

<https://doi.org/10.31891/2307-5732-2025-351-62>

УДК 004.93:519.85:620.9

ТЕСЛЮК ВАСИЛЬ

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0002-5974-9310>e-mail: vasyl.m.teslyuk@lpnu.ua**ГАДЬО ІРИНА**

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0003-1615-6483>e-mail: iryna.v.nychai@lpnu.ua**ВАТУЛЯК ОЛЕГ**

Національний університет "Львівська політехніка"

e-mail: oleh.vatuliak.mknus.2023@lpnu.ua**СИДОРЕНКО РОМАН**

Національний університет "Львівська політехніка"

<https://orcid.org/0000-0002-9026-301X>e-mail: roman.v.sydoorenko@lpnu.ua**РУТЕЦЬКИЙ ЮРІЙ**

Західноукраїнський національний університет

e-mail: ruteczki5@gmail.com

СИСТЕМА ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ СМАРТ-БУДИНКУ НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ

У роботі наведено результати дослідження прогнозування електроспоживання у смарт-будинку із застосуванням глибокого навчання. Проведено аналіз алгоритмів прогнозування та обробку часових рядів для навчання LSTM-мереж. Встановлено оптимальні гіперпараметри моделі та проведено оцінку точності прогнозування. Реалізовано програмну систему, що забезпечує автоматизоване передбачення споживання електроенергії.

Ключові слова: LSTM-нейромережі, аналіз алгоритмів прогнозування, програмна реалізація прогнозування, обробка даних у часових рядах, налаштування гіперпараметрів нейромереж, штучний інтелект у прогнозуванні.

VASYL TESLYUK, IRYNA GADO, OLEG VATULIAK, ROMAN SYDORENKO

National University "Lviv Polytechnic", Lviv, Ukraine

RUTETSKYI YURIY

West Ukrainian National University, Ternopil, Ukraine

DEEP LEARNING-BASED SYSTEM FOR SMART HOME ELECTRICITY CONSUMPTION FORECASTING

The problem of inefficient electricity consumption management in smart homes under conditions of energy instability in Ukraine has been identified. Uneven load on the power grid, caused by emergency outages and an unstable supply schedule, complicates the rational distribution of resources. The study explores the possibility of using LSTM neural networks for electricity consumption forecasting, allowing for the consideration of long-term dependencies in time series and improving prediction accuracy.

An improved energy consumption forecasting model has been developed, which more effectively accounts for historical patterns and external factors such as air temperature, household occupancy, and time of day. A software model has also been designed to automate the processes of data preprocessing, feature selection, and neural network training. A forecasting algorithm has been proposed that considers the variable structure of time series, detects consumption anomalies, and adapts to dynamic energy demand conditions.

The developed system has been implemented as a software module based on Python, utilizing TensorFlow and Keras libraries. Data processing and analysis were conducted using Pandas and NumPy, while the model was deployed in a Jupyter Notebook environment with Docker containerization, ensuring reproducibility, scalability, and easy integration with other smart home management systems. Special attention was given to optimizing hyperparameters, selecting the most effective activation functions, and reducing computational overhead.

Testing confirmed the effectiveness of the developed system, improving the accuracy of electricity consumption forecasting and promoting more rational use of energy resources. The results demonstrated a significant reduction in forecasting errors compared to traditional statistical methods. Future research perspectives include expanding the set of input parameters, improving hyperparameter tuning mechanisms, and linking the system with automated energy management platforms. These improvements will contribute to cost reduction, increased power supply stability, and enhanced energy efficiency for smart homes.

Keywords: LSTM neural networks, forecasting algorithm analysis, software implementation of a forecasting system, time series data processing, neural network hyperparameter tuning, artificial intelligence in forecasting.

Стаття надійшла до редакції / Received 31.03.2025

Прийнята до друку / Accepted 16.04.2025

Постановка проблеми у загальному вигляді

та її зв'язок із важливими науковими чи практичними завданнями

В умовах війни та енергетичної нестабільності в Україні ефективне управління енергоспоживанням стає критично важливим. Розумні будинки, оснащені інтелектуальними системами моніторингу та управління, відіграють ключову роль у зниженні енергетичних витрат і забезпеченні стабільної роботи в умовах можливих відключень електроенергії.

Одним із перспективних методів прогнозування споживання енергії є використання рекурентних нейронних мереж довгої короткочасної пам'яті (LSTM). Ця технологія дозволяє аналізувати часові ряди споживання енергії, враховуючи змінність попиту, зовнішні фактори (температура, рівень освітлення, наявність мешканців) та історичні закономірності.

