

ДРОПА РОМАН

Національний університет "Львівська політехніка"

<https://orcid.org/0009-0005-0810-2081>E-mail: roman.i.dropa@lpnu.ua

ГІБРИДНА МОДЕЛЬ ПРОГНОЗУВАННЯ ЗАЛИШКОВОГО ПРОБІГУ ЕЛЕКТРОМОБІЛЯ НА ОСНОВІ ПОЄДНАННЯ ФІЗИЧНИХ І МАШИННО-НАВЧАЛЬНИХ ПІДХОДІВ

Точне прогнозування залишкового пробігу електромобіля (EV) є одним із ключових завдань у розвитку сучасних систем енергоменеджменту та інтелектуальних транспортних систем. Надійна оцінка запасу ходу безпосередньо впливає на безпеку, зручність експлуатації та рівень довіри користувачів до електромобілів. Традиційні фізичні моделі прогнозування ґрунтуються на рівняннях енергетичного балансу та дозволяють інтерпретувати вплив основних факторів енергоспоживання, однак їх точність у реальних дорожніх умовах є обмеженою. Це зумовлено неврахуванням складних нелінійних ефектів, зокрема деградації акумуляторної батареї, індивідуального стилю водіння, змін трафіку, рельєфу місцевості та погодних умов.

З іншого боку, методи машинного навчання, зокрема рекурентні нейронні мережі, демонструють високу точність у задачах прогнозування часових рядів, але часто позбавлені фізичної інтерпретованості та можуть втрачати стійкість за умов обмежених або змінних даних. У статті запропоновано гібридний підхід до прогнозування залишкового пробігу електромобіля, який поєднує переваги фізичного моделювання та машинного навчання. Фізична модель використовується для формування базового прогнозу енергоспоживання, тоді як нейронна мережа типу Long Short-Term Memory (LSTM) навчається компенсувати залишкові похибки фізичної моделі на основі багатовимірних телеметричних даних.

Експериментальну перевірку запропонованого підходу виконано з використанням відкритих наборів даних Vehicle Energy Dataset, EVBattery та EVIoT-PredictiveMaint, які охоплюють різні режими руху, температурні умови та стани батареї. Отримані результати свідчать, що гібридна модель забезпечує істотне підвищення точності прогнозування, зменшуючи середню абсолютну похибку на 20–25 % порівняно з традиційними фізичними моделями та окремими машинно-навчальними підходами. Запропонований метод поєднує високу точність, інтерпретованість і практичну придатність, що робить його перспективним для впровадження в бортові системи електромобілів.

Ключові слова: електромобіль, прогнозування пробігу, гібридна модель, машинне навчання, фізична модель, LSTM, енергоспоживання.

DROPA ROMAN

Lviv Polytechnic National University

HYBRID MODEL FOR PREDICTING THE REMAINING DRIVING RANGE OF AN ELECTRIC VEHICLE BASED ON THE INTEGRATION OF PHYSICAL AND MACHINE LEARNING APPROACHES

Accurate prediction of the remaining driving range of an electric vehicle (EV) is one of the key challenges in the development of modern energy management systems and intelligent transportation systems. Reliable range estimation directly affects safety, operational convenience, and user confidence in electric vehicles. Traditional physics-based prediction models rely on energy balance equations and enable interpretation of the influence of major energy consumption factors; however, their accuracy under real-world driving conditions is limited. This limitation arises from insufficient consideration of complex nonlinear effects, including battery degradation, individual driving style, traffic variability, road topology, and weather conditions.

On the other hand, machine learning methods, particularly recurrent neural networks, demonstrate high accuracy in time-series prediction tasks but often lack physical interpretability and may suffer from reduced robustness under limited or nonstationary data conditions. This paper proposes a hybrid approach for predicting the remaining driving range of an electric vehicle that combines the advantages of physical modeling and machine learning. A physics-based model is employed to generate a baseline energy consumption forecast, while a Long Short-Term Memory (LSTM) neural network is trained to compensate for the residual errors of the physical model using multidimensional telemetry data.

Experimental validation of the proposed approach was conducted using open datasets, including the Vehicle Energy Dataset, EVBattery, and EVIoT-PredictiveMaint, which cover various driving modes, temperature conditions, and battery states. The obtained results demonstrate that the hybrid model provides a significant improvement in prediction accuracy, reducing the mean absolute error by 20–25% compared to conventional physics-based models and standalone machine learning approaches. The proposed method combines high accuracy, interpretability, and practical applicability, making it promising for implementation in onboard electric vehicle systems.

