

<https://doi.org/10.31891/2307-5732-2026-363-21>

УДК 004.94

МЕЛЬНИК МИХАЙЛО

Національний університет “Львівська політехніка”

<https://orcid.org/0000-0003-0339-3711>

e-mail: mykhailo.v.melnyk@lpnu.ua

ГЕРЕЗ ДМИТРО

Національний університет “Львівська політехніка”

<https://orcid.org/0009-0000-0730-1584>

e-mail: dmytro.herez.mknus.2024@lpnu.ua

МОДЕЛЮВАННЯ РЕЖИМІВ РОБОТИ АКУМУЛЯТОРНОЇ СИСТЕМИ НА ОСНОВІ МЕТОДІВ МАШИННОГО НАВЧАННЯ

В роботі представлено результати досліджень режимів роботи акумуляторної системи у процесі заряджання та розряджання з використанням методів машинного навчання. Розроблено адаптивну модель акумулятора, яка на основі еквівалентної електричної схеми, дозволяє визначати напругу на клеммах і стан заряду акумулятора за історичними даними експлуатації. У ході дослідження було виявлено, що процеси заряджання та розряджання мають нелінійний характер, ступінь якого залежить від стабільності струмів і режимів роботи акумуляторної системи. Встановлено, що метод найменших квадратів забезпечує високу точність моделювання для стабільних режимів із низьким та середніми значеннями струму (до 11А), тоді як застосування нейронних мереж є доцільним за умов високих значень струму (досліджували проміжки від 19-31А), підвищеної нелінійності або обмеженої вибірки вхідних даних. Порівняння змодельованих та експериментальних результатів підтвердило високу точність розробленої моделі, яка становить $R^2 = 0,96$. У подальшому, результати можуть бути використані для аналізу та прогнозування режимів роботи акумуляторних систем, а також при розробленні ефективних інтелектуалізованих систем управління гібридними системами електропостачання різних масштабів.

Ключові слова: моделювання, лінійна регресія, машинне навчання, нейронні мережі, метод найменших квадратів, генетичні алгоритми, акумуляторні системи, заряджання, розряджання.

MELNYK MYKHAILO, HEREZ DMYTRO

Lviv Polytechnic National University

MODELING OF BATTERY SYSTEM OPERATION BASED ON MACHINE LEARNING METHODS

Renewable energy integration and electromobility have become fundamental drivers of modern energy storage systems. A key difficulty in this domain is the accurate estimation of internal battery parameters—particularly the state of charge and terminal voltage—due to the nonlinearity of electrochemical processes governing battery operation. This study provides a battery behavior modeling during charging and discharging cycles, which lead to creating application based on machine learning approach, that provide high level of prediction accuracy and improve battery system control.

To specify limitations of static modeling for capacity prediction, a dynamic battery model was developed. It based on an equivalent electrical circuit approach. Created model allows real-time estimation of voltage and SOC parameters by incorporating instantaneous current measurements together with historical operational data. Particular attention is focus on nonlinear characteristics of charge and discharge processes, as this characteristics are unique for each battery system and influence stability and type operating mode of systems. A detailed comparative evaluation of multiple algorithmic approaches is conducted to identify the most effective parameter estimation techniques under varying load conditions.

The results reveal a distinct dependence of algorithmic performance on current magnitude. For stable operating regimes characterized by low to medium current levels (up to 11 A), the least squares method showcased the highest metrics of efficiency, benefiting from the quasi-linear behavior of the approach and providing a high level of prediction accuracy. Conversely, in high-current operating conditions—examined in the range of 19 A to 31 A—or in scenarios involving pronounced nonlinearity and limited data availability, genetic algorithms demonstrate superior performance. Their heuristic optimization capabilities enable robust parameter estimation in complex, non-convex search spaces where conventional deterministic methods are insufficient.

Model approbation was conducted through comparison of simulation outcomes with experimental measurements, confirming high predictive accuracy, achieving a coefficient of determination of $R^2 = 0.96$. These outputs approve the relevance of the proposed approach as a way to improve performance for the next-generation battery management systems. Overall, the methodology supports scalable and adaptable approaches for predicting battery operating modes, facilitating more efficient strategies for hybrid power generation systems of different scales.

Keywords: battery systems, modeling, energy, regression, machine learning, neural networks, least squares method, charging, discharging.

Стаття надійшла до редакції / Received 16.01.2026

Прийнята до друку / Accepted 11.02.2026

Опубліковано / Published 26.03.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Мельник Михайло, Герез Дмитро

Постановка проблеми у загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями

Сучасний розвиток відновлювальних джерел енергії, ставить перед дослідниками ряд проблем, які потрібно вирішити, для забезпечення ефективного і безперебійного електропостачання споживачів протягом усього циклу використання енергії. Ключовим елементом балансування гібридної системи електропостачання, станом на зараз, є акумуляторні системи [1]. Тому актуальною науковою задачею при дослідженні енергодинамічних режимів є можливість адекватного моделювання процесів заряджання/розряджання акумуляторів електричної енергії. Експериментальні та електрохімічні моделі не надто придатні для представлення динаміки акумулятора, оскільки вони є обчислювально затратними і потребують масштабних

експериментів для визначення параметрів моделі [2].

