

МЕТОДИ МАШИННОГО НАВЧАННЯ ДЛЯ ПІДВИЩЕННЯ ЕНЕРГОЕФЕКТИВНОСТІ БУДІВЕЛЬ

Олександр Вишневський¹, Любов Журавчак¹

Національний університет “Львівська політехніка”, кафедра програмного забезпечення,
вул. С. Бандери, 12, Львів, Україна

¹E-mail: oleksandr.k.vyshnevskyi@lpnu.ua, ORCID 0009-0005-4857-9669

²E-mail: liubov.m.zhuravchak@lpnu.ua, ORCID 0000-0002-1444-5882

© Вишневський О. К., Журавчак Л. М., 2023

Прогнозування споживання енергії в будівлі відіграє важливу роль, оскільки воно може допомогти оцінити її енергоефективність, виявити й діагностувати несправності системи енергопостачання, а також зменшити витрати коштів і покращити вплив на клімат. Проаналізовано актуальні дослідження у галузі забезпечення енергоефективності будівель, зокрема, їх енергетичної оцінки з урахуванням типів розглянутих моделей. Детально розглянуто принципи, переваги, обмеження та практичне застосування основних моделей на основі даних, виділено пріоритетні майбутні напрями прогнозування енергоефективності будівель. Доведено, що ефективність методів є різною для основних типів моделей і залежить від таких факторів: вхідні дані та параметри, тип та якість доступних даних для тренування, придатність методу до конкретного типу моделі тощо. Підкреслено необхідність врахування елемента невизначеності під час прогнозування споживання енергії, оскільки неможливо точно моделювати метеорологічні фактори та поведінку мешканців. Тому для відображення складних нелінійних вхідних та вихідних взаємозв'язків вибрано методи машинного навчання, зокрема, моделі на основі глибокого навчання, оскільки їх продуктивність вища, ніж статистичних методів прогнозування часових рядів.

Аналіз опублікованих праць виявив відсутність робіт з описанням цілісної інформаційної системи прогнозування енергії для застосування у комерційних проєктах. Тому актуальним є розроблення автономної інформаційної системи формування стратегії підвищення енергоефективності будівель, яка поєднуватиме сучасні методи машинного навчання. Ми запропонували новий підхід до поєднання технологій семантичного моделювання та машинного навчання для системи управління енергією розумних будівель із використанням системи знань розробленої нами семантичної моделі.

Ключові слова: енергія; будівля; енергоефективність; прогнозування; часовий ряд; машинне навчання.

Вступ

Близько 40 % світового енергоспоживання припадає на житлові та офісні будівлі, які є одним із найбільших джерел світових викидів оксиду вуглецю (до 33 %) [1]. У зв'язку із закликами до сталого розвитку, занепокоєнням щодо викидів та значним споживанням енергії зростає потреба у підвищенні енергоефективності будівель. Відповідно до Європейської директиви з енергоефективності (European Energy Efficiency Directive) кожна країна-член повинна щорічно реконструювати 3 % свого будівельного фонду, щоб зменшити споживання енергії. Мета до 2050 р. – оновити будівельний фонд до майже нульового енергоспоживання [2].

Оскільки ефективність – це співвідношення між витраченими ресурсами та бажаним результатом, то під терміном “енергоефективність” розуміють менші витрати енергії зі збереженням попереднього рівня економічної діяльності або комфорту. Для будівель бажаними результатами можуть бути тепловий комфорт, достатній рівень освітленості, якість повітря. А витрачені вхідні енергетичні ресурси – кількість газу, яку використовують котли для опалення, та електроенергії для освітлення і систем механічної вентиляції.

Основою багатьох підходів до зменшення споживання енергії є точні та надійні прогнози. Прогнозування витрат енергії дуже актуальне сьогодні, зважаючи на обмеженість ресурсів і постійне підвищення цін на електроенергію. Прогнозування використання енергії будівлею має важливе значення для надання власникам будівель та менеджерам об’єктів можливості приймати обґрунтовані рішення щодо зменшення її споживання. Однак точне прогнозування енергоспоживання будівлі залишається складним завданням через певні фактори, які нелегко визначити, наприклад, поведінка мешканців щодо споживання енергії, фізичні властивості будівлі тощо.

