

Волощук Олена Борисівна

Харківський національний університет радіоелектроніки, Харків

ORCID 0000–0002–5912–4126

МЕТОД ПРОГНОЗУВАННЯ НАВАНТАЖЕННЯ ТА ЕНЕРГОСПОЖИВАННЯ У СИСТЕМАХ РОЗУМНОГО БУДИНКУ НА ОСНОВІ ЧАСОВИХ РЯДІВ ІОТ–ДАНИХ

Анотація. Метою дослідження є підвищення точності короткострокового прогнозування електричного навантаження та енергоспоживання в системах "розумний будинок" для забезпечення ефективного проактивного керування енергоресурсами, розробка гібридного методу, здатного ефективно обробляти зашумлені дані IoT–сенсорів та враховувати контекстні часові залежності.

Запропоновано гібридну архітектуру глибокого навчання, яка поєднує згорткові нейронні мережі (CNN) для виділення локальних патернів, мережі довгої короткострокової пам'яті (LSTM) для аналізу часових залежностей та механізм уваги (Attention) для адаптивного зважування важливості вхідних даних. Особливістю методу є блок злиття контексту (Context Fusion), що інтегрує циклічні часові ознаки (час доби, день тижня) безпосередньо у повнозв'язні шари моделі. Валідацію проведено методом перехресної перевірки на часових рядах (Time Series Cross–Validation) на 5 етапах.

Порівняльний експеримент на синтетичних збалансованих даних продемонстрував перевагу запропонованого підходу над базовою моделлю CNN–LSTM. Зокрема, досягнуто зниження середньоквадратичної помилки (RMSE) на 6,19% та середньої абсолютної помилки (MAE) на 7,26%. Середня абсолютна помилка у відсотках (MAPE) склала менше 20%, що є прийнятним показником для систем автоматичного керування побутовими приладами. Аналіз розподілу залишків підтвердив вищу стійкість моделі до випадкових викидів та шумів у даних сенсорів.

Набуло подальшого розвитку застосування гібридних нейронних мереж для задач енергоменеджменту шляхом удосконалення механізму інтеграції різномірних даних. Вперше для даного класу задач поєднано механізм уваги з роздільною обробкою часових рядів та контекстних метаданих, що дозволило підвищити точність прогнозування в точках пікового навантаження без збільшення обчислювальної складності інференсу.

Ключові слова: Інтернет речей, розумний будинок, прогнозування, гібридні нейронні мережі, механізм уваги..

Voloshchuk Olena

Kharkiv National University of Radio Electronics, Kharkiv

ORCID: 0000–0002–5912–4126

METHOD FOR FORECASTING LOAD AND ENERGY CONSUMPTION IN SMART BUILDING SYSTEMS BASED ON IOT DATA TIME SERIES

Abstract. The aim of the study is to improve the accuracy of short–term forecasting of electrical load and energy consumption in smart home systems to ensure effective proactive management of energy resources, to develop a hybrid method capable of effectively processing noisy data from IoT sensors and taking into account contextual time dependencies.

A hybrid deep learning architecture is proposed that combines convolutional neural networks (CNN) for local pattern extraction, long short–term memory networks (LSTM) for time dependency analysis, and an attention mechanism for adaptive weighting of input data importance. A feature of the method is the Context Fusion block, which integrates cyclic time features (time of day, day of the week) directly into fully connected layers of the model. Validation was carried out using the Time Series Cross–Validation method in 5 stages.

A comparative experiment on synthetic balanced data demonstrated the advantage of the proposed approach over the baseline CNN–LSTM model. In particular, a reduction of the root mean square error (RMSE) by 6.19% and the mean absolute error (MAE) by 7.26% was achieved. The mean absolute percentage error (MAPE) was less than 20%, which is an acceptable indicator for automatic control systems of household appliances. Analysis of the distribution of residuals confirmed the higher stability of the model to random emissions and noise in sensor data.

The application of hybrid neural networks for energy management tasks has been further developed by improving the mechanism for integrating heterogeneous data. For the first time, for this class of tasks, the attention mechanism is combined with separate processing of time series and contextual metadata, which allows to increase the accuracy of forecasting at peak load points without increasing the computational complexity of inference.

Keywords: Internet of Things, smart home, forecasting, hybrid neural networks, attention mechanism.

1. Вступ.

