

ISSN 1998-7927(print) ISSN 2664-6498 (online)

DOI: <https://doi.org/10.33216/1998-7927-2026-304-6-161-169>

УДК 004.89:621

ПОРІВНЯЛЬНЕ ОЦІНЮВАННЯ МОДЕЛЕЙ МАШИННОГО ТА ГЛИБОКОГО НАВЧАННЯ ДЛЯ КОРОТКОСТРОКОВОГО ПРОГНОЗУВАННЯ ЕЛЕКТРОСПОЖИВАННЯ

Бунке О.С., Грудзинський Ю.Є.

COMPARATIVE EVALUATION OF MACHINE AND DEEP LEARNING MODELS FOR SHORT-TERM ELECTRICITY CONSUMPTION FORECASTING

Bunke O.S., Hrudzynskiy Yu.Ye.

Зростання обсягів цифровізації енергетичних систем, розвиток технологій Інтернету речей (IoT) та впровадження концепції Smart Grid зумовлюють необхідність підвищення точності короткострокового прогнозування електроспоживання. Від якості прогнозу залежать ефективність керування електричними навантаженнями, оптимізація режимів роботи систем накопичення енергії, інтеграція відновлюваних джерел енергії та підтримка прийняття рішень в інтелектуальних енергетичних системах. Одночасно відсутні однозначні висновки щодо переваг складних моделей глибокого навчання над сучасними алгоритмами машинного навчання для прогнозування регулярних часових рядів електроспоживання.

Метою роботи є порівняльне оцінювання ефективності моделей машинного та глибокого навчання для короткострокового прогнозування енергоспоживання, а також аналіз впливу механізму часової уваги (Attention) на якість прогнозування рекурентної нейронної мережі типу Long Short-Term Memory (LSTM).

Для забезпечення відтворюваності результатів використано відкритий набір даних Power Consumption of Tetoian City, що містить понад 52 тис. вимірювань електроспоживання та синхронізовані метеорологічні параметри. Виконано агрегування даних до погодинної дискретизації, стандартизацію ознак, циклічне кодування календарних характеристик та формування навчальних послідовностей із використанням ковзного часового вікна тривалістю 24 години. У межах єдиної експериментальної методики проведено порівняльне дослідження моделей Persistence, Ridge Regression, Random Forest, HistGradientBoosting, LSTM, GRU та LSTM-Attention. Якість прогнозування оцінювалася за показниками MAE, RMSE, MAPE та коефіцієнтом детермінації (R^2).

Результати експерименту показали, що найкращу якість прогнозування для досліджуваного набору даних забезпечили моделі Ridge Regression та HistGradientBoosting, які досягли значень RMSE 898,29 та

901,13 відповідно, коефіцієнта детермінації понад 0,977 і MAPE близько 2,2%. Встановлено, що застосування механізму часової уваги дозволило покращити результати рекурентної моделі LSTM: середньоквадратична похибка зменшилася на 16,70%, а середня абсолютна похибка – на 23,66% порівняно зі стандартною LSTM. Разом із тим для досліджуваного часового ряду запропонована модель LSTM-Attention не перевершила найкращі регресійні моделі, що свідчить про доцільність вибору алгоритму прогнозування залежно від властивостей конкретного набору даних.

Отримані результати підтверджують ефективність використання механізму Attention для підвищення якості рекурентних нейронних мереж та демонструють, що для регулярних погодинних часових рядів сучасні регресійні алгоритми можуть забезпечувати вищу точність прогнозування, ніж складні моделі глибокого навчання. Практичне значення дослідження полягає у можливості використання отриманих результатів під час вибору моделей прогнозування для систем енергоменеджменту, інтелектуальних електричних мереж та аналітичних платформ оброблення енергетичних даних.

Ключові слова: Інтернет речей, IoT, прогнозування енергоспоживання, штучний інтелект, машинне навчання, глибоке навчання, LSTM.

Вступ. Сучасний етап розвитку світової енергетики характеризується активною цифровою трансформацією, широким впровадженням інтелектуальних електричних мереж (Smart Grid), розподіленої генерації, систем накопичення енергії та технологій Інтернету речей. Масове використання інтелектуальних лічильників, сенсорних мереж, промислових контролерів та бездротових засобів передачі даних забезпечує отримання великих масивів інформації про режими функціонування

енергетичних систем у режимі реального часу. Це відкриває нові можливості для побудови адаптивних моделей прогнозування електроспоживання, які є основою сучасних систем підтримки прийняття рішень у сфері енергетики [1].

Однією з ключових задач цифрової енергетики є прогнозування електричного навантаження. Від точності прогнозу залежить ефективність диспетчерського керування, планування генерації, оптимізація роботи систем накопичення енергії, функціонування локальних енергетичних систем та забезпечення стійкості електроенергетичних мереж. Особливої актуальності ця проблема набуває в умовах інтеграції значної кількості відновлюваних джерел енергії, генерація яких характеризується високою стохастичністю та залежністю від погодних умов [2].

За останні роки спостерігається суттєве зростання кількості IoT-пристроїв у сфері енергетики. Інтелектуальні лічильники, сенсори мікроклімату, системи моніторингу електричних мереж, пристрої автоматизації будівель та промислові контролери формують безперервний потік даних, що характеризується значним обсягом, високою швидкістю надходження та різноманітністю форматів. Ефективне використання таких даних потребує застосування сучасних методів аналізу великих даних та штучного інтелекту [3].