Математична модель акумулятора базується на емпіричних рівняннях і використовується для моделювання часу заряджання/розряджання, ефективності та втрати ємності [3]. Однак її застосування в схемних симуляторах обмежене, оскільки вона недостатньо пов'язана з параметрами моделі та вольт-амперними характеристиками акумулятора.

Моделі на основі еквівалентної електричної схеми (ЕЕС), або моделі Тевенена, ефективно представляють експлуатаційні характеристики акумуляторів. Найпростіша ЕЕС (рис.1) подана електрорушійною силою U_0 та опором R_1 , а також паралельним з'єднанням опору R_2 та ємності C_1 [4]. Параметри цих елементів визначаються за допомогою поліноміального представлення, оскільки вони пропорційні швидкості заряджання/розряджання батареї.

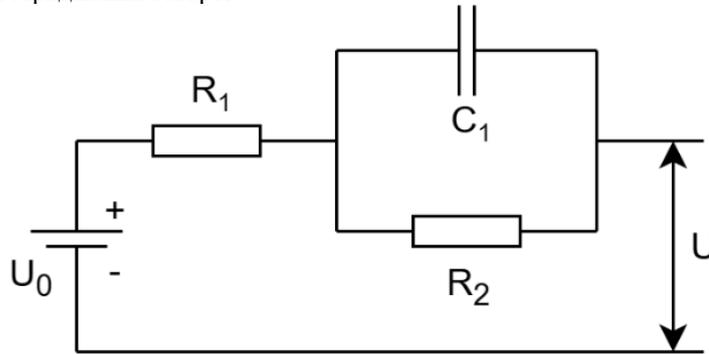


Рис. 1. Модель Тевенена першого порядку

Для забезпечення можливості ефективно використовувати модель акумуляторної системи, з подальшим дослідженням режимів її роботи, важливо точно визначити її поточні параметри. Як правило, ці параметри обчислюються з експериментальних замірів, які потребують значних ресурсів і часу.

Проведення таких дорогих і масштабних експериментів для оцінки характеристик різних типів акумуляторів є ресурсозатратним. Крім того, окремі підвиди моделей, не враховують втрати ємності (деградацію). Тому в рамках цього дослідження, розглядатиметься математична модель літій-ферум-фосфатного акумулятора, структурну схему якої подано на рис. 2. У даному випадку моделювання втрати ємності здійснюється з врахуванням номінальної ємності акумулятора, обсягах обробленої енергії під час заряджання/розряджання та швидкості цих процесів.

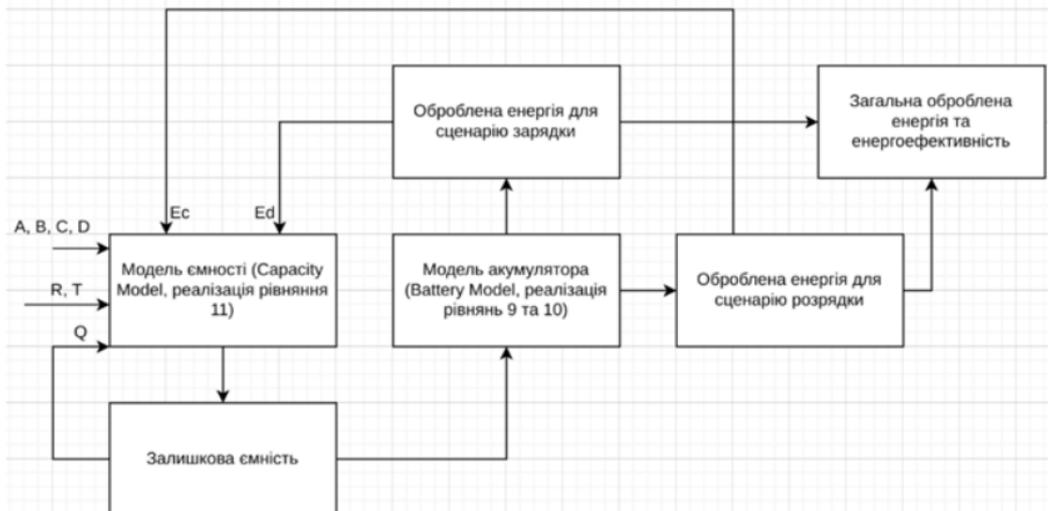


Рис. 2. Блок-схема акумулятора з моделлю ємності

Аналіз досліджень та публікацій

У сучасних наукових дослідженнях для вивчення характеристик та режимів роботи акумуляторних систем застосовуються різні підходи, які, умовно, можна поділити на експериментальні, фізико-хімічні та математичні методи моделювання.

Одним із найбільш поширених підходів є експериментальні дослідження акумуляторів, що передбачають проведення багаторазових циклів заряджання та розряджання з подальшим вимірюванням напруги, струму, ємності та оцінкою швидкості деградації. Такий підхід забезпечує високу точність результатів і дозволяє оцінювати поведінку акумуляторів у реальних умовах експлуатації. Водночас експериментальні методи характеризуються значною вартістю випробувань, тривалістю процесу отримання даних та обмеженими можливостями швидкої адаптації результатів до інших типів акумуляторів [2].

Іншим напрямом досліджень є математичні моделі електричних акумулюючих систем, які базуються на описі фізико-хімічних процесів, зокрема дифузії іонів, електродних реакцій та термодинамічних явищ. Такі моделі забезпечують високий рівень деталізації та дозволяють досліджувати поведінку акумуляторів на мікро- та молекулярному рівнях [3,4].