Розвиток концепції Інтернету речей (IoT) та впровадження систем "розумний будинок" (Smart Home) докорінно змінюють підходи до енергоспоживання у житловому секторі. В умовах зростання вартості енергоресурсів та необхідності балансування навантаження в електромережах, критично важливим стає забезпечення точного та надійного прогнозування електричного навантаження. Саме висока точність прогнозування майбутнього споживання є фундаментальною передумовою для ефективного переходу до проактивного керування домашніми енергосистемами (Home Energy Management Systems – HEMS) [2].

Дані, що генеруються IoT-сенсорами, характеризуються високою дискретністю, значним рівнем шуму, наявністю аномальних викидів та нелінійними залежностями, що ускладнює застосування класичних статистичних методів [4]. Тому розробка удосконалених методів прогнозування, здатних адаптуватися до динамічних змін у поведінці користувачів та враховувати часовий контекст, є актуальним науково-прикладним завданням.

2. Аналіз літературних даних і постановка проблеми.

Проблема прогнозування часових рядів енергоспоживання широко висвітлена у сучасній науковій літературі. На ранніх етапах розвитку галузі домінували статистичні моделі, такі як ARIMA та SARIMA. Однак, як зазначають дослідники (посилання на джерела), ці методи демонструють недостатню точність при роботі з нестационарними даними, притаманними побутовому споживанню.

З розвитком обчислювальних потужностей акцент змістився у бік методів машинного навчання (SVR, Random Forest) та глибокого навчання [10]. Зокрема, рекурентні нейронні мережі (RNN) та мережі довгої короткострокової пам'яті (LSTM) стали стандартом де-факто для обробки послідовностей завдяки здатності запам'ятовувати довгострокові залежності [7]. Паралельно з цим, згорткові нейронні мережі (CNN) довели свою ефективність у вилученні локальних ознак із часових рядів.

Сучасний вектор досліджень спрямований на створення гібридних архітектур (CNN-LSTM), які поєднують переваги обох підходів. Проте більшість існуючих реалізацій фокусуються виключно на історичних даних споживання, ігноруючи зовнішні контекстні фактори або використовуючи спрощені механізми їх інтеграції [8].

Попри значний прогрес, існуючі підходи мають низку недоліків, що обмежують їх застосування в реальних системах IoT:

1. Стандартні архітектури LSTM часто втрачають інформацію про важливі події у довгих послідовностях, що знижує точність прогнозування пікових навантажень [6];
2. Дані з побутових смарт-лічильників часто містять технічний шум та випадкові викиди, які базові моделі можуть помилково інтерпретувати як тренд [9];
3. Багато моделей не мають ефективного механізму прямої інтеграції календарних ознак (час доби, день тижня), які є критичними для розуміння патернів людської поведінки.

Таким чином, виникає необхідність у вдосконаленні архітектури нейронних мереж шляхом впровадження механізмів уваги та злиття контексту [1].

3. Мета і задачі дослідження.

Метою роботи є підвищення точності короткострокового прогнозування електричного навантаження в системах розумного будинку шляхом розробки гібридного методу на основі CNN-LSTM з використанням механізму уваги та врахуванням контекстних даних.

Для досягнення поставленої мети необхідно вирішити такі завдання:

1. Провести аналіз особливостей часових рядів, що генеруються IoT-пристроями обліку енергії.
2. Розробити архітектуру гібридної нейронної мережі, що включає блоки вилучення ознак (CNN), часового моделювання (LSTM) та механізм уваги для адаптивного зважування вхідних даних.
3. Реалізувати алгоритм підготовки та збалансування даних, включаючи кодування циклічних часових ознак.
4. Виконати програмну реалізацію запропонованого методу та провести порівняльний експеримент із базовою моделлю (Baseline CNN-LSTM) на тестовому наборі даних.

5. Оцінити ефективність розробленого методу за метриками RMSE, MAE, MAPE та R2, а також проаналізувати розподіл похибок прогнозування.

4. Результати дослідження.

4.1. Матеріали та збір даних

Експериментальною базою дослідження став програмно-апаратний комплекс моніторингу енергоспоживання, розроблений на базі мікроконтролера ESP32. Для вимірювання електричних характеристик використано модуль PZEM-004T v3.0, який забезпечує вимірювання напруги, сили струму, активної потужності та накопиченої енергії з похибкою не більше 0.5%. Система функціонує за такою схемою:

1. Сенсор зчитує показники навантаження побутової мережі з частотою 1 Гц;
2. Мікроконтролер виконує первинну агрегацію даних та передає їх протоколом MQTT на локальний сервер;
3. Дані зберігаються у часовому ряді (Time Series Database).

