

**О. К. Вишневецький, Л. М. Журавчак**

Національний університет «Львівська політехніка», м. Львів, Україна

ПРОГНОЗУВАННЯ СПОЖИВАННЯ ЕЛЕКТРОЕНЕРГІЇ ЗА ДОПОМОГОЮ АНСАМБЛЮ МОДЕЛЕЙ МАШИННОГО НАВЧАННЯ

Досліджено використання моделей машинного навчання для прогнозування електроспоживання інтелектуальної мережі. З'ясовано, що попереднє оброблення даних збільшує продуктивність моделі прогнозування споживання енергії, а методи машинного навчання підвищують її точність завдяки інтеграції кількох алгоритмів та оптимізації гіперпараметрів. Виявлено, що ансамблева модель, яка поєднує низку моделей із різними структурними характеристиками, забезпечує вищу точність прогнозування, ніж кожна модель зокрема. Запропоновано вибір базових моделей із різною будовою: лінійні, рекурсивні, деревоподібні. Вибрано набір даних із часовими рядами кліматичних показників, а також попитом на електроспоживання, досліджено вплив кліматичних характеристик на прогнозовану величину електроспоживання, виконано кореляційний і автокореляційний аналіз. Побудовано базові моделі (авторегресії, регресії опорних векторів, випадкового лісу, довгої короткочасної пам'яті та екстремального посилення градієнта), здійснено їх навчання як слабких учнів та обчислено їхні похибки (середню квадратичну, абсолютну і відносну) між фактичними і прогнозованими значеннями електроспоживання. Здійснено оптимізацію гіперпараметрів базових моделей методом табличного пошуку. Побудовано ансамблеву модель прогнозування (сильного учня) як лінійну комбінацію прогнозів слабких учнів зі зваженими коефіцієнтами. Вагові коефіцієнти для кожного алгоритму оптимізовано за допомогою функції втрат середньоквадратичної похибки за методом найменших квадратів для послідовностей. Встановлено, що запропонована ансамблева модель показала менші значення похибки порівняно із окремими базовими моделями. Тому її використання для прогнозування споживання електроенергії забезпечить вищу точність, ніж кожна окрема базова модель.

Ключові слова: часові ряди, регресія, енергія, потужність, нейронні мережі.

Вступ / Introduction

Світовий попит на енергію збільшується через приріст населення, економічний розвиток і зміну клімату. Будівлі споживають до 40 % енергії, що використовують в усьому світі. Кількість енергії, що подають в електричну мережу, має завжди відповідати кількості споживання, щоб її частота та напруга були стабільними [1]. Як наслідок, важливо якомога точніше оцінити кількість електроенергії для кожного споживача, а електроенергії в мережі має бути достатньо для задоволення потреб усіх будівель, підключених до неї. Недооцінка кількості електроенергії, спожитої будівлями, може призвести до вимкнень електростанції, перепадів частоти й напруги та навіть збою системи. І навпаки, її завищення призводить до додаткових експлуатаційних витрат і відключення електростанцій. Отже, щоб допомогти в управлінні енергією будівлі, виявленні проблем з її обладнанням та інфраструктурою електромережі, потрібна високоточна, надійна, повторювана та адаптована модель для прогнозування попиту на електроенергію.

Точні та надійні прогнози є фундаментальним компонентом багатьох стратегій зниження споживання енергії. Прогнозування витрат на енергоносії сьогодні дуже актуальне через обмежені ресурси та постійне зростання цін на електроенергію. Енергетичне прогно-

зування має вирішальне значення для управління та збереження енергії, оскільки його можна використовувати для оцінювання енергетичних показників, пошуку та усунення недоліків системи, зниження витрат і зменшення впливу на навколишнє середовище. Прогнозування попиту на електроенергію має важливе значення на всіх рівнях, починаючи від електромережі регіону і закінчуючи кінцевими споживачами. Для вирішення завдань прогнозування споживання електроенергії в електроенергетиці широко використовують програмні системи, основані на методах прогнозування часових рядів статистичного та машинного навчання на підставі попередніх даних про споживання.

В останні роки машинне навчання з глибокими нейронними мережами стає все популярнішим. Неглибокі моделі (*shallow learning*) здебільшого виконують лінійні та нелінійні перетворення вхідних даних на вихідні лише один або два рази. Глибокі моделі (*deep learning*) продемонстрували свою ефективність в аналізованні числових рядів через вивчення складніших закономірностей. Це дає змогу навчати без необхідності ручного вибору основних характеристик [2].

Проблему вибору найкращої моделі прогнозування залежно від різних факторів можна вирішити за рахунок комбінації різних моделей. Ансамблеве навчання часто досягає значно вищої ефективності прогнозуван-

ня, ніж окремих учень, об'єднуючи кількох учнів у одного сильного учня з ширшими можливостями [3], [4].

Цілі нашої роботи: по-перше, проаналізувати сучасні методи машинного навчання, які використовують для прогнозування споживання електроенергії; по-друге, побудувати базові моделі прогнозування на вибраному наборі даних; по-третє, підвищити точність прогнозування за допомогою ансамблю моделей машинного навчання з оптимізованими ваговими коефіцієнтами, враховуючи переваги моделей-складових.

Об'єкт дослідження – прогнозування споживання електроенергії.

Предмет дослідження – методи та засоби для побудови ансамблю моделей машинного навчання для прогнозування споживання електроенергії.

Мета роботи – розроблення ансамблю моделей машинного навчання для прогнозування споживання електроенергії, що дасть змогу підвищити точність прогнозування.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- проаналізувати наявні літературні джерела щодо визначення методів і засобів машинного навчання для прогнозування споживання електроенергії;
- побудувати базові моделі прогнозування на вибраному наборі даних;

- розробити ансамбль моделей машинного навчання з оптимізованими ваговими коефіцієнтами з урахуванням переваг базових моделей, що дасть змогу підвищити точність прогнозування споживання електроенергії.

Матеріали та методи дослідження. Для дослідження використано загальнодоступний набір даних про попит на електроенергію міста Тетуан, розташованого на півночі Марокко [5]. Для нього характерний сухий і спекотний літній клімат з дощовою і теплою зимою. Дані були зібрані з трьох окремих зон розподільної мережі за допомогою системи диспетчерського контролю та збирання даних (SCADA). Набір даних охоплює весь 2017 р. із роздільною здатністю вибірки 10 хв, містить 52417 записів без пропущених значень.

На попит на електроенергію впливають різні фактори, такі як погода, кількість населення, час доби, день тижня або ціни на електроенергію. В цьому дослідженні ми використовували погодні характеристики, зокрема, температуру, вологість, швидкість вітру, дифузні потоки і загальних дифузні потоки. Опис характеристик набору даних наведено в табл. 1.