Традиційні статистичні методи прогнозування, зокрема авторегресійні моделі ARIMA, експоненціальне згладжування та регресійний аналіз, демонструють прийнятну точність лише для відносно простих часових рядів із лінійними закономірностями. Проте процеси електроспоживання формуються під впливом значної кількості взаємопов'язаних факторів, серед яких температура навколишнього середовища, вологість повітря, сонячна активність, день тижня, сезонність, кількість споживачів, режим роботи обладнання та інші параметри. У результаті залежності між вхідними змінними набувають складного нелінійного характеру, що істотно знижує ефективність класичних моделей прогнозування [4].

Останніми роками найбільш перспективним напрямом стали методи машинного та глибокого навчання. Особливе місце займають рекурентні нейронні мережі Long Short-Term Memory (LSTM), здатні ефективно моделювати довготривалі часові залежності та враховувати історію зміни навантаження. Додаткове використання механізмів уваги (Attention Mechanism) дозволяє автоматично визначати найбільш значущі часові інтервали, що позитивно впливає на точність прогнозування [14]. Подальший розвиток цього напрямку пов'язаний із поєднанням технологій IoT, хмарних обчислень, периферійних обчислень (Edge Computing) та штучного інтелекту в єдині інтелектуальні інформаційно-керувальні системи [5].

Особливої актуальності задача прогнозування енергоспоживання набуває для України, енергетична

система якої функціонує в умовах постійної зміни структури генерації, інтеграції розподілених джерел енергії та необхідності підвищення стійкості енергетичної інфраструктури. Використання інтелектуальних методів прогнозування дозволяє підвищити ефективність диспетчерського керування, забезпечити раціональне використання енергетичних ресурсів, мінімізувати пікові навантаження та знизити втрати електроенергії [6]. Сучасні дослідження також демонструють переваги гібридних моделей, що поєднують статистичні методи та глибоке навчання для прогнозування попиту на електроенергію, зокрема на даних енергосистеми України.

Таким чином, розроблення нових методів прогнозування енергоспоживання, які поєднують можливості технологій Інтернету речей та штучного інтелекту, є актуальною науково-прикладною задачею, вирішення якої сприятиме підвищенню ефективності функціонування сучасних енергетичних систем, забезпеченню їхньої надійності та створенню інтелектуальних систем керування енергоспоживанням.

Проблема прогнозування енергоспоживання належить до ключових напрямів розвитку сучасної цифрової енергетики, оскільки від точності прогнозу безпосередньо залежить ефективність диспетчерського керування, планування генерації, функціонування систем накопичення енергії, інтеграції відновлюваних джерел енергії та реалізації концепції Smart Grid [1]. Активне впровадження технологій Інтернету речей (IoT) суттєво збільшило обсяги доступних даних про режими функціонування енергетичних систем, що стимулювало розвиток інтелектуальних методів аналізу часових рядів та прогнозування електричних навантажень.

Перші підходи до прогнозування енергоспоживання базувалися переважно на статистичних методах аналізу часових рядів. Найбільшого поширення набули авторегресійні моделі ARIMA, SARIMA, моделі експоненціального згладжування Holt-Winters, множинна регресія та їх модифікації. Основною перевагою таких методів є простота математичної реалізації, можливість інтерпретації результатів та невисокі обчислювальні витрати. Разом із тим зазначені моделі демонструють прийнятну точність лише за наявності стаціонарних часових рядів та відносно простих лінійних залежностей між змінними [4].

Для України проблема прогнозування попиту на електроенергію набула особливої актуальності внаслідок зміни структури енергетичної системи, інтеграції відновлюваних джерел енергії та необхідності підвищення стійкості електромереж. У роботі, присвяченій прогнозуванню електроспоживання України, запропоновано гібридний підхід, який поєднує регресійний аналіз, ARIMA та LSTM. Отримані результати продемонстрували точність прогнозування понад 96%, що підтверджує доцільність комбінування

статистичних методів із сучасними алгоритмами штучного інтелекту [2,3,10].

Українські науковці також активно досліджують застосування методів машинного навчання для прогнозування попиту в інтелектуальних енергетичних мережах. Зокрема, показано, що використання LSTM забезпечує зменшення показників MAE та RMSE на 20–50% порівняно з традиційними статистичними моделями, особливо при використанні високочастотних даних із п'ятихвилинною дискретизацією [6].

Окремої уваги заслуговують дослідження, присвячені застосуванню штучного інтелекту для підвищення енергоефективності в Україні. У цих роботах обґрунтовано перспективність використання алгоритмів машинного навчання для прогнозування попиту, оптимізації споживання електроенергії, керування розумними мережами та зменшення енергетичних витрат.

Незважаючи на значну кількість наукових праць, аналіз літератури показує, що більшість існуючих методів має низку обмежень. По-перше, значна частина моделей використовує лише історичний часовий ряд електроспоживання без урахування комплексної інформації від IoT-сенсорів. По-друге, недостатньо досліджено питання автоматичного відбору найбільш інформативних ознак та адаптивної оптимізації гіперпараметрів моделей. По-третє, більшість існуючих рішень або характеризується високою точністю за рахунок значних обчислювальних витрат, або забезпечує високу швидкість ціною втрати якості прогнозування.

У зв'язку з цим актуальною науковою задачею є порівняльне оцінювання ефективності моделей машинного та глибокого навчання для короткострокового прогнозування електроспоживання, а також аналіз впливу механізму часової уваги на якість прогнозування рекурентних нейронних мереж. Такий підхід дозволить підвищити точність прогнозування, зменшити обчислювальні витрати та забезпечити ефективне використання інформації, що надходить від сучасних IoT-пристроїв.