Разом з тим, їх практичне застосування ускладнюється через потребу значних обчислювальних ресурсів, необхідністю використання великої кількості вхідних параметрів, значна частина яких є нелінійно взаємопов'язаними або неможливими для прямого вимірювання, а також обмеженою можливістю швидких інженерних визначень [5,6].

Найбільш поширеним компромісним підходом є використання ЕЕС, у яких акумулятор подається у вигляді сукупності внутрішнього опору, ємнісних елементів та електрорушійної сили. Такий підхід дозволяє суттєво спростити процес моделювання, зосередившись на ключових електричних параметрах акумулятора.

Перевагами ЕЕС-моделей є простота реалізації в середовищах моделювання, зокрема MATLAB/Simulink, а також висока ефективність у прогнозуванні короткострокових змін характеристик акумулятора. Основними обмеженнями даного підходу є неповний облік складних хімічних процесів деградації та необхідність періодичної калібрування параметрів для забезпечення точності довгострокового прогнозування [4].

Окрему увагу в наукових публікаціях приділено дослідженню різних типів акумуляторів.

Свинцево-кислотні (AGM) акумулятори, незважаючи на тривалий термін використання та відносно просту технологію виробництва, і досі широко застосовуються у системах резервного живлення, автомобільних акумуляторах і джерелах безперебійного електроживлення.

До їх переваг належать низька вартість, здатність працювати з короткочасними високими навантаженнями та надійність в умовах важкої експлуатації. Разом з тим, ці акумулятори мають низьку енергетичну щільність, значну масу, потребують регулярного обслуговування та характеризуються меншим терміном служби порівняно з сучасними типами акумуляторів [7].

Літій-іонні батареї є одними з найбільш поширених у сучасних енергетичних та електронних системах завдяки високій енергетичній щільності, низькій саморозрядності та значному ресурсу циклів заряджання-розряджання. Водночас вони є чутливими до температурних перевантажень, глибокого розряду та перезаряджання, що призводить до прискореної деградації та підвищених вимог до систем керування і захисту [6,8]. На сьогодні в системах накопичення енергії для сонячних електростанцій найбільшого поширення набули літій-ферум-фосфатні (LiFePO_4) акумулятори. Це зумовлено їх високою енергетичною щільністю, значним ресурсом циклів заряджання/розряджання та низьким рівнем саморозряду. Проте, до важливих особливостей використання LiFePO_4 -акумуляторів є їхня чутливість до режимів перезаряду та глибокого розряду, що вимагає застосування ефективних методів контролю та керування [9]. Подальший розвиток технології виробництва літій-ферум-фосфатних батарей поступово зменшує ці обмеження, підвищуючи рівень їх безпеки та надійності. У рамках даного дослідження розраханки будувалися на використанні сучасний восьмимодульних акумуляторних систем LiFePO_4 , що відповідає актуальним технічним рішенням для систем відновлюваної енергетики.

Порівняльний аналіз різних типів акумуляторів показує, що літій-іонні батареї характеризуються найвищою енергетичною щільністю, однак поступаються LiFePO_4 -акумуляторам за показниками стабільності та довговічності [6]. Свинцево-кислотні батареї, незважаючи на нижчу вартість, мають значну масу та менший життєвий цикл, що обмежує їх використання в мобільних і високоефективних системах накопичення енергії. Натомість літій-ферум-фосфатні батареї широко застосовуються у системах зберігання енергії електромереж, електромобілях та установках, де критичними є показники безпеки та надійності [10].

У практичних застосуваннях окремі акумуляторні елементи об'єднуються в батарейні пакети з метою досягнення необхідних електричних параметрів джерела живлення. Паралельне з'єднання дозволяє збільшити загальну ємність системи, тоді як послідовне з'єднання забезпечує підвищення вихідної напруги. Додатково, варто наголосити, що у склад однієї акумуляторної системи, включають батареї одного типу, з одного виробничого лоту та з однаковим рівнем початкового заряду, оскільки відмінності у стані заряду (SOC), загальній ємності та внутрішньому опорі можуть призводити до нерівномірного розподілу енергії між елементами [11].

Нерівномірність параметрів окремих елементів батарейного пакета може спричинити перезаряджання або надмірний розряд окремих акумуляторів, що в кінцевому підсумку призводить до їх деградації або виходу з ладу. Для запобігання таким ситуаціям у сучасних системах застосовуються системи керування батареями (Battery Management System, BMS), які забезпечують захист від перевантаження, перезаряджання та глибокого розряджання шляхом безперервного моніторингу електричних параметрів кожного елемента. При цьому точне визначення SOC є одним із ключових завдань BMS, оскільки безпосередньо впливає на ефективність управління та довговічність акумуляторної системи [12].

Методи апроксимації та визначення параметрів акумуляторів при їх моделюванні передбачають широке застосування різних підходів статистики та машинного навчання. Одним із найпоширеніших є метод найменших квадратів [13], який забезпечує мінімізацію суми квадратів відхилень між експериментальними та модельними даними і характеризується високою точністю за наявності достатнього обсягу вимірювань. Для оптимізації параметрів моделей також використовується метод градієнтного спуску, ефективність якого значною мірою залежить від коректного вибору швидкості навчання та структури даних [14].