Місячний і годинний розподіли споживання електроенергії чітко відображають залежність від температури (рис. 1).

Табл. 1. Опис характеристик набору даних / Description of dataset features

№	Характеристика	Тип	Опис
1	DateTime	Date	Час, кожні 10 хв
2	Temperature	float64	Температура, °C
3	Humidity	float64	Вологість, %
4	Wind Speed	float64	Швидкість вітру, м/с
5	General diffuse flows	float64	Загальні дифузні потоки, м ³ /с
6	Diffuse flows	float64	Дифузні потоки, м ³ /с
7	Zone 1 Power Consumption	float64	Спожита електроенергія для зони 1, МВт·год
8	Zone 2 Power Consumption	float64	Спожита електроенергія для зони 2, МВт·год
9	Zone 3 Power Consumption	float64	Спожита електроенергія для зони 3, МВт·год

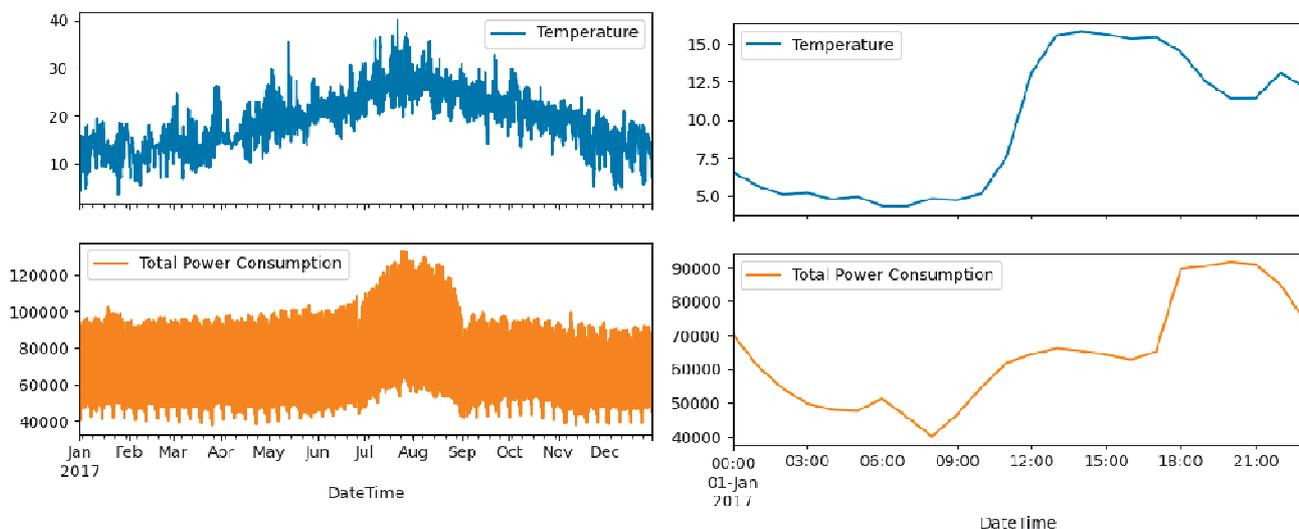


Рис. 1. Місячний і годинний розподіли температури та загального споживання електроенергії / Monthly and hourly distribution of temperature and total power consumption

Під час аналізу методів вирішення поставлених завдань та способів їхньої практичної реалізації вибрано

п'ять методів машинного навчання, які найчастіше використовували інші дослідники і показали хороші ре-

зультати для задачі прогнозування часових рядів. Запропоновано вибір базових моделей із різною будовою – лінійні, рекурсивні, деревоподібні.

Модель авторегресії (AR) використовує попередні значення (лаги) з того самого часового ряду для регресії майбутнього значення часового ряду.

Модель випадкового лісу (RF) – це комплексна техніка машинного навчання, яка поєднує кілька дерев рішень, щоб робити точні прогнози на підставі історичних даних, упорядкованих за часом. Агрегування кожного окремого дерева передбачення виконує передбачення RF, і продуктивність цього прогнозування агрегування вища, ніж окремого передбачення дерев. Крім того, випадковий ліс надає оцінку відповідних важливих характеристик і того, як кожна функція впливає на прогноз. Ключовими характеристиками цієї моделі є простота, швидкість, можливість інтерпретації, точність і легкість використання.

Модель опорної векторної регресії (SVR) має на меті знайти функцію, яка наближено визначає зв'язок між вхідними змінними та постійною цільовою змінною, мінімізуючи похибку передбачення.

Екстремальне посилення градієнта (XGBoost), масштабована модель збільшення дерева – це потужний алгоритм машинного навчання, відомий високою ефективністю. Він використовує структуру посилення градієнта, яка послідовно додає дерева рішень для ітеративного уточнення прогнозів, пропонуючи надійну продуктивність.

Довга короткочасна пам'ять (LSTM) – модель із рекурентною нейронною мережевою архітектурою, що може ідентифікувати довгострокові зв'язки в послідовних даних, важливі для прогнозування часових рядів. LSTM ефективно використовує комірки пам'яті, вхідні та вихідні вентиля, пропускні ворота для збереження даних, а також дані із попередніх часових кроків для надання точних прогнозів.

Для оцінки ефективності розроблених моделей на навчальних та тестових вибірках використано такі метрики:

- середня квадратична похибка

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}$$
- середня абсолютна похибка

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$
- середня абсолютна відсоткова похибка

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%$$

де y_i – фактичне значення; \hat{y}_i – прогнозоване значення; N – кількість значень.

Одиниці вимірювання MAE та RMSE такі самі, як і для прогнозування спожитої електроенергії, тобто МВт·год. Метрику MAPE вимірюють у відсотках, що робить її зручною під час порівняння наборів даних із різних джерел.

Аналіз останніх досліджень та публікацій. Для пошуку найновіших досліджень і публікацій використано бібліографічну і реферативну базу даних Scopus.

Статті шукали за назвою, анотацією та ключовими словами відповідно до розширеного запиту: TITLE-ABS-KEY (“energy” OR “electricity”) AND (“Machine Learning”) AND (“time-series” OR “time series”) AND (“prediction” OR “forecast” OR “ensemble”). Літературу, зібрану у результаті пошуку, відфільтровано вручну за назвами та анотаціями. Подальша фільтрація передбачала ручний перегляд документів, щоб переконатися, що вони відповідають тематиці дослідження. Для зберігання та систематизації інформації вибраних робіт використано додаток Zotero. Знайдено та проаналізовано більше ніж 20 статей про застосування машинного навчання в секторі управління споживанням електроенергії.