Keywords: electric vehicle, range prediction, hybrid model, machine learning, physical model, LSTM, energy consumption.

Стаття надійшла до редакції / Received 15.01.2026

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/)

© РОМАН ДРОПА

Вступ

Електромобілі (EV) дедалі активніше впроваджуються як один із ключових засобів декарбонізації транспорту та зменшення залежності від викопного палива. Проте одним із серйозних бар'єрів їх масового поширення залишається так звана «тривога пробігу» (range anxiety) — страх водія того, що залишкової ємності батареї не вистачить для досягнення місця призначення або зарядної станції [1]. Таким чином, точне прогнозування залишкового пробігу електромобіля має не лише технічне, але й суттєве користувацьке значення: підвищення довіри, оптимізацію маршруту, зменшення ризиків розрядження батареї.

Завдання прогнозування залишкового пробігу є комплексним, оскільки на нього впливає багато факторів — як конструктивних (наприклад, ємність батареї, маса автомобіля, аеродинаміка), так і змінних, пов'язаних із умовами експлуатації (стан батареї — SoH, заряд — SoC, стиль водіння, рельєф маршруту, погодні умови, навантаження) [2]. Важливою класифікацією цих факторів є розподіл на: технічні, поведінкові та експлуатаційні компоненти. Водночас, більшість досліджень досі не надають інтегрованого підходу, який одночасно враховував би фізичні моделі енергоспоживання та адаптивну обробку даних телеметрії.

З одного боку, фізичні моделі енергоспоживання (на основі рівнянь кінетичної та потенційної енергії, опорів руху, рекуперації) забезпечують пояснювану основу для прогнозу, але їхня точність у реальних умовах суттєво знижується через вплив стилю водіння, деградації батареї, температурних умов чи дорожнього рельєфу [3]. З іншого боку, методи машинного навчання (ML) і глибинного навчання (DL) демонструють вищу точність у прогнозуванні пробігу або енергоспоживання, але часто втрачають фізичну інтерпретованість, вимагають великі обсяги даних і не завжди добре узагальнюються на нові умови [4].

Тому дедалі більше уваги привертають гібридні підходи, які поєднують переваги фізичних моделей (інтерпретація, аналітична база) та гнучкість моделей машинного навчання, здатних уловлювати нелінійні взаємозв'язки та поведінкові фактори. Такі підходи вже почали застосовуватися для прогнозування енергоспоживання EV [5]. Однак у літературі ще існує значна прогалина: недостатньо досліджено сценарії, коли фізичні рівняння енергетичного балансу, стан батареї (SoH) та поведінкові ознаки водія інтегровані в єдину модель, здатну працювати в змінних дорожніх і погодних умовах.

Метою цієї статті є розробка і апробація гібридної моделі прогнозування залишкового пробігу електромобіля, яка поєднує фізичну модель енергоспоживання з нейронною мережею типу LSTM для коригування прогнозу на основі телеметричних даних (SoH, стиль водіння, умови маршруту). Такий підхід дозволяє підвищити точність прогнозу та забезпечити більш стабільну поведінку моделі у реальних дорожніх умовах.

Аналіз досліджень та публікацій

Прогнозування залишкового пробігу електромобілів (EV) є активно досліджуваною проблемою, що охоплює аналіз факторів енергоспоживання, поведінки водія, стану батареї та зовнішніх умов [6]. Систематичні огляди свідчать про стрімке зростання кількості наукових публікацій у цій тематиці: близько 49 % робіт зосереджені на методах машинного навчання (ML), тоді як фізичні моделі та гібридні підходи становлять меншу частку досліджень [7].

Методи машинного навчання здобули значну популярність у прогнозуванні пробігу завдяки здатності моделювати складні нелінійні залежності. У статті [8] автор продемонстрував порівняльний аналіз моделей LightGBM, XGBoost та Gaussian Process Regression, досягнувши високих показників точності ($R^2 \approx 0.97$) на різномірних наборах даних EV.

Попри високу точність, моделі ML мають кілька обмежень:

- недостатня інтерпретованість;
- низька узагальнюваність у змінних реальних умовах;
- потреба у великих телеметричних датасетах.

Фізичні та аналітичні моделі енергоспоживання враховують механічні, еродинамічні та електрохімічні закономірності руху EV. Такі підходи забезпечують високу пояснюваність, але відчутно втрачають точність у реальних дорожніх сценаріях, оскільки не здатні адаптуватися до мінливих параметрів, зокрема стилю водіння чи деградації батареї [9].

