залежить здатність моделі вивчати складні залежності у даних. В рамках розробленого методу проводиться експериментальний підбір цих параметрів для забезпечення оптимального балансу між складністю моделі (яка впливає на її здатність вивчати складні залежності) та її здатністю до узагальнення (яка визначає точність прогнозування на нових даних).

Результатом третього етапу є спроектована архітектура LSTM-мережі, готова до навчання на підготовлених даних. Четвертий етап методу – навчання та валідація LSTM-моделі – є завершальним у процесі розробки системи прогнозування залишкового ресурсу акумуляторів. На цьому етапі відбувається налаштування параметрів моделі на основі навчальних даних та оцінка її точності на незалежних тестових даних.

Перший крок четвертого етапу – розділення даних на навчальну та тестову вибірки. Це необхідно для об'єктивної оцінки точності моделі на даних, які не використовувались для навчання. Зазвичай дані розділяються у співвідношенні 80% на 20% для навчання та тестування відповідно. Розділення може виконуватися випадковим чином або за часовою послідовністю, залежно від особливостей даних. У випадку прогнозування залишкового ресурсу акумуляторів, коли важливо враховувати часову послідовність деградаційних процесів, переважно використовується розділення за часовою послідовністю, де ранні цикли використовуються для навчання, а пізні – для тестування.

Другий крок – налаштування функції втрат та оптимізатора. Функція втрат визначає, наскільки прогнози моделі відрізняються від реальних значень, і оптимізатор використовує цю інформацію для налаштування параметрів моделі. Для задачі прогнозування залишкового ресурсу акумуляторів, яка є задачею регресії, зазвичай використовується функція втрат середньоквадратичної помилки. Ця функція штрафує більші відхилення прогнозів від реальних значень сильніше, ніж менші відхилення, що важливо для точного прогнозування залишкового ресурсу. Як оптимізатор зазвичай використовується алгоритм Adam, який поєднує переваги методів адаптивного градієнтного спуску та моментуму, що дозволяє навчати складні нейронні мережі.

Третій крок – процес навчання з контролем перенавчання. Навчання моделі відбувається шляхом ітеративного оновлення її параметрів на основі навчальних даних з метою мінімізації функції втрат. Однак, надмірне підлаштування під навчальні дані може призвести до перенавчання, коли модель добре працює на навчальних даних, але погано узагальнюється на нових даних. Для запобігання перенавчанню використовується метод раннього зупинення, який припиняє процес навчання, коли точність моделі на нашій вибірці перестає покращуватися протягом визначеної кількості епох. Валідаційна вибірка – це частина навчальних даних, яка не використовується для оновлення параметрів моделі, а лише для контролю перенавчання.

Четвертий крок – оцінка моделі на нашій вибірці. Після завершення навчання модель оцінюється на незалежних тестових даних, які не використовувались для навчання. Для оцінки точності використовуються такі метрики як середньоквадратична помилка (RMSE), також застосовна середня абсолютна помилка (MAE) та коефіцієнт детермінації (R^2). Ці метрики дають різні аспекти оцінки точності моделі: RMSE чутлива до великих помилок, MAE дає середню абсолютну помилку прогнозування, а R^2 показує, яку частку варіації цільової змінної пояснює модель.

П'ятий крок – тонке налаштування гіперпараметрів моделі. На базі отриманих результатів точності можна виконати тонке налаштування гіперпараметрів моделі для підвищення її точності. Гіперпараметри – це параметри, які не навчаються під час основного процесу навчання, а визначаються заздалегідь. До гіперпараметрів LSTM-моделі належать шари, нейрони у кожному шарі, як швидко навчається, коефіцієнт регуляризації тощо. Тонке налаштування гіперпараметрів може виконуватися методом підбору або більш системними методами, такими як пошук по сітці або випадковий пошук.

Результатом четвертого етапу є навчена та валідована LSTM-модель, здатна прогнозувати залишковий ресурс літій-іонних акумуляторів на основі інформативних ознак, вилучених з часових рядів вимірювань.

Програмна реалізація розробленого методу прогнозування залишкового ресурсу літій-іонних акумуляторів складається з кількох модулів, кожен з яких відповідає за певний етап або групу етапів. Перший модуль відповідає за попередню обробку даних та створення інформативних ознак (перший і другий етапи методу). Другий модуль забезпечує об'єднання наборів даних від усіх акумуляторів в єдиний набір для навчання нейронної мережі. Третій модуль містить реалізацію LSTM-моделі та функції для її навчання та оцінки (третій і четвертий етапи методу).

Кінцевими результатами роботи методу прогнозування залишкового ресурсу літій-іонних акумуляторів є:

1. Прогнозоване значення залишкового ресурсу літій-іонного акумулятора, виражене в кількості циклів до досягнення кінця життєвого циклу (коли ємність падає нижче встановленого порогу, зазвичай 80% від початкової ємності).
2. Оцінка стану здоров'я акумулятора (State of Health, SOH) у відсотках від початкової ємності, яка вказує на ступінь деградації акумулятора.

3. Візуалізація деградації ємності акумулятора з прогнозом на майбутнє, яка дозволяє наочно представити результати прогнозування та оцінити тенденції деградації.

Аналіз схеми методу, наведеної на рисунку 2.1, дозволяє краще зрозуміти послідовність кроків, необхідних для прогнозування залишкового ресурсу літій-іонних акумуляторів, не заглиблюючись у деталі реалізації окремих алгоритмів. Чітке розуміння вхідних даних, проміжних результатів та кінцевого виходу методу дозволяє спроектувати та розробити інформаційну систему для практичного застосування розробленого методу.

Розроблений метод отримання залишкового ресурсу літій-іонних акумуляторів забезпечує вирішення задачі прогнозування на основі даних, які отримуємо під час звичайної експлуатації акумуляторів, без необхідності прямого вимірювання ємності. Метод базується на чотирьох взаємопов'язаних етапах: попередній обробці даних, створенні інформативних ознак, розробці архітектури LSTM-мережі та її навчанні й валідації. Реалізація цього методу дозволяє створити систему прогнозування залишкового ресурсу акумуляторів, яка може бути інтегрована в різноманітні пристрої та системи, що використовують літій-іонні акумулятори, для забезпечення їх надійної та безпечної експлуатації.

2.2 Архітектурне рішення для прогнозування залишкового ресурсу літій-іонних акумуляторів

Основна концепція розробленого архітектурного рішення полягає у забезпеченні логічно послідовної обробки даних – від їх збору та попередньої обробки до формування інформативних ознак, побудови прогностичної LSTM-моделі та візуалізації результатів. Така модульна структура забезпечує гнучкість, масштабованість та можливість незалежного вдосконалення окремих

компонентів системи, що особливо важливо для сучасних інформаційних систем.

Розроблене архітектурне рішення для системи прогнозування залишкового ресурсу літій-іонних акумуляторів представлено на рисунку 2.2. У складі архітектури можна виділити сім основних функціональних модулів, кожен з яких має своє призначення та місце в загальному процесі прогнозування.

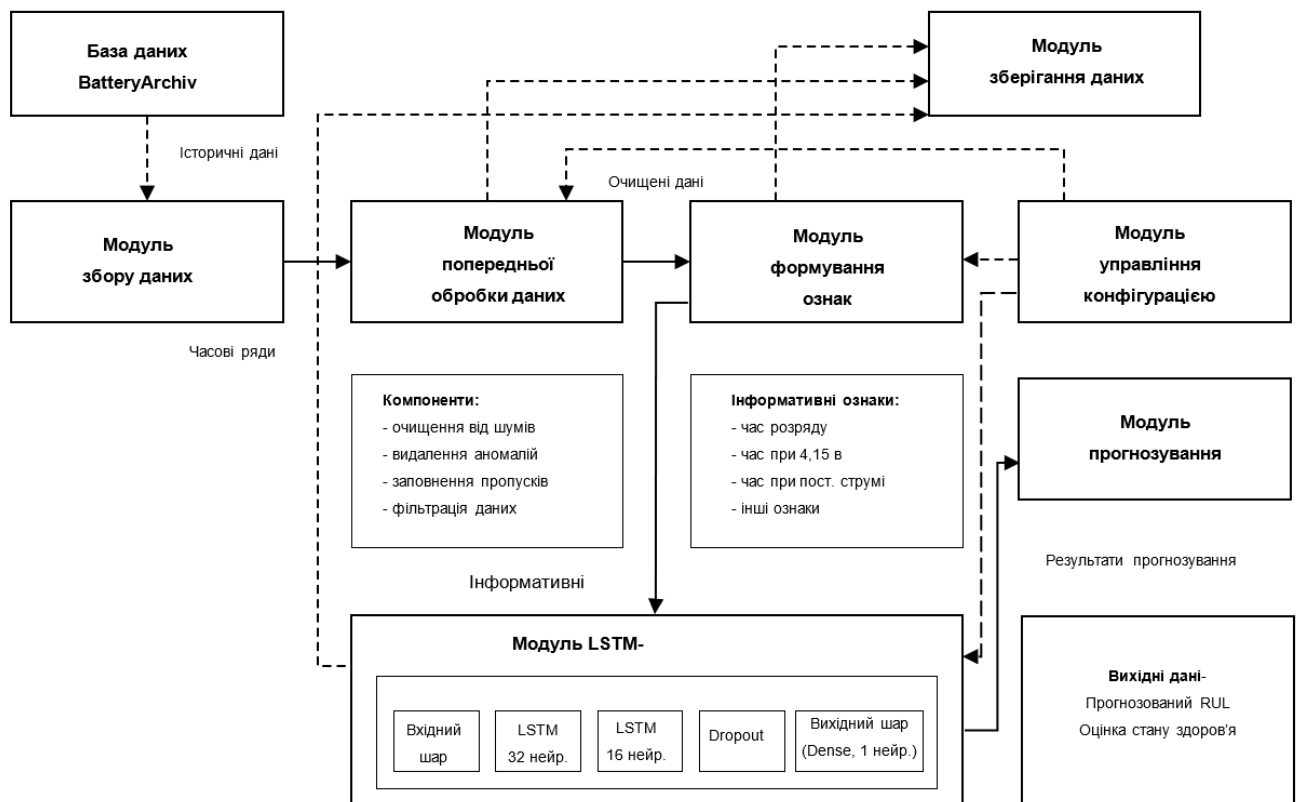


Рисунок 2.2 – Архітектура системи прогнозування залишкового ресурсу літій-іонних акумуляторів

Центром архітектури є джерело даних – база даних BatteryArchive, яка містить експериментальні дані для акумуляторів типу HNEI_18650_NMC_LCO_25C, отримані в результаті довготривалих випробувань. Взаємодія з цією базою даних здійснюється через модуль збору даних, який забезпечує надходження первинних часових рядів вимірювань до системи.

Наступним важливим елементом є модуль оброблення даних, який відповідає за підготовку зібраних часових рядів до подальшого аналізу. Цей модуль має структуру, що включає чотири основні компоненти: очищення від шумів, видалення аномалій, заповнення пропущених значень та фільтрація неінформативних фрагментів даних.

Після попередньої обробки дані надходять до модуля формування ознак, де відбувається створення семи інформативних ознак, які характеризують стан акумулятора. Ці ознаки пізніше використовуються як вхідні дані для прогностичної моделі.

Центральним компонентом архітектури є модуль LSTM-моделі, який забезпечує побудову, навчання та використання нейронної мережі для прогнозування залишкового ресурсу акумуляторів. Архітектура LSTM-мережі включає вхідний шар, два LSTM-шари з 32 та 16 нейронами відповідно, шар Dropout для запобігання перенавчанню та вихідний повнозв'язний шар.

Результати роботи LSTM-моделі передаються до модуля прогнозування та візуалізації, який працює за формуванням кінцевих прогнозів залишкового ресурсу та їх візуальне представлення у зручному для користувача форматі.

Окрім основних модулів, архітектура включає два допоміжні модулі: модуль зберігання даних, який забезпечує отримання результатів роботи системи, та модуль управління конфігурацією, який дозволяє налаштовувати параметри системи відповідно до конкретних умов використання.

Архітектурно джерелом даних для системи є база даних BatteryArchive, яка містить результати експериментів, проведених Гавайським інститутом природної енергії. Це база з часових рядів вимірювань параметрів літій-іонних акумуляторів, зокрема напруги, струму та часу, отриманих під час численних зарядно-розрядних циклів.

Модуль збору даних становить собою інтерфейсний компонент, який забезпечує взаємодію системи з джерелом даних. Його основні функції включають:

- встановлення з'єднання з джерелом даних;
- формування та виконання запитів для отримання необхідних даних;
- конвертацію отриманих даних до уніфікованого формату, зручного для подальшої обробки;
- поетапне завантаження даних для оптимізації використання обчислювальних ресурсів;
- первинну верифікацію даних для виявлення очевидних помилок або пошкоджень.

Важливою особливістю цього модуля є його здатність працювати не лише з історичними даними з бази даних, і також з батарейними системами управління (BMS). Це дозволяє використовувати розроблену систему як для ретроспективного аналізу даних, так і для стану акумуляторів під час їх експлуатації.

2.3 Структурні складові інформаційної системи

Розглянемо структурні складові архітектури інформаційної системи. Модуль оброблення даних є критично важливим компонентом архітектури, оскільки від якості підготовки даних значною мірою залежить точність прогнозування. Цей модуль архітектурно складається з чотирьох компонентів, кожен з них робить специфічну функцію в процесі підготовки даних:

Компонент очищення від шумів призначений для видалення з часових рядів випадкових шумів, які виникають внаслідок електромагнітних завад, нестабільної роботи вимірювальної апаратури або інших факторів. Архітектурно цей компонент побудований за принципом конвеєра фільтрів, де кожен фільтр реалізує певний метод очищення даних. Зокрема, застосовуються методи медіанної фільтрації, фільтр ковзного середнього для видалення шумів різної природи.