Метою роботи є порівняльне оцінювання ефективності моделей машинного та глибокого навчання для короткострокового прогнозування електроспоживання, а також аналіз впливу механізму часової уваги на якість прогнозування рекурентних нейронних мереж.

Для досягнення поставленої мети необхідно вирішити такі наукові завдання:

- виконати аналіз сучасних методів прогнозування енергоспоживання в інтелектуальних енергетичних системах;
- сформулювати математичну модель прогнозування багатофакторних часових рядів;
- розробити гібридну модель прогнозування на основі LSTM та механізму Attention;

- реалізувати автоматичний відбір інформативних ознак та оптимізацію гіперпараметрів моделі;

- провести числові експериментальні дослідження та порівняти запропонований метод із сучасними алгоритмами прогнозування за показниками MAE, RMSE, MAPE та коефіцієнтом детермінації R^2 .

Виклад основного матеріалу дослідження.

Однією з ключових умов побудови високоточних моделей прогнозування енергоспоживання є використання репрезентативних часових рядів, які містять інформацію про режими функціонування енергетичних систем та фактори, що впливають на величину електричного навантаження. Для забезпечення відтворюваності результатів дослідження та можливості об'єктивного порівняння із сучасними методами машинного навчання у роботі використано відкритий набір даних Power Consumption of Tetouan City, вперше описаний у роботі Salam та El Hibaoui [11], а також опублікований у репозиторії UCI Machine Learning Repository [12].

Набір даних сформовано на основі інформації, отриманої автоматизованою системою диспетчерського керування електричною мережею міста Тетуан (Марокко). Дані охоплюють період з 1 січня по 31 грудня 2017 року та містять результати вимірювань із часовою дискретизацією 10 хвилин. Загальний обсяг вибірки становить 52 416 часових спостережень, що забезпечує достатню репрезентативність для навчання та тестування моделей прогнозування.

На відміну від багатьох досліджень, у яких використовуються синтетичні або частково агреговані дані, набір Tetouan City Power Consumption містить реальні експлуатаційні вимірювання електричного навантаження та погодних характеристик. Це дозволяє оцінити ефективність моделей прогнозування в умовах, максимально наближених до практичного використання.

Кожен запис набору даних містить часову позначку, метеорологічні параметри та значення електроспоживання трьох незалежних зон міської електромережі. У роботі як прогнозовану величину обрано споживання електроенергії першої зони (Zone 1 Power Consumption), що використовується як цільова змінна моделі.

До складу вихідного набору входять такі ознаки:

- дата та час вимірювання;
- температура навколишнього повітря, °C;
- відносна вологість, %;
- швидкість вітру, м/с;
- показник General Diffuse Flows, Вт/м²;
- показник Diffuse Flows, Вт/м²;
- електроспоживання Zone 1, Вт;
- електроспоживання Zone 2, Вт;
- електроспоживання Zone 3, Вт.

Оскільки метою дослідження є короткострокове прогнозування електроспоживання окремої зони, до навчання моделі використовувалися історичні значення навантаження Zone 1, а також метеорологічні параметри, що характеризують умови функціонування енергетичної системи.

Для підвищення інформативності моделі до вихідних даних було додано календарні ознаки, сформовані безпосередньо із часової позначки. До них належать номер години доби та номер дня тижня. Оскільки ці параметри мають циклічний характер, їх представлено у вигляді синусної та косинусної складових, що дозволяє уникнути штучного розриву між кінцем і початком циклу, наприклад між 23-ю та 0-ю годинами або між неділею та понеділком.

Годину доби та день тижня закодовано за такими співвідношеннями:

$$h_{sin} = \sin\left(\frac{2\pi h}{24}\right), \quad (1)$$

$$h_{cos} = \cos\left(\frac{2\pi h}{24}\right), \quad (2)$$

$$d_{sin} = \sin\left(\frac{2\pi d}{7}\right), \quad (3)$$

$$d_{cos} = \cos\left(\frac{2\pi d}{7}\right), \quad (4)$$

де h – година доби; d – номер дня тижня.

Після формування календарних характеристик кожний момент часу описувався таким вектором ознак:

$$X_t = \left\{ P_t, T_t, RH_t, WS_t, GDF_t, DF_t, h_{sin}, h_{cos}, d_{sin}, d_{cos} \right\}, \quad (5)$$

де P_t – значення електроспоживання першої зони у момент часу t ; T_t – температура повітря;

RH_t – відносна вологість; WS_t – швидкість вітру; GDF_t – General Diffuse Flows; DF_t – Diffuse Flows; h_{sin}, h_{cos} – циклічне представлення години доби; d_{sin}, d_{cos} – циклічне представлення дня тижня.

Таким чином, модель прогнозування використовує виключно ті ознаки, які або безпосередньо містяться у відкритому наборі даних, або однозначно формуються на їх основі. Це забезпечує повну відтворюваність експерименту та виключає використання додаткових параметрів, відсутніх у вихідних даних.

Задачу прогнозування сформульовано як задачу однокрокового короткострокового прогнозування. Необхідно, використовуючи інформацію про попередні 24 години функціонування системи,

визначити середнє значення електроспоживання протягом наступної години.