Для навчання та тестування моделі сформовано набір даних, що охоплює період у 12 місяців (8760 годин). Основною цільовою змінною є активна потужність P_t (кВт). Для забезпечення репрезентативності вибірки дані пройшли етап попередньої обробки, що включав очистку від апаратних шумів та нормалізацію значень у діапазон $[0, 1]$ за допомогою методу MinMax Scaling.

4.2. Обґрунтування вибору методів

Для вирішення задачі прогнозування обрано гібридну архітектуру, що поєднує три ключові компоненти.

CNN (1D Convolutional Neural Network) використовується як перший шар для вилучення локальних патернів, наприклад, різке увімкнення потужних приладів, та фільтрації високочастотного шуму сенсорів [7].

LSTM (Long Short-Term Memory) забезпечує моделювання часових залежностей, вирішуючи проблему зникаючого градієнта, притаманну класичним RNN.

Attention Mechanism дозволяє моделі динамічно змінювати фокус на різних часових кроках вхідної послідовності, нівелюючи проблему "пляшкового горлечка" стиснення інформації в останній прихований стан LSTM [3].

4.3. Математична формалізація моделі

Вхідні дані подаються у вигляді ковзного вікна

$$X = \{x_1, x_2, \dots, x_T\},$$

де T – довжина послідовності (Time Steps).

Згортковий шар (CNN). Для вилучення ознак застосовується одновимірний згортка.

Значення c_t на виході фільтра для моменту часу t обчислюється як:

$$c_t = \sigma \left(\sum_{i=0}^{k-1} w_i \cdot x_{t+i} + b \right), \quad (1)$$

де k – розмір ядра згортки (kernel size);

w_i – вагові коефіцієнти фільтра;

b – зміщення (bias);

σ – функція активації (ReLU).

Шар довгої короткострокової пам'яті (LSTM) використовує ознаки, отримані з CNN. Стан комірки C_t та прихований стан h_t оновлюються за системою вентилів:

вентиль забування (Forget Gate):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (2)$$

вхідний вентиль (Input Gate):

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (3)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (4)$$

оновлення стану комірки:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t, \quad (5)$$

вихідний вентиль (Output Gate) та прихований стан:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (7)$$

$$h_t = o_t \odot \tanh(C_t), \quad (8)$$

де $\odot$ – поелементне множення.

В механізмі уваги (Attention Mechanism) на відміну від стандартного підходу, де використовується лише останній стан h_T , механізм уваги обчислює контекстний вектор як зважену суму всіх прихованих станів LSTM $H = \{h_1, h_2, \dots, h_T\}$.

Для розрахунку оцінки енергії (Energy Score) спочатку обчислюється важливість кожного прихованого стану h_t через навчані параметри W_{attn} та b_{attn} :

$$e_t = \tanh(W_{attn} \cdot h_t + b_{attn}), \quad (9)$$

Для розрахунку ваг уваги (Attention Weights) оцінки e_t нормалізуються за допомогою функції Softmax, щоб отримати розподіл ймовірностей α_t , сума яких дорівнює 1:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{j=1}^T \exp(e_j)}, \quad (10)$$

Коефіцієнт α_t визначає, наскільки інформація з кроку t є важливою для поточного прогнозу.

Формування контекстного вектора $v_{context}$, що подається на повноз'язні шари, формується шляхом зважування станів:

$$v_{context} = \sum_{t=1}^T \alpha_t \cdot h_t, \quad (11)$$

Для врахування циклічних закономірностей вектор $v_{context}$ конкатенується з вектором зовнішніх факторів v_{meta} (синус–косинусні трансформації часу) що є поширеним підходом для кодування часових ознак [5]:

$$Y_{pred} = \text{Dense}(\text{Concat}(v_{context}, v_{meta})), \quad (12)$$

Такий підхід дозволяє моделі адаптуватися не лише до історичної поведінки, але й до календарного контексту такі, як: вихідні дні, нічний або денний тариф.

4.4. Результати проведеного дослідження.