Компонент видалення аномалій відповідає за виявлення та видалення аномальних значень, які можуть спотворити результати аналізу. Архітектурно цей компонент побудований на основі статистичних методів аналізу даних та міжквартильного розмаху. Для кожного часового ряду автоматично визначаються статистичні параметри розподілу, на основі яких ідентифікуються та обробляються аномальні значення.

Компонент заповнення пропущених значень забезпечує відновлення безперервності часових рядів у випадку наявності пропусків у даних. Архітектурно цей компонент реалізує різні функції інтерполяції, такі як лінійна інтерполяція, які застосовуються в залежності від характеру даних та розміру пропусків. Важливою особливістю цього компонента є здатність автоматично вибрати оптимальний метод інтерполяції на основі аналізу прилеглих до пропуску даних.



Рисунок 2.3 – Схема послідовності етапів обробки даних у підсистемі обробки даних

Компонент фільтрації неінформативних фрагментів відповідає за виділення з часових рядів найбільш інформативних частин, які найкраще

характеризують стан акумулятора. Архітектурно цей компонент побудований на основі алгоритмів сегментації часових рядів та аналізу характерних точок кривих заряду-розряду. Особливу увагу приділено виділенню ключових фаз циклів заряду-розряду, таких як фаза постійного струму, фаза постійної напруги та фази релаксації.

Архітектурною особливістю модуля попередньої обробки даних є його адаптивність до різних типів даних та умов вимірювань. Модуль включає механізми автоматичного налаштування параметрів обробки на основі аналізу характеристик вхідних даних, що дозволяє працювати з даними різної якості та походження.

Модуль формування ознак є одним з ключових елементів архітектури, оскільки він відповідає за створення інформативних ознак, які безпосередньо використовуються для прогнозування залишкового ресурсу акумуляторів. Архітектурно цей модуль побудований як сукупність спеціалізованих екстракторів ознак, кожен з яких відповідає за обчислення певної характеристики акумулятора.

Окрім екстракторів ознак, модуль формування ознак включає компонент нормалізації, який приводить значення ознак до єдиного масштабу, що необхідно для навчання нейронної мережі. Архітектурно цей компонент реалізує мінімакс-нормалізацію, де значення кожної ознаки перетворюються до діапазону $[0, 1]$.

Важливою архітектурною особливістю модуля формування ознак є його розширюваність – архітектура дає змогу отримувати нові екстрактори ознак та модифікувати існуючі, що забезпечує можливість адаптації системи до специфічних умов використання та врахування додаткових факторів, які впливають на деградацію акумуляторів.

Модуль LSTM-моделі є центральним компонентом архітектури з точки зору прогностичних можливостей системи. Цей модуль відповідає за побудову, навчання та використання нейронної мережі архітектури LSTM для

прогнозування залишкового ресурсу акумуляторів. Архітектурно модуль складається з кількох взаємопов'язаних компонентів, кожен з яких виконує специфічну функцію.

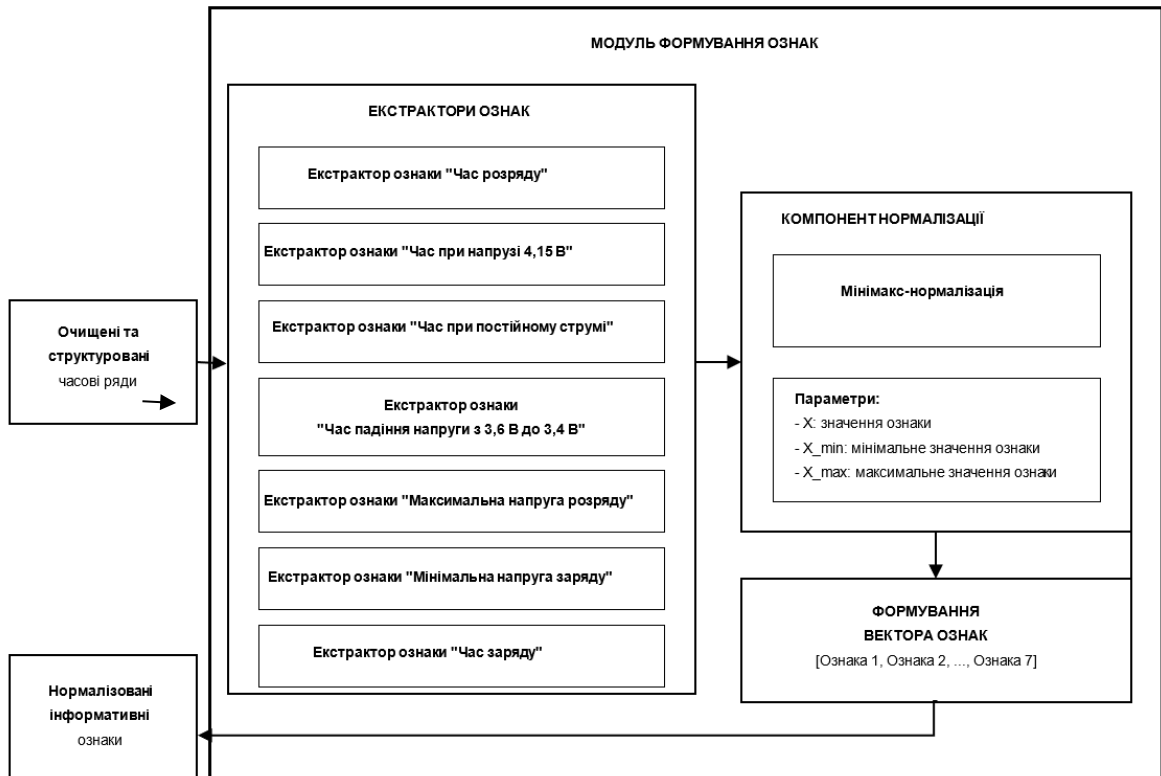


Рисунок 2.4 – Схема модуля формування інформативних ознак для прогнозування залишкового ресурсу акумуляторів

Оснoву модуля становить компонент архітектури нейронної мережі, який визначає структуру та параметри LSTM-моделі. В рамках розробленого архітектурного рішення обрано п'ятишарову конфігурацію нейронної мережі:

1. Шар входу, який приймає сформовані на попередньому етапі інформативні ознаки. Розмірність вхідного шару визначається кількістю ознак (7) та довжиною послідовності, яка відповідає кількості циклів заряду-розряду, що використовуються для прогнозування.

2. Перший LSTM-шар з 32 нейронами, який обробляє вхідні послідовності даних та формує внутрішні представлення залежностей між параметрами акумуляторів та їх деградацією.

3. Другий LSTM-шар з 16 нейронами, який виконує подальшу обробку даних, виділяючи більш складні та абстрактні залежності у даних.
4. Шар Dropout з коефіцієнтом 0.2, який випадковим чином вимикає 20% нейронів під час навчання, що запобігає перенавчанню моделі та підвищує її здатність до узагальнення.
5. Вихідний повнозв'язний шар з одним нейроном, який перетворює внутрішні представлення, сформовані LSTM-шарами, у прогнозоване значення залишкового ресурсу акумулятора.

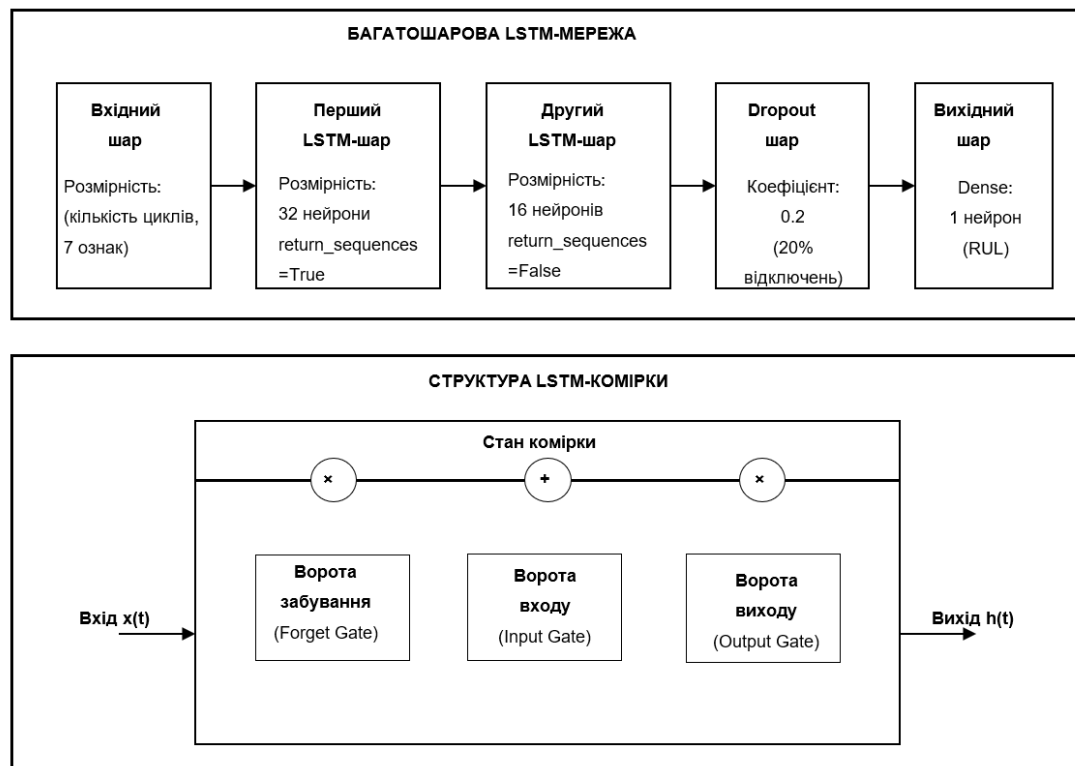


Рисунок 2.5 – Архітектура LSTM-моделі для прогнозування залишкового ресурсу акумуляторів

Окрім компонента архітектури нейронної мережі, модуль включає компонент навчання, який відповідає за налаштування параметрів моделі на основі навчальних даних. Архітектурно цей компонент реалізує оптимізаційний алгоритм Adam, який адаптивно налаштовує швидкість навчання для різних параметрів моделі, що забезпечує навчання та швидку збіжність.

Компонент валідації відповідає за оцінку точності моделі та контроль перенавчання. Архітектурно цей компонент реалізує метод раннього зупинення, який припиняє процес навчання, коли точність моделі на валідаційній вибірці перестає покращуватися протягом визначеної кількості епох. Це дозволяє отримати модель з оптимальною здатністю до узагальнення.

Модуль прогнозування та візуалізації є завершальним компонентом архітектури, який відповідає за використання навченої LSTM-моделі для отримання прогнозів залишкового ресурсу акумуляторів та їх візуальне представлення. Архітектурно цей модуль складається з двох основних компонентів: компонента прогнозування та компонента візуалізації.

Компонент прогнозування забезпечує підготовку вхідних даних для прогнозування, отримання прогнозованих значень залишкового ресурсу та стану здоров'я акумулятора, а також інтерпретацію цих значень. Архітектурно цей компонент реалізує механізм формування вікон даних, який дозволяє використовувати різні дані для майбутніх значень. Хорошою функцією цього компонента є також перетворення прогнозованих значень залишкового ресурсу у більш зрозумілі показники, такі як оцінка стану здоров'я акумулятора (State of Health, SOH) у відсотках від початкової ємності.

Компонент візуалізації відповідає за графічне представлення результатів прогнозування у зручному для аналізу форматі. Архітектурно цей компонент побудований на основі системи шаблонів візуалізації, кожен з яких оптимізований для представлення певного аспекту прогнозування. Основні типи візуалізації включають:

- графіки деградації ємності акумулятора з прогнозом на майбутнє, які дозволяють наочно оцінити тенденції деградації;
- графіки зміни інформативних ознак з часом, які дають уявлення про характер деградаційних процесів;
- порівняльні графіки прогнозованих та реальних значень залишкового ресурсу, які дозволяють оцінити точність прогнозування.

Важливою архітектурною особливістю модуля прогнозування та візуалізації є його інтерактивність – архітектура передбачає можливість налаштування параметрів прогнозування та візуалізації відповідно до потреб користувача, що дозволяє глибше аналізувати стан акумуляторів та приймати обґрунтовані рішення щодо їх експлуатації.

2.4 Елементи допоміжної архітектури системи

Окрім основних функціональних модулів, архітектура системи включає два допоміжні модулі: модуль зберігання даних та модуль управління конфігурацією, які забезпечують підтримку роботи основних компонентів та розширюють функціональні можливості системи.

Модуль зберігання даних відповідає за зберігання первинних часових рядів, оброблених даних, сформованих ознак та результатів прогнозування для їх подальшого використання та аналізу. Архітектурно цей модуль побудований за принципом багаторівневого сховища, де різні типи даних зберігаються з використанням оптимальних для них форматів та структур. Модуль забезпечує доступ до збережених даних, їх резервне копіювання та можливість відновлення в разі збоїв.

Модуль управління конфігурацією дозволяє налаштовувати параметри системи, такі як тип акумуляторів, параметри обробки даних, архітектура нейронної мережі тощо, без необхідності зміни програмного коду. Архітектурно цей модуль побудований на основі системи профілів конфігурації, кожен з яких відповідає певному сценарію використання системи. Модуль забезпечує збереження та автоматичне завантаження конфігураційних параметрів, їх валідацію та можливість динамічної зміни під час роботи системи.

Важливою особливістю допоміжних модулів є їх інтеграція з основними функціональними модулями через систему подій та сповіщень, що дозволяє

гнучко координувати роботу всіх компонентів системи та забезпечує її стабільність та надійність.