Математично задача описується виразом:

$$\hat{P}_{t+1} = f(X_{t-23}, X_{t-22}, \dots, X_t), \quad (6)$$

де $\hat{P}_{t+1}$ – прогнозоване значення електроспоживання на наступну годину; X_t – вектор ознак у момент часу t ; $f(\cdot)$ – функція прогнозування, що реалізується моделлю машинного навчання.

Така постановка задачі відповідає практичним сценаріям роботи сучасних систем енергоменеджменту, у яких прогноз електричного навантаження використовується для оперативного керування режимами роботи енергетичних об'єктів, планування навантаження та підтримки прийняття рішень щодо розподілу енергетичних ресурсів.

На першому етапі виконано аналіз структури набору Power Consumption of Tetouan City. Перевірка показала, що набір даних не містить пропущених значень, а часові мітки мають регулярний інтервал дискретизації 10 хвилин. Завдяки цьому не виникла необхідність у застосуванні процедур інтерполяції або відновлення відсутніх спостережень.

Додатково було перевірено часову послідовність записів та відсутність дубльованих вимірювань. Отримані результати підтвердили цілісність набору даних, що дозволило використовувати його без попереднього очищення від пропусків.

Оскільки метою роботи є короткострокове прогнозування середнього електричного навантаження на одну годину вперед, вихідні десятихвилинні вимірювання були агреговані до погодинних значень.

Нехай протягом однієї години виконано $m = 6$ вимірювань. Тоді погодинне значення навантаження визначалося як

$$P_h = \frac{1}{m} \sum_{i=1}^m P_i, \quad (7)$$

де P_i – потужність під час i -го десятихвилинного вимірювання; P_h – середнє значення електроспоживання за відповідну годину.

Аналогічне агрегування застосовано до температури, відносної вологості, швидкості вітру та показників сонячного випромінювання.

Після агрегування кількість часових записів становила

$$N = \frac{52416}{6} = 8736, \quad (8)$$

що відповідає погодинним спостереженням протягом одного календарного року.

Використання погодинного представлення дозволило зменшити вплив випадкових короточасних коливань навантаження, характерних для десятихвилинних вимірювань, та забезпечило більш стійке навчання моделей машинного навчання.

Відомо, що електроспоживання характеризується яскраво вираженою добовою та тижневою циклічністю. У більшості будівель спостерігається регулярне повторення режимів роботи протягом доби та робочого тижня. Для врахування цих закономірностей із часової мітки було сформовано додаткові календарні ознаки.

Пряме використання номера години або дня тижня є небажаним, оскільки модель інтерпретує такі значення як лінійні величини. Наприклад, години 23 та 0 фактично є сусідніми моментами часу, однак їх числові значення істотно відрізняються.

Для усунення цього недоліку застосовано циклічне кодування.

Оскільки різні параметри мають різні одиниці вимірювання та масштаби, перед навчанням моделей усі числові ознаки було стандартизовано.

Для кожної ознаки обчислювалися середнє значення та стандартне відхилення лише за навчальною вибіркою. Після цього виконувалося перетворення:

$$x_i^* = \frac{x_i - \mu_i}{\sigma_i} \quad (9)$$

де μ_i та σ_i визначалися виключно за навчальною частиною даних. Такий підхід виключає витік інформації з тестової вибірки та відповідає сучасним рекомендаціям щодо побудови моделей машинного навчання.

Для прогнозування електроспоживання використовувалася модель послідовного аналізу часових рядів.

Кожний навчальний приклад формувався за допомогою ковзного вікна довжиною 24 години.

Нехай

$$X_t = \{x_1, x_2, \dots, x_t\}, \quad (10)$$

тоді один навчальний приклад визначався як

$$S_t = \{X_{t-23}, X_{t-22}, \dots, X_t\}, \quad (11)$$

а відповіддю моделі було

$$Y_t = P_{t+1} \quad (12)$$

Таким чином, модель використовувала інформацію про попередні 24 години для

прогнозування середнього навантаження наступної години.

У результаті застосування ковзного вікна було сформовано 8712 навчальних послідовностей, кожна з яких містила 24 часові кроки та 10 інформаційних ознак.

Для забезпечення об'єктивності оцінювання моделей часовий ряд не перемішувався.

Поділ здійснювався у хронологічному порядку:

70% – навчальна вибірка;

15% – валідаційна вибірка;

15% – тестова вибірка.

Такий підхід відповідає реальним умовам експлуатації систем прогнозування, коли модель навчається лише на історичних даних і використовується для прогнозування майбутніх значень.

У результаті попередньої обробки сформовано однорідний набір погодинних часових послідовностей, який містить лише ознаки, реально наявні у Power Consumption of Tetouan City Dataset [11], а також календарні характеристики, сформовані на їх основі. Це забезпечує повну відтворюваність експерименту, узгодженість математичної моделі з вихідними даними та створює основу для побудови моделі прогнозування

Після завершення попередньої обробки даних наступним етапом дослідження є побудова математичної моделі короткострокового прогнозування електроспоживання. Основною вимогою до моделі є здатність враховувати часові залежності між послідовними спостереженнями, а також нелінійний вплив погодних факторів і календарних характеристик на величину електричного навантаження.

У задачах прогнозування часових рядів широко застосовуються як класичні статистичні методи, так і алгоритми машинного навчання. Проте статистичні моделі, зокрема ARIMA або експоненціальне згладжування, ефективні переважно для стаціонарних процесів із відносно простими лінійними залежностями. У реальних системах електроспоживання навантаження формується під впливом взаємодії багатьох факторів, що призводить до виникнення складних нелінійних закономірностей. Саме тому у роботі як базову модель обрано рекурентну нейронну мережу типу Long Short-Term Memory (LSTM), яка здатна ефективно моделювати довготривалі часові залежності.