У статті [6] проаналізовано 116 наукових праць з прогнозування споживання енергії будівлями на підставі моделей, керованих даними, та машинного навчання. Висвітлено фактори, що впливають на прогнозування, і підсумовано ключові підходи на основі часу, рівнів будівлі та типів енергії. Виявлено, що попереднє оброблення даних може підвищити продуктивність моделі прогнозування споживання енергії, тоді як алгоритми машинного навчання – збільшити точність моделі завдяки інтеграції кількох алгоритмів та оптимізації гіперпараметрів. Розподіл за типами алгоритмів машинного навчання показав переважне використання LSTM (16%), штучних нейронних мереж (ANN) (10%), XGBoost (6%) і SVR (6%).

У статті [7] запропоновано модель глибокого навчання довготривалої пам'яті (LSTM) для прогнозування енергоспоживання будівлі інституту в м. Малака. Автори продемонстрували новий метод прогнозування енергоспоживання для щоденного енергоспоживання на наступний день з використанням прогнозованих даних про погоду від місцевої метеорологічної організації, Метеорологічного департаменту Малайзії (MET). Прогнозу модель навчено з урахуванням залежності між споживанням енергії та даними про погоду. Її продуктивність порівняно з двома іншими моделями: SVR і регресія процесу Гаусса (GPR). Експериментальні результати перевершили SVR і GPR. Запропонована модель досягла найкращих показників похибок RMSE (561,692-592,319) порівняно із SVR (3135,590-3472,765) і GPR (1243,307-1334,919). Завдяки методу дропауту істотно знизили перенавчання моделі.

У [8] досліджено прогнозування температурного навантаження на будівлю на основі машинного навчання. Порівняння 12 моделей (сім моделей машинного навчання, дві моделі глибокого навчання та три евристичні моделі) показало найкращі результати для короткострокового прогнозування навантаження (на годину вперед) для моделі нейронної мережі LSTM порівняно з лінійною регресією (LR), методом опорного вектора (SVM), методом випадкового дерева (RF) й алгоритмом XGBoost. А для довгострокового прогнозування (на 24 години вперед) кращі результати дала модель на основі алгоритму XGBoost.

У статті [9] нейронну мережу пояснюваного причинно-наслідкового графіка (X-CGNN) запропоновано для багатовимірного прогнозування попиту на електроенергію, що долає обмеження, пов'язані зі складною інтерпретацією людей. Автори порівняли запропоновану модель X-CGNN з такими наявними моделями: RF,

XGBoost, AR, LSTM, Spatiotemporal Graph Convolutional Networks (STGCN), Spectral Temporal Graph Neural Networks (STEM), Multivariate Time Series Graph Neural Network (MTGNN) і Autoformer.

Відповідно до низки робіт, точніші прогнози може забезпечити комбінована модель, яка поєднує декілька моделей. Зокрема, у [10] подано гібридну модель, яка поєднує модель усереднення профілю та метод регресії випадкового лісу для покращеного прогнозування далекого горизонту (10 % покращення, коли горизонт прогнозування становить один тиждень). Вона зрозуміла, модульна і не потребує великого набору даних. Вхідна характеристика моделі прогнозування часу (коефіцієнт важливості 35 %) продемонструвала важливість явного кодування часу за допомогою аналізу ознак.

У [11] наведено гібридну структуру глибокого навчання для точного прогнозування споживання енергії різними типами будівель у Канаді та Великобританії. Автори запропонували архітектури, що охоплюють згорткову нейронну мережу (CNN), автоенкодер (AE) з двонаправленою довгою короткочасною пам'яттю (LSTM) і двонаправлену LSTM (BLSTM). Результати свідчать про підвищення продуктивності в часі обчислення на 56 % і 75,2 %, а також зменшення похибки MSE порівняно зі структурою на основі CNN BLSTM (EECP-CBL) і ванільним LSTM відповідно.

У праці [12] розроблено метод побудови комбінованої моделі прогнозування часових рядів на основі базових моделей прогнозування. Вибрано такі базові моделі: модель авторегресії, метод найменших квадратів із ваговими коефіцієнтами, моделі Брауна першого та другого порядків. Такий підхід, як показали результати, дав змогу істотно підвищити точність прогнозування комбінованої моделі.

У роботі [13] побудовано семантичну модель системи управління будівлями. Завдяки поєднанню семантичних знань і можливостей міркування (reasoning) з моделями машинного навчання майбутня гібридна модель дає обнадійливі результати.

Результати дослідження та їх обговорення / Research results and their discussion

Дослідження виконано із використанням середовища Jupiter Lab, мови програмування Python і бібліотек Keras та Tensorflow.

Побудовано графіки автокореляції та часткової автокореляції для розуміння зв'язків часового ряду між точками даних споживання електроенергії в різних часових лагах (рис. 2). Ми бачимо чітко виражений 24-годинний тренд часового ряду споживання електроенергії.

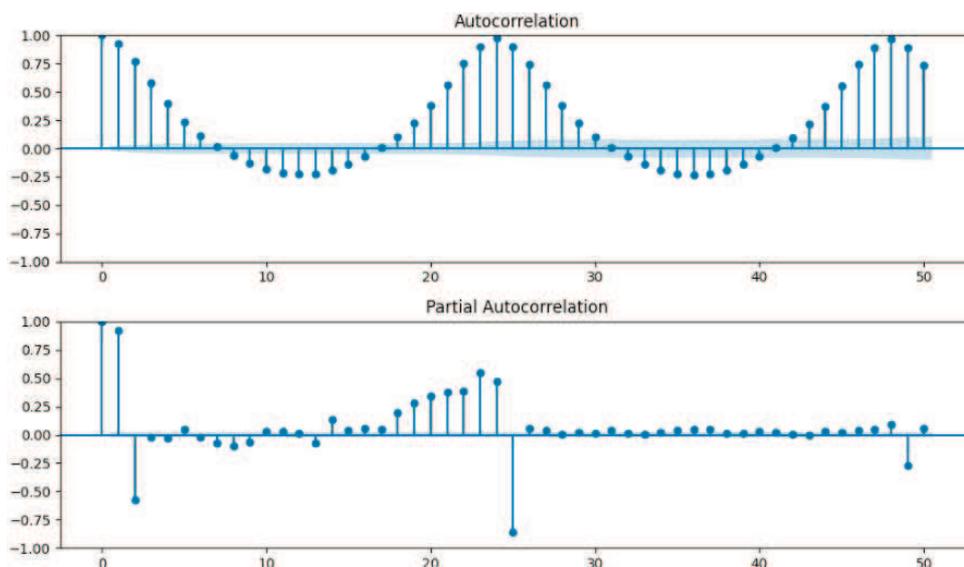


Рис. 2. Автокореляція та часткова автокореляція енергоспоживання / Autocorrelation and partial autocorrelation of Power Consumption

Здійснено інженерію характеристик (*feature engineering*) і додано додаткові характеристики особливостей часового ряду: година, день, місяць, день тижня, місяць, квартал. Також додано нову характеристику загального енергоспоживання для трьох зон (*Total Power Consumption*). Для розуміння зв'язків між характеристиками набору даних побудовано кореляційну матрицю Пірсона (рис. 3). Простежено позитивну кореляцію між температурою і загальним енергоспоживанням, а це свідчить про те, що зростання температури впливає на збільшення енергоспоживання. Негативна кореляція для вологості свідчить про те, що вона обернено пропорційно впливає на енергоспоживання (рис. 4). Часові характеристики місяця, кварталу і тижня року дуже сильно корелюють між собою. Це може негативно впли-

нути на точність навчання, тому їх краще вилучити з набору характеристик.