Інструменти енергетичного моделювання будівель, такі як TRNSYS, DOE-2 і EnergyPlus, широко використовують для прогнозування енергоспоживання експлуатаційних будівель і будівель на етапі проектування. Однак вони дуже деталізовані та трудомісткі, часто потребують великої кількості вхідних параметрів про будівлю та її середовище, наприклад, система HVAC (опалення, вентиляція та кондиціонування повітря) просить задати фізичні характеристики, інформацію про сонячну енергію тощо, які зазвичай недоступні для користувачів [3]. У багатьох випадках неможливість забезпечити необхідні вхідні параметри призводить до низької точності прогнозування [4].

Для розв’язування задач прогнозування електроспоживання в електроенергетиці широко застосовують програмні системи на основі машинного навчання, статистичних та нейромережових методів прогнозування часових рядів, яким вистачає для роботи даних про минуле споживання (статистичні або історичні дані). Штучні нейронні мережі (Artificial Neural Network, ANN) – один з найвідоміших алгоритмів машинного навчання для прогнозування. Розвиток математичних моделей будівель є важливим кроком для визначення енергоефективності будівель та оцінки потенціалу енергозбереження.

Для проектування енергоефективніших будівель потрібні вдосконалені обчислювальні методи, які б забезпечили вищу точність і могли б справлятися з все більшими обсягами даних. Отже, актуальне розроблення нових інструментів для аналізу числових рядів та обчислення прогнозованих значень числових характеристик досліджуваних процесів і явищ для підвищення ефективності використання енергії в будівлях.

Об’єкт дослідження – процес споживання енергії будівлями.

Предмет дослідження – методи та засоби машинного навчання для проектування системи прогнозування енерговитрат будівель.

Мета дослідження – аналіз методів і засобів для прогнозування енерговитрат будівлями на підставі даних споживання за попередні періоди та кліматичних даних із використанням машинного навчання, які дають змогу зменшити використання енергії за рахунок програмної системи для надання рекомендацій споживачам.

Постановка проблеми

Комерційні системи управління енергією (*Energy Management Systems*) приділяють особливу увагу розробленню енергоефективних рішень, які забезпечили б зменшення витрат енергії будівлями, зниження негативного впливу на клімат та економію коштів. Наявні реалізації цих систем використовують спрощені, статистичні методи прогнозування. Проте технології розвиваються і системи управління енергією впроваджують щораз інші, новітні підходи з метою поліпшення якості прогнозів і можливості обробляти великі обсяги даних.

Зважаючи на це, важливим науково-практичним завданням є аналіз та прогнозування витрат енергії будівель для зменшення використання енергетичних ресурсів, враховуючи фактори клімату, сезонності, шаблони споживання користувачами.

Формулювання мети статті

Основна мета статті – дослідження методів і засобів машинного навчання для підвищення енергоефективності будівель.

Результати виконаної роботи у сукупності вирішують актуальне науково-практичне завдання – прогнозування споживання енергії будівлями і слугують підґрунтям для створення методологічного забезпечення у цій предметній області.

Це дослідження спрямоване на перевірку ефективності наявних методів прогнозування та оптимізації енергоспоживання будівель для розроблення енергетичних моделей будівель, придатних для інструментів підтримки та управління енергоспоживанням. З цією метою виконано систематичний аналіз наукових статей за останні 15 років щодо конкретних методологій енергозбереження, опублікованих у провідних журналах, індексованих в SCOPUS. Для досягнення поставленої мети виконано такі завдання:

- класифіковано наявні методи;
- проаналізовано методології та використані для їх реалізації підходи до моделювання;
- розглянуто конкретні сфери використання різних підходів (у контексті будівельної енергетики), оцінено та порівняно їх продуктивність.