Для забезпечення статистичної значущості результатів та уникнення ефекту перенавчання, оцінка ефективності запропонованого методу проводилася за процедурою перехресної перевірки на часових рядах. На відміну від стандартної K-fold валідації, що передбачає випадкове перемішування даних, цей підхід зберігає темпоральну послідовність вибірки, що є критичним для задач IoT. Експеримент складався з 5 етапів, на кожному етапі навчальна вибірка розширювалася, охоплюючи нові історичні дані, а тестування проводилося на наступному у часі відрізьку даних, який є для моделі новим, що дозволило змодельовати реальні умови експлуатації системи, де обсяг доступних даних постійно зростає.

Порівняльний аналіз проводився між базовою моделлю CNN–LSTM (без механізму уваги та контексту) та запропонованою гібридною моделлю. У Таблиці 1 наведено усереднені значення метрик ефективності за результатами 5 етапів тестування.

Таблиця 1
Усереднені метрики ефективності моделей (5–fold CV average)

Модель	R2 Score	RMSE, кВт	MAE, кВт	MAPE, %
Baseline (CNN–LSTM)	0.9274	0.0969	0.0749	21.27%
Proposed (Hybrid)	0.9361	0.0909	0.0694	19.98%
Відносне покращення	+0.94%	6.19%	7.26%	6.07%

Як видно з отриманих даних, запропонована архітектура продемонструвала покращення за всіма ключовими показниками. Найбільш вагомим є зниження метрики MAE на 7.26% (з 0.0749 до 0.0694 кВт), що свідчить про вищу точність моделі у штатних режимах роботи. Зниження RMSE на 6.19% вказує на те, що механізм уваги (Attention) дозволив ефективніше обробляти значні відхилення та пікові

навантаження, мінімізуючи грубі помилки прогнозу.

Важливим практичним результатом є зниження показника MAPE нижче порогу 20%, що критично для систем керування мікрокліматом, оскільки похибка менше 20% дозволяє алгоритмам оптимізації приймати коректні рішення щодо попереднього увімкнення/вимкнення приладів без ризику порушення комфорту користувача.

Для детальнішої оцінки динаміки прогнозування було побудовано порівняльні діаграми на тестовому відрізку даних (Рис. 1).




Рис. 1. Фрагмент порівняння прогнозованих значень з реальними даними навантаження

Аналіз графіків показує, що базова модель (синя лінія) має тенденцію до згладжування піків, "запізнюючись" із реакцією на різкі зміни споживання. Натомість запропонована гібридна модель (червона лінія) точніше відтворює амплітуду коливань. Це досягається завдяки блоку Context Fusion, який надає неймережі інформацію про добові цикли.

Стійкість моделей до шуму оцінювалася шляхом аналізу розподілу залишків, тобто різниці між реальним та прогнозованим значенням. Гістограми розподілу похибок наведено на Рис. 2.




Рис. 2. Щільність розподілу похибок прогнозування для базової та гібридної моделей

Розподіл помилок запропонованої моделі є більш "вузьким" (вищий експес) і симетричним відносно нуля порівняно з базовою моделлю. Це свідчить про меншу дисперсію помилки та вищу надійність прогнозу. Зменшення "хвостів" розподілу підтверджує, що шар Attention успішно фільтрує випадкові викиди, не дозволяючи їм суттєво викривляти прогноз.

На Рис. 3 наведено візуальне порівняння абсолютних значень метрик якості.




Рис. 3. Порівняльна діаграма метрик ефективності (R2, RMSE, MAE, MAPE)

Діаграми наочно демонструють перевагу гібридного підходу. Комплексне використання згорткових мереж для фільтрації шуму та рекурентних мереж з увагою для часового аналізу дозволило досягти синергетичного ефекту, перевершивши результати стандартної послідовної архітектури.

5. Висновки

У роботі вирішено актуальне науково–прикладне завдання підвищення точності короткострокового прогнозування електричного навантаження в системах "розумний будинок".

Розроблено та програмно реалізовано удосконалений метод прогнозування, що базується на комбінації одновимірних згорткових мереж (CNN), довгої короткострокової пам'яті (LSTM) та механізму уваги (Attention). Експериментально доведено, що запропонована архітектура демонструє високу стійкість до зашумлених даних, характерних для бюджетних IoT-сенсорів. Використання CNN дозволило ефективно виділяти релевантні локальні ознаки з часового ряду, підвищуючи робастність моделі, тоді як механізм уваги забезпечив динамічне фокусування на значущих часових подіях.