Проаналізовано зміну електроспоживання упродовж днів та годин тижня і побудовано гістограму для перших чотирьох тижнів із набору даних. Визначено, що найменше споживання у години 1–9, середнє – в 10–17 і найбільше – в 18–22 (рис. 5).

Побудовано п'ять моделей машинного навчання для прогнозування електроенергії на одну годину вперед із використанням вікна тривалістю 24 години. Для підвищення точності та пошуку найкращих параметрів виконано оптимізацію гіперпараметрів кожної моделі методом табличного пошуку (функції GridSearchCV). Сформовано модель авторегресії з 24 лагами. Модель RandomForestRegressor побудова-

но з використанням таких параметрів: $n_estimators=100$, $max_depth=10$, $random_state=42$. Модель опорної векторної регресії створено з ядром радіальної базисної функції. Для побудови моделі XGBRegressor використано такі параметри: $n_estimators=100$, $max_depth=5$, $learning_rate=0.1$.

Для реалізації архітектури довгої короткочасної пам'яті побудовано послідовну модель з одним вхідним шаром, трьома прихованими шарами LSTM й одним вихідним шаром з такими гіперпараметрами: $batch = 32$; $epochs=20$; $optimizer=adam$; $activation=tanh$, $dropout_rate=0.2$, $learning_rate=0.0001$.

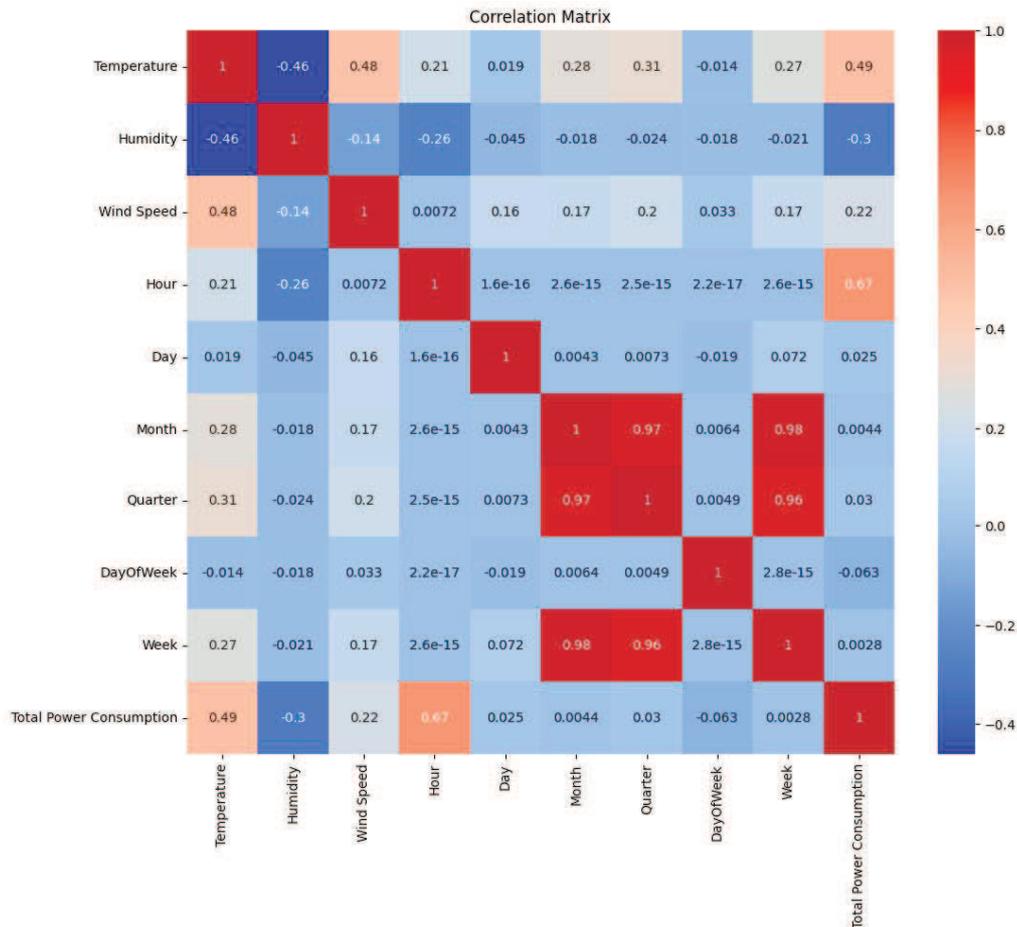


Рис. 3. Кореляційна матриця Пірсона / Pearson Correlation Matrix

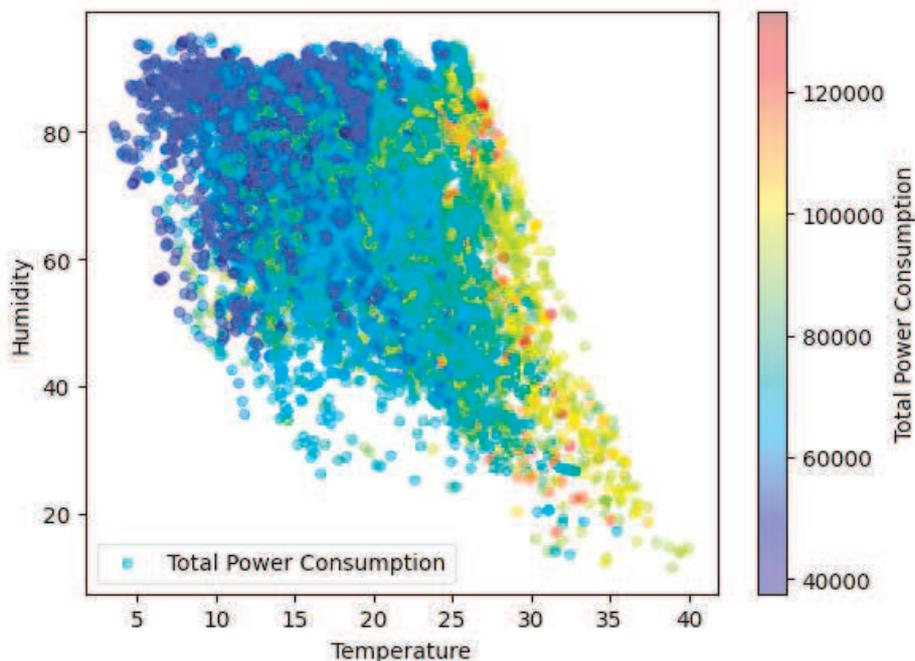


Рис. 4. Залежність енергоспоживання від кліматичних характеристик / Power Consumption and weather features