Окрім цього, в роботах застосовуються методи поліноміальної регресії, що дозволяють описувати нелінійні залежності між параметрами акумулятора, однак при використанні поліномів високого порядку можуть виникати проблеми переобчислення та нестійкості результатів. Метод інтерполяції Лагранжа використовується для побудови аналітичних залежностей на основі обмеженої кількості експериментальних точок, проте його застосування є доцільним переважно для гладких функцій і невеликих наборів даних [15]. Порівняльний аналіз зазначених методів апроксимації при визначенні параметрів акумуляюючих систем наведено в таблиці 1.

Таблиця 1

Порівняння методів апроксимації

Метод	Переваги	Недоліки	Додаткові характеристики
Генетичний алгоритм	Універсальність, ефективність для складних задач	Високі обчислювальні витрати	Працює незалежно від типу функції
Метод найменших квадратів	Висока точність, простота реалізації	Може бути неточним для нелінійних задач	Потребує великої вибірки даних
Гradientний спуск	Гарний для великих моделей	Чутливий до параметра навчання	Використовується в машинному навчанні
Поліноміальна регресія	Простота у застосуванні	Може призводити до "перенавчання"	Ефективна для гладких даних

Формулювання цілей статті

Метою роботи є розроблення моделі LiFePO₄ акумуляторної системи та оцінка її точності й ефективності при дослідженні режимів заряджання і розряджання.

Виклад основного матеріалу

На початковому етапі дослідження було проведено попередню обробку експериментальних даних, яка включала видалення аномальних значень та записів з відсутніми параметрами. Підготовлений набір даних було розділено на вісім груп відповідно до значень струму зарядки та розрядки, а саме на чотири групи для кожного режиму. Діапазони струмів становили: перший 1-3 А, другий 9-11 А, третій 19-21 А, четвертий 29-31 А, що дозволило охопити весь робочий діапазон акумуляторної системи.

Після класифікації даних у кожній групі було визначено середні значення напруги на клеммах акумулятора для відповідних рівнів стану заряду (SOC). Для зменшення коливань вимірювань та підвищення стабільності отриманих характеристик результати були додатково згладжені за допомогою поліноміальної апроксимації. Такий підхід дозволив сформувати узагальнені профілі залежності напруги від SOC для кожного режиму струму.

Для можливості аналізу повного діапазону станів заряду були згенеровані синтетичні значення напруги для низьких рівнів SOC, які були відсутні в експериментальних даних. Це дозволило підвищити універсальність моделі та забезпечити точність прогнозів в умовах неповної вхідної інформації.

Сформована цільова функція для завдань регресії, а саме MSE (Mean Squared Error), формула для розрахунку значень наведена нижче:

$$L(y, y') = \frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2$$

забезпечує визначення прогнозованого значення напруги на клеммах акумулятора, на основі якого оцінюється рівень залишкового заряду та загальна точність моделі. Під час її розрахунку дані проходять покрокову обробку: для кожного рівня заряду визначається прогнозована напруга з урахуванням струму, часу, режиму роботи, параметрів акумулятора та аналітичних залежностей. Розраховані значення порівнюються з експериментальними вимірюваннями, після чого обчислюється середньоквадратична похибка.

Для підвищення стійкості моделі додатково вводиться штрафний компонент, який враховує варіацію похибок між фактичними та розрахунковими значеннями напруги. Це дозволяє уникнути ситуацій, коли загальна похибка моделі низька, але спостерігаються значні локальні відхилення. Поєднання MSE (середньої квадратичної похибки) з індексом варіації похибки, зваженим коефіцієнтом α , формує кінцеве значення цільової функції та забезпечує пошук параметрів, для яких модель є максимально точною та стабільною.

Наступним етапом дослідження було вдосконалення моделі шляхом комплексного застосування методу найменших квадратів та генетичного алгоритму, для прогнозування параметрів акумулятора при заряджанні та розряджанні струмами різної потужності. Метод найменших квадратів використовувався для уточнення початкових параметрів та мінімізації різниці між розрахунковими та експериментальними значеннями напруги, забезпечуючи ітеративне наближення до оптимальних коефіцієнтів моделі.

Результати розрахунку параметрів акумулятора при заряджанні та розряджанні струмами з інтервалу [19-21]А наведено, відповідно, на рисунках 3,4.