Постановка задачі. Нехай часовий ряд електроспоживання описується послідовністю

$$X = \{X_1, X_2, \dots, X_T\}, \quad (13)$$

де X_t – вектор інформаційних ознак у момент часу t .

Для кожного моменту часу формується вхідна послідовність довжиною 24 часові кроки

$$S_t = \{X_{t-23}, X_{t-22}, \dots, X_t\}, \quad (14)$$

яка використовується для прогнозування електроспоживання наступної години

$$\hat{P}_{t+1} = f(S_t; \Theta), \quad (15)$$

де $\hat{P}_{t+1}$ – прогнозоване значення електроспоживання; $f(\cdot)$ – модель прогнозування; Θ – множина параметрів моделі.

Таким чином, задача навчання полягає у знаходженні такого набору параметрів

$$\Theta^* = \arg \min_{\Theta} L(\Theta), \quad (16)$$

що мінімізує функцію втрат.

Запропонована модель складається з п'яти послідовних блоків:

1. вхідний шар;
2. шар LSTM;
3. механізм часової уваги (Attention);
4. повнозв'язний шар;
5. вихідний нейрон прогнозування.

На відміну від класичної LSTM, запропонована архітектура (рисунок 1) використовує механізм уваги, який дозволяє визначити, які часові кроки є найбільш інформативними для прогнозування наступного значення навантаження.




Рис. 1. Архітектура запропонованої моделі прогнозування електроспоживання на основі LSTM з механізмом уваги

Для оцінювання ефективності запропонованої моделі прогнозування виконано порівняльне експериментальне дослідження із використанням відкритого набору даних Power Consumption of Tetouan City, який містить погодні характеристики та часові ряди електроспоживання трьох зон міської електромережі [11].

Експеримент проводився для задачі короткострокового прогнозування середнього електроспоживання на одну годину вперед. Після агрегування початкових десятихвилинних вимірювань було сформовано 8736 погодинних спостережень. Для побудови навчальної вибірки використовувалося ковзне часове вікно довжиною 24 години, що дозволило сформувати 8712 навчальних послідовностей.

Поділ вибірки здійснювався у хронологічному порядку:

- навчальна вибірка – 70%;
- валідаційна вибірка – 15%;
- тестова вибірка – 15%.

Такий підхід виключає використання майбутньої інформації під час навчання моделі та відповідає реальним умовам функціонування систем прогнозування.

Для перевірки ефективності запропонованого підходу виконано порівняння з такими моделями:

- Persistence;
- Ridge Regression;
- Random Forest;
- HistGradientBoosting;
- LSTM;
- GRU;
- LSTM-Attention (запропонована модель).

Навчання нейронних мереж виконувалося із використанням оптимізатора Adam, функції втрат Mean Squared Error, максимальної кількості епох 20 та механізму Early Stopping.

Для комплексного аналізу якості прогнозування використовувалися чотири показники:

- середня абсолютна похибка (MAE);
- середньоквадратична похибка (RMSE);
- середня абсолютна відносна похибка (MAPE);
- коефіцієнт детермінації (R^2).

Нижчі значення MAE, RMSE та MAPE відповідають більш точному прогнозу, тоді як значення коефіцієнта детермінації, наближене до одиниці, свідчить про краще відтворення часового ряду моделлю.

Результати експериментального дослідження наведено у таблиці.

Отримані результати свідчать, що найменші значення середньої абсолютної похибки та середньої абсолютної відносної похибки забезпечила модель HistGradientBoosting, для якої MAE становила 650,76, а MAPE – 2,218%. Найменше значення RMSE (898,29) та найбільше значення коефіцієнта детермінації (0,9776) продемонструвала модель Ridge Regression.

Таблиця

Порівняння моделей прогнозування

Модель	MAE	RMSE	MAPE, %	R ²
Persistence	1748,22	2303,05	6,027	0,8525
Ridge Regression	667,09	898,29	2,328	0,9776
HistGradient Boosting	650,76	901,13	2,218	0,9774
Random Forest	879,94	1217,26	2,903	0,9588
LSTM	1434,60	1776,39	5,069	0,9123
GRU	1166,73	1603,02	3,943	0,9286
LSTM-Attention	1095,21	1479,68	3,783	0,9391

Отже, для досліджуваного набору даних класичні регресійні моделі та алгоритми градієнтного бустингу виявилися більш ефективними, ніж рекурентні нейронні мережі.

Разом із тим запропонована архітектура LSTM-Attention показала суттєве покращення порівняно зі стандартною LSTM.

Для оцінювання впливу механізму часової уваги було виконано безпосереднє порівняння моделей LSTM та LSTM-Attention.

Зменшення середньоквадратичної похибки визначалося за співвідношенням

$$\Delta RMSE = \frac{RMSE_{LSTM} - RMSE_{Attention}}{RMSE_{LSTM}} \cdot 100\% \quad (17)$$

Підстановка експериментальних значень дає

$$\Delta RMSE = \frac{1776,39 - 1479,68}{1776,39} \cdot 100 = 16,70\% \quad (18)$$

Аналогічно визначимо зменшення середньої абсолютної похибки

$$\Delta MAE = \frac{1434,60 - 1095,21}{1434,60} \cdot 100 = 23,66\% \quad (19)$$

Отже, використання механізму Attention дозволило зменшити RMSE на 16,70%, а MAE – на 23,66% порівняно зі звичайною архітектурою LSTM.