Важливою особливістю взаємодії між модулями є використання уніфікованих форматів даних та інтерфейсів, що дає змогу міняти окремі модулі без необхідності зміни інших компонентів системи. Це забезпечує гнучкість та масштабованість архітектури, що особливо важливо для систем, які мають постійно розвиватися та адаптуватися до нових вимог.

Розроблене архітектурне рішення має ряд важливих особливостей, які відрізняють його від існуючих систем прогнозування залишкового ресурсу літій-іонних акумуляторів:

1. Модульність та гнучкість архітектура побудована за модульним принципом, коли є відповідність за конкретну функціональну задачу. Це дозволяє легко модифікувати або замінювати окремі компоненти системи без необхідності перебудови всієї архітектури.

2. Адаптивність до різних типів даних архітектура включає механізми автоматичного налаштування параметрів обробки на основі аналізу характеристик вхідних даних, що дозволяє працювати з даними різної якості та походження.

3. Розширюваність архітектура передбачає можливість легкого додавання нових функціональних модулів та компонентів для розширення можливостей системи, зокрема для врахування додаткових факторів, які впливають на деградацію акумуляторів.

4. Інтеграція з різними джерелами даних архітектура дозволяє додавати пізні дані, такі як бази даних, системи управління акумуляторами (BMS) та інші, без необхідності зміни інших компонентів системи.

5. Відсутність необхідності прямого вимірювання ємності – архітектура базується на методі прогнозування, який не потребує прямого вимірювання ємності акумуляторів, а використовує лише параметри, які можуть бути виміряні під час звичайної експлуатації. Ці особливості роблять розроблене архітектурне

рішення хорошим інструментом для прогнозування ресурсу літій-іонних акумуляторів.

2.5 Висновок до розділу 2

У розділі роботи представлено підхід до прогнозування стану літій-іонних акумуляторів та оцінювання їхнього залишкового ресурсу з використанням технологій глибинного навчання.

Ключовою перевагою розробленого підходу є відмова від необхідності прямого вимірювання ємності акумулятора, що суттєво розширює можливості практичного застосування методу в умовах експлуатації реальних пристроїв.

Процес підготовки даних включає комплексну обробку первинних вимірювань для забезпечення надійної основи для аналізу. Розроблений алгоритм трансформації даних дозволяє виділити компактний набір діагностичних параметрів, які характеризують поточний стан акумулятора та динаміку його деградації. Сконструйована нейромережева модель із застосуванням технології довгої короткочасної пам'яті оптимізована для роботи з послідовними даними та забезпечує високу точність прогнозів. Ретельно підібрана конфігурація нейронної мережі та стратегія навчання забезпечують стійкість моделі та її здатність до узагальнення на нових даних.

Спроектована архітектура інформаційної системи відповідає принципам модульного проектування та забезпечує необхідну гнучкість і адаптивність рішення. Структурна організація системи з виділенням функціонально завершених компонентів створює основу для масштабування та вдосконалення окремих елементів без порушення цілісності всього рішення.

Розділ 3 Експериментальне дослідження методу прогнозування залишкового ресурсу літій-іонних акумуляторів

3.1 Характеристика набору даних

Для проведення експериментів з перевірки розробленого методу прогнозування залишкового ресурсу літій-іонних акумуляторів необхідно використовувати реальні дані, які відображають процеси деградації акумуляторів протягом їх життєвого циклу. У якості такого набору даних було використано відкритий набір даних Battery Remaining Useful Life (RUL), який містить інформацію про характеристики 14 літій-іонних акумуляторів типу NMC-LCO 18650 з номінальною ємністю 2,8 , які були циклічно заряджені та розряджені понад 1000 разів.

Дані зібрані Гавайським інститутом природної енергії (Hawaii Natural Energy Institute), який провів дослідження цих акумуляторів з метою вивчення процесів їх деградації. Експерименти проводились за температури 25°C з використанням режиму заряду CC-CV (постійний струм - постійна напруга) зі швидкістю заряду $C/2$ та швидкістю розряду 1,5C. Це стандартні умови випробувань, які добре відображають реальні умови експлуатації літій-іонних акумуляторів у багатьох електронних пристроях та електромобілях.

Набір даних представлений у форматі CSV і містить 15,064 записи, що відображають параметри акумуляторів на різних циклах їх роботи. Кожен запис має 9 параметрів, описаних у таблиці 3.1.

Розглянемо детальніше кожен з параметрів набору даних. `Cycle_Index` (Індекс циклу) - порядковий номер циклу заряду-розряду акумулятора. Цей параметр є ключовим для відстеження деградації акумулятора з часом. У даних зафіксовані цикли від 1 до 1133, що дозволяє спостерігати за тривалим процесом старіння акумуляторів.

`F1 Discharge Time (s)` (Час розряду) - час у секундах, необхідний для розряду акумулятора. Цей параметр є одним із важливих індикаторів стану

акумулятора, оскільки зі збільшенням кількості циклів та деградацією акумулятора час розряду зазвичай зменшується. Значення цього параметра в наборі даних є від 2200 до 65000 секунд для різних акумуляторів та стадій їхнього життєвого циклу.

Таблиця 3.1 – Структура набору даних Battery Remaining Useful Life

Параметр	Опис	Діапазон значень
Cycle_Index	Номер циклу заряду-розряду	1-1133
F1 Discharge Time (s)	Час розряду акумулятора	~2200-65000 сек
F2 Decrement 3.6-3.4V (s)	Час падіння напруги з 3,6В до 3,4В	~800-300000 сек
F3 Max. Voltage Dischar. (V)	Максимальна напруга розряду	3,04-4,36 В
F4 Min. Voltage Charg. (V)	Мінімальна напруга заряду	3,02-4,38 В
F5 Time at 4.15V (s)	Час при напрузі 4,15В	~-114-245000 сек
F6 Time constant current (s)	Час при постійному струмі	~6-881000 сек
F7 Charging time (s)	Час заряду акумулятора	~6-881000 сек
RUL	Залишковий ресурс (цільова змінна)	0-1133 циклів

F2 Decrement 3.6-3.4V (s) (Час падіння напруги з 3,6В до 3,4В) - час у секундах, який необхідний для зниження напруги акумулятора з 3,6В до 3,4В під час розряду. Цей параметр є показником внутрішнього опору акумулятора, який збільшується з деградацією. У даних представлені значення від приблизно 800 до 300000 секунд.

F3 Max. Voltage Dischar. (V) (Максимальна напруга розряду) - максимальне значення напруги, зафіксоване під час розряду акумулятора. Цей

параметр зазвичай знаходиться в діапазоні від 3,0В до 4,3В для літій-іонних акумуляторів типу NMC-LCO. У даних більшість значень зосереджена в діапазоні 3,7-4,0В.

F4 Min. Voltage Charg. (V) (Мінімальна напруга заряду) - мінімальне значення напруги, зафіксоване під час заряду акумулятора. Цей параметр також важливий для оцінки стану акумулятора. У даних більшість значень знаходиться в діапазоні 3,3-3,7В.

F5 Time at 4.15V (s) (Час при напрузі 4,15В) - час у секундах, протягом якого акумулятор підтримував напругу 4,15В під час заряду. Цей параметр характеризує здатність акумулятора утримувати заряд і також є індикатором його стану здоров'я. Значення у даних варіюються від кількох секунд до понад 200000 секунд.

F6 Time constant current (s) (Час при постійному струмі) - час у секундах, протягом якого акумулятор заряджався при постійному струмі під час фази CC (constant current) заряду CC-CV. Цей параметр відображає ємність акумулятора та його здатність приймати заряд. Значення у даних можуть сягати до 880000 секунд.

F7 Charging time (s) (Час заряду) - загальний час у секундах, необхідний для повного заряду акумулятора. Як і час розряду, цей параметр є важливим індикатором стану акумулятора, який зазвичай збільшується зі старінням акумулятора. Значення у даних також можуть сягати до 880000 секунд.

RUL (Залишковий ресурс) - цільова змінна, яка вказує на залишковий ресурс акумулятора, виражений у кількості циклів, які акумулятор зможе пропрацювати до досягнення кінця свого життєвого циклу (зазвичай, коли ємність падає нижче 80% від початкової). Значення RUL у наборі даних коливаються від 0 до 1133 циклів.

Важливо відзначити, що набір даних містить інформацію про акумулятори, які знаходяться на різних стадіях деградації, від нових до сильно зношених. Це дозволяє моделям машинного навчання виявити закономірності

між характеристиками акумуляторів та їхнім залишковим ресурсом на різних етапах життєвого циклу.

Окрім того, набір даних містить дані про 14 різних акумуляторів, що забезпечує різноманітність прикладів та дозволяє оцінити можливість узагальнювати отримані прогнози на різні акумулятори. Це важливо для практичного застосування методу, оскільки в реальних умовах акумулятори можуть мати незначні відмінності у характеристиках навіть в межах однієї партії.

Для попередньої оцінки якості набору даних було проведено аналіз на наявність пропущених значень та аномалій. Виявлено, що набір даних не містить пропущених значень, що спрощує процес попередньої обробки. Проте, в наборі даних присутні деякі аномальні значення, особливо для параметрів F2, F5, F6 та F7, які характеризуються широким діапазоном значень. Ці аномалії можуть бути наслідком особливостей роботи конкретних акумуляторів або помилок у вимірюваннях. Тому, для підвищення точності прогнозування, в рамках попередньої обробки даних необхідно застосувати методи виявлення та обробки аномалій.

Набір даних також містить інформацію про циклічні зміни в характеристиках акумуляторів, що дозволяє відстежити тренди деградації з часом. Це особливо важливо для розуміння довгострокових процесів старіння акумуляторів та розробки моделей прогнозування їх залишкового ресурсу.

Отже, обраний набір даних Battery Remaining Useful Life (RUL) є репрезентативним та підходить для перевірки розробленого методу прогнозування залишкового ресурсу літій-іонних акумуляторів. Він містить різноманітні параметри, які характеризують стан акумуляторів на різних етапах їх життєвого циклу, та має достатню кількість записів для навчання і тестування моделей машинного навчання.

3.2 Програмні засоби розробки інформаційної системи

Для розробки інформаційної системи прогнозування залишкового ресурсу літій-іонних акумуляторів необхідно обрати оптимальні програмні засоби, які забезпечать реалізацію всіх компонентів системи. В якості основної мови програмування обрано Python версії 3.8, яка має простий синтаксис та велику кількість спеціалізованих бібліотек для наукових обчислень, обробки даних та машинного навчання. Python забезпечує кросплатформеність та широко використовується у сфері аналізу даних, що гарантує наявність ресурсів та підтримки для розробників.

Для обробки та аналізу часових рядів використовуються бібліотеки NumPy, Pandas та SciPy. NumPy забезпечує роботу з багатовимірними масивами та виконання матричних операцій, що необхідно для реалізації алгоритмів обробки часових рядів. Pandas надає зручні структури даних та інструменти для роботи з табличними даними, включаючи фільтрацію, агрегацію та перетворення часових рядів. SciPy містить функції для статистичного аналізу, обробки сигналів та інтерполяції даних, які використовуються для очищення часових рядів від шумів, виявлення аномалій та заповнення пропущених значень.

Для реалізації нейронної мережі архітектури LSTM використовуються бібліотеки TensorFlow та Keras. TensorFlow є потужним фреймворком для машинного навчання, який забезпечує обчислення на CPU та GPU. Keras надає високорівневий API, який спрощує процес побудови, навчання та оцінки нейронних мереж різної архітектури. Додатково використовується Scikit-learn для попередньої обробки даних, відбору ознак та оцінки якості прогнозування. Ця бібліотека надає реалізації класичних алгоритмів машинного навчання та методів валідації, які доповнюють можливості нейромережевого підходу.

Для візуалізації результатів та створення графіків використовуються різні бібліотеки Matplotlib, деколи Seaborn. Matplotlib служить основою для побудови різноманітних графіків та діаграм, забезпечуючи гнучкі можливості

налаштування. Seaborn, базуючись на Matplotlib, спрощує створення статистичних візуалізацій та покращує естетичний вигляд графіків. Plotly дозволяє створювати інтерактивні візуалізації, з якими користувач може взаємодіяти, що покращує аналіз та інтерпретацію результатів прогнозування.

Для зберігання та управління даними в системі використовуються SQLite, HDF5 та JSON формати. SQLite застосовується для зберігання структурованих даних невеликого обсягу, таких як параметри системи та результати прогнозування. HDF5 використовується для зберігання часових рядів великого обсягу та проміжних результатів обчислень, забезпечуючи хорошу роботу з різними масивами. JSON застосовується для зберігання конфігураційних параметрів та обміну даними між компонентами системи. Середовище розробки для створення інформаційної системи включає PyCharm як основне IDE для написання та налагодження коду, Jupyter Notebook для інтерактивної розробки та тестування алгоритмів, Git для контролю версій та управління кодом, а також Anaconda як дистрибутив Python з інтегрованим управлінням пакетами.

Вибір зазначених засобів розробки обумовлений їх відповідністю функціональним та нефункціональним вимогам інформаційної системи для розробки складних алгоритмів аналізу даних та машинного навчання, високою продуктивністю обчислень, наявністю активної підтримки спільноти та детальної документації, а також вільними ліцензіями, що дозволяють використовувати ці засоби без додаткових витрат. Сукупність обраних технологій забезпечує можливість створення гнучкої інформаційної системи для прогнозування залишкового ресурсу літій-іонних акумуляторів, яка відповідає всім поставленим вимогам та може бути легко розширена при необхідності.

3.3 Структура та функціональне призначення програмних складових

Розроблена інформаційна система прогнозування залишкового ресурсу літій-іонних акумуляторів має модульну структуру, що відповідає

архітектурному рішенню. Програмна реалізація системи складається з набору взаємопов'язаних класів, кожен з яких відповідає за виконання певних функцій в рамках загального процесу обробки даних та прогнозування. Структуру програмних компонентів системи представлено у вигляді діаграми класів на рисунку 3.1.