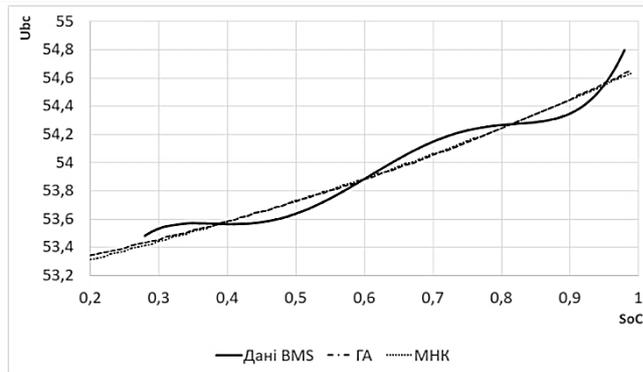


Рис. 3. Результати розрахунку параметрів акумулятора при заряджанні

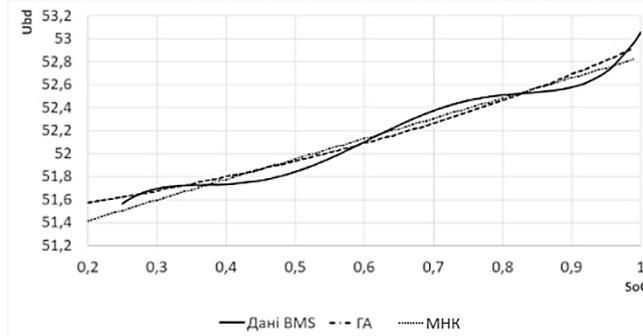


Рис. 4. Результати розрахунку параметрів акумулятора при розряджанні

У даному випадку маємо можливість аналізувати результати моделювання роботи батареї у співставленні з реальними історичними даними BMS напруги на клеммах акумулятора (U_b) та ємності (SOC). Ефективність моделі підтверджено на незалежному наборі даних (який складається з восьми груп за значенням сили струму заряджання/розряджання, по чотири для заряджання і розрядж, отриманий з акумуляторної станції на основі якого будувалася запропонована модель) із використанням критеріїв $R^2 \geq 0,96$, $MAE \pm 0,0587$, $MSE \pm 0,005$, $PFGE \pm 0,1623$ та $MAPE \pm 0,0001$. Щоб забезпечити високу точність моделювання напруги, застосовано гібридний підхід, який інтегрує різні парадигми машинного навчання та компенсує обмеження моно-методів.

Для моделювання зміни напруги акумулятора застосовано гібридну стратегію, що поєднує різні парадигми машинного навчання. Такий вибір дозволяє компенсувати недоліки окремих методів:

- 1.1. Глибокі нейронні мережі. Основний інструмент апроксимації завдяки їхній здатності апроксимувати будь-яку неперервну функцію. Для вирішення проблеми "згасання градієнта" та моделювання знакозмінних струмів замість класичної ReLU застосовано LeakyReLU та GELU (Gaussian Error Linear Unit).
- 1.2. Градієнтний бустинг. Використовується як еталонний метод (baseline) для табличних даних. Його перевага полягає у стійкості до перенавчання на основі вбудованої регуляризації, що важливо при роботі з обмеженим вибірками даних у реальних сонячних станціях.
- 1.3. Ансамблювання (підхід стекування). Реалізовано для підвищення гнучкості і адаптвності системи. Вибір мета-моделі навчання на основі Ridge Regression (L2 регуляризація) обумовлений необхідністю доповнення прогнозів базових нелінійних моделей та врахування лінійної залежності напруги від струму, на основі закону Ома.

Для обґрунтування вибору фінальної архітектури проведено порівняльний аналіз методів за ключовими критеріями, результати наведено у таблиці 2.

Таблиця 2

Порівняння використаних методів за ключовими критеріями

Модель	Точність	Швидкість навчання	Інтерпретованість	Стійкість до шуму	Примітка
ЕЕС + Генетичний алгоритм	Середня	Низька	Висока (Фізична)	Середня	Використовується для аналізу SOH
MLP (GELU/LeakyReLU)	Висока	Середня	Низька ("Black box")	Висока	Найкраще для прогнозу в реальному часі
XGBoost	Висока	Висока	Середня (Feature Importance)	Висока	Потужний baseline
Stacking Ensemble	Найвища	Низька	Низька	Найвища	Остаточний вибір на основі метрик точності

У процесі навчання моделей задача регресії зводиться до мінімізації функції втрат. Функція втрат (Loss Function): Обрано MSE (Mean Squared Error). Вибір квадратичної функції штрафує великі відхилення сильніше, ніж малі, що дозволяє уникнути критичних помилок у прогнозі напруги, які можуть призвести до аварійного відключення інвертора. Для моделі Stacking Ensemble застосовано більш складну стратегію 5-Fold Cross-Validation (5-кратна перехресна перевірка) при генерації мета-ознак для моделі другого рівня. Це критично важливо для запобігання витоку даних (Data Leakage), коли мета-модель могла б "підглядати" правильні відповіді через перенавчання базових моделей.

Експерименти проводилися з фіксованими наборами гіперпараметрів, підібраними емпіричним шляхом для забезпечення балансу між швидкістю навчання та точністю. Конфігурації моделей наведено в таблиці 3.

Таблиця 3

Критерії конфігурації моделей

Тип моделі	Параметри	Значення
ANN (Single)	Архітектура	Input -> Dense(32) -> Dense(16) -> Output(1)
	Оптимізатор	Adam (Learning Rate: default)
	Batch Size	16 (для Single ANN), 32 (для Ensemble)
	Early Stopping	Patience: 15 епох (відновлення найкращих ваг)
XGBoost	Кількість естиматорів	1000
	Learning Rate	0.05
	Глибина дерева	5 (max depth)
	Early Stopping	10 раундів
Stacking	Базові моделі (L0)	RandomForest (n=50), LightGBM, Ridge
	Мета-модель (L1)	Ridge Regression
Genetic Alg.	Розмір популяції	100 особин
	Кількість поколінь	100
	Мутація	Адаптивна (Гауссian, scale 0.1 -> 0.01)

Вибір тестових діапазонів струму базується на принципі стратифікованої вибірки, що має на меті охопити весь спектр експлуатаційних режимів акумуляторної системи - від станів спокою до граничних навантажень. Результати моделювання процесів заряджання акумуляторної системи засвідчують залежність ефективності застосованих методів оптимізації від величини зарядного струму. В умовах середніх і високих значень струму генетичний алгоритм демонструє перевагу над методом найменших квадратів. Зокрема, в інтервалі зарядного струму моделей четвертого рівня [29-31] А, побудована із застосуванням нейронної мережі, характеризується меншою похибкою та вищими значеннями коефіцієнта детермінації, що свідчить про кращу здатність відтворювати нелінійні динамічні процеси заряджання.