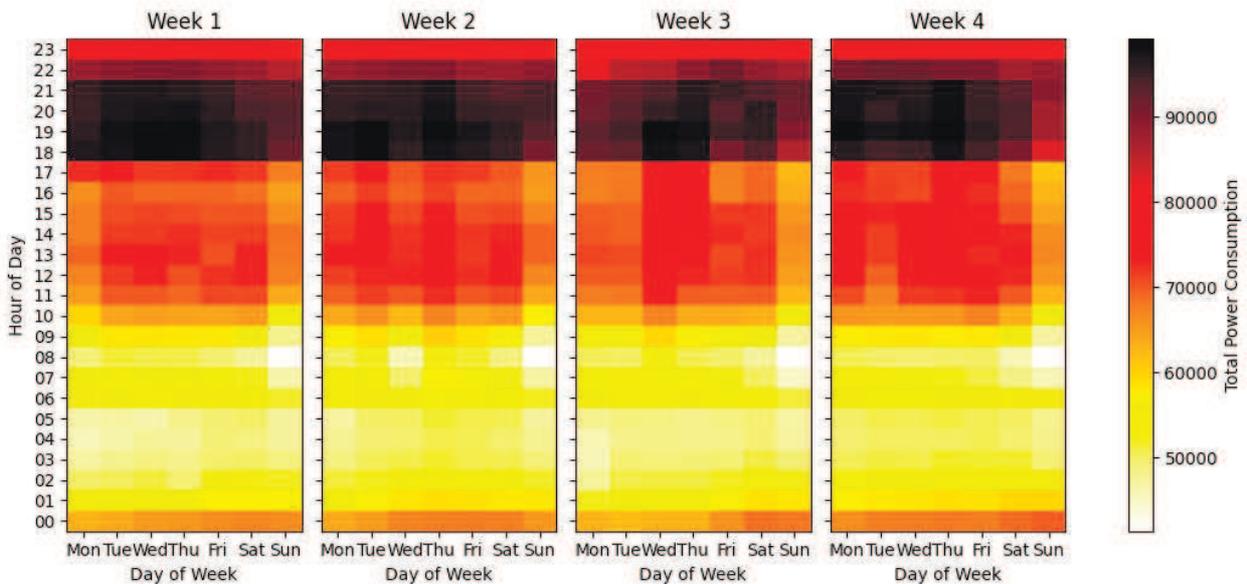


Рис. 5. Гістограма енергоспоживання для тижнів 1, 2, 3, 4 / Histogram of energy consumption for weeks 1, 2, 3, 4

В обчислювальних експериментах використано 80 % набору даних для навчання моделей та 20 % для тестування. Виконано навчання окремих базових моделей: AR, RF, SVR, LSTM і XGBoost. Перевірено якість

прогнозів щодо кожної моделі за допомогою похибок RMSE, MAE, MAPE. Побудовано графіки для порівняння прогнозу побудованих моделей і фактичними значеннями електроспоживання (рис. 6).

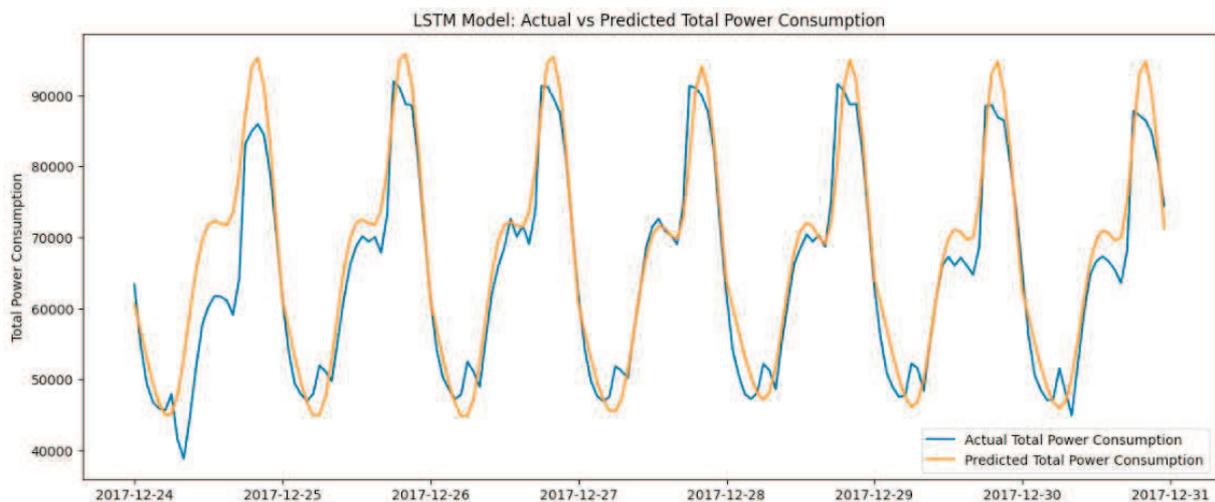


Рис. 6. Прогноз споживання електроенергії для моделі LSTM / Power Consumption prediction for LSTM model

Щоб підвищити ефективність прогнозування, передбачення із кількох моделей об'єднують для створення моделі ансамблю. Цього можна досягти кількома методами, серед яких підсумування, зважене усереднення та усереднення. Ми створили модель ансамблю прогнозування на основі зваженого усереднення для перерахованих вище п'яти базових моделей (рис. 7).