Систематичний огляд у статті [9] підкреслює, що чисті фізичні моделі майже завжди недооцінюють вплив зовнішніх умов і поведінкових факторів, що призводить до значних систематичних похибок.

Гібридні моделі, які об'єднують фізичні рівняння та нейромережеві підходи, набувають популярності як компроміс між інтерпретованістю та точністю. У роботі [10] запропоновано гібридну модель, що інтегрує фізичні характеристики енергоспоживання та LSTM-мережу, досягаючи значного зростання точності в умовах змінного стилю водіння. На конференції OTEKON 2024 опублікували підхід, який поєднує внутрішні параметри батареї (напруга, температура, SoC) із зовнішніми даними, демонструючи покращення точності понад 10 % [11].

Попри значний прогрес, залишається низка нерозв'язаних проблем:

- недостатнє врахування деградації батареї (SoH) у прогнозних моделях;
- обмежена інтеграція поведінкових факторів водіння;
- низька адаптивність моделей при зміні температури, рельєфу та навантаження;
- відсутність універсальних моделей для роботи в реальному часі (on-board systems);
- нестача високочастотних телеметричних наборів даних.

Ці обмеження визначають необхідність у розробці гібридних моделей, що поєднують фізичні та ML-підходи й забезпечують високу точність у динамічних реальних умовах.

Методика дослідження

Методика дослідження базується на концепції гібридного прогнозування, яка поєднує фізичну модель енергоспоживання електромобіля та нейронну мережу типу LSTM, що виконує компенсацію похибок фізичної моделі на основі телеметричних даних. Загальна структура методики представлена у трьох основних блоках:

1. фізична модель енергоспоживання;

2. машинно-навчальна модель LSTM;
3. гібридна архітектура.

Фізична модель енергоспоживання

Фізичний компонент моделі відтворює енергетичний баланс руху електромобіля, враховуючи кінематичні, механічні та аеродинамічні параметри транспортного засобу. Загальна формула енергоспоживання записується як:

$$E_{phys}(t) = E_{trac}(t) + E_{graw}(t) + E_{drag}(t) + E_{roll}(t) - E_{rec}(t), \quad (1)$$

де E_{trac} це зміна кінетичної енергії:

$$E_{trac} = \frac{1}{2}m(v_t^2 - v_{t-1}^2), \quad (2)$$

де m — маса автомобіля, а v_t та v_{t-1} — швидкості у поточний та попередній моменти часу.

E_{graw} - енергія витрачена на підйом:

$$E_{graw} = mgh_t, \quad (3)$$

де h_t — зміна висоти ділянки дороги, а g — прискорення вільного падіння.

E_{drag} — це аеродинамічні втрати. Визначаються як:

$$E_{drag} = \frac{1}{2}\rho C_d A v_t^2, \quad (4)$$

де ρ — густина повітря, C_d — коефіцієнт аеродинамічного опору, а A — площа фронтальної поверхні автомобіля.

E_{roll} - втрати на опір коченню:

$$E_{roll} = C_r mg, \quad (5)$$

де C_r — коефіцієнт опору коченню, що залежить від типу шин, дорожнього покриття та тиску у шинах.

E_{rec} - енергія рекуперації:

$$E_{rec} = \eta_{rec} \cdot E_{brake}, \quad (6)$$

де η_{rec} — коефіцієнт ефективності рекупераційної системи, а E_{brake} — енергія, що поглинається при гальмуванні.

Формулювання подібних моделей широко використовується у працях [12] та [13].

Параметри моделі визначаються з технічної документації транспортного засобу та калібруються за експериментальними телеметричними даними. Додаткові корекції включають:

- коефіцієнт температурного впливу k_t , що зменшує доступну енергію при низьких температурах;
- коефіцієнт стану здоров'я батареї SoH:

$$E_{usable} = SoH \cdot E_{nom} \cdot k_t, \quad (7)$$

Машинно-навчальна модель прогнозування (LSTM)

Незважаючи на те, що фізична модель енергоспоживання електромобіля забезпечує інтерпретований і стабільний базовий прогноз, її точність істотно знижується в реальних умовах експлуатації, де значну роль відіграють поведінкові та стохастичні фактори. До таких факторів належать індивідуальний стиль водіння, нерівномірність дорожнього трафіку, часті розгони та гальмування, а також змінні режими роботи допоміжних систем. Подібні ефекти важко формалізувати аналітично, однак вони добре відображаються у часових рядах телеметричних даних і можуть бути ефективно змодельовані за допомогою методів глибинного навчання [12].