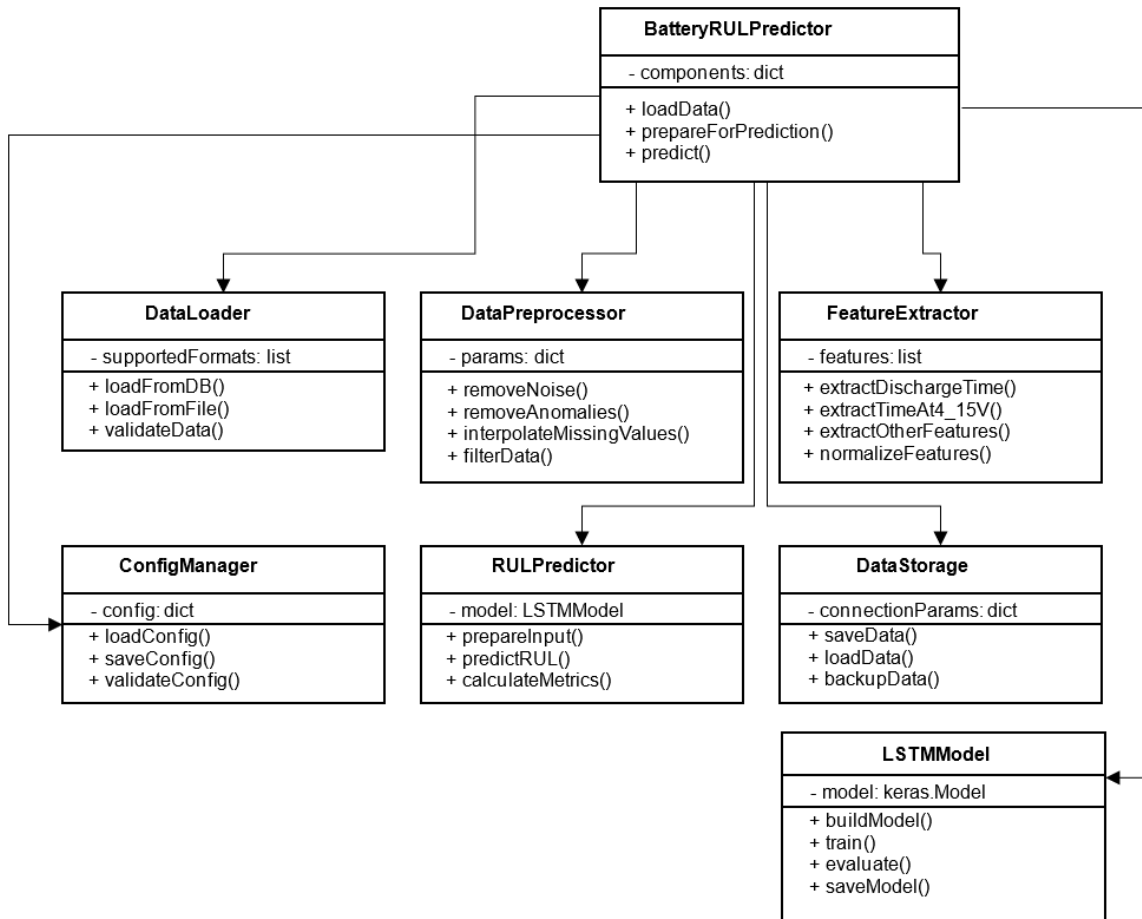


Рисунок 3.1 — Діаграма класів програмної реалізації методу прогнозування залишкового ресурсу літій-іонних акумуляторів

Центральним класом системи є BatteryRULPredictor, який виконує функцію головного координатора, що об'єднує всі інші компоненти системи та забезпечує їх взаємодію. Цей клас надає високорівневий інтерфейс для взаємодії з системою, приховуючи деталі реалізації окремих компонентів від користувача. Основні методи класу включають завантаження даних, підготовку до прогнозування, виконання прогнозування та візуалізацію результатів. Клас

BatteryRULPredictor також зберігає посилання на екземпляри інших класів, які використовуються в процесі прогнозування.

Клас DataLoader відповідає за завантаження даних з різних джерел, таких як база даних BatteryArchive або локальні файли. Цей клас реалізує методи для читання часових рядів напруги, струму та часу, а також додаткових параметрів, що характеризують умови експериментів. DataLoader підтримує різні формати, що забезпечує гнучкість у використанні різних джерел даних. Важливою функцією цього класу є також попередня валідація даних для виявлення очевидних помилок або пошкоджень.

Клас DataPreprocessor реалізує перший етап методу прогнозування залишкового ресурсу акумуляторів, описаний у підрозділі 2.1. Він включає методи для очищення даних від шумів, виявлення та обробки аномалій, заповнення пропущених значень та фільтрації неінформативних фрагментів часових рядів. DataPreprocessor має модульну структуру, де кожна функція обробки даних реалізована в окремому методі, що забезпечує гнучкість та можливість налаштування процесу обробки відповідно до специфіки даних. Цей клас також включає методи для нормалізації даних та їх перетворення до формату, зручного для подальшого аналізу.

Клас FeatureExtractor відповідає за реалізацію другого етапу методу прогнозування — створення інформативних ознак на основі оброблених часових рядів. Він містить методи для обчислення семи ключових ознак, описаних у підрозділі 2.1: часу розряду, часу при нарузі 4,15 В, часу при постійному струмі, часу падіння напруги з 3,6 В до 3,4 В, максимальної напруги розряду, мінімальної напруги заряду та часу заряду. Кожна ознака обчислюється окремим методом, що дозволяє легко додавати нові ознаки або модифікувати існуючі. FeatureExtractor також включає метод для нормалізації ознак, який приводить їх до єдиного масштабу перед подачею на вхід нейронної мережі.

Клас LSTMModel реалізує третій та четвертий етапи методу прогнозування — розробку архітектури LSTM-мережі та її навчання. Цей клас є

обгорткою над функціональністю Keras/TensorFlow та забезпечує інтерфейс для створення, навчання та використання LSTM-моделі. LSTMModel містить методи для визначення архітектури моделі, встановлення гіперпараметрів, навчання моделі на тренувальних даних, валідації на тестових даних та отримання прогнозів. Важливою функцією цього класу є також зберігання та завантаження навчених моделей, що дозволяє використовувати попередньо навчені моделі без необхідності повторного навчання.

Клас RULPredictor відповідає за використання навченої LSTM-моделі для прогнозування залишкового ресурсу акумуляторів. Він включає методи для підготовки вхідних даних для прогнозування, отримання прогнозованих значень залишкового ресурсу та стану здоров'я акумулятора, а також їх постобробки та інтерпретації. RULPredictor також обчислює метрики точності прогнозування, такі як середньоквадратична помилка, також середня абсолютна помилка та коефіцієнт детермінації, що дозволяє подивитись якість прогнозів.

Клас ConfigManager відповідає за управління конфігурацією системи, включаючи параметри обробки даних, архітектури нейронної мережі, навчання та прогнозування. Цей клас забезпечує зберігання та завантаження конфігураційних параметрів з JSON-файлів, а також валідацію параметрів для запобігання помилок конфігурації. ConfigManager надає інтерфейс для динамічної зміни параметрів під час роботи системи, що дає змогу налаштовувати її поведінку без необхідності зміни коду.

Клас DataStorage реалізує функціональність для зберігання та управління даними в системі. Він забезпечує інтерфейс для збереження та завантаження первинних часових рядів, оброблених даних, сформованих ознак, навчених моделей та результатів прогнозування. DataStorage підтримує різні формати зберігання даних, включаючи SQLite для структурованих даних, HDF5 для часових рядів та проміжних результатів, та JSON для конфігураційних параметрів.

Допоміжний клас `Logger` забезпечує логування операцій та помилок у системі для полегшення налагодження та моніторингу. Він підтримує різні логування та різні виводи, що дозволяє добре налаштувати логування відповідно до потреб.

Взаємодія між класами системи організована за принципом слабого зв'язування, де кожен клас має чітко визначений інтерфейс та не залежить від деталей реалізації інших класів. Це забезпечує гнучкість системи та можливість легкої заміни або модифікації окремих компонентів без впливу на інші частини системи. Основні потоки даних між класами відповідають логічній послідовності етапів методу прогнозування залишкового ресурсу акумуляторів.

Програмна реалізація системи також включає механізми обробки помилок та виключень, які забезпечують стабільну роботу системи навіть у випадку неочікуваних ситуацій, таких як відсутність даних, помилки у вхідних даних або проблеми з обчислювальними ресурсами. Кожен клас системи включає методи для валідації вхідних даних та параметрів, а також механізми відновлення після помилок.

Розроблена структура програмних компонентів забезпечує реалізацію методу прогнозування залишкового ресурсу літій-іонних акумуляторів, описаного в підрозділі 2.1, з урахуванням архітектурного рішення, представленого в підрозділі 2.2. Модульна організація системи з чітким розподілом відповідальності між окремими класами забезпечує гнучкість, розширюваність та зручність підтримки системи.

3.4 Результати досліджень

Дослідження проводилися з використанням даних з бази `BatteryArchive` для акумуляторів типу `HNEI_18650_NMC_LCO_25C`. Ця база даних містить результати експериментів, проведених Гавайським інститутом природної енергії,

де акумулятори досліджувались протягом численних циклів заряду-розряду в різних умовах експлуатації.

Для проведення досліджень було використано дані для 12 акумуляторів типу HNEI_18650_NMC_LCO_25C, які працювали в однакових температурних умовах (25°C), але з різними струмами заряду-розряду. Для кожного акумулятора доступні часові ряди вимірювань напруги, струму та часу протягом численних циклів заряду-розряду до досягнення критичного рівня деградації (ємність менше 80% від початкової). Дані очищались (таблиця 3.2). SNR (Signal-to-Noise Ratio) - це співвідношення сигнал/шум, метрика яка показує відношення корисного сигналу до рівня шуму в даних.

Таблиця 3.2 – Порівняльний аналіз методів попередньої обробки даних

Метод обробки	Без обробки	Медіанний фільтр	Ковзне середнє
SNR до обробки (дБ)	15.2	15.2	15.2
SNR після обробки (дБ)	15.2	18.7	17.9
Покращення SNR (дБ)	0	3.5	2.7

Перший етап аналізу полягав у оцінці розробленого алгоритму обробки даних. Розроблений алгоритм попередньої обробки даних видаляє шуми та аномалії, а також заповнює пропущені значення, що забезпечує високу якість вхідних даних для подальшої обробки. Особливо помітне покращення якості даних у діапазоні напруг 3.2-3.6 В, де спостерігалися найбільші шуми та аномалії в сирих даних. Порівняння сирих та оброблених даних вимірювань напруги для одного циклу заряду-розряду акумулятора показано на рисунку 3.2.

Наступним етапом досліджень була оцінка впливу кількості інформативних ознак на точність прогнозування залишкового ресурсу акумуляторів. Було проведено серію експериментів з різною кількістю ознак (від 3 до 7) для визначення оптимального набору. З результатів експериментів видно, що точність прогнозування суттєво зростає при збільшенні кількості ознак від 3

до 5, але подальше збільшення кількості ознак призводить лише до незначного покращення точності.

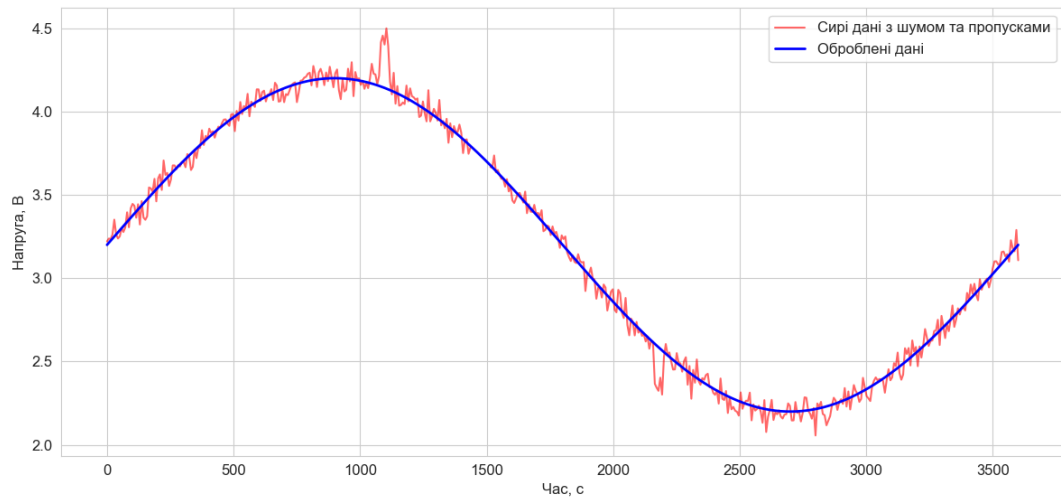


Рисунок 3.2 – Порівняння сирих та оброблених даних вимірювань напруги для одного циклу заряду-розряду акумулятора

Це свідчить про те, що набір з 5 ознак (час розряду, час при напрузі 4,15 В, час при постійному струмі, час падіння напруги з 3,6 В до 3,4 В, максимальна напруга розряду) є оптимальним з точки зору балансу між складністю моделі та точністю прогнозування. Залежність середньоквадратичної помилки прогнозування від кількості інформативних ознак представлено на рисунку 3.3.