Розумний будинок в Україні функціонує в умовах підвищених ризиків та нестабільності, що суттєво впливає на енергоспоживання. Одним із ключових викликів є перебої в електропостачанні, через які система має адаптуватися до аварійних відключень і своєчасно перемикатися на резервні джерела живлення. Водночас змінний графік споживання електроенергії стає наслідком вимушеного підлаштування мешканців під графіки відключень, формуючи нестандартні тренди використання ресурсів. Не менш важливу роль відіграють погодні умови: температура, рівень сонячного світла та вологість визначають роботу опалювальних систем, кондиціонерів та освітлення, змушуючи систему гнучко реагувати на зміну зовнішніх факторів. Крім того, поведінка мешканців також значною мірою впливає на енергоспоживання – їхні звички, використання побутової техніки та необхідність заощадження ресурсів у складних умовах визначають реальні навантаження на електромережу. Усі ці фактори створюють додаткові виклики для ефективного функціонування розумного будинку та вимагають впровадження сучасних алгоритмів управління енергоспоживанням. Розумний будинок, оснащений IoT-сенсорами, здатен збирати та аналізувати ці дані, що дає змогу передбачати майбутнє споживання енергії та більш раціонально розподіляти її ресурси.

Ця робота досліджує метод прогнозування енергоспоживання в розумному будинку в Україні, що сприяє більш ефективному використанню ресурсів, підвищенню автономності систем та зменшенню навантаження на електромережу в умовах кризових ситуацій.

Аналіз досліджень та публікацій

Прогнозування електроспоживання у смарт-будинках є важливим завданням, яке потребує ефективного аналізу часових рядів. Традиційні статистичні методи [1–3] забезпечують високу точність у короткострокових прогнозах, проте мають обмеження при обробці нелінійних залежностей. Це зумовлює необхідність застосування нейронних мереж, зокрема LSTM [4–6], які здатні враховувати довготривалі тенденції та адаптуватися до змін у споживанні електроенергії.

Одним із ключових аспектів підвищення точності прогнозування є налаштування гіперпараметрів моделі, зокрема кількості нейронів, швидкості навчання та методів регуляризації [7, 10–12]. Крім того, дослідження [8, 9] підтверджують значний вплив зовнішніх факторів, таких як сезонні та ринкові коливання, на точність прогнозів, що обґрунтовує необхідність їх врахування в моделі.

Останні роботи [13–17] досліджують переваги гібридних моделей, які дозволяють підвищити точність прогнозування. Однак такі підходи відзначаються високою обчислювальною складністю та значними вимогами до ресурсів. Водночас використання LSTM без додаткових архітектур є ефективним компромісом між точністю та продуктивністю, що робить цей підхід доцільним для прогнозування електроспоживання.

Аналіз літератури підтверджує, що застосування LSTM із оптимізацією гіперпараметрів та врахуванням зовнішніх факторів є перспективним напрямом для підвищення точності прогнозів. У цьому дослідженні запропоновано реалізацію такої моделі для смарт-будинків, що забезпечує точніші та стабільніші прогнози споживання електроенергії.

Формулювання цілей статті

Мета роботи – розробка системи прогнозування споживання електроенергії на основі LSTM-нейромереж, що використовують історичні дані для підвищення точності прогнозів та ефективного управління енергоресурсами на рівні споживачів.

Виклад основного матеріалу

Неефективне використання електроенергії призводить до зайвих витрат для споживачів, оскільки вони оплачують більше, ніж могли б за оптимального підходу. Відсутність ефективної системи управління енергоспоживанням також спричиняє марнування ресурсів і знижує можливість економії, що у довгостроковій перспективі негативно впливає як на фінансові витрати, так і на загальну ефективність використання енергії.

Отже, щоб вирішити проблему неефективного споживання електроенергії, необхідно комплексно підходити до її розв'язання: розвивати інструменти контролю споживання, удосконалювати прогнозування, використовувати сучасні технології аналізу даних та впроваджувати розумні системи енергоменеджменту.

Математична модель. Одним із найефективніших рішень є впровадження прогнозних моделей, які дають змогу передбачати споживання електроенергії з урахуванням різних факторів, таких як історичні дані, погодні умови та часові закономірності. Крім того, для забезпечення високої точності прогнозування необхідно використовувати математичні моделі, здатні ефективно опрацьовувати великі обсяги даних та виявляти складні нелінійні залежності між параметрами.

Таким чином, основою прогнозової моделі є LSTM (Long Short-Term Memory) – різновид рекурентних нейронних мереж (RNN), який дозволяє ефективно працювати з часовими рядами та довгостроковими залежностями у даних. На відміну від стандартних RNN, які використовують лише поточні та попередні входи для формування прогнозу, LSTM має спеціальні осередки пам'яті, що дають змогу зберігати інформацію на довгі періоди.

Стандартна RNN оновлює свій стан за допомогою вагових матриць та поточного входу, що призводить до втрати інформації на великих часових відрізках. Натомість LSTM усуває цей недолік за рахунок введення механізмів контролю пам'яті. Вона використовує три основні сигнали для управління потоком інформації:

- сигнал забування визначає, які попередні дані можна виключити, щоб модель не накопичувала зайву інформацію;
- сигнал запису контролює, які нові дані слід додати до пам'яті, що дозволяє моделі адаптуватися до змін;
- сигнал виходу формує підсумковий стан нейронної мережі, передаючи найбільш релевантну інформацію до наступного етапу прогнозування.

Завдяки цим механізмам LSTM здатна обробляти довготривалі залежності у часових рядах, що робить її особливо ефективною у задачах прогнозування енергоспоживання.