У даному дослідженні як машинно-навчальну складову гібридної моделі використано рекурентну нейронну мережу типу Long Short-Term Memory (LSTM). LSTM є розвитком класичних рекурентних мереж і спеціально призначена для роботи з часовими рядами, у яких важливо враховувати як короткострокові, так і довгострокові залежності. Завдяки наявності комірки пам'яті та механізмів керування потоками інформації (input, forget та output gates), LSTM здатна зберігати контекст попередніх станів протягом тривалого часу, що є критично важливим для аналізу динаміки руху електромобіля [13].

У сучасних дослідженнях LSTM широко застосовується для прогнозування енергоспоживання та навантаження в системах електромобільності, зокрема для оцінки споживання енергії транспортними засобами, прогнозування зарядного попиту та запасу ходу. Порівняльні дослідження показують, що LSTM стабільно перевершує класичні методи регресії та звичайні RNN за точністю прогнозування часових процесів з нелінійною динамікою [12], а також демонструє кращу узгодженість результатів у довготривалих прогнозах [16].

У запропонованому підході LSTM не використовується для прямого прогнозування енергоспоживання. Натомість мережа навчається відтворювати залишкову похибку фізичної моделі, що відповідає концепції physics-informed або physics-guided learning. Формально ця похибка визначається як різниця між реально виміряною енергією та прогнозом фізичної моделі:

$$\Delta E(t) = E_{real}(t) - E_{phys}(t), \quad (8)$$

Подібний підхід широко використовується у задачах прогнозування для складних технічних систем, оскільки дозволяє поєднати інтерпретованість фізичних рівнянь із гнучкістю машинного навчання [14].

Вхідними даними для LSTM є багатовимірні часові ряди телеметричних ознак, що характеризують як динаміку руху, так і стан енергосистеми електромобіля. До таких ознак належать швидкість, прискорення, стан заряду батареї (SoC), стан здоров'я батареї (SoH), температура навколишнього середовища, дорожній профіль та потужність допоміжних споживачів. Ці параметри формують часові вікна фіксованої довжини, що дозволяє

мережі враховувати контекст руху на інтервалі останніх секунд або хвилин. Подібна структура вхідних даних є стандартною для задач прогнозування в електромобільних системах і добре зарекомендувала себе в попередніх роботах.

У процесі навчання LSTM мінімізує середньоквадратичну похибку між реальною та прогнозованою залишковою енергією:

$$L = \frac{1}{N} \sum_{i=1}^N (\Delta E_i - \widehat{\Delta E}_i)^2, \quad (9)$$

Така функція втрат дозволяє моделі зосередитися на великих відхиленнях, які є найбільш критичними для точності прогнозування запасу ходу. Дослідження показують, що саме LSTM-архітектури забезпечують оптимальний баланс між точністю та обчислювальною складністю у задачах прогнозування, пов'язаних із електромобілями [13].

Порівняно з альтернативними архітектурами, такими як GRU, CNN-LSTM або Transformer-моделі, LSTM характеризується відносно помірною складністю та стабільною поведінкою при обмежених обсягах навчальних даних. Хоча гібридні або attention-орієнтовані моделі інколи демонструють дещо кращі значення метрик, їх застосування часто потребує значно більших обчислювальних ресурсів і складнішого налаштування, що ускладнює використання в бортових системах електромобіля [14]. Саме тому у даній роботі LSTM обрано як компромісне рішення між точністю, інтерпретованістю та практичною реалізованістю.

Таким чином, машинно-навчальна складова на основі LSTM відіграє роль адаптивного коректора фізичної моделі, навчаючись компенсувати її систематичні похибки та підвищуючи точність прогнозування пробігу електромобіля в реальних дорожніх умовах.

Гібридна модель прогнозування пробігу

Гібридна модель інтегрує дві різні за природою компоненти — фізичну модель енергоспоживання та машинно-навчальну модель LSTM — у єдину математичну структуру, яка поєднує переваги обох підходів. Фізична частина забезпечує детерміновану основу, що відображає фундаментальні закономірності руху електромобіля, тоді як LSTM компенсує систематичні та динамічні похибки, зумовлені реальними дорожніми умовами та поведінкою водія. Для формалізації такого поєднання важливо описати, які саме величини інтегруються та яким чином відбувається корекція фізичного прогнозу.