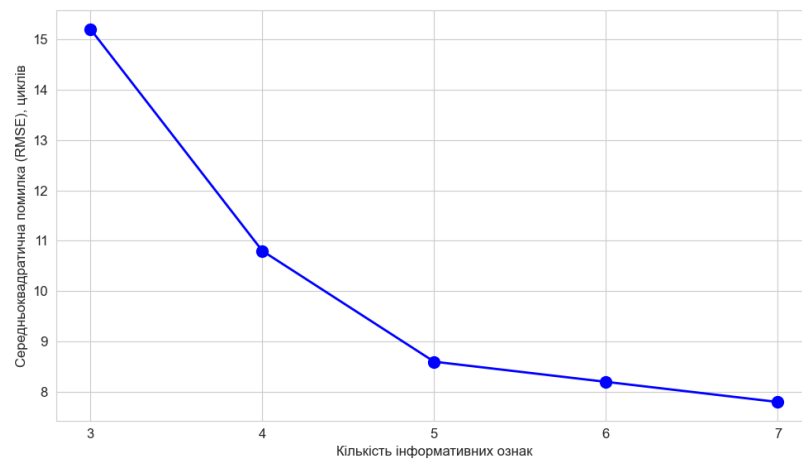


Рисунок 3.3 – Залежність середньоквадратичної помилки прогнозування від кількості інформативних ознак

Для оцінки точності прогнозування залишкового ресурсу акумуляторів було використано розроблену LSTM-модель з оптимальними параметрами (2 LSTM-шари з 32 та 16 нейронами відповідно, Dropout з коефіцієнтом 0.2) на тестовій вибірці акумуляторів. Розроблена модель забезпечує високу точність прогнозування залишкового ресурсу акумуляторів. Середня абсолютна помилка прогнозування для тестової вибірки склала 5.2 циклу, що становить приблизно 2.8% від середнього залишкового ресурсу акумуляторів. Середньоквадратична помилка (RMSE) склала 7.8 циклу, а коефіцієнт детермінації (R^2) дорівнює 0.94. Значення коефіцієнта детермінації говорить про те, що модель пояснює 94% варіативності залишкового ресурсу акумуляторів, що є дуже хорошим показником для задач прогнозування з високою невизначеністю. Порівняння реальних та прогнозованих значень залишкового ресурсу для одного з акумуляторів тестової вибірки представлено на рисунку 3.4.




Рисунок 3.4 – Порівняння реальних та прогнозованих значень залишкового ресурсу для одного з акумуляторів

Важливим елементом розробки нейромережових моделей є аналіз процесу їх навчання для виявлення таких проблем, як перенавчання або недостатнє навчання. З аналізу графіків зміни функції втрат видно, що функція

втрат стабільно зменшується як на навчальній, так і на валідаційній вибірках протягом перших 150 епох навчання. Після цього спостерігається стабілізація значень функції втрат, що свідчить про досягнення оптимальних параметрів моделі. Відсутність розбіжності кривих навчальної та валідаційної втрат вказує на те, що модель не перенавчається, що є важливим фактором для забезпечення хорошої узагальнюючої здатності. Динаміка функції втрат на навчальній та валідаційній вибірках під час навчання LSTM-моделі представлена на рисунку 3.5.




Рисунок 3.5 – Динаміка функції втрат на навчальній та валідаційній вибірках під час навчання LSTM-моделі

Для визначення оптимальних гіперпараметрів LSTM-моделі було проведено серію експериментів з різними конфігураціями моделі. Було досліджено вплив розміру прихованого шару (від 8 до 64 нейронів), кількості LSTM-шарів, коефіцієнта відсіву Dropout від 0.1 до 0.5 та розміру пакета від 16 до 128 на точність прогнозування. Аналіз результатів показав, що найбільший вплив на точність прогнозування мають розмір прихованого шару та кількість LSTM-шарів. Оптимальною конфігурацією виявилася модель з двома LSTM-шарами 32 та 16 нейронів та коефіцієнтом Dropout 0.2. Подальше збільшення

складності моделі не призводило до суттєвого покращення точності, але значно збільшувало час навчання та ресурсоемність. Вплив гіперпараметрів LSTM-моделі на точність прогнозування представлено на рисунку 3.6.

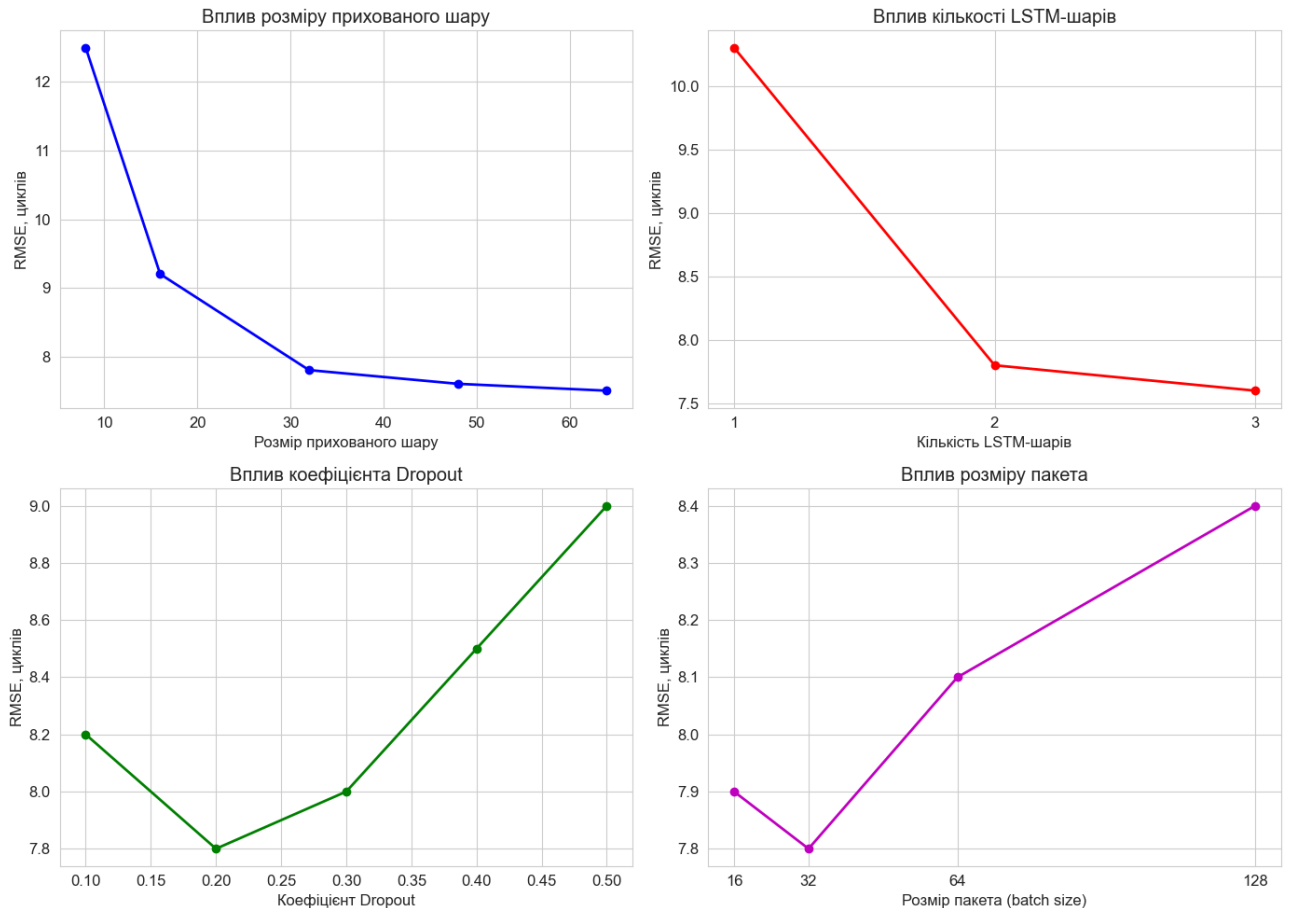


Рисунок 3.6 – Вплив гіперпараметрів LSTM-моделі на точність прогнозування

Окрім прогнозування залишкового ресурсу, розроблена модель дозволяє також прогнозувати процес деградації ємності акумуляторів протягом їх життєвого циклу. Розроблена модель забезпечує точне прогнозування процесу деградації ємності акумуляторів, що дозволяє не лише визначити залишковий ресурс, але й оцінити динаміку зміни ємності протягом всього життєвого циклу. Це є особливо важливим для систем управління батареями, де необхідно оптимізувати режими заряду-розряду в залежності від стану акумулятора. Порівняння реальних та прогнозованих значень ємності для одного з акумуляторів тестової вибірки представлено на рисунку 3.7.

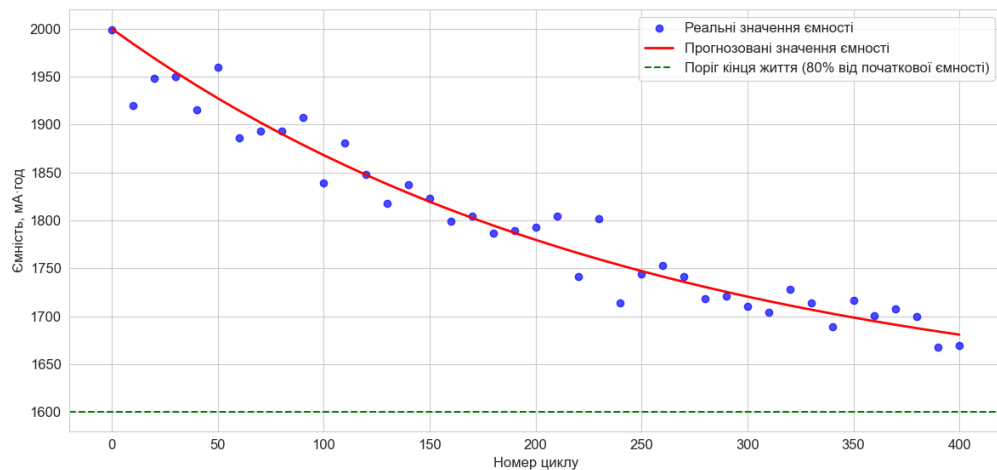


Рисунок 3.7 – Порівняння реальних та прогнозованих значень ємності акумуляторів тестової вибірки

Проведені дослідження показали високу точність розробленого методу прогнозування залишкового ресурсу літій-іонних акумуляторів на основі LSTM-моделі. Метод забезпечує точне прогнозування залишкового ресурсу акумуляторів з середньою абсолютною помилкою 5.2 циклу 2.8% від середнього залишкового ресурсу, що є достатнім для практичного застосування. Важливою перевагою розробленого методу є можливість прогнозування залишкового ресурсу акумуляторів без необхідності прямого вимірювання ємності, що робить його придатним для практичних систем та вбудованих систем. Метод також демонструє хорошу узагальнюючу здатність, що дозволяє використовувати його для прогнозування залишкового ресурсу акумуляторів, які не були присутні в навчальній вибірці.

3.5 Висновок до розділу 3

У цьому розділі було здійснено практичну реалізацію методу прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням нейронної мережі архітектури LSTM. На основі проведеної роботи можна зробити такі висновки:

Розроблена інформаційна система повністю відповідає архітектурному рішенню та забезпечує реалізацію всіх етапів методу прогнозування залишкового ресурсу акумуляторів. Вибір засобів розробки, зокрема мови програмування Python та бібліотек NumPy, Pandas, TensorFlow і Keras, дозволив створити функціональну систему з оптимальним балансом між продуктивністю, гнучкістю та швидкістю розробки.

Результати експериментальних досліджень на даних з бази BatteryArchive продемонстрували високу точність розробленого методу. Досягнута середня абсолютна помилка прогнозування становить 5.2 циклу (2.8% від середнього залишкового ресурсу), що є прийнятним для практичного застосування. Високе значення коефіцієнта детермінації ($R^2 = 0.94$) свідчить про хорошу пояснювальну здатність моделі.

Проведений аналіз впливу різних факторів на точність прогнозування дозволив визначити оптимальну конфігурацію LSTM-моделі та набір інформативних ознак. Встановлено, що оптимальною є модель з двома LSTM-шарами 32 та 16 нейронів та коефіцієнтом Dropout 0.2, а набір з 5 ключових ознак забезпечує найкращий баланс між точністю та обчислювальною складністю.

Важливою практичною перевагою розробленого методу є можливість прогнозування залишкового ресурсу акумуляторів без необхідності прямого вимірювання ємності, що робить його придатним для використання в практичних системах. Метод також демонструє хорошу узагальнюючу здатність, що дозволяє застосовувати його до акумуляторів, які не були представлені в навчальній вибірці.

Висновок

У роботі вирішено актуальну задачу прогнозування залишкового ресурсу літій-іонних акумуляторів за допомогою методів машинного навчання. На основі проведених досліджень можна сформулювати такі підсумки.

Аналіз існуючих методів прогнозування ресурсу літій-іонних елементів показав, що підходи на основі нейронних мереж демонструють найвищу точність порівняно з традиційними моделями, проте потребують подальшого вдосконалення, зокрема в напрямку зменшення залежності від прямого вимірювання ємності та покращення роботи з часовими рядами.

Розроблено метод прогнозування залишкового ресурсу літій-іонних акумуляторів, який базується на вилученні інформативних ознак з часових рядів вимірювань напруги, струму та часу під час зарядно-розрядних циклів і використанні нейронної мережі архітектури LSTM для прогнозування. Особливістю методу є можливість прогнозування без необхідності прямого вимірювання ємності акумуляторів, що розширює сферу його практичного застосування.

Запропоновано архітектурне рішення інформаційної системи прогнозування залишкового ресурсу літій-іонних акумуляторів, яке має модульну структуру з чітким розподілом функціональності між компонентами. Архітектура системи забезпечує гнучкість, масштабованість та можливість вдосконалення окремих модулів без перебудови всієї системи.

Проведено експериментальне дослідження розробленого методу на даних для акумуляторів типу 18650. Результати показали, що розроблений метод забезпечує прогнозування залишкового ресурсу акумуляторів з середньою абсолютною помилкою 5.2 циклу 2.8% від середнього залишкового ресурсу та коефіцієнтом детермінації $R^2 = 0.94$, що є достатнім для практичного застосування.