Основні рівняння, що описують роботу LSTM:

2. Оновлення прихованого стану RNN:

$$h_t = f(W_{xh}x_t + W_{hh}h_{t-1} + b_h), \quad (1)$$

де: h_t – поточний прихований стан, x_t – поточний вхід, W_{xh} , W_{hh} – вагові матриці, b_h – вектор зсуву.

3. Сигнал забування (визначає, яка інформація не є релевантною та може бути видалена):

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

4. Сигнал запису (контролює, які нові дані слід додати до пам'яті):

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

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

5. Оновлення стану пам'яті:

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

6. Сигнал виходу (визначає, які частини пам'яті передати до наступного стану):

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (6)$$

Ці рівняння визначають функціонування LSTM та її здатність враховувати довготривалі залежності у часових рядах.

LSTM-мережа ідеально підходить для аналізу часових рядів, оскільки дозволяє моделювати залежності між послідовними значеннями. Це дає їй змогу "запам'ятовувати" ключову інформацію та використовувати її для точного прогнозування майбутніх рівнів енергоспоживання.

Щоб LSTM працювала коректно, необхідно ретельно підготувати дані, забезпечивши їхню узгодженість та придатність для аналізу. Основні кроки цього процесу включають агрегування, нормалізацію, кодування категорійних ознак та створення часових вікон для навчання моделі.

Перший етап – агрегування даних за певними часовими періодами (година, день тощо), що дає змогу усунути зайві коливання та виділити ключові тренди. Далі застосовується нормалізація, яка масштабує значення у стандартний діапазон, що покращує швидкість навчання та стабільність моделі.

Оскільки споживання електроенергії залежить від часу доби, дня тижня та пори року, важливо враховувати категорійні змінні. Для цього використовується One-Hot Encoding, який переводить часові характеристики у числовий формат, доступний для нейронної мережі.

Ключовий аспект підготовки – створення тимчасових вікон, що дозволяють моделі аналізувати не лише поточні значення, а й кілька попередніх. Це допомагає встановити зв'язки між минулими та майбутніми значеннями, що критично важливо для ефективного прогнозування.

Для оцінки якості прогнозу використовуються метрики MAE (середня абсолютна похибка) та MSE (середньоквадратична похибка), які допомагають визначити точність передбачень. Вони дозволяють оцінити, наскільки добре модель адаптується до реальних даних, та виявити області для її покращення.

Особливості розроблення програмного забезпечення. Загальна архітектура програмного забезпечення (див. рис. 1) гарантує гнучкість і модульність, спрощуючи роботу з даними, їхнє моделювання та візуалізацію результатів. Такий підхід дозволяє досягти високої продуктивності системи, а також полегшує її подальший розвиток і підтримку.

Архітектура програмного забезпечення включає три основні компоненти: Модуль обробки даних, Модуль моделювання та тренування і Модуль візуалізації результатів.

Модуль обробки даних відповідає за підготовку вхідної інформації, щоб забезпечити коректне функціонування моделі прогнозування. Одним із ключових завдань є обробка часових рядів: дані розподіляються на зручні інтервали (місяці, квартали, роки), а також створюються зсуви для формування послідовностей, придатних для навчання нейронної мережі. Використовуючи функції `feature_analyser` (рис. 2) та `plot_day_data`, система аналізує закономірності у часових рядах і виокремлює найважливіші ознаки для прогнозування.




Рис. 1. Архітектура програмного забезпечення з використанням Docker

```

1 def feature_analyser(feature:str,df:pd.DataFrame) -> None:
2
3     # Create subplots with 3 rows and 1 column, and set figure size
4     fig, ax = plt.subplots(nrows=3, ncols=1, figsize=(15,20))
5     plt.subplots_adjust(hspace=0.6)
6
7     # Loop through resample intervals: monthly, quarterly, and yearly
8     for number, resample in enumerate(['M', 'Q', 'Y']):
9
10        df[feature].resample(resample).mean().plot(kind='bar', ax=ax[number])
11        ax[number].set_ylabel('{} mean'.format(feature))
12
13        # Set title for each subplot
14        if resample == 'M':
15            ax[number].set_title('{} per month'.format(feature), fontsize=20)
16
17

```

Рис. 2. Фрагмент коду функції feature_analyser()

Окрім цього, модуль допомагає моделі краще розуміти особливості часу, категоризуючи дні тижня та сезони за допомогою функцій `get_weekday` і `get_season`. Це дозволяє враховувати сезонні та щотижневі зміни, що впливають на електроспоживання. Для роботи з LSTM-моделлю використовується функція `LSTM_df_generator`, яка створює тимчасові вікна, що допомагають нейромережі навчитися розпізнавати часові залежності в даних. Завдяки цьому прогнозування стає більш точним і адаптивним.

Модуль моделювання та тренування відповідає за створення та навчання нейромережі для прогнозування електроспоживання. Основу моделі складає функція `create_model`, яка будує LSTM-архітектуру з двома LSTM-шарами, Dropout-шаром для запобігання перенавчанню та фінальним Dense-шаром для точного регресійного прогнозування. Щоб покращити результати, використовується метод автоматичного налаштування гіперпараметрів, який допомагає знайти оптимальні значення таких параметрів, як кількість нейронів і швидкість навчання. Це підвищує точність моделі та забезпечує її стабільність під час прогнозування.