Порівняно з моделлю GRU покращення також є помітним. Значення RMSE зменшилося з 1603,02 до 1479,68, що відповідає приблизно 7,7%, а середня абсолютна похибка зменшилася майже на 6,1%.

Запропонована модель LSTM-Attention істотно покращує результати порівняно з класичною LSTM та GRU, однак для досліджуваного набору даних найвищу точність прогнозування забезпечили Ridge Regression і HistGradientBoosting. Це свідчить про необхідність вибору моделі залежно від властивостей конкретного часового ряду та не підтверджує універсальної переваги глибоких нейронних мереж над сучасними алгоритмами машинного навчання.

Висновки. У роботі досліджено задачу короткострокового прогнозування електроспоживання на основі часових рядів із

використанням методів машинного та глибокого навчання. Проведений аналіз сучасних досліджень показав, що для задач прогнозування навантаження перспективними є як класичні регресійні алгоритми, так і рекурентні нейронні мережі, однак їх ефективність істотно залежить від структури даних, горизонту прогнозування та характеру часових залежностей.

Для забезпечення відтворюваності дослідження експериментальну перевірку виконано на відкритому наборі даних Power Consumption of Tetouan City (UCI Machine Learning Repository), який містить погодні параметри та часові ряди електроспоживання трьох зон міської електромережі. На основі вихідних даних сформовано погодинні часові послідовності, виконано стандартизацію ознак, циклічне кодування календарних характеристик та побудовано навчальні вибірки за допомогою ковзного вікна тривалістю 24 години.

У межах єдиної експериментальної методики проведено порівняльне оцінювання семи моделей прогнозування: Persistence, Ridge Regression, Random Forest, HistGradientBoosting, LSTM, GRU та LSTM-Attention. Оцінювання здійснювалося за показниками MAE, RMSE, MAPE та коефіцієнтом детермінації (R²), що забезпечило комплексний аналіз точності прогнозування.

Наукова новизна дослідження полягає в одержанні та кількісному обґрунтуванні результатів порівняльного оцінювання моделей різної складності для короткострокового прогнозування регулярно-го часового ряду електроспоживання за однакових умов підготовки даних, горизонту прогнозування та критеріїв оцінювання.

На відміну від підходу, за якого ускладнення архітектури прогнозування апіорно розглядається як засіб підвищення точності, у роботі експериментально оцінено окремо два ефекти: ефект переходу від класичних моделей машинного навчання до рекурентних нейронних мереж та ефект додавання механізму часової уваги до LSTM.

Встановлено, що для погодинного прогнозування електроспоживання на одну годину вперед механізм Attention зменшує RMSE моделі LSTM на 16,70 %, а MAE – на 23,66 %, однак це покращення не забезпечує переваги над менш складними моделями Ridge Regression та HistGradientBoosting. Для Ridge Regression отримано RMSE 898,29 і (R²=0,9776), тоді як для LSTM-Attention – RMSE 1479,68 і (R²=0,9391).

Авторським результатом є встановлення для досліджуваного сценарію факту, що підвищення структурної складності моделі не є достатньою умовою підвищення точності короткострокового прогнозування: за вираженої регулярності та циклічності часового ряду використання компактної регуляризованої регресійної моделі може бути ефективнішим за рекурентну нейронну мережу з механізмом уваги. Отриманий результат обґрунтовує необхідність вибору класу моделі на основі властивостей

часового ряду та експериментального порівняння, а не апріорної переваги моделей глибокого навчання.

Подальші дослідження доцільно спрямувати на оцінювання запропонованого підходу для інших наборів даних, багатокрокового прогнозування електроспоживання, використання архітектур Transformer і Temporal Fusion Transformer, а також дослідження можливостей інтеграції моделей прогнозування до систем енергоменеджменту та платформ Інтернету речей із використанням реальних поточкових даних.