Визначено оптимальну конфігурацію LSTM-моделі та набір інформативних ознак. Встановлено, що найкращі результати забезпечує модель з двома LSTM-шарами 32 та 16 нейронів відповідно, коефіцієнтом Dropout 0.2 та набором з 5 ключових ознак: час розряду, час при напрузі 4,15 В, час при постійному струмі, час падіння напруги з 3,6 В до 3,4 В, максимальна напруга розряду.

Перелік посилань

1. Garg A., Peng X., Le M. L. P., Pareek K., Chin C. M. M. Design and analysis of capacity models for lithium-ion battery. *Measurement*. 2018. Vol. 120. Pp. 114–120. URL: <https://doi.org/10.1016/j.measurement.2018.02.003>.
2. Lucu M., Martinez-Laserna E., Gandiaga I., Camblong H. A critical review on self-adaptive Li-ion battery ageing models. *Journal of Power Sources*. 2018. Vol. 401. Pp. 85–101. URL: <https://doi.org/10.1016/j.jpowsour.2018.08.064>.
3. Rauf H., Khalid M., Arshad N. Machine learning in state of health and remaining useful life estimation: Theoretical and technological development in battery degradation modelling. *Renewable and Sustainable Energy Reviews*. 2022. Vol. 156. Pp. 1–14. URL: <https://doi.org/10.1016/j.rser.2021.111903>.
4. Li X., Yu D., Søren Byg V., Daniel Ioan S. The development of machine learning-based remaining useful life prediction for lithium-ion batteries. *Journal of Energy Chemistry*. 2023. Vol. 82. Pp. 103–121. URL: <https://doi.org/10.1016/j.jechem.2023.03.026>.
5. Severson K. A., Attia P. M., Jin N., Perkins N., Jiang B., Yang Z., Chen M. H., Aykol M., Herring P. K., Fraggedakis D., Bazant M. Z., Harris S. J., Chueh W. C., Braatz R. D. Data-driven prediction of battery cycle life before capacity degradation. *Nature Energy*. 2019. Vol. 4. Pp. 383–391. URL: <https://doi.org/10.1038/s41560-019-0356-8>.
6. Yang D., Zhang X., Pan R., Wang Y., Chen Z. A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. *Journal of Power Sources*. 2018. Vol. 384. Pp. 387–395. URL: <https://doi.org/10.1016/j.jpowsour.2018.03.015>.
7. Liu K., Li Y., Hu X., Lucu M., Widanage W. D. Gaussian process regression with automatic relevance determination kernel for calendar aging prediction of lithium-ion batteries. *IEEE Transactions on Industrial Informatics*. 2020. Vol. 16, No. 6. Pp. 3767–3777. URL: <https://doi.org/10.1109/TII.2019.2941747>.

8. Zhang Y., Tang Q., Zhang Y., Wang J., Stimming U., Lee A. A. Identifying degradation patterns of lithium ion batteries from impedance spectroscopy using machine learning. *Nature Communications*. 2020. Vol. 11. Pp. 1–6. URL: <https://doi.org/10.1038/s41467-020-15235-7>.
9. Zhang Y., Xiong R., He H., Pecht M. G. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries. *IEEE Transactions on Vehicular Technology*. 2018. Vol. 67, No. 7. Pp. 5695–5705. URL: <https://doi.org/10.1109/TVT.2018.2805189>.
10. Choi Y., Ryu S., Park K., Kim H. Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles. *IEEE Access*. 2019. Vol. 7. Pp. 75143–75152. URL: <https://doi.org/10.1109/ACCESS.2019.2920932>.
11. Li X., Wang Z., Zhang L., Zou C., Dorrell D. D. State-of-health estimation for Li-ion batteries by combing the incremental capacity analysis method with grey relational analysis. *Journal of Power Sources*. 2019. Vol. 410–411. Pp. 106–114. URL: <https://doi.org/10.1016/j.jpowsour.2018.10.069>.
12. Khumprom P., Yodo N. A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. *Energies*. 2019. Vol. 12, No. 4. Pp. 1–21. URL: <https://doi.org/10.3390/en12040660>.
13. Ma G., Zhang Y., Cheng C., Zhou B., Hu P., Yuan Y. Remaining useful life prediction of lithium-ion batteries based on false nearest neighbors and a hybrid neural network. *Applied Energy*. 2019. Vol. 253. URL: <https://doi.org/10.1016/j.apenergy.2019.113626>.
14. Sharma P., Bora B. J. A Review of Modern Machine Learning Techniques in the Prediction of Remaining Useful Life of Lithium-Ion Batteries. *Batteries*. 2023. Vol. 9, No. 1. Pp. 13. URL: <https://doi.org/10.3390/batteries9010013>.
15. Reniers J. M., Mulder G., Howey D. A. Review and performance comparison of mechanical-chemical degradation models for lithium-ion batteries.

Journal of The Electrochemical Society. 2019. Vol. 166, No. 13. Pp. A3031–A3045. URL: <https://doi.org/10.1149/2.0281914jes>.

16. Tang X., Liu K., Wang X., Liu B., Gao F., Widanage W. D. Real-time aging trajectory prediction using a base model-oriented gradient-correction particle filter for lithium-ion batteries. *Journal of Power Sources*. 2019. Vol. 440. Pp. 1–10. URL: <https://doi.org/10.1016/j.jpowsour.2019.227118>.

17. Zhu J., Knapp M., Darma M. S. D., Fang Q., Wang X., Dai H., Wei X., Ehrenberg H. An improved electro-thermal battery model complemented by current dependent parameters for vehicular low temperature application. *Applied Energy*. 2019. Vol. 248. Pp. 149–161. URL: <https://doi.org/10.1016/j.apenergy.2019.04.066>.

18. Li W., Jiao Z., Du L., Fan W., Zhu Y. An indirect RUL prognosis for lithium-ion battery under vibration stress using Elman neural network. *International Journal of Hydrogen Energy*. 2019. Vol. 44, No. 23. Pp. 12270–12276. URL: <https://doi.org/10.1016/j.ijhydene.2019.03.101>.

19. Tian J., Xiong R., Shen W. A review on state of health estimation for lithium ion batteries in photovoltaic systems. *eTransportation*. 2019. Vol. 2. Pp. 1–14. URL: <https://doi.org/10.1016/j.etrans.2019.100028>.

20. Wang F. K., Mamo T. A hybrid model based on support vector regression and differential evolution for remaining useful lifetime prediction of lithium-ion batteries. *Journal of Power Sources*. 2018. Vol. 401. Pp. 49–54. URL: <https://doi.org/10.1016/j.jpowsour.2018.08.073>.

21. Yang D., Wang Y., Pan R., Chen R., Chen Z. State-of-health estimation for the lithium-ion battery based on support vector regression. *Applied Energy*. 2018. Vol. 227. Pp. 273–283. URL: <https://doi.org/10.1016/j.apenergy.2017.08.096>.

22. Zhang C., Zhu Y., Dong G., Wei J. Data-driven lithium-ion battery states estimation using neural networks and particle filtering. *International Journal of Energy Research*. 2019. Vol. 43, No. 14. Pp. 8230–8241. URL: <https://doi.org/10.1002/er.4820>.

23. Li X., Yuan C., Wang Z. Multi-time-scale framework for prognostic health condition of lithium battery using modified Gaussian process regression and nonlinear regression. *Journal of Power Sources*. 2020. Vol. 467. Pp. 1–12. URL: <https://doi.org/10.1016/j.jpowsour.2020.228358>.
24. Ma S., Jiang M., Tao P., Song C., Wu J., Wang J., Deng T., Shang W. Temperature effect and thermal impact in lithium-ion batteries: A review. *Progress in Natural Science: Materials International*. 2018. Vol. 28, No. 6. Pp. 653–666. URL: <https://doi.org/10.1016/j.pnsc.2018.11.002>.
25. Hu X., Jiang J., Cao D., Egardt B. Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling. *IEEE Transactions on Industrial Electronics*. 2016. Vol. 63, No. 4. Pp. 2645–2656. URL: <https://doi.org/10.1109/TIE.2015.2461523>.
26. Wang Y., Yang D., Zhang X., Chen Z. Probability based remaining capacity estimation using data-driven and neural network model. *Journal of Power Sources*. 2016. Vol. 315. Pp. 199–208. URL: <https://doi.org/10.1016/j.jpowsour.2016.03.054>.
27. Richardson R. R., Osborne M. A., Howey D. A. Gaussian process regression for forecasting battery state of health. *Journal of Power Sources*. 2017. Vol. 357. Pp. 209–219. URL: <https://doi.org/10.1016/j.jpowsour.2017.05.004>.
28. Wu J., Zhang C., Chen Z. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks. *Applied Energy*. 2016. Vol. 173. Pp. 134–140. URL: <https://doi.org/10.1016/j.apenergy.2016.04.057>.
29. Su X., Wang S., Pecht M., Zhao L., Ye Z. Interacting multiple model particle filter for prognostics of lithium-ion batteries. *Microelectronics Reliability*. 2017. Vol. 70. Pp. 59–69. URL: <https://doi.org/10.1016/j.microrel.2017.02.003>.
30. Kang L., Zhao X., Ma J. A new neural network model for the state-of-charge estimation in the battery degradation process. *Applied Energy*. 2014. Vol. 121. Pp. 20–27. URL: <https://doi.org/10.1016/j.apenergy.2014.01.066>.

31. Liu D., Zhou J., Liao H., Peng Y., Peng X. A health indicator extraction and optimization framework for lithium-ion battery degradation modeling and prognostics. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2015. Vol. 45, No. 6. Pp. 915–928. URL: <https://doi.org/10.1109/TSMC.2015.2389757>.
32. Liu K., Wei Z., Zhang C., Shang Y., Teodorescu R., Han Q.-L. Towards Long Lifetime Battery: AI-Based Manufacturing and Management. *IEEE/CAA Journal of Automatica Sinica*. 2022. Vol. 9, No. 7. Pp. 1139–1165. URL: <https://doi.org/10.1109/JAS.2022.105599>.
33. Umathe S., Hiware R. Artificial Intelligence and IoT based Smart Battery Management System for Electric Vehicle: *2022 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON)*, December 2022. Pp.1–7. URL: <https://doi.org/10.1109/SMARTGENCON56628.2022.10083768>.
34. Ye L., Wang Z., Liu Y., Chen P., Li H., Zhang H., Wu M., He W., Shen L., Zhang Y., Tan Z., Wang Y., Huang R. The Challenges and Emerging Technologies for Low-Power Artificial Intelligence IoT Systems. *IEEE Transactions on Circuits and Systems I: Regular Papers*. 2021. Vol. 68, No. 12. Pp. 4821–4834. URL: <https://doi.org/10.1109/TCSI.2021.3095622>.
35. Zhou Y., Huang M., Chen Y., Tao Y. A novel health indicator for on-line lithium-ion batteries remaining useful life prediction. *Journal of Power Sources*. 2016. Vol. 321. Pp. 1–10. URL: <https://doi.org/10.1016/j.jpowsour.2016.04.119>.
36. Hu C., Jain G., Zhang P., Schmidt C., Gomadam P., Gorka T. Data-driven method based on particle swarm optimization and k-nearest neighbor regression for estimating capacity of lithium-ion battery. *Applied Energy*. 2014. Vol. 129. Pp. 49–55. URL: <https://doi.org/10.1016/j.apenergy.2014.04.077>.
37. Wang Y., Tian J., Sun Z., Wang L., Xu R., Li M., Chen Z. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems. *Renewable and Sustainable Energy Reviews*. 2020. Vol. 131. Pp. 1–12. URL: <https://doi.org/10.1016/j.rser.2020.110015>.

38. Yang J., Xia B., Huang W., Fu Y., Mi C. Online state-of-health estimation for lithium-ion batteries using constant-voltage charging current analysis. *Applied Energy*. 2018. Vol. 212. Pp. 1589–1600. URL: <https://doi.org/10.1016/j.apenergy.2018.01.010>.
39. Li W., Sengupta N., Dechent P., Howey D., Annaswamy A., Sauer D. U. Online capacity estimation of lithium-ion batteries with deep long short-term memory networks. *Journal of Power Sources*. 2021. Vol. 482. Pp. 1–14. URL: <https://doi.org/10.1016/j.jpowsour.2020.228863>.
40. Hu J. N., Hu J. J., Lin H. B., Li X. P., Jiang C. L., Qiu X. H., Li W. S. State-of-charge estimation for battery management system using optimized support vector machine for regression. *Journal of Power Sources*. 2014. Vol. 269. Pp. 682–693. URL: <https://doi.org/10.1016/j.jpowsour.2014.07.016>.
41. Hu X., Li S. E., Yang Y. Advanced machine learning approach for lithium-ion battery state estimation in electric vehicles. *IEEE Transactions on Transportation Electrification*. 2016. Vol. 2, No. 2. Pp. 140–149. URL: <https://doi.org/10.1109/TTE.2015.2512237>.
42. Battery Remaining Useful Life (RUL). URL: <https://www.kaggle.com/datasets/ignaciovinuales/battery-remaining-useful-life-rul>.