Підхід до зваженого усереднення за ансамблем полягає в поєднанні передбачень, отриманих із кількох моделей, із наданням кожній моделі вагового коефіцієнта. Мета полягає у тому, щоб знайти оптимальні ваги, які мінімізують похибку передбачення. Спочатку створено модель ансамблю з початковими вагами, які дорівнюють для всіх п'яти моделей: 0,2; 0,2; 0,2; 0,2; 0,2. Потім її удосконалено у результаті використання методів оптимізації для знаходження найкращих вагових коефіцієнтів, які мінімізують вибрану функцію втрат

RMSE за допомогою алгоритму оптимізації послідовного програмування найменших квадратів (SLSQP). Використано функцію `scipy.optimize.minimize` для виявлення найкращих ваг: 0,01; 0,26; 0,23; 0,21; 0,29. Цей підхід оптимізує модель ансамблю, поєднуючи сильні сторони кількох базових моделей, і підвищує точність та продуктивність.

За вибраними метриками похибок RMSE, MAE, MAPE оцінено якість прогнозу комбінованої моделі за допомогою порівняння її результатів з результатами базових моделей.

Результати прогнозу базових моделей і моделі ансамблю з оптимізованими ваговими коефіцієнтами наведено в табл. 2.

Обговорення отриманих результатів дослідження. У дослідженні [14] показано, як підхід до ансамблювання може підвищити точність моделей класифіка

ції дефектів програмного забезпечення (ПЗ) і розпаралелити результативну модель, що збільшує швидкість обчислень. Побудовано стековий ансамбль нейронних мереж, до якого входять багатосаровий перцептрон (MLP), нейронна мережа на основі радіально-базисних

функцій (RBFNN), рекурентна нейронна мережа (RNN) та довга короткотермінова пам'ять (LSTM). Як метамодель використано логістичну регресію. Цей підхід дав змогу авторам підвищити точність прогнозування дефектів ПЗ до 93,97 %.

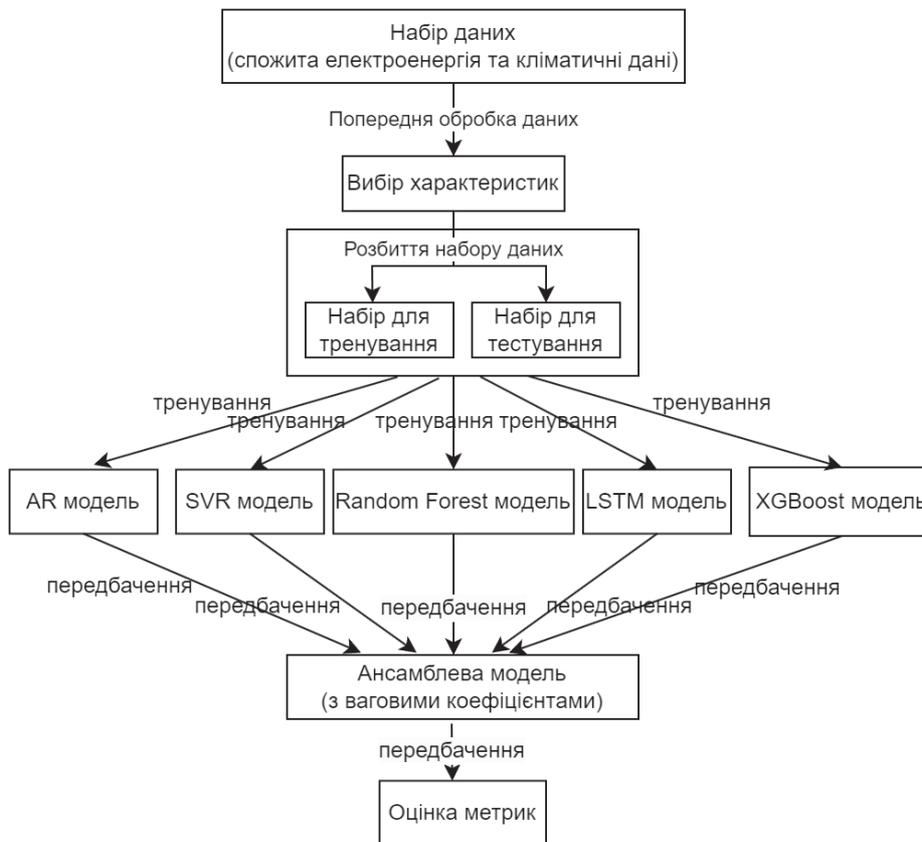


Рис. 7. Схема запропонованої ансамблевої моделі / Proposed ensemble of five machine learning models

Табл. 2. Порівняння метрик реалізованих моделей / Comparison of model's metrics

№	Модель	Метрика		
		RMSE	MAE	MAPE
1	Auto Regression	0,178264	0,142164	98,886063
2	SVR	0,111505	0,086764	72,177382
3	Random Forest	0,119409	0,09080	72,983590
4	LSTM	0,124194	0,098509	72,720098
5	XGBoost	0,113765	0,088730	72,510753
	Ансамблева модель	0,109301	0,084062	72,111396

Згідно з табл. 2, ансамблева модель прогнозування має найменші показники похибок RMSE, MAE та MAPE порівняно з іншими базовими моделями, тому її точність прогнозування вища, ніж окремих базових моделей.

У статті [15] запропоновано модель прогнозування часових рядів авторегресійної зваженої мережі (ARWNet), натхненню ідеєю ансамблевого навчання. Модель використовує класичний авторегресійний аналіз для оптимізації слабких учнів: LSTM, тимчасову згорткову мережу (TCN) та XGBoost. Використано комбінований метод оптимізації ваги для створення ефективного сильного учня. Масштабованість структури істотно покращили за рахунок можливості експериментувати з іншими учнями для допомоги у прийнятті рішень. У дослідженні використано набір даних ETT (Electricity

Transformer Temperature) для порівняння точності прогнозування ARWNet та інших основних моделей. Запропонована модель ARWNet продемонструвала сильну здатність до узагальнення та високу точність прогнозування з характеристиками затримки, які перевершують поточні популярні методи прогнозування часових рядів.

У дослідженні [16] автори описують методологію ансамблевої штучної нейронної мережі (EANN) для прогнозування попиту на енергію на добу вперед для оператора централізованого тепlopостачання (DHO). Використано дані з великої агломерації в Північній Італії. В кінці доби автори прогнозували потребу в енергії на 24 години наступної доби. Їхня методологія поєднує три моделі штучних нейронних мереж (ANN), кожна з яких фіксує різні аспекти прогнозо-

ваного часового ряду. Результати трьох моделей ANN об'єднано в єдиний прогноз за допомогою процедури послідовної впорядкованої оптимізації (SOOP), яка встановлює ваги трьох моделей у кінцевому виході. Запропоновану процедуру оптимізації виконано з урахуванням однієї конкретної години за раз. Якщо робити це під час оптимізації ваг, пов'язаних із певною годинаю, остаточні прогнози пов'язані з уже доступними годинами, оскільки їхні відповідні ваги визначено на попередньому кроці SOOP. Вагові коефіцієнти оптимізовано відповідно до двох критеріїв, що відображають два різні показники продуктивності: середню абсолютну відсоткову похибку (MAPE) і максимальну абсолютну відсоткову похибку (MaxAPE). Виконано порівняння ефективності запропонованого методу EANN із методом, який використовує ДНО і побудований на множинній лінійній регресії, що потребує експертного втручання. Крім того, здійснено порівняння із моделями сезонної авторегресійної інтегрованої ковзної середньої (SARIMAX) та нейронної мережі із відлунням стану (ESN). Результати показали, що EANN досягає вищої продуктивності, ніж інші три методи, з погляду похибок MAPE і MaxAPE. Продемонстровано, що EANN дає якісні результати для довших горизонтів прогнозування.