Після навчання система візуалізує результати, щоб користувач міг оцінити якість прогнозів. Функція `plot_history` будує графіки зміни середньої похибки (MSE) на тренувальній та валідаційній вибірках, що допомагає зрозуміти, наскільки добре модель навчається. А функція `plot_predictions` дозволяє порівняти справжні та передбачені значення, що наочно демонструє точність прогнозування.

Усі модулі тісно взаємодіють між собою: підготовлені дані надходять у модуль моделювання, після чого результати навчання візуалізуються для подальшого аналізу. Така структурована система дає змогу отримувати точні прогнози та приймати обґрунтовані рішення в реальному часі.

Діаграма послідовностей (див. рис. 3) відображає ключові етапи роботи програми зі створення та навчання моделі прогнозування. Вона демонструє взаємодію користувача з програмою, включаючи завантаження й опрацювання даних, аналіз ознак, підготовку входів для LSTM, побудову та навчання моделі, налаштування гіперпараметрів, а також оцінювання та візуалізацію результатів. Завершальним етапом є представлення отриманих прогнозів користувачеві.

Система використовує історичні дані про споживання електроенергії та кліматичні показники, отримані з відповідних баз даних або метеорологічних сервісів. Оскільки погодні умови суттєво впливають на рівень енергоспоживання, їх урахування дозволяє підвищити точність прогнозів. Початкове опрацювання даних виконується за допомогою бібліотек `Pandas` та `NumPy`, після чого структурована інформація зберігається у форматі `.csv` для подальшого використання у процесі прогнозування.

Як зазначалося у попередньому розділі, для аналізу даних застосовується LSTM (Long Short-Term Memory), яка ефективно моделює довготривалі залежності у часових рядах. Це особливо важливо для прогнозування енергоспоживання, оскільки метод дозволяє точно враховувати попередні тенденції та адаптуватися до змін у даних, забезпечуючи високу точність прогнозу.




Рис. 3. Діаграма послідовностей

Результати прогнозування візуалізуються за допомогою бібліотек Matplotlib та Seaborn, що спрощує аналіз та інтерпретацію отриманих даних.

Для реалізації моделі прогнозування використано сучасні фреймворки на основі Python, які є стандартом у сфері машинного навчання та аналізу даних:

- TensorFlow і Keras – для побудови та навчання нейронних мереж, ефективної обробки великих обсягів даних.
- Scikit-learn – для реалізації алгоритмів машинного навчання, зокрема методів регресії, дерев рішень та ансамблевих підходів.
- Pandas і NumPy – для обробки, трансформації та аналізу даних.

Формат .csv використовується для збереження історичних даних, оскільки забезпечує зручність імпорту, експорту та обробки у Python.

Для тестування та розгортання системи використано Docker, що дозволяє створити ізольоване середовище для запуску необхідних інструментів. У цьому середовищі розгорнуто сервер із підтримкою Jupyter Notebook, що забезпечує інтерактивну роботу з кодом, аналіз даних у реальному часі та зручну візуалізацію результатів. Використання Docker спрощує налаштування середовища та забезпечує легке перенесення проєкту між різними машинами.

Хоча дані зберігаються у вигляді .csv-файлів, структура системи організована у вигляді бази даних, яка включає чотири основні таблиці, що відображають їх взаємозв'язки. Схематична модель цієї структури наведена на рисунку 4.




Рис. 4. Схема бази даних

Загалом функціонал системи зосереджений на опрацюванні даних та створенні прогнозної моделі на основі нейронних мереж.

Усі функції програми покриті тестами для перевірки їхньої коректної роботи. На рисунку 5 представлено фрагмент коду з тестовими функціями, що ілюструє процес тестування окремих компонентів системи.

```

14 > class TestFeatureAnalyser(unittest.TestCase):
15 >     def test_feature_analyser(self):
16         data = pd.DataFrame( data= {
17             'feature': [1, 2, 3, 4, 5],
18         }, index=pd.date_range( start= '2024-01-01', periods=5, freq='D'))
19         feature_analyser( feature= 'feature', data)
20         self.assertTrue(True)
21
22 > class TestLSTMDFGenerator(unittest.TestCase):
23 >     def test_LSTM_df_generator(self):
24         data = pd.DataFrame( data= {
25             'feature': [1, 2, 3, 4, 5],
26         }, index=pd.date_range( start= '2024-01-01', periods=5, freq='D'))
27         result = LSTM_df_generator(data, rows_before=1, rows_after=1)
28         self.assertEqual(result.shape, second: (3, 0))

```


Рис. 5. Фрагмент коду з тестовими функціями

Для оцінки ефективності прогнозування електроспоживання було проведено експерименти з використанням історичних даних про енергоспоживання будинків. Обраний датасет [18] вирізняється частими замірами (кожну хвилину) та великим часовим охопленням, що робить його придатним для детального аналізу. Файл розміром приблизно 150 МБ містить інформацію про загальну активну та реактивну потужність, рівень напруги, силу струму, а також показники для трьох підсистем.