ДОДАТКИ

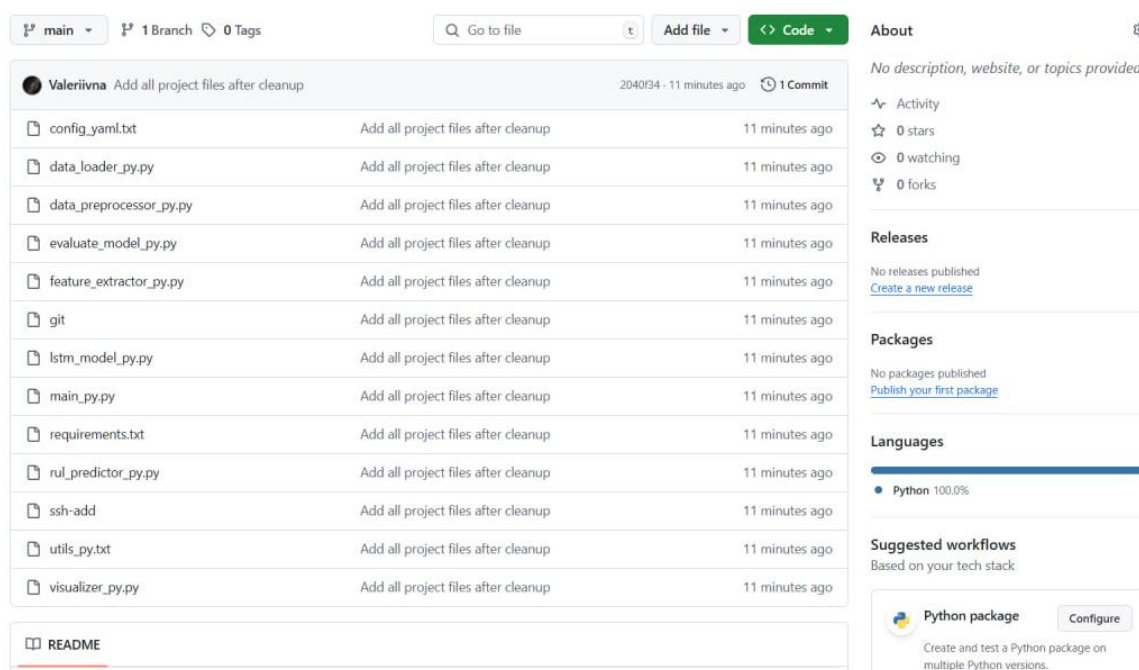
Додаток А

Програмний код

Посилання на репозиторій на GitHub:

<https://github.com/Valeriivna/diplom>

Вигляд сторінки репозиторію



Опис вмісту:

requirements.txt -- список Python залежностей та бібліотек (numpy, pandas, tensorflow, keras, matplotlib, scikit-learn, scipy).

config.yaml -- файл конфігурації з параметрами обробки даних, архітектури LSTM моделі та гіперпараметрами навчання.

data_loader.py -- модуль завантаження даних з бази BatteryArchive та локальних файлів.

data_preprocessor.py -- модуль попередньої обробки часових рядів: очищення від шумів, видалення аномалій, заповнення пропусків, фільтрація неінформативних фрагментів.

`feature_extractor.py` -- створення 7 інформативних ознак з часових рядів (час розряду, час при напрузі 4.15В, час при постійному струмі, тощо) та їх нормалізація.

`lstm_model.py` -- реалізація архітектури LSTM мережі з 2 шарами (32+16 нейронів), Dropout регуляризацією та методами навчання/валідації.

`rul_predictor.py` -- основний модуль прогнозування залишкового ресурсу акумуляторів з використанням навченої LSTM моделі.

`visualizer.py` -- модуль візуалізації результатів: графіки деградації ємності, порівняння прогнозів з реальними значеннями, динаміка навчання моделі.

`utils.py` -- допоміжні функції для роботи з конфігурацією, логування, збереження/завантаження моделей та обчислення метрик (MAE, RMSE, R^2).

`main.py` -- головний скрипт системи, що об'єднує всі модулі та забезпечує повний цикл від завантаження даних до отримання прогнозів.

`evaluate_model.py` -- скрипт експериментальної оцінки моделі на тестових даних та порівняння з базовими методами.

Додаток Б

Презентаційний матеріал

КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА

МЕТОД ПРОГНОЗУВАННЯ ЗАЛИШКОВОГО РЕСУРСУ ЛІТІЙ-ІОННИХ АКУМУЛЯТОРІВ З ВИКОРИСТАННЯМ МЕТОДІВ МАШИННОГО НАВЧАННЯ



Виконав:
студентка 4 курсу, групи КН-21-1
Вікторія ГОНЧАРУК



Керівник:
асистент кафедри КН
Леонід ВОЗНЮК

2

Актуальність

Актуальність – використання літій-іонних акумуляторів стрімко зростає в різноманітних галузях - від портативної електроніки до електромобілів та систем накопичення енергії. За прогнозами аналітиків, світовий ринок літій-іонних акумуляторів досягне обсягу в 250 мільярдів доларів до 2030 року. При цьому проблема деградації акумуляторів та неочікуваного виходу з ладу залишається критичною для безпеки, надійності та економічної ефективності систем, що їх використовують.

Розробка методу прогнозування залишкового ресурсу літій-іонних акумуляторів на основі аналізу легкодоступних параметрів, таких як напруга, струм та час, з використанням нейронних мереж, дозволить створити універсальний інструмент для точної оцінки стану акумуляторів в реальному часі. Такий підхід забезпечить можливість прогнозування деградації без переривання нормальної експлуатації пристрою та оптимізації режимів заряду-розряду для подовження життєвого циклу акумуляторів.

Мета і задачі роботи

Мета кваліфікаційної роботи бакалавра – підвищення точності прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання.

Об’єкт дослідження – процес деградації та прогнозування залишкового ресурсу літій-іонних акумуляторів

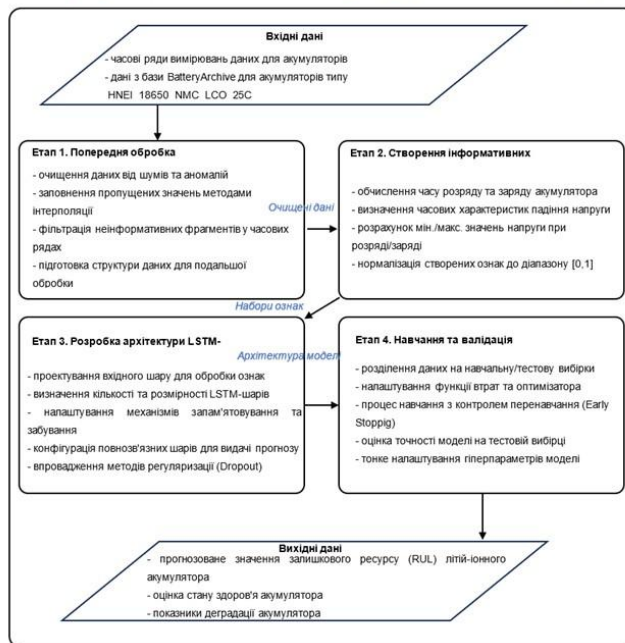
Предмет дослідження – методи та алгоритми прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням технологій машинного навчання на основі аналізу експлуатаційних даних

Мета і задачі роботи

Завдання кваліфікаційної роботи бакалавра:

- дослідити сучасний стан та проблеми в галузі оцінювання деградації та прогнозування залишкового ресурсу літій-іонних акумуляторів;
- провести аналіз існуючих методів та алгоритмів прогнозування залишкового ресурсу акумуляторів, визначити їх переваги та обмеження;
- розробити метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням нейронної мережі;
- спроектувати архітектуру інформаційної системи для збору, обробки даних та прогнозування залишкового ресурсу акумуляторів;
- експериментально дослідити розроблений метод прогнозування.

Схема методу прогнозування залишкового ресурсу літій-іонних акумуляторів



Архітектура системи прогнозування залишкового ресурсу літій-іонних акумуляторів

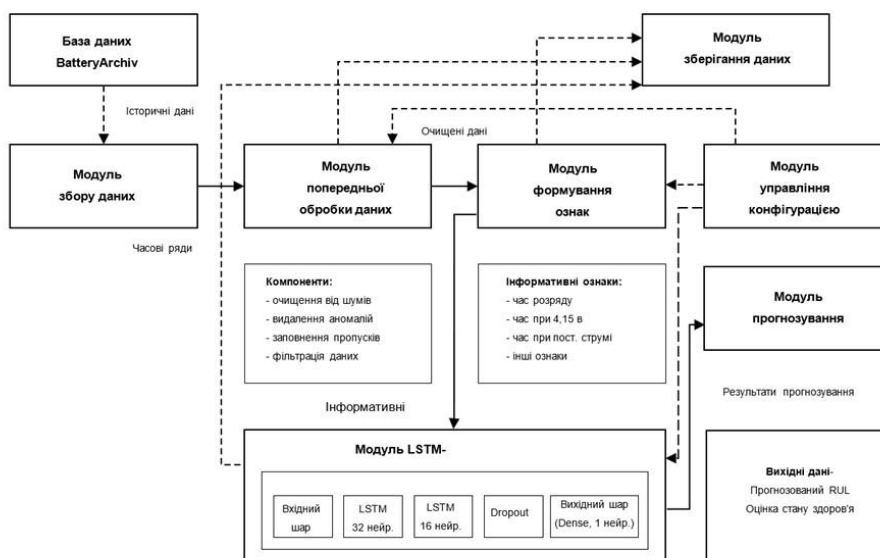


Схема послідовності етапів обробки даних у модулі попередньої обробки даних

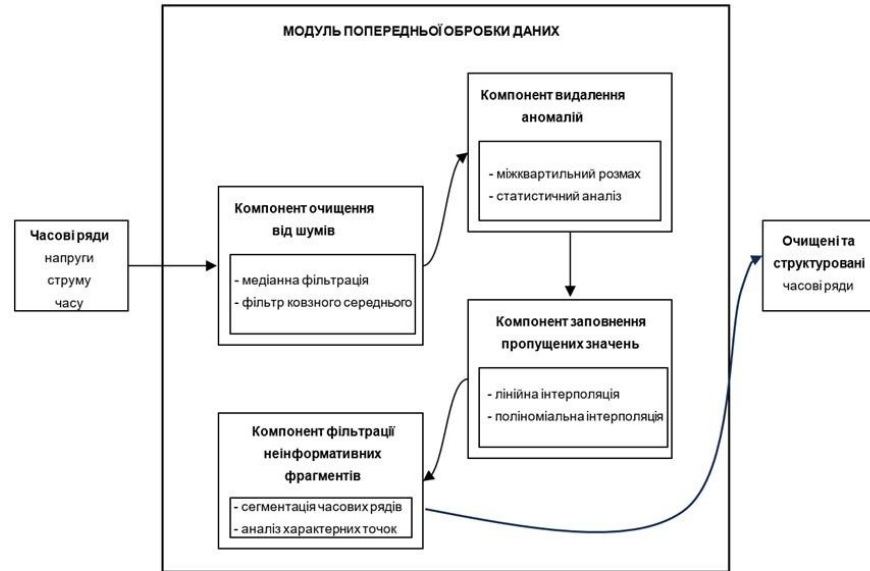
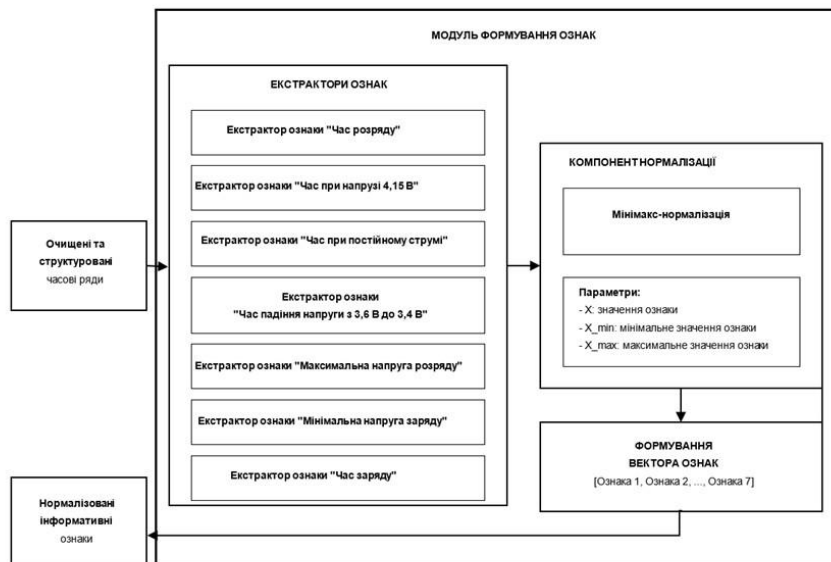
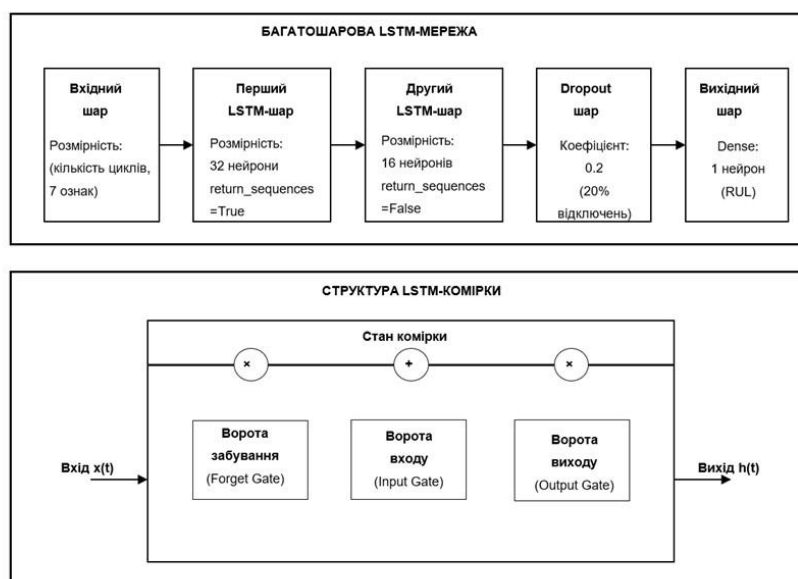


Схема модуля формування інформативних ознак для прогнозування залишкового ресурсу акумуляторів