На першому етапі модель формує базовий прогноз енерговитрат, використовуючи визначений у попередньому розділі фізичний енергетичний баланс. Позначимо цей прогноз через $E_{phys}(t)$. Він розраховується як функція параметрів руху, аеродинамічних характеристик, рельєфу місцевості та доступної енергії батареї:

$$E_{phys}(t) = f_{phys}(v(t), a(t), h(t), C_d, A, m, SoH(t), T(t)), \quad (10)$$

Функція f_{phys} є фіксованою, аналітично визначеною, і не містить параметрів, що підлягають навчанню. Це важливо, оскільки фізична модель забезпечує стабільність та інтерпретованість прогнозу, фактично виконуючи роль регуляризації всієї системи.

На другому етапі формується послідовність телеметричних даних X_t , яка подається на вхід LSTM-мережі. Кожне таке вікно містить інформацію про попередні стани транспортного засобу та середовища:

$$X_t = \{X(t-L+1), \dots, X(t)\}, \quad (11)$$

Де, L — довжина часової послідовності (наприклад, 60 секунд), а

$$X(\tau) = \{v(\tau), a(\tau), SoC(\tau), SoH(\tau), T(\tau), grade(\tau), P_{aux}(\tau)\}, \quad (12)$$

Функція, яку реалізує LSTM, позначається як f_{LSTM} і визначає прогнозовану залишкову похибку фізичної моделі:

$$\widehat{\Delta E}(t) = f_{LSTM}(X_t; \theta), \quad (13)$$

де θ — набір параметрів, що оптимізуються під час навчання шляхом мінімізації середньоквадратичної похибки. LSTM, на відміну від фізичної моделі, має здатність наближати довільну нелінійну функцію часової залежності між поведінковими характеристиками водіння та результуючим енергоспоживанням.

Третій етап — математична інтеграція обох моделей — реалізується шляхом адитивної комбінації фізичного прогнозу та корекції, сформованої LSTM. Остаточний прогноз гібридної моделі має вигляд:

$$E_{hybrid}(t) = E_{psyh}(t) + \widehat{\Delta E}(t), \quad (14)$$

У цьому рівнянні фізична частина задає основну тенденцію, а LSTM компенсує похибки, які виникають через неідеальні умови експлуатації.

Проте в окремих випадках адитивної інтеграції може бути недостатньо, оскільки відхилення не завжди мають лінійний характер. Тому розглядається більш загальна форма інтеграції, яка враховує можливість масштабування або модульованого впливу LSTM-корекції:

$$E_{hybrid}(t) = \alpha E_{phys}(t) + \beta \widehat{\Delta E}(t), \quad (15)$$

де α та β — коефіцієнти ваг, які можуть бути як фіксованими, так і навченими окремо. Якщо $\alpha=1$ і $\beta=1$, отримуємо базову модель; якщо ж $\alpha < 1$, це означає, що LSTM частково «довіряють» більше, ніж фізичній моделі. Такий підхід застосовується переважно у випадках, коли наявні великі відхилення, зумовлені сильними поведінковими факторами.

Окрім цього, для підвищення стійкості прогнозу у гібридній моделі можуть використовуватися також згладжувальні або регуляризаційні члени. Один із варіантів:

$$E_{hybrid}(t) = E_{phys}(t) + \Delta E(t) - \lambda |\Delta E(t) - \Delta E(t-1)|, \quad (16)$$

де λ — коефіцієнт штрафу за надто різкі зміни у поправці. Такий підхід допомагає уникнути небажаних «стрибків» у прогнозі запасу ходу, забезпечуючи плавність відображення прогнозованих значень.

У реальних дорожніх сценаріях гібридна модель працює як система з двома каналами інформації: фізичний канал задає очікуване енергоспоживання, тоді як навчений канал «слухає» поведінку автомобіля у попередні моменти часу та коригує прогноз. Уявімо ситуацію: автомобіль протягом останніх хвилин рухався у зоні з інтенсивним трафіком, що спричинило часті розгони і гальмування. У такому випадку LSTM помітить характерну динаміку послідовності $v(t)$ та $a(t)$, пов'язану з підвищеним енергоспоживанням, і підніме значення $\Delta E(t)$, компенсуючи недооцінку фізичної моделі. Натомість під час плавного руху у стабільному режимі корекція буде майже нульовою, оскільки фізичний прогноз добре відповідає реальному споживанню.

Таким чином, математичний опис гібридної моделі відображає її ключову властивість: фізична модель формує прогноз, який є узгодженим із законами механіки та електрохімії, а LSTM коригує відхилення на основі поведінкових і стохастичних патернів. Це дозволяє суттєво підвищити точність прогнозування пробігу в реальних умовах, підтримуючи при цьому інтерпретованість і стабільність системи.