Водночас у режимах із низькими значеннями зарядного струму першого рівня [1-3] А, спостерігається зворотна тенденція: метод найменших квадратів забезпечує дещо кращі показники за середньоквадратичною похибкою та коефіцієнтом детермінації. Це вказує на його ефективність у менш динамічних і відносно стабільних режимах роботи акумулятора. Значення метрик MAE та MAPE для обох методів залишаються в допустимих межах, що підтверджує загальну узгодженість результатів моделювання з експериментальними даними.

Таблиця 4

Результати точності прогнозування для процесу заряджання при інтервалі струму від 1А до 3А

Метод	MAE	MSE	R ²
ReLU	0.8970	0.0152	0.0851
LeakyReLU	0.7732	0.0388	0.1613
Tanh	0.8505	0.0256	0.1321
GELU	0.7198	0.0479	0.1701
Stacking	0.8934	0.0182	0.0906
Bagging	0.7518	0.0425	0.1604
xgboost	0.8564	0.0246	0.1018

Таблиця 5

Результати точності прогнозування для процесу розряджання при інтервалі струму від 1А до 3А

Метод	MAE	MSE	R ²
ReLU	0.7455	0.0200	0.1177
LeakyReLU	0.6761	0.0352	0.1545
Tanh	0.6710	0.0357	0.1460
GELU	0.6143	0.0419	0.1770
Stacking	0.7515	0.0270	0.1072
Bagging	0.8197	0.0196	0.0999
xgboost	0.8564	0.0246	0.1018

Як свідчать кількісні показники, наведені у Таблицях 4 і 5, вибір оптимального алгоритму моделювання безпосередньо корелює з інтенсивністю розрядження батареї. У більшості сценаріїв із середніми та високими струмами Метод найменших квадратів забезпечує мінімальне відхилення від реальних історичних даних, підтверджуючи свою надійність для лінеаризованих ділянок роботи.

Однак специфіка протікання електрохімічних процесів при малих струмах ($1-3 \text{ A}$) вимагає більш чутливого інструментарію. Саме тут модель на основі нейронної мережі виявила вищу здатність до узагальнення (generalization capability). Аналіз похибок MAE та MAPE підтверджує, що нейромережа ефективніше "вловлює" приховані закономірності та слабко виражені нелінійності, характерні для цього режиму роботи. Це дозволяє зробити висновок про доцільність диференційованого підходу: використання МНК як основного методу та залучення нейромереж для уточнення прогнозу в зонах малих струмів, де точність традиційних методів знижується.

У діапазоні високих струмів розрядження четвертого рівня 29-31 А, обидва методи характеризуються зниженням точності, що зумовлено зростанням нелінійності процесів та впливом обмежень експериментальних даних. Результати аналізу наведені в таблицях 6, 7.

Таблиця 6

Результати розрахунку похибки обчислення параметрів процесу зарядження акумулятора LiFePO

Інтервал струму розрядження (А)	Метод	Метрика точності		
		MAE	MSE	R ²
1-3	ReLU	0.8970	0.0152	0.0851
	Stacking	0.8934	0.0182	0.0906
9-11	Stacking	0.9440	0.0081	0.0738
	xgboost	0.9346	0.0095	0.0681
19-21	ReLU	0.9481	0.0067	0.0626
	Stacking	0.9667	0.0043	0.0478
	xgboost	0.9508	0.0063	0.0609
29-31	ReLU	0.9456	0.0049	0.0539
	Stacking	0.9795	0.0019	0.0342
	xgboost	0.9676	0.0029	0.0414

Таблиця 7

Результати розрахунку похибки обчислення параметрів процесу розрядження акумулятора LiFePO₄

Інтервал струму розрядження (А)	Метод	Метрика точності		
		MAE	MSE	R ²
1-3	ReLU	0.8970	0.0152	0.0851
	Stacking	0.8934	0.0182	0.0906
9-11	Stacking	0.9440	0.0081	0.0738
	xgboost	0.9346	0.0095	0.0681
19-21	ReLU	0.9481	0.0067	0.0626
	Stacking	0.9667	0.0043	0.0478
	xgboost	0.9508	0.0063	0.0609
29-31	ReLU	0.9456	0.0049	0.0539
	Stacking	0.9795	0.0019	0.0342
	xgboost	0.9676	0.0029	0.0414

Найбільш суперечливі результати показали поодинокі нейронні мережі (ANN) з різними функціями активації. У "спокійних" режимах зарядження моделі з активацією ReLU демонстрували високу точність, проте в динамічних режимах розрядження (особливо в діапазонах 19-21 А та 29-31 А) спостерігався повний колапс окремих архітектур.