Література

- Gubbi J., Buyya R., Marusic S., Palaniswami M. Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Generation Computer Systems*. 2013. Vol. 29. No. 7. P. 1645–1660. DOI: <https://doi.org/10.1016/j.future.2013.01.010>
- Dzhheria T., Shevchuk V. Forecasting electricity consumption using neural networks. *Control, Navigation and Communication Systems*. 2023. No. 2(72). P. 42–44. DOI: <https://doi.org/10.26906/SUNZ.2023.2.042>
- Крилова Т. В., Худа Ж. В., Балясний О. М. Прогнозування обсягів електроспоживання з використанням нейромережових технологій. *Математичне моделювання*. 2023. № 2(49). С. 116–124. DOI: [https://doi.org/10.31319/2519-8106.2\(49\)2023.292610](https://doi.org/10.31319/2519-8106.2(49)2023.292610)
- Шиманюк П. В., Мірошник В. О., Блінов І. В. Визначення втрат електричної енергії на основі прогнозів вузлового електричного навантаження. *Енергетика: економіка, технології, екологія*. 2022. № 3. С. 83–91. DOI: <https://doi.org/10.20535/1813-5420.3.2022.271484>
- Лободзинський В., Бурик М., Паламарчук А. Прогнозування попиту на електроенергію в Smart Grids на основі моделей машинного навчання. *Енергетика: економіка, технології, екологія*. 2026. № 1. DOI: <https://doi.org/10.20535/1813-5420.1.2026.351525>
- Лоскутов С. С., Шиманюк П. В. Прогнозування електричного навантаження на ієрархічних рівнях ОЕС України з використанням нейронної мережі типу LSTM. *Праці Інституту електродинаміки НАН України*. 2021. № 59. С. 69–75. DOI: <https://doi.org/10.15407/publishing2021.59.081>
- Yan K., Zhou X., Chen J. Collaborative deep learning framework on IoT data with bidirectional NLSTM neural networks for energy consumption forecasting. *Journal of Parallel and Distributed Computing*. 2022. Vol. 163. P. 248–255. DOI: <https://doi.org/10.1016/j.jpdc.2022.01.012>
- Mounir N., Ouadi H., Jhrilifa I. Short-term electric load forecasting using an EMD-BI-LSTM approach for smart grid energy management system. *Energy and Buildings*. 2023. Vol. 288. Article 113022. DOI: <https://doi.org/10.1016/j.enbuild.2023.113022>
- Sideratos G., Paspatis A., Kotsampopoulos P. et al. Deployment of forecasting tools in diverse demonstration areas to improve energy scheduling of microgrids. In: *Proceedings of the 27th International Conference on Electricity Distribution (CIRED)*. Rome, 2023. DOI: <https://doi.org/10.1049/icp.2023.1199>

- Sinityn I. P., Doroshenko A. Yu., Yatsenko O. A. et al. Research of software solutions for forecasting electricity generation and consumption in Ukraine that are based on machine learning methods. *Проблеми програмування*. 2023. № 3. С. 99–113. DOI: <https://doi.org/10.15407/pp2023.03.099>
- Salam A., El Hibaoui A. Comparison of Machine Learning Algorithms for the Power Consumption Prediction: Case Study of Tetouan City // *2018 6th International Renewable and Sustainable Energy Conference (IRSEC)*. IEEE, 2018. P. 1–5. DOI: <https://doi.org/10.1109/IRSEC.2018.8703007>
- Salam A., El Hibaoui A. *Power Consumption of Tetouan City* [Dataset]. UCI Machine Learning Repository. DOI: <https://doi.org/10.24432/C5B034>
- Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9. No. 8. P. 1735–1780.
- Vaswani A., Shazeer N., Parmar N. et al. Attention Is All You Need. In: *Advances in Neural Information Processing Systems*. 2017. Vol. 30. P. 5998–6008.
- Gonzalez Grandon T., Schwenzer J., Steens T., Breuing J. Electricity Demand Forecasting with Hybrid Statistical and Machine Learning Algorithms: Case Study of Ukraine. *Applied Energy*. 2024. Vol. 355. Article 122295. DOI: <https://doi.org/10.1016/j.apenergy.2023.122249>
- Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*. 4th ed. Cambridge, MA: Morgan Kaufmann, 2023.

References

- Gubbi J., Buyya R., Marusic S., Palaniswami M. Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Generation Computer Systems*. 2013. Vol. 29. No. 7. P. 1645–1660. DOI: <https://doi.org/10.1016/j.future.2013.01.010>
- Dzhheria T., Shevchuk V. Forecasting electricity consumption using neural networks. *Control, Navigation and Communication Systems*. 2023. No. 2(72). P. 42–44. DOI: <https://doi.org/10.26906/SUNZ.2023.2.042>
- Krylova T. V., Khuda Zh. V., Baliasnyi O. M. Prohnozuvannya obsiahiv elektrospozhyvannya z vykorystanniam nei-ro-merezhevykh tekhnolohii. *Matematychnye modeliuvannya*. 2023. № 2(49). С. 116–124. DOI: [https://doi.org/10.31319/2519-8106.2\(49\)2023.292610](https://doi.org/10.31319/2519-8106.2(49)2023.292610)
- Shymaniuk P. V., Miroshnyk V. O., Blinov I. V. Vyznachennia vtrat elektrychnoi enerhii na osnovi prohnoziv vuzlo-voho elektrychnoho navantazhennia. *Enerhetyka: ekonomika, tekhnolohii, ekolohiia*. 2022. № 3. С. 83–91. DOI: <https://doi.org/10.20535/1813-5420.3.2022.271484>
- Lobodzynskyi V., Buryk M., Palamarchuk A. Prohnozuvannya popytu na elektroenerhiiu v Smart Grids na osnovi modelei mashynnoho navchannia. *Enerhetyka: ekonomika, tekhnolohii, ekolohiia*. 2026. № 1. DOI: <https://doi.org/10.20535/1813-5420.1.2026.351525>
- Loskutov S. S., Shymaniuk P. V. Prohnozuvannya elektrychnoho navantazhennia na iierarkhichnykh rivniakh OES Ukrainy z vykorystanniam neironnoi merezhi typu LSTM. *Pratsi Instytutu elektrodynamiky NAN Ukrainy*. 2021. № 59. С. 69–75. DOI: <https://doi.org/10.15407/publishing2021.59.081>
- Yan K., Zhou X., Chen J. Collaborative deep learning framework on IoT data with bidirectional NLSTM neural networks for energy consumption forecasting. *Journal of Parallel and Distributed Computing*. 2022. Vol. 163. P.