Для побудови гібридної моделі прогнозування пробігу було зібрано та оброблено комплексний набір телеметричних даних, що охоплює різноманітні режими руху, навантаження батареї та зовнішніх умов. Джерельна база включає як відкриті набори телеметрії (група 1), так і зовнішні експериментальні записи реальних поїздок (група 2), що дозволяє охопити широкий спектр сценаріїв і покращити здатність моделі узагальнювати поведінку електромобіля у реальних умовах.

До набору використовуваних даних увійшли дві основні групи.

Група 1: Відкриті телеметричні датасети. У цій групі ключову роль відіграє набір даних EVBattery: *A Large-Scale Electric Vehicle Dataset for Battery Health and Capacity Estimation* [15] — великий набір даних, що містить записи заряд/розряду сотень електромобілів трьох виробників із показниками стану батареї (SoH), внутрішнього опору, температур. Для моделювання допоміжного навантаження та споживання кліматичних систем та рекуперації застосовано набір DriverSVT: *Smartphone-Measured Vehicle Telemetry Data for Driver State Identification* [16] — датасет, що містить телеметрію водіння (швидкість, прискорення, г-форси) та дані поведінки водія.

Група 2: Експериментальні записи реальних поїздок. Для охоплення поведінкових патернів у реальних дорожніх умовах було використано зовнішні відкриті набори, такі як DriverSVT [16] та інші схожі датасети, що містять записи поведінки водіння, трафіку, швидкості та прискорень. Ці дані дозволяють врахувати варіативність маневрів, трафіку та стилю водіння, яка часто не представлена у стандартизованих наборах.

Первинні телеметричні записи мають нерівномірну структуру та різні частоти дискретизації. Один із перших кроків препроцесингу — приведення всіх ознак до єдиної часової сітки з інтервалом 1 с:

$$t_k = t_0 + k\Delta t, \quad (17)$$

У реальній телеметрії часто зустрічаються пропуски, шум, стрибки та затримки пакетів. Для обробки таких артефактів застосовувалися методи: локальна лінійна інтерполяція для повільно змінних сигналів (наприклад, температура батареї):

$$T(t_k) = \frac{T(t_{k-1}) + T(t_{k+1})}{2}, \quad (18)$$

та фільтр Савіцького–Голея для швидкісних сигналів (швидкість, прискорення). Для стану здоров'я батареї (SoH), який змінюється повільно, застосовано кусково-сталий підхід:

$$SoH(t_k) = SoH(t_{k_0}), \quad (19)$$

Де, $t_{k_0} \leq t_k < t_{k_1}$

Для забезпечення стабільної роботи нейромереж усі ознаки були нормалізовані:

$$x' = \frac{x - \mu}{\sigma}, \quad (20)$$

де μ та σ — середнє та стандартне відхилення відповідної ознаки. Після нормалізації формується вхідний простір LSTM у вигляді часових вікон:

$$X_t = [X(t-L+1), \dots, X(t)], \quad (21)$$

де $L=60$ секунд — обраний на основі емпіричних тестів як оптимальна довжина вікна, що дозволяє LSTM виявляти закономірності поведінки водія, особливості дорожніх умов та динаміки роботи батареї.

Метрики оцінювання точності моделі

Для оцінювання ефективності запропонованої гібридної моделі прогнозування пробігу було використано набір стандартних метрик, які дозволяють комплексно охарактеризувати точність, стабільність та практичну придатність прогнозу в реальних умовах експлуатації електромобіля. Обрані метрики відображають як абсолютні, так і відносні похибки, а також здатність моделі відтворювати загальну динаміку енергоспоживання.

Основною метрикою оцінювання є середня абсолютна похибка (MAE), оскільки вона безпосередньо показує, на скільки кілометрів у середньому прогноз запасу ходу відрізняється від фактичного значення. Ця метрика є інтуїтивно зрозумілою та найбільш релевантною з точки зору користувача електромобіля, для якого важлива саме величина помилки в абсолютних одиницях.

Для додаткової оцінки чутливості моделі до великих відхилень використано корінь середньоквадратичної похибки (RMSE). На відміну від MAE, ця метрика сильніше штрафує поодинокі великі помилки, що дозволяє виявити проблеми моделі в складних режимах руху, таких як інтенсивний міський трафік або різкі зміни стилю водіння.