Такий феномен пояснюється двома факторами. По-перше, розбиття даних на вузькі діапазони струму критично зменшило обсяг навчальної вибірки для нейромереж, які потребують великих масивів даних для коректної настройки ваг. По-друге, хаотичний характер побутового навантаження при розрядженні створює перехідні процеси, які нейромережа на малій вибірці сприймає як шум або аномалії, що призводить до перенавчання та нездатності узагальнювати тренд.

Узагальнення отриманих результатів дозволяє зробити висновок про доцільність застосування ансамблевого підходу, який поєднує метод найменших квадратів і нейронних мереж. Такий підхід забезпечує отримання високої точності моделювання на всіх діапазонах струмів зарядження та розрядження, використовуючи переваги кожного з методів залежно від режиму роботи акумуляторної системи. Крім того, встановлено, що ключовим фактором забезпечення якісного моделювання системи акумуляування електроенергії є етап попереднього опрацювання даних, який включає усунення аномальних значень, нормалізацію параметрів та введення коефіцієнтів урахування часових залежностей, що істотно підвищує стабільність і достовірність результатів моделювання.

Висновки з даного дослідження і перспективи подальших розвідок у даному напрямі

У ході виконання даного дослідження, було розроблено комп'ютерну адаптивну модель процесів заряджання/розряджання акумулятора, яка дає змогу визначати напругу на його клеммах, як індикатор енергетичного потенціалу, на основі параметрів акумулятора та історичних даних про режими експлуатації за різних умов.

Ключовим науковим результатом даної статті є розроблена адаптивна модель процесів заряджання та розряджання при різних значеннях струму акумулятора, яка на основі еквівалентної електричної схеми, дозволяє визначати напругу на клеммах і стан заряду акумулятора за історичними даними експлуатації.

Ансамблевий підхід при розробленні моделі дозволяє застосовувати декілька різномісних методів для реалізації управління системою акумулявання електричної енергії, а саме, при низьких і середніх стабільних струмах заряджання, доцільніше застосовувати метод найменших квадратів, а при використанні високих струмів зарядження, кращу точність демонструє нейронна мережа (яка?) для визначення параметрів цільової функції та ідентифікації стану акумулятора. Проведене порівняння розрахованих та експериментальних даних підтвердило високий рівень точності моделювання, коефіцієнт $R^2 = 0,96$.

Отримані результати підтверджують доцільність використання розробленої моделі для аналізу режимів роботи акумуляторів та дослідження впливу їх параметрів на функціонування гібридних систем електропостачання, що створює підґрунтя для подальшого вдосконалення систем управління енергодинамічними процесами та прогнозування енергетичних характеристик акумуляторів електричної енергії.

Література

1. Li, P., Liu, T., Jin, P., Wang, Z., Wang, S., Yuan, H., Ma, Z., & Di, Y. Identification of lithium-ion battery equivalent circuit model parameters based on the multi-innovation identification algorithm. *Energy Storage Science and Technology*, 12(10), 3155-3169. URL: <https://esst.cip.com.cn/EN/10.19799/j.cnki.2095.4239.2023.0358>
2. Zhang, Y., Zou, Y., Liu, P., Lai, Z., & Wen, L. EIS equivalent circuit model prediction using interpretable machine learning and parameter identification using global optimization algorithms. *Electrochimica Acta*, June, 2022. URL: <https://doi.org/10.1016/j.electacta.2022.06.XXX>
3. Tian, N., Wang, Y., Chen, J., & Fang, H. One-Shot Parameter Identification of the Thevenin's Model for Batteries: Methods and Validation. arXiv preprint arXiv:2003.06504. URL: <https://arxiv.org/abs/2003.06504>.
4. Iurilli, P., Brivio, C., Carrillo, R.E., & Wood, V. DRT-based modelling framework for Li-ion cells. arXiv preprint arXiv:2203.08515. URL: <https://arxiv.org/abs/2203.08515>
5. Biju, N. & Fang, H. BattX: An Equivalent Circuit Model for Lithium-Ion Batteries Over Broad Current Ranges. arXiv preprint arXiv:2211.05999. URL: <https://arxiv.org/abs/2211.05999>
6. Kirk, T.L., Lewis-Douglas, A., Howey, D.A., Please, C.P., & Chapman, S.J. Nonlinear electrochemical impedance spectroscopy for lithium-ion battery model parameterization. arXiv preprint arXiv:2209.03961. URL: <https://arxiv.org/abs/2209.03961>
7. Itani, K., & De Bernardinis, A. Review on New-Generation Batteries Technologies: Trends and Future Directions. *Energies*, 16(22), 7530. URL: <https://doi.org/10.3390/en16227530>
8. Hu, X., & Tang, X. A Review of Modeling Techniques for Lithium-Ion Traction Batteries in Electric Vehicles. *Journal of Mechanical Engineering*, 2020. URL: <https://link.springer.com/article/10.1007/s11771-020-4412-7>.
9. Gradient-based optimization for parameter identification of lithium-ion. *International Journal on Intelligent Systems*, 2024. URL: <https://www.sciencedirect.com/science/article/pii/S2590123024011009>.
10. Zhao, R., Xia, B., Li, B., Cao, L., & Lai, Y. A Study on the Open Circuit Voltage and State of Charge Characterization of High Capacity Lithium-Ion Battery Under Different Temperature. *Energies*, 2018. URL: <https://doi.org/10.3390/en11092345>.
11. Wu, Y., Liu, X., Zhang, J., Liu, M., Wang, L., Du, X., & Yan, X. Temperature-Influenced SOC Estimation of LiFePO4 Batteries in Hybrid Electric Tractors Based on SAO-LSTM Model. *World Electric Vehicle Journal*, 16(5), 283. URL: <https://doi.org/10.3390/wevj16050283>.
12. Kurkin, A.; Chivenkov, A.; Aleshin, D.; Trofimov, I.; Shalukho, A.; Vilkov, D. Battery Management System for Electric Vehicles: Comprehensive Review of Circuitry Configuration and Algorithms. *World Electr. Veh. J.* 2025, 16, 451. URL: <https://doi.org/10.3390/wevj16080451>
13. Grisetti, G., Guadagnino, T., Aloise, I., Colosi, M., Della Corte, B., & Schlegel, D. Least squares optimization: From theory to practice. arXiv. URL: <https://doi.org/10.48550/arXiv.2002.11051>.
14. Ruder, S. *An overview of gradient descent optimization algorithms*. arXiv. URL: <https://doi.org/10.48550/arXiv.1609.04747>.
15. Liu, X., & Tian, H. Research on Imbalanced Data Regression Based on Confrontation. *Processes*, 12(2), 375. URL: <https://doi.org/10.3390/pr12020375>.