Дослідження [17] зосереджено на розробленні та порівнянні алгоритмів прогнозування попиту на енергетичне навантаження на один крок вперед (48 годин) на основі історичних даних для будівлі та даних про температуру. Виконано оцінку метрик різних базових алгоритмів і методів машинного навчання, урахувавши штучні нейронні мережі та дерева рішень, а також їх поєднання. З цієї метою розроблено нову гібридну модель, що використовує ансамблеві методи. Вона поєднала кілька базових алгоритмів машинного навчання (RF, LGBM, CATBoost (Categorical Boosting), MLP (Multilayer perceptron), LSTM), результати яких використали для навчання метамоделі регресора голосування (Voting Regressor). Ця гібридна модель діє як нормалізатор для будь-якого нового набору вхідних даних. Експериментальне порівняння моделі із тестовими даними та іншими ансамблевими підходами та базовими алгоритмами показало кращі результати прогнозування (MAPE = 5,39 %).

У дослідженні [18] запропоновано гібридну модель Machine Learning and Statistical Hybrid Model (MLSHM), яка поєднує методи машинного навчання з тета-статистичним методом для точнішого прогнозування майбутнього виробництва сонячної енергії на заводах, що працюють з відновлюваними джерелами енергії. Побудовано такі моделі машинного навчання: LSTM, GRU (Gated recurrent unit), AutoEncoder LSTM і Auto-GRU. Щоб підвищити точність запропонованої моделі, використали два методи різноманітності: структурної та даних. Щоб поєднати передбачення моделей ансамблю, у запропонованій моделі використано чотири методи комбінування: підхід простого усереднення, зважене усереднення із лінійним підходом, нелінійний підхід та комбінування через дисперсію зі зворотним підходом. Запропоновану схему MLSHM перевірено на двох наборах даних: Шагая у Кувейті та Какао в США. Експерименти показали, що модель MLSHM із використан-

ням комбінованих методів досягла вищої точності порівняно з прогнозуванням традиційних окремих моделей. Результати демонструють, що гібридна модель, яка поєднує методи машинного навчання із тета-статистичним методом, перевершила гібридну модель, яка поєднує лише моделі машинного навчання без статистичних методів.

Результати нашого дослідження також засвідчили вищу точність прогнозування для побудованої ансамблевої моделі порівняно з окремими базовими моделями. Експерименти показали, що комбінована модель прогнозування споживання електроенергії дала менші похибки RMSE(0,10), MAE(0,08) і MAPE(72,11) порівняно з іншими базовими моделями (AR, RF, SVR, LSTM і XGBoost).

Подальша робота буде спрямована на прогнозування часових рядів на основі архітектури трансформерів (Transformer), які вважають революційними моделями глибокого навчання, що переймають механізм уваги, роздільно зважуючи вплив кожної частини вхідних даних для вивчення складних шаблонів та динаміки [19], [20].

За результатами виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – розроблено ансамбль моделей машинного навчання із оптимізованими ваговими коефіцієнтами з урахуванням переваг базових моделей, що дає змогу підвищити точність прогнозування споживання електроенергії.

Практична значущість результатів дослідження – результати дослідження демонструють, що побудований ансамбль моделей машинного навчання забезпечує вищу точність прогнозування споживання електроенергії порівняно із базовими моделями і тому може бути практично використаний у системах управління та збереження енергії для ефективного вирішення завдань прогнозування споживання електроенергії.

Висновки / Conclusions

У цьому дослідженні розглянуто використання сукупності моделей машинного навчання для підвищення точності прогнозів споживання електроенергії, важливого компонента її управління і збереження. За результатами дослідження можна зробити такі основні висновки.

1. Проаналізовано сучасні методи машинного навчання, які використовують для прогнозування споживання електроенергії. Для дослідження вибрано п'ять методів машинного навчання з різною структурою, які найчастіше використовували в інших роботах: AR, RF, SVR, LSTM і XGBoost.

2. Реалізовано п'ять базових моделей для прогнозування споживання електроенергії для вибраного набору даних.

3. Створено ансамбль моделей машинного навчання з оптимізованими ваговими коефіцієнтами.

4. Встановлено, що запропонована ансамблева модель забезпечила підвищену точність прогнозування споживання електроенергії з урахуванням переваг кожної базової моделі. Такий підхід дає змогу побудувати

ефективну модель, яку можна успішно використовувати для прогнозування споживання електроенергії.