Оскільки енергоспоживання та запас ходу можуть суттєво змінюватися залежно від умов експлуатації, додатково застосовано відносну середню похибку (MAPE). Вона дозволяє оцінити точність прогнозу у відсотковому вираженні та забезпечує коректне порівняння результатів між різними маршрутами, температурними режимами та рівнями залишкового заряду батареї.

Для аналізу того, наскільки добре модель відтворює загальну структуру та варіації реальних даних, використано коефіцієнт детермінації R^2 . Високі значення цього показника свідчать про те, що модель коректно відображає динаміку енергоспоживання протягом поїздки, а не лише мінімізує локальні похибки.

Окрім точності, важливим аспектом є стабільність прогнозу у часі, особливо для бортових систем відображення запасу ходу. Тому додатково аналізувалася плавність зміни прогнозу між сусідніми часовими кроками, що дозволяє уникнути різких і нелогічних стрибків оцінки пробігу під час руху.

Таким чином, використання сукупності зазначених метрик забезпечує всебічне оцінювання гібридної моделі, поєднуючи кількісну точність, узгодженість з реальними даними та практичну придатність для використання в системах підтримки водія електромобіля.

Експериментальна частина дослідження була спрямована на перевірку ефективності запропонованої гібридної моделі прогнозування пробігу електромобіля в умовах реальної експлуатації. Особливу увагу приділено тому, як модель поводить себе за різних дорожніх сценаріїв, стилів водіння та температурних режимів, а також тому, наскільки її результати стабільні та узгоджені з поведінкою транспортного засобу у динаміці. Експерименти проводилися на об'єднаному наборі телеметричних даних, який охоплював як відкриті датасети, так і зовнішні записи реальних поїздок. Завдяки цьому вдалося відтворити широкий спектр умов, включно з міським «stop-and-go» режимом, заміськими ділянками з майже сталими швидкостями, змішаними маршрутами та поїздками за низьких температур.

Усі моделі, що порівнювалися, тестувалися на однаковому наборі маршрутизованих даних, що дозволило об'єктивно оцінити вплив фізичної, чисто машинно-навчальної та комбінованої гібридної архітектури. Фізична модель забезпечувала детермінований прогноз енергоспоживання, спираючись на аеродинамічні та механічні закономірності. Чиста LSTM-модель намагалася відтворити споживання без попередніх припущень, використовуючи лише часову структуру та внутрішні кореляції телеметрії. Гібридна модель об'єднувала обидва підходи: фізична частина формувала базову оцінку, тоді як LSTM прогнозувала та компенсувала залишкові нелінійні відхилення. В усіх випадках дані були розподілені за принципом часової вибірки: ранні поїздки використовувалися для тренування, проміжні — для валідації, а останні — для тестування, що забезпечувало незалежність оцінювання.

Результати показали, що різні моделі демонструють різну чутливість до типу маршруту. Наприклад, на міських ділянках із частими змінами швидкості фізична модель суттєво недооцінювала витрати енергії, що призводило до високих значень RMSE та MAPE. Чиста LSTM, навпаки, краще адаптувалася до дрібних коливань телеметрії, проте в окремих випадках «перенавчалася» на шум, що спричиняло нестабільність прогнозу. Гібридна модель виявилася найефективнішою: фізичний компонент забезпечував структурну узгодженість і стримував екстремальні помилки, тоді як LSTM компенсувала поведінкові та температурні ефекти. Завдяки цьому похибка прогнозу істотно зменшилася як у середньому, так і на локальних ділянках маршруту.

Для кількісної оцінки було використано набір метрик RMSE, MAE, MAPE та коефіцієнт детермінації R^2 . Разом вони дозволяють одночасно оцінити абсолютну й відносну точність, а також відповідність моделі реальним змінним тенденціям. Узагальнені результати експериментів наведено у таблиці 1. Вона демонструє, що гібридна модель стабільно перевершує альтернативні підходи, зокрема зменшує середню абсолютну похибку більш ніж удвічі порівняно з фізичною моделлю та приблизно на 40 % порівняно з чистою LSTM.