References

1. Li, P., Liu, T., Jin, P., Wang, Z., Wang, S., Yuan, H., Ma, Z., & Di, Y. Identification of lithium-ion battery equivalent circuit model parameters based on the multi-innovation identification algorithm. *Energy Storage Science and Technology*, 12(10), 3155-3169. URL: <https://esst.cip.com.cn/EN/10.19799/j.cnki.20954239.2023.0358>
2. Zhang, Y., Zou, Y., Liu, P., Lai, Z., & Wen, L. EIS equivalent circuit model prediction using interpretable machine learning and parameter identification using global optimization algorithms. *Electrochimica Acta*, June, 2022. URL: <https://doi.org/10.1016/j.electacta.2022.06.XXX>
3. Tian, N., Wang, Y., Chen, J., & Fang, H. One-Shot Parameter Identification of the Thevenin's Model for Batteries: Methods and Validation. arXiv preprint arXiv:2003.06504. URL: <https://arxiv.org/abs/2003.06504>.
4. Iurilli, P., Brivio, C., Carrillo, R.E., & Wood, V. DRT-based modelling framework for Li-ion cells. arXiv preprint arXiv:2203.08515. URL: <https://arxiv.org/abs/2203.08515>
5. Biju, N. & Fang, H. BattX: An Equivalent Circuit Model for Lithium-Ion Batteries Over Broad Current Ranges. arXiv preprint arXiv:2211.05999. URL: <https://arxiv.org/abs/2211.05999>
6. Kirk, T.L., Lewis-Douglas, A., Howey, D.A., Please, C.P., & Chapman, S.J. Nonlinear electrochemical impedance spectroscopy for lithium-ion battery model parameterization. arXiv preprint arXiv:2209.03961. URL: <https://arxiv.org/abs/2209.03961>
7. Itani, K., & De Bernardinis, A. Review on New-Generation Batteries Technologies: Trends and Future Directions. *Energies*, 16(22), 7530. URL: <https://doi.org/10.3390/en16227530>
8. Hu, X., & Tang, X. A Review of Modeling Techniques for Lithium-Ion Traction Batteries in Electric Vehicles. *Journal of Mechanical Engineering*, 2020. URL: <https://link.springer.com/article/10.1007/s11771-020-4412-7>.
9. Gradient-based optimization for parameter identification of lithium-ion. *International Journal on Intelligent Systems*, 2024. URL: <https://www.sciencedirect.com/science/article/pii/S2590123024011009>.
10. Zhao, R., Xia, B., Li, B., Cao, L., & Lai, Y. A Study on the Open Circuit Voltage and State of Charge Characterization of High Capacity Lithium-Ion Battery Under Different Temperature. *Energies*, 2018. URL: <https://doi.org/10.3390/en11092345>.
11. Wu, Y., Liu, X., Zhang, J., Liu, M., Wang, L., Du, X., & Yan, X. Temperature-Influenced SOC Estimation of LiFePO₄ Batteries in Hybrid Electric Tractors Based on SAO-LSTM Model. *World Electric Vehicle Journal*, 16(5), 283. URL: <https://doi.org/10.3390/wevj16050283>.
12. Kurkin, A.; Chivenkov, A.; Aleshin, D.; Trofimov, I.; Shalukho, A.; Vilkov, D. Battery Management System for Electric Vehicles: Comprehensive Review of Circuitry Configuration and Algorithms. *World Electr. Veh. J.* 2025, 16, 451. URL: <https://doi.org/10.3390/wevj16080451>
13. Grisetti, G., Guadagnino, T., Aloise, I., Colosi, -M., Della Corte, B., & Schlegel, D. Least squares optimization: From theory to practice. arXiv. URL: <https://doi.org/10.48550/arXiv.2002.11051>.
14. Ruder, S. *An overview of gradient descent optimization algorithms*. arXiv. URL: <https://doi.org/10.48550/arXiv.1609.04747>.
15. Liu, X., & Tian, H. Research on Imbalanced Data Regression Based on Confrontation. *Processes*, 12(2), 375. URL: <https://doi.org/10.3390/pr12020375>.