References

1. Luo, X., & Oyedele, L. O. (2022). A self-adaptive deep learning model for building electricity load prediction with moving horizon. *Machine Learning with Applications*, 7, 100257. <https://doi.org/10.1016/j.mlwa.2022.100257>
2. Sanzana, M. R., Maul, T., Wong, J. Y., Abdulrazic, M. O. M., & Yip, C.-C. (2022). Application of deep learning in facility management and maintenance for heating, ventilation, and air conditioning. *Automation in Construction*, 141, 104445. <https://doi.org/10.1016/j.autcon.2022.104445>
3. Liu, H., Liang, J., Liu, Y., & Wu, H. (2023). A Review of Data-Driven Building Energy Prediction. *Buildings*, 13(2), 532. <https://doi.org/10.3390/buildings13020532>
4. Salam, A., & Hibaoui, A. E. (2018). Comparison of Machine Learning Algorithms for the Power Consumption Prediction: Case Study of Tetouan city. *2018 6th International Renewable and Sustainable Energy Conference (IRSEC)*, 1–5. <https://doi.org/10.1109/IRSEC.2018.8703007>
5. Abdulwahed Salam, A. E. H. (2018). Power Consumption of Tetouan City Dataset. *UCI Machine Learning Repository*. <https://doi.org/10.24432/C5B034>
6. Shapi, M. K. M., Ramli, N. A., & Awalim, L. J. (2021). Energy consumption prediction by using machine learning for smart building: Case study in Malaysia. *Developments in the Built Environment*, 5, 100037. <https://doi.org/10.1016/j.dibe.2020.100037>
7. Faiq, M., Geok Tan, K., Pao Liew, C., Hossain, F., Tso, C.-P., Li Lim, L., Khang Wong, A. Y., & Mohd Shah, Z. (2023). Prediction of energy consumption in campus buildings using long short-term memory. *Alexandria Engineering Journal*, 67, 65–76. <https://doi.org/10.1016/j.aej.2022.12.015>
8. Wang, Z., Hong, T., & Piette, M. A. (2020). Building thermal load prediction through shallow machine learning and deep learning. *Applied Energy*, 263, 114683. <https://doi.org/10.1016/j.apenergy.2020.114683>
9. Miraki, A., Parviainen, P., & Arghandeh, R. (2024). Electricity demand forecasting at distribution and household levels using explainable causal graph neural network. *Energy and AI*, 16, 100368. <https://doi.org/10.1016/j.egyai.2024.100368>
10. Hammoudeh, A., & Dupont, S. (2022). The prediction of residential building consumption using profiling and time encoding. *Procedia Computer Science*, 210, 7–11. <https://doi.org/10.1016/j.procs.2022.10.113>
11. Jogunola, O., Adebisi, B., Hoang, K. V., Tsado, Y., Popoola, S. I., Hammoudeh, M., & Nawaz, R. (2022). CBLSTM-AE: A Hybrid Deep Learning Framework for Predicting Energy Consumption. *Energies*, 15(3), 810. <https://doi.org/10.3390/en15030810>
12. Geche, F., Batyuk, A., Mulesa, O., & Voloshchuk, V. (2020). The Combined Time Series Forecasting Model. *2020 IEEE Third International Conference on Data Stream Mining & Processing (DSMP)*, 272–275. <https://doi.org/10.1109/DSMP47368.2020.9204311>
13. Vyshnevskyy, O., & Zhuravchak, L. (2023). Semantic Models for Buildings Energy Management. *2023 IEEE 18th International Conference on Computer Science and Information Technologies (CSIT)*, 1–4. <https://doi.org/10.1109/CSIT61576.2023.10324108>
14. Yakovyna, V. S., & Symets I.I. (2021). Software defect prediction using neural network ensemble. *Scientific Bulletin of UNFU*, 31(6), 104–111. <https://doi.org/10.36930/40310616>
15. Li, Z., Qian, X., Li, L., & Xia, Z. (2024). Time series prediction model based on autoregression weight network. *Engineering Reports*, 6(4), e12756. <https://doi.org/10.1002/eng2.12756>
16. Manno, A., Intini, M., Jabali, O., Malucelli, F., & Rando, D. (2024). An ensemble of artificial neural network models to forecast hourly energy demand. *Optimization and Engineering*. <https://doi.org/10.1007/s11081-024-09883-7>
17. Tsalikidis, N., Mystakidis, A., Tjortjis, C., Koukaras, P., & Ioannidis, D. (2024). Energy load forecasting: One-step ahead hybrid model utilizing ensembling. *Computing*, 106(1), 241–273. <https://doi.org/10.1007/s00607-023-01217-2>
18. AlKandari, M., & Ahmad, I. (2024). Solar power generation forecasting using ensemble approach based on deep learning and statistical methods. *Applied Computing and Informatics*, 20(3/4), 231–250. <https://doi.org/10.1016/j.aci.2019.11.002>
19. Wu, N., Green, B., Ben, X., & O'Banion, S. (2020). Deep Transformer Models for Time Series Forecasting: The Influenza Prevalence Case (arXiv:2001.08317). [arXiv. http://arxiv.org/abs/2001.08317](http://arxiv.org/abs/2001.08317)
20. Liu, D., & Wang, H. (2024). Time series analysis model for forecasting unsteady electric load in buildings. *Energy and Built Environment*, 5(6), 900–910. <https://doi.org/10.1016/j.enbenv.2023.07.003>

O. K. Vyshnevskyy, L. M. Zhuravchak

Lviv Polytechnic National University, Lviv

FORECASTING THE ELECTRICITY CONSUMPTION USING AN ENSEMBLE OF MACHINE LEARNING MODELS

The use of machine learning models for electricity consumption prediction for smart grid has been investigated. It was found that data pre-processing can improve the performance of the energy consumption prediction model, while machine learning algorithms can improve model prediction accuracy through the integration of multiple algorithms and hyperparameter optimization. It was found that the ensemble learning method can provide better prediction accuracy than each individual method by combining the strong features of different methods that have different structural characteristics. Based on this idea, a choice of basic models with different structures was offered – linear, recursive, tree-like. We have used for research publicly available dataset containing time series of electric power demand and weather data. The influence of climatic characteristics on the predicted value (electric power demand) was studied, correlation and autocorrelation analysis were carried out. Individual basic models for electric power demand prediction were built and trained using Auto-regression, Support Vector Regression, Random Forest, Long Short-Term Memory and Extreme Gradient Boosting. Then

testing of forecasting errors (Root Mean Squared Error, Mean Absolute Error, Mean Absolute Percentage Error) between actual power consumption and predicted values was carried out. Optimization of the hyperparameters of each weak learner of the integrated model was carried out using the grid search method. An ensemble model (strong learner) for forecasting electricity consumption based linear combination of several basic models' forecasts (weak learners) with weighting coefficients was presented. The weighting coefficients of individual models' forecasts have been established and then optimized using the root-mean-square error loss function with the sequential least-squares optimization algorithm. It was established that the proposed ensemble model for forecasting electricity consumption showed smaller error metrics compared to individual basic models.

Therefore, the results demonstrated the effectiveness of our proposed ensemble model, it can be used to predict electricity consumption with greater accuracy and outperform the individual models with different structure, considering each base models' advantages.

Keywords: time series, regression, energy, power, neural networks.

Інформація про авторів:

Вишневський Олександр Костянтинович, асистент, кафедра програмного забезпечення.

Email: oleksandr.k.vyshnevskiy@lpnu.ua; <http://orcid.org/0009-0005-4857-9669>

Журавчак Любов Михайлівна, д-р техн. наук, професор, кафедра програмного забезпечення.

Email: liubov.m.zhuravchak@lpnu.ua; <http://orcid.org/0000-0002-1444-5882>

Цитування за ДСТУ: Вишневський О. К., Журавчак Л. М. Прогнозування споживання електроенергії за допомогою ансамблю моделей машинного навчання. *Український журнал інформаційних технологій*. 2024, т. 6, № 2. С. 20–29.

Citation APA: Vyshnevskyy, O. K., & Zhuravchak, L. M. (2024). Forecasting the electricity consumption using an ensemble of machine learning models. *Ukrainian Journal of Information Technology*, 6(2), 20–29. <https://doi.org/10.23939/ujit2024.02.20>