На першому етапі проведено аналіз даних для виявлення основних закономірностей і перевірки їхньої повноти, що дозволило встановити сезонні та часові тенденції у споживанні електроенергії. Для прогнозування використано LSTM-нейронну мережу, яку навчено та протестовано на наявному датасеті, а точність оцінено за середньоквадратичною помилкою (MSE). Отримані результати підтвердили, що модель демонструє високу точність прогнозування та мінімальні відхилення від фактичних значень.

Крім того, перевірено коректність виконання основних обчислень і стабільність роботи алгоритму. Підсумкові результати засвідчили, що система може ефективно прогнозувати електроспоживання, що робить її корисним інструментом для оптимізації енергетичних витрат у будівлях.

Рисунок 6 ілюструє співставлення фактичних та прогнозованих значень, які в цілому слідують схожим тенденціям із незначними розбіжностями. Даний графік відіграє важливу роль у проєкті, оскільки чітко демонструє результати прогнозування.

Рис. 6. Аналіз точності прогнозування
(вісь у – кВт·год на день, вісь x – індекси спостережень у тестовому наборі)

Обговорення результатів дослідження. Після проведення експериментів, результати прогнозування електроспоживання були оцінені за ключовими показниками точності, зокрема середньоквадратичною помилкою (MSE). MSE надає кількісну оцінку відхилення прогнозованих значень від фактичних, що дає змогу оцінити, наскільки ефективно модель передбачає реальні дані. Низьке значення MSE свідчить про точність і стабільність побудованої моделі, що є важливим для надійності системи прогнозування.

Для оцінки впливу гіперпараметрів на точність прогнозування електроспоживання було протестовано п'ять конфігурацій LSTM. Найкращий результат показала модель із 100 нейронами, коефіцієнтом випадання 0.1, швидкістю навчання 0.01 та оптимізатором *gmsrprop*, яка досягла середньої похибки -0.0745 із стандартним відхиленням 0.0192. Конфігурація з 50 нейронами та оптимізатором *adamax* також показала хороший результат (-0.0753, std dev 0.0174). Найгірший результат був зафіксований у моделі з 200 нейронами, швидкістю навчання 0.1 та оптимізатором *gmsrprop* (-1.0378, std dev 0.8965), що вказує на нестабільність при високій швидкості навчання.

Крім того, проведено порівняння точності різних методів прогнозування енергоспоживання. Дані отримані на основі реальних досліджень прогнозування енергоспоживання, зокрема із застосуванням LSTM і Random Forest для опрацювання даних часових рядів [19-21]. Аналіз базується

на трьох метриках: середня абсолютна похибка (MAE), середньоквадратична похибка (MSE) та загальна точність прогнозу (%).

Лінійна регресія показала найгірші результати серед усіх розглянутих методів, з середньою абсолютною похибкою (MAE = 0.145) і середньоквадратичною похибкою (MSE = 0.035). Її точність прогнозу склала лише 84.7%, що свідчить про обмежені можливості цього підходу в моделюванні складних нелінійних залежностей у часових рядах енергоспоживання. Через свою простоту лінійна регресія не може ефективно враховувати довготривалі взаємозв'язки між значеннями, що робить її менш придатною для точного прогнозування.

Метод Random Forest демонструє покращені результати у порівнянні з лінійною регресією: MAE зменшилася до 0.120, а MSE – до 0.025, що забезпечило точність прогнозу на рівні 89.2%. Завдяки здатності працювати з нелінійними залежностями та виявляти взаємозв'язки у великих наборах даних, цей метод є більш ефективним. Водночас Random Forest має обмежену здатність до обробки послідовних залежностей у часових рядах, що робить його менш точним у довгострокових прогнозах порівняно з нейронними мережами.

Модель Bi-directional LSTM (BiLSTM) суттєво покращує точність прогнозування, зменшуючи середню абсолютну похибку до 0.078 та MSE до 0.011. Використання двонаправленої архітектури дозволяє аналізувати часові ряди як у прямому, так і в зворотному напрямку, що допомагає краще враховувати контекст минулих і майбутніх значень. Завдяки цьому точність прогнозу підвищується до 96.5%, що робить цей метод одним із найефективніших у завданні прогнозування енергоспоживання. Проте, у порівнянні зі стандартною LSTM, BiLSTM продемонструвала дещо гірші результати. Це може пояснюватися кількома факторами. По-перше, двонаправлена архітектура подвоює кількість параметрів, що може спричинити перенавчання, особливо якщо модель працює з даними, що містять шум або мають нерівномірну динаміку. По-друге, врахування зворотного контексту в прогнозуванні енергоспоживання може бути зайвим, оскільки цей процес зазвичай залежить лише від попередніх значень.

Запропонована система на основі LSTM показала найкращі результати серед усіх розглянутих підходів: MAE = 0.072, MSE = 0.009, а точність прогнозу сягнула 97.8%. Головною перевагою LSTM є здатність ефективно враховувати довготривалі залежності в часових рядах, що є критично важливим для точного прогнозування енергоспоживання. Це робить її найперспективнішою моделлю для автоматизованого управління електроспоживанням у розумних будинках, особливо в умовах мінливості поведінкових факторів і зовнішніх впливів.