- 248–255. DOI: <https://doi.org/10.1016/j.jpdc.2022.01.012>
8. Mounir N., Ouadi H., Jhrilifa I. Short-term electric load forecasting using an EMD-BI-LSTM approach for smart grid energy management system. *Energy and Buildings*. 2023. Vol. 288. Article 113022. DOI: <https://doi.org/10.1016/j.enbuild.2023.113022>
 9. Sideratos G., Paspatis A., Kotsampopoulos P. et al. Deployment of forecasting tools in diverse demonstration areas to improve energy scheduling of microgrids. In: *Proceedings of the 27th International Conference on Electricity Distribution (CIRED)*. Rome, 2023. DOI: <https://doi.org/10.1049/icp.2023.1199>
 10. Sinitsyn I. P., Doroshenko A. Yu., Yatsenko O. A. et al. Research of software solutions for forecasting electricity generation and consumption in Ukraine that are based on machine learning methods. *Problemy prohrumuvannia*. 2023. № 3. P. 99–113. DOI: <https://doi.org/10.15407/pp2023.03.099>
 11. Salam A., El Hibaoui A. Comparison of Machine Learning Algorithms for the Power Consumption Prediction: Case Study of Tetouan City // *2018 6th International Renewable and Sustainable Energy Conference (IRSEC)*. IEEE, 2018. P. 1–5. DOI: <https://doi.org/10.1109/IRSEC.2018.8703007>
 12. Salam A., El Hibaoui A. *Power Consumption of Tetouan City [Dataset]*. UCI Machine Learning Repository. DOI: <https://doi.org/10.24432/C5B034>
 13. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997. Vol. 9. No. 8. P. 1735–1780.
 14. Vaswani A., Shazeer N., Parmar N. et al. Attention Is All You Need. In: *Advances in Neural Information Processing Systems*. 2017. Vol. 30. P. 5998–6008.
 15. Gonzalez Grandon T., Schwenzer J., Steens T., Breuing J. Electricity Demand Forecasting with Hybrid Statistical and Machine Learning Algorithms: Case Study of Ukraine. *Applied Energy*. 2024. Vol. 355. Article 122295. DOI: <https://doi.org/10.1016/j.apenergy.2023.122249>
 16. Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*. 4th ed. Cambridge, MA: Morgan Kaufmann, 2023.

Bunke O.S., Hrudzynskyi Yu.Ye. Comparative evaluation of machine and deep learning models for short-term electricity consumption forecasting

The growth of digitalization of energy systems, the development of Internet of Things (IoT) technologies and the implementation of the Smart Grid concept necessitate increasing the accuracy of short-term electricity consumption forecasting. The efficiency of electrical load management, optimization of energy storage systems, integration of renewable energy sources and decision support in intelligent energy systems depend on the quality of the forecast. At the same time, there are no unambiguous conclusions regarding the advantages of complex deep learning models over modern machine learning algorithms for forecasting regular time series of electricity consumption.

The aim of the work is to comparatively assess the effectiveness of machine and deep learning models for short-term energy consumption forecasting, as well as to analyze the impact of the temporal attention mechanism (Attention) on the

forecasting quality of a recurrent neural network of the Long Short-Term Memory (LSTM) type.

To ensure the reproducibility of the results, the open dataset Power Consumption of Tetouan City (UCI Machine Learning Repository) was used, which contains over 52 thousand electricity consumption measurements and synchronized meteorological parameters. Data aggregation to hourly discretization, feature standardization, cyclic encoding of calendar characteristics and formation of training sequences using a sliding time window of 24 hours were performed. Within the framework of a single experimental methodology, a comparative study of the Persistence, Ridge Regression, Random Forest, HistGradientBoosting, LSTM, GRU and LSTM-Attention models was conducted. The quality of prediction was assessed by MAE, RMSE, MAPE and coefficient of determination (R²).

The experimental results showed that the best prediction quality for the studied data set was provided by the Ridge Regression and HistGradientBoosting models, which achieved RMSE values of 898.29 and 901.13, respectively, a coefficient of determination of more than 0.977 and a MAPE of about 2.2%. It was found that the application of the temporal attention mechanism allowed to improve the results of the recurrent LSTM model: the mean square error decreased by 16.70%, and the mean absolute error by 23.66% compared to the standard LSTM. However, for the studied time series, the proposed LSTM-Attention model did not outperform the best regression models, which indicates the feasibility of choosing a forecasting algorithm depending on the properties of a specific data set. The obtained results confirm the effectiveness of using the Attention mechanism to improve the quality of recurrent neural networks and demonstrate that for regular hourly time series, modern regression algorithms can provide higher forecasting accuracy than complex deep learning models. The practical significance of the study lies in the possibility of using the obtained results when choosing forecasting models for energy management systems, smart grids, and analytical platforms for processing energy data.

Keywords: Internet of Things, IoT, energy forecasting, artificial intelligence, machine learning, deep learning, LSTM.

Бунке Олександр Сергійович – кандидат технічних наук, доцент, кафедра автоматизації енергетичних процесів, Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського».

<https://orcid.org/0000-0002-7945-7040>

E-mail: als.bunke@gmail.com

Грудзинський Юліан Євгенович – старший викладач, кафедра автоматизації енергетичних процесів, Національний технічний університет України «КПІ ім. І. Сікорського».

<https://orcid.org/0000-0001-9220-0621>

E-mail: jug@sonettele.com

Дата першого надходження статті 20.07.2026.

Дата прийняття статті до друку після рецензування 26.08.2026.

Дата публікації 30.09.2026.



Стаття з відкритим доступом,
відповідно до умов ліцензії
[Creative Commons \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)