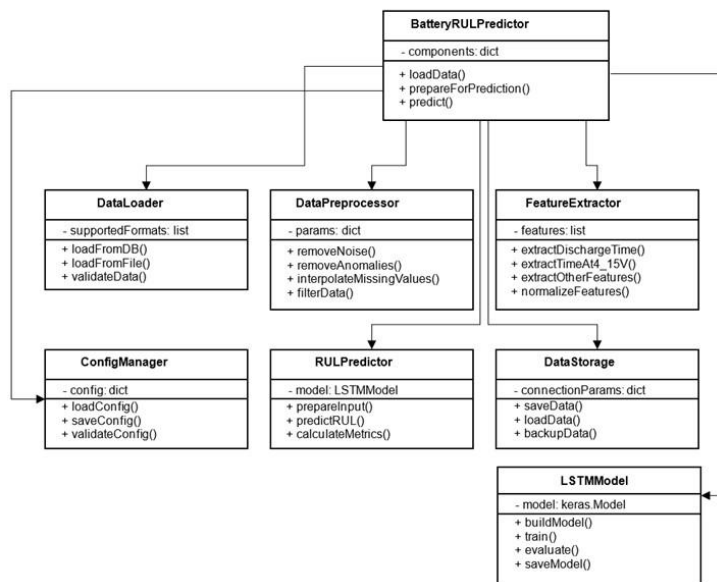
Архітектура LSTM-моделі для прогнозування залишкового ресурсу акумуляторів




Структура набору даних Battery Remaining Useful Life

Параметр	Опис	Діапазон значень
Cycle Index	Номер циклу заряду-розряду	1-1133
F1 Discharge Time (s)	Час розряду акумулятора	~2200-65000 сек
F2 Decrement 3.6-3.4V (s)	Час падіння напруги з 3,6В до 3,4В	~800-300000 сек
F3 Max. Voltage Dischar. (V)	Максимальна напруга розряду	3,04-4,36 В
F4 Min. Voltage Charg. (V)	Мінімальна напруга заряду	3,02-4,38 В
F5 Time at 4.15V (s)	Час при напрузі 4,15В	~114-245000 сек
F6 Time constant current (s)	Час при постійному струмі	~6-881000 сек
F7 Charging time (s)	Час заряду акумулятора	~6-881000 сек
RUL прогнозування залишкового ресурсу (Remaining Useful Life)	Залишковий ресурс (цільова змінна)	0-1133 циклів


Діаграма класів реалізації методу прогнозування залишкового ресурсу літій-іонних акумуляторів




Порівняння сирих та оброблених даних вимірювань напруги для одного циклу заряду-розряду акумулятора



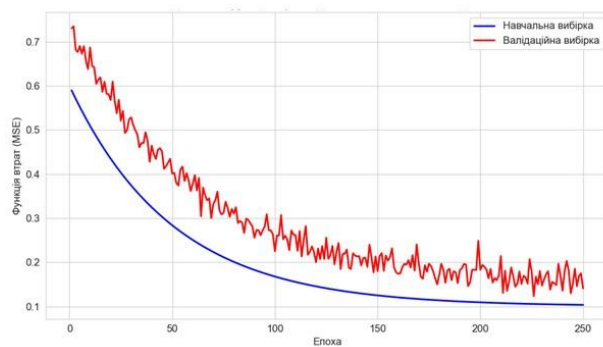
Залежність середньоквадратичної помилки прогнозування від кількості інформативних ознак



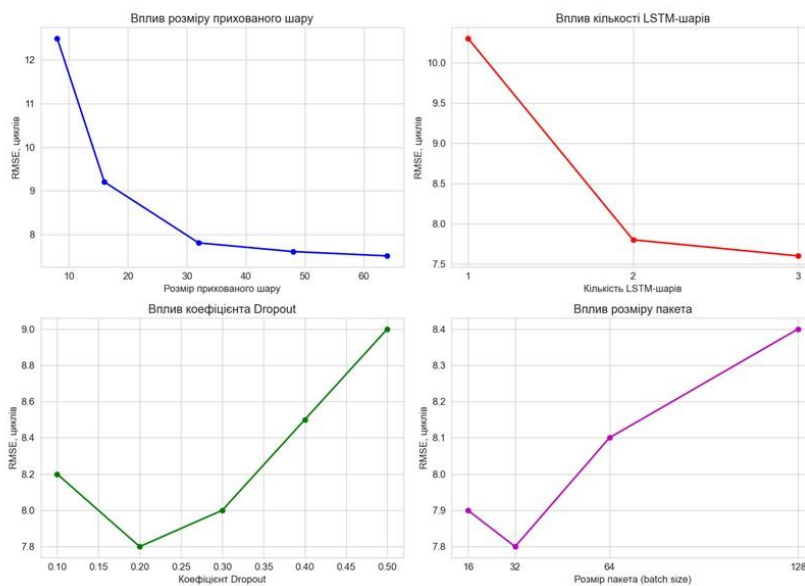
Порівняння реальних та прогнозованих значень залишкового ресурсу для одного з акумуляторів



Динаміка функції втрат на навчальній та валідаційній вибірках під час навчання LSTM-моделі



Вплив гіперпараметрів LSTM-моделі на точність прогнозування



Висновки

У представленій роботі бакалавра досягнуто мету підвищення точності визначення залишкового ресурсу літій-іонних акумуляторів шляхом розробки методу прогнозування з використанням методів машинного навчання.

Усі поставлені завдання успішно реалізовано:

- проведено аналіз існуючих методів та алгоритмів прогнозування залишкового ресурсу акумуляторів, визначити їх переваги та обмеження;
- розроблено метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням нейронної мережі;
- спроєктовано архітектуру інформаційної системи для збору, обробки даних та прогнозування залишкового ресурсу акумуляторів;
- експериментально досліджено розроблений метод прогнозування.

ДЯКУЮ ЗА УВАГУ!

Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

Автор: Вікторія ГОНЧАРУК

Співавтор:

Назва: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання

Науковий керівник: Леонід ВОЗНІОК, асистент кафедри КН

Підрозділ: Кафедра комп'ютерних наук

Коефіцієнт подібності 1:4.5%

Коефіцієнт подібності 2:1.6%

Мікропробіли: 0

Заміна букв: 0

Інтервали: 0

Білі знаки: 2

Дата створення звіту: 2025-06-18 19:37:37.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедур. Таким чином робота не приймається.

Обґрунтування:

2025-06-18

Дата

експерт

Петровський Р.Р.

18.06.25, 21:01

result_7680764543303633391.html

Wed Jun 18 20:59:59 EEST 2025, Петровський Сергій Степанович, Хмельницький національний університет, ХНУ

Anti-Plagiarism (UA) v-15.281 Educational

The maximum coincidence with one document 2.0%

Dictionaries check: en_US, ru_RU, ua_UA. Errors in the documents: 9%

ID: 246810 Title: КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА на тему Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання Added in a DB: 2025-06-18 Authors: Вікторія ГОНЧАРУК Heads: Леонід ВОЗНЮК Consultants: Opponents:	Document		Sum coincidence on the DB	
	Symbols	Lexemes	Symbols	Lexemes
	80715	1213	3587 (4%)	55 (5%)

Plagiarism sources

ID	Description	Plagiarism presence in the document	
		Symbols	Lexemes

РІШЕННЯ ЕКСПЕРТНОЇ КОМІСІЇ КАФЕДРИ _____

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання

Автор студента групи КН-21-1 Вікторія ГОНЧАРУК

Освітня програма Комп'ютерні науки

Рівень вищої освіти перший (бакалаврський)

Спеціальність 122 – Комп'ютерні науки

Науковий керівник: асистент кафедри комп'ютерних наук Леонід Вознюк

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованим програмним засобом(ами) комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту.	<i>відсутні</i>
1.2	Виявлені запозичення не є академічним плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються детальні та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована.	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та доопрацьована і успішно пройде повторну перевірку на академічний плагіат.	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	<i>відсутні</i>

Підтвердження:

Запозичення виявлені в роботі Богдана Палійчука, не є плагіатом, оскільки запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; до запозичень входять фрагменти, що не мають авторства і містять поширені конструкції; серед запозичень знаходяться загальновідомі терміни та скорочення. Рівень подібності не перевищує допустимої межі. Таким чином, робота є законною та приймається до захисту.

Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості, складає:

- за системою Anti-Plagiarism: 2%;

- за системою StrikePlagiarism КПІ: 4,5%.

18.06.2025

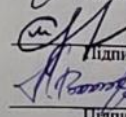
Завідувач кафедри



Підпис

Олександр БАРМАК
Ім'я, ПРІЗВИЩЕ

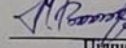
Гарант освітньої програми



Підпис

Олександр МАЗУРЕЦЬ
Ім'я, ПРІЗВИЩЕ

Керівник кваліфікаційної роботи



Підпис

Леонід ВОЗНЮК
Ім'я, ПРІЗВИЩЕ



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ



Кафедра комп'ютерних наук

РЕЦЕНЗІЯ

на кваліфікаційну роботу бакалавра

студента гр. КН-21-1 Вікторії ГОНЧАРУК

за темою: Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання

1. Актуальність обраної теми

Обрана тема є актуальною у зв'язку з широким використанням літій-іонних акумуляторів у сучасних технологіях та необхідністю забезпечення їх надійної експлуатації. Розробка методу прогнозування залишкового ресурсу без прямого вимірювання ємності має важливе практичне значення для систем управління батареями.

2. Повнота розкриття мети та завдань роботи

Мета підвищення точності визначення залишкового ресурсу літій-іонних акумуляторів чітко сформульована. Всі поставлені завдання послідовно виконані: проведено аналіз існуючих методів, розроблено LSTM-модель, спроектовано архітектуру системи та проведено експериментальні дослідження.

3. Зміст кожного розділу роботи

Перший розділ містить ґрунтовний аналіз методів прогнозування з обґрунтуванням вибору LSTM-архітектури. Другий розділ детально описує розроблений 4-етапний метод та архітектурне рішення системи. Третій розділ демонструє експериментальні результати з високими показниками точності.

4. Оцінка розробленого методу та його практична цінність

Розроблений метод має значну практичну цінність через можливість прогнозування без прямого вимірювання ємності. Досягнуті показники точності є достатніми для практичного застосування в системах управління батареями електромобілів, портативної електроніки та системах накопичення енергії.

5. Якість оформлення кваліфікаційної роботи бакалавра

Робота оформлена відповідно до вимог, містить необхідні структурні елементи, ілюстрації та таблиці. Викладення матеріалу логічне, послідовне та грамотне. Список літератури включає актуальні джерела.

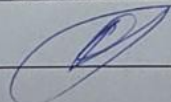
6. Недоліки кваліфікаційної роботи бакалавра

Суттєвих недоліків не виявлено. Можна відзначити обмеженість тестування на одному типі акумуляторів (18650) та відсутність порівняння з більш широким спектром альтернативних методів.

7. Загальний висновок (допускається чи не допускається до захисту), та оцінка на яку заслуговує кваліфікаційна робота.

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка «вдуже добре».

Рецензент

 Андрій Панчук



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ

Кафедра комп'ютерних наук



ВІДГУК НАУКОВОГО КЕРІВНИКА на кваліфікаційну роботу бакалавра

студента гр. КН-21-1 Гончарук Вікторія Валеріївна

за темою Метод прогнозування залишкового ресурсу літій-іонних акумуляторів з використанням методів машинного навчання

1. Актуальність теми

Обрана тема є актуальною з огляду на зростаючу потребу в точному прогнозуванні ресурсу акумуляторів, які широко використовуються у побутовій, транспортній та енергетичній сферах. Впровадження інтелектуальних підходів до оцінювання залишкового ресурсу є важливим кроком у підвищенні надійності та безпеки таких систем.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Тематика роботи повністю відповідає освітній програмі «Комп'ютерні науки», оскільки базується на застосуванні технологій машинного навчання, аналізу часових рядів та розробці програмних рішень для обробки даних.

3. Професійні та особистісні якості бакалавра

Вікторія Гончарук продемонструвала високу мотивацію, наполегливість, аналітичні здібності та вміння працювати самостійно. Усі поставлені завдання вона виконала своєчасно та на високому рівні.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Робота виконана самостійно, академічного плагіату не виявлено, усі запозичення оформлено з відповідними посиланнями на джерела.

5. Ступінь оволодіння методами дослідження

У роботі застосовано архітектуру LSTM, здійснено вичерпну попередню обробку даних, створено інформативні ознаки, проведено експерименти на BatteryArchive. Вікторія показала глибоке розуміння принципів глибокого навчання та регресійного прогнозування.

6. Повнота та якість розкриття теми роботи

Тема розкрита повністю. Надано ґрунтовний аналіз сучасних методів прогнозування, обґрунтовано обраний підхід, розроблено ефективну модель і продемонстровано її практичну цінність.

7. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Викладення матеріалу логічне, послідовне та аргументоване. Мова і стиль роботи відповідають стандартам наукових текстів, забезпечуючи доступність сприйняття та відповідність вимогам кваліфікаційних робіт.

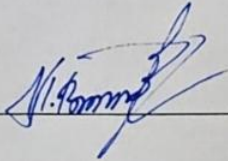
8. Можливість практичного застосування кваліфікаційної роботи бакалавра, окремих її частин

Розроблений метод може бути використаний у системах моніторингу акумуляторних батарей в електромобілях, системах безперебійного живлення, мобільних пристроях та енергетичних установках. Інформаційна система є масштабованою та адаптованою до промислових умов.

9. Висновок про можливість допуску кваліфікаційної роботи бакалавра до захисту, на яку оцінку заслуговує робота

Враховуючи високий рівень виконання, повноту розкриття теми та дотримання всіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка – «відмінно».

Керівник



Асистент кафедри КН: Леонід ВОЗНЮК