Таким чином, результати підтверджують, що LSTM є найкращим методом для прогнозування енергоспоживання, оскільки вона забезпечує мінімальні похибки та максимальну точність у порівнянні з іншими розглянутими підходами без зайвого ускладнення структури моделі.

Отже, за результатами виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – вдосконалено модель прогнозування споживання електроенергії в розумних будинках на основі нейронних мереж глибокого навчання шляхом оптимізації процесу підготовки даних, зокрема формування часових вікон, та аналізу впливу гіперпараметрів, що дало змогу підвищити точність прогнозів і забезпечити ефективніше управління енергоресурсами в умовах нестабільного електропостачання.

Практична значущість результатів дослідження – розроблено систему прогнозування споживання електроенергії в розумних будинках на основі LSTM-нейронних мереж, що дає змогу аналізувати динаміку енергоспоживання та формувати прогнози для ефективного управління енергоресурсами в умовах нестабільного електропостачання.

Висновки з даного дослідження

і перспективи подальших розвідок у даному напрямі

У ході дослідження було розроблено та впроваджено систему прогнозування енергоспоживання, спрямовану на підвищення енергоефективності розумних будинків. Вдосконалена математична модель та розроблене програмне забезпечення враховують не лише історичні дані, а й зовнішні фактори, такі як температура повітря та час доби, що дало змогу підвищити точність прогнозів. Удосконалення процесу підготовки даних, зокрема формування часових вікон, а також аналіз впливу гіперпараметрів сприяли покращенню точності прогнозування.

Реалізація системи на основі сучасних технологій машинного навчання забезпечила її здатність працювати з часовими рядами та адаптуватися до змін у споживанні електроенергії. Експериментальна перевірка підтвердила високу ефективність розробленої моделі, а оцінка якості прогнозів за відповідними метриками продемонструвала її перевагу над традиційними методами.

Отримані результати можуть бути використані для впровадження автоматизованих систем управління енергоспоживанням, що сприятиме зменшенню витрат на електроенергію та підвищенню стабільності роботи розумних будинків в умовах нестабільного електропостачання. Подальші дослідження можуть бути зосереджені на вдосконаленні архітектури нейромережі, розширенні набору вхідних параметрів та інтеграції розробленої системи з автоматизованими платформами управління енергоспоживанням.