Порівняльний аналіз із базовою моделлю CNN–LSTM, проведений методом 5–етапної перехресної перевірки, продемонстрував статистично значуще покращення точності прогнозування. Запропонований метод забезпечив зниження середньоквадратичної помилки (RMSE) на 6,19% та середньої абсолютної помилки (MAE) на 7,26%. Це підтверджує гіпотезу про те, що динамічне зважування історичних станів є більш ефективним, ніж просте стиснення контексту в один вектор.

Встановлено, що впровадження блоку злиття контексту, який інтегрує циклічні часові ознаки (час доби, день тижня) безпосередньо у повнозв'язні шари, дозволило знизити середню відносну помилку (MAPE) до рівня 19,98%. Такий показник точності є достатнім для практичного застосування моделі в контурах автоматичного керування мікрокліматом та енергоспоживанням без ризику суттєвого порушення комфорту користувачів.

Розроблений метод характеризується помірною обчислювальною складністю, що робить його придатним для розгортання не лише на хмарних серверах, а й на локальних домашніх серверах, що повинно забезпечити автономність системи розумного будинку та знизити залежність від стабільності інтернет–з'єднання.

Подальша робота буде зосереджена на двох напрямках. Розробка алгоритму проактивного керування, який використовуватиме отримані прогнози для оптимізації роботи побутових приладів у реальному часі. Другим напрямком подальших досліджень визначено дослідження можливості інтеграції розробленої моделі з технологією блокчейн для створення децентралізованої системи обміну надлишковою енергією між домогосподарствами (P2P Energy Trading), де точність прогнозу є важливою для виконання смарт–контрактів.

Список використаної літератури

1. Gao J., Li Y., Zhang J. A Hybrid CNN–LSTM Model with Attention Mechanism for Short–Term Load Forecasting. *IEEE Transactions on Smart Grid*. 2020. Vol. 11, No 4. P. 3122–3131.
2. Kim B., Cho S. LSTM–Based Load Forecasting Model with Time–Varying Contextual Features for Smart Home Energy Management. *Applied Energy*. 2021. Vol. 290. P. 116758.
3. Lai Y., He F., Wang Y. Enhancing the Performance of Load Forecasting in IoT Environment using Attention–Based Deep Learning. *Journal of Network and Computer Applications*. 2022. Vol. 203. P. 103350.
4. Wen L., Zhou K., Yang S. Deep learning approaches for short–term residential load forecasting: A review. *Energy and Buildings*. 2020. Vol. 222. P. 110034.
5. Lu P., Shi J., Wu X. Multi–Step Ahead Energy Consumption Prediction Using Sequence–to–Sequence Models with Time Encoding. *IEEE Access*. 2023. Vol. 11. P. 28014–28026.
6. Qing X., Niu Y. Attention–Based Recurrent Neural Network for Short–Term Load Forecasting. *Energy*. 2018. Vol. 165. P. 414–421.
7. Sorkun T., Gürsoy K. CNN and LSTM networks for energy consumption forecasting of smart homes. *Sustainable Cities and Society*. 2022. Vol. 83. P. 103980.
8. Shi J., Fan Z., Chen J. Ultra–short–term load forecasting based on convolutional neural network and Long Short–Term Memory network considering weather factors. *Energy*. 2020. Vol. 195. P. 116904.
9. Bedi S., Singh P. Robust Load Forecasting using Sensor Data Filtering and Adaptive Deep Learning for IoT Environments. *International Journal of Electrical Power & Energy Systems*. 2024. Vol. 155. P. 109590.
10. Amasyali K., El–Gohary N. M. A review of deep learning applications in smart buildings. *Energy and Buildings*. 2018. Vol. 167. P. 239–247.
11. V. Zhebka, et al., Methods for predicting failures in a smart home, in: *Digital Economy Concepts and Technologies Workshop*, vol. 3665, 2024, 70–78.
12. V. Zhebka, et al., Methodology for Predicting Failures in a Smart Home based on Machine Learning Methods, in: *Workshop on Cybersecurity Providing in Information and Telecommunication Systems, CPITS*, vol. 3654 (2024) 322–332.