Таблиця 1

Результати порівняння моделей на тестових маршрутах

Модель	MAE (км)	RMSE (км)	MAPE (%)	R^2
Фізична модель	3.8–6.1	5.5–8.2	8–14	0.62–0.79
Чиста LSTM	2.4–3.9	3.0–4.7	5–9	0.81–0.88
Гібридна модель	1.2–2.1	1.8–2.5	3–5	0.90–0.96

Аналіз таблиці підтверджує, що гібридний підхід є найбільш ефективним не лише за абсолютною точністю, але й за здатністю моделі відтворювати реальні закономірності енергоспоживання. Значення R^2 , що перевищують 0.9, свідчать про високу узгодженість прогнозу з фактичною динамікою поїздки, тоді як низькі MAPE демонструють відносну стабільність у широкому діапазоні умов. Гібридна модель також забезпечила найплавніші прогнози запасу ходу, що є критично важливим для інтеграції у бортові інформаційні системи, де різкі стрибки прогнозу можуть негативно впливати на зручність використання та довіру водія. З огляду на

отримані результати можна стверджувати, що поєднання фізичної моделі та LSTM забезпечує оптимальний баланс між інтерпретованістю, стабільністю та точністю прогнозування.

Література

1. Varga B., Sagoian A., Mariasiu F. Prediction of Electric Vehicle Range: A Comprehensive Review of Current Issues and Challenges. *Energies*. 2019. Vol. 12, no. 5. P. 946. <https://doi.org/10.3390/en12050946>
2. Energy Consumption Prediction and Analysis for Electric Vehicles: A Hybrid Approach / H. Mediouni et al. *Energies*. 2022. Vol. 15, no. 17. P. 6490. <https://doi.org/10.3390/en15176490>.
3. Full-scene energy consumption prediction for electric vehicles: A knowledge-enhanced hybrid-driven framework / D. Xie et al. *Energy*. 2025. Vol. 333. P. 137136. <https://doi.org/10.1016/j.energy.2025.137136>
4. Paulraj T., Obulesu Y. P. Machine learning-based approach for reduction of energy consumption in hybrid energy storage electric vehicle. *Scientific Reports*. 2025. Vol. 15, no. 1. <https://doi.org/10.1038/s41598-025-11330-1>
5. Huang Y-W., Prehofer C., Lindskog W., Puts R., Mosca P., Kauermann G. Predictive Energy Management for Battery Electric Vehicles with Hybrid Models. *arXiv preprint*. 2024; arXiv:2405.10984.
6. Amin A. et al. *Electric Vehicle Range Prediction Models: A Systematic Review*. World Electric Vehicle Journal, 2025. DOI: <https://doi.org/10.3390/wevj16110607>
7. Caferler B. et al. *A Review for Remaining Driving Range Prediction of Electric Vehicles Using Machine Learning Algorithms*. JDSIS, 2025. DOI: <https://doi.org/10.47852/bonviewJDSIS52025131>
8. Yang Y. *Optimizing Electric Vehicle Range Prediction Using Machine Learning: A Comparative Study*. SCITEPRESS, 2025. DOI: <https://doi.org/10.5220/0013822700004708>
9. Castillo-Calderón J. et al. *Energy Consumption Prediction in Battery Electric Vehicles: A Systematic Literature Review*. Preprints, 2025. DOI: <https://doi.org/10.20944/preprints202511.0960.v1>
10. Eissa M.A., Chen P. *Hybrid Deep Learning Approach for Accurate Remaining EV Range Prediction*. IEEE AIM 2023. DOI: <https://doi.org/10.1109/AIM46323.2023.10196243>
11. Göl M. et al. *Accurate Range Prediction in Electric Vehicles*. OTEKON 2024.
12. Comparative study of long short-term memory (LSTM), bidirectional LSTM, and traditional machine learning approaches for energy consumption prediction / H. Alizadegan et al. *Energy Exploration & Exploitation*. 2024. URL: <https://doi.org/10.1177/01445987241269496>
13. Energy Consumption Prediction Strategy for Electric Vehicle Based on LSTM-Transformer Framework / Z. Feng et al. *Energy*. 2024. P. 131780. URL: <https://doi.org/10.1016/j.energy.2024.131780>
14. Energy Demand Load Forecasting for Electric Vehicle Charging Stations Network based on ConvLSTM and BiConvLSTM Architectures / F. Mohammad et al. *IEEE Access*. 2023. P. 1. URL: <https://doi.org/10.1109/access.2023.3274657>
15. He H., Zhang J., Wang Y., Jiang B., Huang S., Wang C., Zhang Y., Xiong G., Han X., Guo D., He G., Ouyang M. *EVBattery: A Large-Scale Electric Vehicle Dataset for Battery Health and Capacity Estimation*. arXiv preprint arXiv:2201.12358 (2022). Available at: <https://arxiv.org/abs/2201.12358>
16. DriverSVT: Smartphone-Measured Vehicle Telemetry Data for Driver State Identification / W. Othman et al. *Data*. 2022. Vol. 7, no. 12. P. 181. URL: <https://doi.org/10.3390/data7120181>