Література

1. Ananthu, D. P., & Neelashetty, K. (2021). Electrical load forecasting using ARIMA, Prophet and LSTM networks. *International Journal of Electrical and Electronics Research*, 9(4), 114–119. <https://doi.org/10.37391/IJEER.090404>
2. Fathin, M. R., Widhiyasana, Y., & Syakrani, N. (2021). Model for predicting electrical energy consumption using ARIMA method. *Proceedings of the 2nd International Seminar of Science and Applied Technology (ISSAT 2021)*. <https://doi.org/10.2991/aer.k.211106.047>
3. Gopikrishna, P. B., & Mathew, J. A. (2021). Power consumption analysis and prediction of a smart home using ARIMA model. *SSRN*. <https://doi.org/10.2139/ssrn.3819512>
4. Severiche-Maury, Z., Arrubla-Hoyos, W., Ramirez-Velarde, R., Cama-Pinto, D., Holgado-Terriza, J., Damas, M., & Cama-Pinto, A. (2024). LSTM networks for home energy efficiency. *Designs*, 8(4), 78. <https://doi.org/10.3390/designs8040078>
5. Nazir, S., Ab Aziz, A., Hosen, J., Aziz, N. A., & Ramana Murthy, G. (2021). Forecast energy consumption time-series dataset using multistep LSTM models. *Journal of Physics: Conference Series*, 1933, 012054. <https://doi.org/10.1088/1742-6596/1933/1/012054>
6. Nazir, S., Azlan, Aziz, A., Hossen, J., Jaya Ganesan, N., Aziz, A., & Murthy, G. R. (2021). An evaluation of deep neural network models on short-term energy consumption forecasting for smart home management system. https://www.semanticscholar.org/paper/An-Evaluation-of-Deep-Neural-Network-Models-on-for-Nazir-Azlan/8b22d8b8d201351cbf5dfd01ad0d08ecde8ba6a5?utm_source=direct_link
7. Kervancı, I., & Akay, F. (2023). LSTM hyperparameters optimization with Hparam parameters for Bitcoin price prediction. *Sakarya University Journal of Computer and Information Sciences*, 6(1), 1–9. <https://doi.org/10.35377/saucis...1172027>
8. Hoang, T. T., et al. (2024). The application of time series models considering seasonality in monthly electricity production forecasting. *2024 7th International Conference on Green Technology and Sustainable Development (GTSD)*, Ho Chi Minh City, Vietnam, 200–206. <https://doi.org/10.1109/GTSD62346.2024.10675225>
9. Gülmez, B., & Selçuklu, S. (2024). Electricity market price forecasting using deep LSTM network optimized with artificial rabbits optimization: A case study of the Turkish day-ahead market. *SSRN*. <https://doi.org/10.2139/ssrn.5035223>
10. Chang, Z., Zhang, Y., & Chen, W. (2018). Effective Adam-optimized LSTM neural network for electricity price forecasting. *2018 International Conference on Software Engineering and Service Science (ICSESS)*, 245–248. <https://doi.org/10.1109/ICSESS.2018.8663710>
11. Salleh, N. S. M., Saripuddin, M., Suliman, A., & Jørgensen, B. N. (2021). Electricity anomaly point detection using unsupervised technique based on electricity load prediction derived from long short-term memory. *2021 2nd International Conference on Artificial Intelligence and Data Sciences (AiDAS)*, IPOH, Malaysia, 1–5. <https://doi.org/10.1109/AiDAS53897.2021.9574184>
12. Soomro, S., & Pora, W. (2023). Effect of drop-out layers inside a long short-term memory for household load forecast application. *2023 5th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, Istanbul, Türkiye, 1–7. <https://doi.org/10.1109/HORA58378.2023.10156722>
13. Chung, J., & Jang, B. (2022). Accurate prediction of electricity consumption using a hybrid CNN-LSTM model based on multivariable data. *PLOS ONE*, 17(11), e0278071. <https://doi.org/10.1371/journal.pone.0278071>
14. Ou, A. I. H., Agga, A., Ouassaid, M., Maaroufi, M., Elrashidi, A., & Kotb, H. (2024). Predicting short-term energy usage in a smart home using hybrid deep learning models. *Frontiers in Energy Research*, 12, 1323357. <https://doi.org/10.3389/fenrg.2024.1323357>
15. Irwansyah, A., Muhammad, E., Arifin, F., Iman, B. N., & Hermawan, H. (2023). Power consumption predictive analytics and automatic anomaly detection based on CNN-LSTM neural networks. *Jurnal Rekayasa Elektrika*, 19(4). <https://doi.org/10.17529/jre.v19i4.31695>
16. Skaf, Z., Abdilmouti, H., Alshareif, A., & Albanna, M. H. (2023). Electricity consumption forecasting based on machine learning techniques. *2023 Advances in Science and Engineering Technology International Conferences (ASET)*, Dubai, United Arab Emirates, 1–6. <https://doi.org/10.1109/ASET56582.2023.10180605>
17. Kim, A.-R., Park, D., Lee, C.-S., & Chang, H. (2023). A comparative analysis of time series forecasting methods for short-term electricity demand prediction. *2023 14th International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju Island, South Korea, 1235–1238. <https://doi.org/10.1109/ICTC58733.2023.10392314>
18. GitHub. (2024). *Dataset: Household power consumption*. https://media.githubusercontent.com/media/dmkn96/Power_consumption/refs/heads/main/Dataset/household_power_consumption.txt

19. Maarif, M. R., Saleh, A. R., Habibi, M., Fitriyani, N. L., & Syafrudin, M. (2023). Energy Usage Forecasting Model Based on Long Short-Term Memory (LSTM) and eXplainable Artificial Intelligence (XAI). *Information*, 14(5), 265. <https://doi.org/10.3390/info14050265>
20. Alghamdi, M. A., AL-Malaise AL-Ghamdi, A. S., & Ragab, M. (2024). Predicting energy consumption using stacked LSTM snapshot ensemble. *Big Data Mining and Analytics*, 7(2), 247–270. <https://doi.org/10.26599/BDMA.2023.9020030>
21. Yan, K., Li, W., Ji, Z., Qi, M., & Du, Y. (2019). A hybrid LSTM neural network for energy consumption forecasting of individual households. *IEEE Access*, 7, 157633–157642. <https://doi.org/10.1109/ACCESS.2019.2949065>