Основні моделі машинного навчання

Коротко опишемо найчастіше використовувані для тренування моделі машинного навчання.

Моделі машинного навчання на основі **лінійної регресії** (LR) виражають споживання енергії будівлі (залежна змінна) як лінійну функцію від однієї або кількох вхідних змінних (незалежні або предикторні змінні), що генерує рівняння загальної форми:

$$y(x_1 \dots x_n) = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_n x_n + \varepsilon,$$

де α_0 – точка перетину лінії регресії (значення y , коли всі інші значення параметрів дорівнюють нулю); α_i – коефіцієнти регресії (або вагові коефіцієнти, пов'язані з кожною змінною); ε – похибка, пов'язана із регресією, передбачена випадковим розподілом. Відповідність моделі позначають коефіцієнтом детермінації R – це міра дисперсії y , яка визначається параметрами, що входять у модель.

Метод опорних векторів (*Support Vector Machine, SVM*) є перспективним алгоритмом машинного навчання завдяки сильним нелінійним можливостям, здатним реалізувати класифікацію та регресію. SVM зазвичай використовують для задач класифікації, тоді як регресію опорного вектора (*Support Vector Regression, SVR*) – для прогнозування навантажень на будівлі. Основна ідея методу опорних векторів полягає у введенні функції, яка здатна нелінійно відображати вхідний простір у багатовимірний простір ознак, який формулює оптимізовану гіперплощину для реалізації лінійної регресії у просторі ознак.

Метод випадкового лісу (*Random Forest, RF*) – ансамблевий метод машинного навчання для класифікації, регресії та інших завдань, який працює за допомогою побудови численних дерев прийняття рішень під час тренування моделі й продукує моду для класів (класифікацій) або усереднений прогноз (регресію) побудованих дерев. Недоліком є схильність до перенавчання (*overfitting*).

Екстремальне градієнтне підсилювання (*eXtreme Gradient Boosting, XGB*) – порівняно новий і просунутий алгоритм, досі не вивчений глибоко щодо прогнозування споживання енергії будівлі. XGB ґрунтується на алгоритмі градієнтного посилення та домінує у галузі машинного навчання, який перетворює слабких учнів на сильних. Він може давати кращі результати прогнозування, контролюючи складність моделі та зменшуючи перенавчання завдяки вбудованій регуляції. На відміну від RF алгоритму, в якому кілька предикторів працюють паралельно, XGB додає предиктори послідовно.

Найпоширенішою глибокою моделлю є **багаторівневий перцептрон** (Multi-level Perceptron, MLP), який додає декілька прихованих шарів до звичайної нейронної мережі для покращення здатності вивчення складних шаблонів і закономірностей. У проаналізованих роботах MLP використано для прогнозування споживання енергії, але ця модель не дуже підходить для аналітики послідовних числових рядів.

Натомість **рекурентні нейронні мережі** (RNN) добре справляються із послідовними даними. Нейронна мережа довгої короткочасної пам'яті (*Long short-term memory*, LSTM) – підвид рекурентних нейронних мереж, які добре справляються з довгими послідовностями даних. LSTM може передавати інформацію із останніх кроків на наступний часовий крок (*backpropagation*).