References

1. Ananthu, D. P., & Neelashetty, K. (2021). Electrical load forecasting using ARIMA, Prophet and LSTM networks. *International Journal of Electrical and Electronics Research*, 9(4), 114–119. <https://doi.org/10.37391/IJEER.090404>
2. Fathin, M. R., Widhiyasana, Y., & Syakrani, N. (2021). Model for predicting electrical energy consumption using ARIMA method. *Proceedings of the 2nd International Seminar of Science and Applied Technology (ISSAT 2021)*. <https://doi.org/10.2991/aer.k.211106.047>
3. Gopikrishna, P. B., & Mathew, J. A. (2021). Power consumption analysis and prediction of a smart home using ARIMA model. *SSRN*. <https://doi.org/10.2139/ssrn.3819512>
4. Severiche-Maury, Z., Arrubla-Hoyos, W., Ramirez-Velarde, R., Cama-Pinto, D., Holgado-Terriza, J., Damas, M., & Cama-Pinto, A. (2024). LSTM networks for home energy efficiency. *Designs*, 8(4), 78. <https://doi.org/10.3390/designs8040078>
5. Nazir, S., Ab Aziz, A., Hosen, J., Aziz, N. A., & Ramana Murthy, G. (2021). Forecast energy consumption time-series dataset using multistep LSTM models. *Journal of Physics: Conference Series*, 1933, 012054. <https://doi.org/10.1088/1742-6596/1933/1/012054>
6. Nazir, S., Azlan, Aziz, A., Hossen, J., Jaya Ganesan, N., Aziz, A., & Murthy, G. R. (2021). An evaluation of deep neural network models on short-term energy consumption forecasting for smart home management system. https://www.semanticscholar.org/paper/An-Evaluation-of-Deep-Neural-Network-Models-on-for-Nazir-Azlan/8b22d8b8d201351cbf5dfd01ad0d08ecde8ba6a5?utm_source=direct_link
7. Kervancı, I., & Akay, F. (2023). LSTM hyperparameters optimization with Hparam parameters for Bitcoin price prediction. *Sakarya University Journal of Computer and Information Sciences*, 6(1), 1–9. <https://doi.org/10.35377/saucis...1172027>
8. Hoang, T. T., et al. (2024). The application of time series models considering seasonality in monthly electricity production forecasting. *2024 7th International Conference on Green Technology and Sustainable Development (GTSD)*, Ho Chi Minh City, Vietnam, 200–206. <https://doi.org/10.1109/GTSD62346.2024.10675225>
9. Gülmez, B., & Selçuklu, S. (2024). Electricity market price forecasting using deep LSTM network optimized with artificial rabbits optimization: A case study of the Turkish day-ahead market. *SSRN*. <https://doi.org/10.2139/ssrn.5035223>
10. Chang, Z., Zhang, Y., & Chen, W. (2018). Effective Adam-optimized LSTM neural network for electricity price forecasting. *2018 International Conference on Software Engineering and Service Science (ICSESS)*, 245–248. <https://doi.org/10.1109/ICSESS.2018.8663710>
11. Salleh, N. S. M., Saripuddin, M., Suliman, A., & Jørgensen, B. N. (2021). Electricity anomaly point detection using unsupervised technique based on electricity load prediction derived from long short-term memory. *2021 2nd International Conference on Artificial Intelligence and Data Sciences (AiDAS)*, IPOH, Malaysia, 1–5. <https://doi.org/10.1109/AiDAS53897.2021.9574184>
12. Soomro, S., & Pora, W. (2023). Effect of drop-out layers inside a long short-term memory for household load forecast application. *2023 5th International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, Istanbul, Türkiye, 1–7. <https://doi.org/10.1109/HORA58378.2023.10156722>
13. Chung, J., & Jang, B. (2022). Accurate prediction of electricity consumption using a hybrid CNN-LSTM model based on multivariable data. *PLOS ONE*, 17(11), e0278071. <https://doi.org/10.1371/journal.pone.0278071>
14. Ou, A. I. H., Agga, A., Ouassaid, M., Maaroufi, M., Elrashidi, A., & Kotb, H. (2024). Predicting short-term energy usage in a smart home using hybrid deep learning models. *Frontiers in Energy Research*, 12, 1323357. <https://doi.org/10.3389/fenrg.2024.1323357>
15. Irwansyah, A., Muhammad, E., Arifin, F., Iman, B. N., & Hermawan, H. (2023). Power consumption predictive analytics and automatic anomaly detection based on CNN-LSTM neural networks. *Jurnal Rekayasa ElektriKa*, 19(4). <https://doi.org/10.17529/jre.v19i4.31695>
16. Skaf, Z., Abdilmouti, H., Alshareif, A., & Albanna, M. H. (2023). Electricity consumption forecasting based on machine learning techniques. *2023 Advances in Science and Engineering Technology International Conferences (ASET)*, Dubai, United Arab Emirates, 1–6. <https://doi.org/10.1109/ASET56582.2023.10180605>
17. Kim, A.-R., Park, D., Lee, C.-S., & Chang, H. (2023). A comparative analysis of time series forecasting methods for short-term electricity demand prediction. *2023 14th International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju Island, South Korea, 1235–1238. <https://doi.org/10.1109/ICTC58733.2023.10392314>
18. GitHub. (2024). *Dataset: Household power consumption*. https://media.githubusercontent.com/media/dmkn96/Power_consumption/refs/heads/main/Dataset/household_power_consumption.txt
19. Maarif, M. R., Saleh, A. R., Habibi, M., Fitriyani, N. L., & Syafrudin, M. (2023). Energy Usage Forecasting Model Based on Long Short-Term Memory (LSTM) and eXplainable Artificial Intelligence (XAI). *Information*, 14(5), 265. <https://doi.org/10.3390/info14050265>
20. Alghamdi, M. A., AL-Malaise AL-Ghamdi, A. S., & Ragab, M. (2024). Predicting energy consumption using stacked LSTM snapshot ensemble. *Big Data Mining and Analytics*, 7(2), 247–270. <https://doi.org/10.26599/BDMA.2023.9020030>
21. Yan, K., Li, W., Ji, Z., Qi, M., & Du, Y. (2019). A hybrid LSTM neural network for energy consumption forecasting of individual households. *IEEE Access*, 7, 157633–157642. <https://doi.org/10.1109/ACCESS.2019.2949065>