Трансформер (*Transformer*) – це модель глибокого навчання, яка переймає механізм уваги, роздільно оцінюючи важливість кожної частини даних входу. Як і рекурентні нейронні мережі, трансформери призначено для опрацювання послідовних даних входу, таких як природна мова, для завдань перекладу та реферування тексту. Проте, на відміну від RNN, трансформери обробляють дані не обов'язково послідовно. Механізм уваги забезпечує контекст для будь-якого положення у вхідній послідовності. Ця властивість уможливило набагато більше розпаралелювання, ніж RNN, і відтак знижує тривалість тренування. З моменту появи у 2017 р. трансформери все частіше вибирають як модель у задачах опрацювання природної мови, замінивши моделі RNN, зокрема, LSTM. Додаткове розпаралелювання уможливило тренування на більших наборах даних, ніж це було раніше. Трансформер використовує кодувально-декодувальну (Encoder/Decoder) архітектуру. Encoder складається із кодувальних шарів, що обробляють вхідні дані ітеративно, шар за шаром, тоді як Decoder складається із декодувальних шарів, які роблять те саме з виходом кодувальника. Трансформери вважаються революційними моделями глибокого навчання, оскільки роблять прогнози надійнішими та точнішими. Проте є деякі проблеми із трансформерами, через які їх неможливо реалізувати безпосередньо в довгостроковому прогнозуванні часових рядів (LSTF). Квадратична часова складність, високе використання пам'яті та обмеження кодувально-декодувальної архітектури зумовили розроблення ефективних трансформер-моделей, таких як Автоформер (*Autoformer*) та Інформер (*Informer*).

Метрики оцінки ефективності розроблених моделей

Для оцінювання ефективності розроблених моделей на навчальних та тестових вибірках використовують такі метрики:

- середня квадратична похибка $RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}$;
- середня абсолютна похибка $MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$;
- коефіцієнт детермінації $R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2}$;
- коефіцієнт варіації $CV(\%) = \frac{RMSE}{\bar{y}_i} \times 100\%$;
- середня квадратична похибка $MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$;
- середня абсолютна похибка $MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\%$;

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

Аналіз останніх досліджень та публікацій

Поява великих даних привела до необхідності розроблення ефективних інтелектуальних програм моніторингу та прогнозованого обслуговування. Сучасні додатки, керовані даними, з розподіленими обчислювальними архітектурами істотно підвищили ефективність обслуговування. Процедури в комп'ютеризованому процесі технічного обслуговування відбуваються з мінімальною участю людини, що мінімізує помилки особи. У таких процедурах необхідний високий ступінь авто-

матизації. Однак перед прогнозними обслуговуваннями постає проблема об'єднання технологій із різних сфер застосування, зокрема, великі дані, Інтернет речей (IoT), машинне та глибоке навчання. Ці складні рішення працюють повністю автономно, а завдяки можливості навчання здатні постійно збирати, зберігати та аналізувати дані. Водночас для передбачення збоїв або простоїв потрібно аналізувати історичні дані, а також постійно контролювати дані в режимі реального часу. Із застосуванням математичних і статистичних методів інтелектуальне технічне обслуговування може виявити, де, коли і чому компонент може вийти з ладу, отже, під час прогнозованого обслуговування компонент ремонтують або замінюють до того, як станеться збій, що економить кошти та підвищує надійність обладнання. Існує п'ять типів технічного обслуговування, які часто впроваджують у промисловості: коригувальний, профілактичний, заздалегідь визначений, оснований на стані та прогнозований. Різні компанії застосовують різні типи технічного обслуговування залежно від своїх конкретних потреб. Стратегії прогнозованого обслуговування, об'єднані з передовими технологіями, такими як IoT, стали кращим вибором для підвищення ефективності управління та обслуговування об'єктів [5].

Для пошуку останніх досліджень і публікацій у цій галузі використано бібліографічну і реферативну базу Scopus. Здійснено пошук статей за заголовком та ключовими словами згідно із запитом: TITLE-ABS-KEY(("energy") AND ("building") AND ("Machine Learning") AND ("time-series" OR "time series") AND ("prediction" OR "forecast")). Літературу, зібрану в результаті пошуку, відфільтрували вручну, беручи за основу заголовки й анотації. Подальша фільтрація передбачала поверхневий перегляд документів, щоб переконатися, що вони відповідають темі прогнозування споживання енергії будинками на основі машинного навчання. У результаті проаналізовано 40 статей, для зберігання та систематизації інформації щодо них (рік появи кожної роботи, підхід до машинного навчання, тип управління енергоспоживанням будинків та кількість робіт у кожному році) використано Microsoft Excel.

Проаналізувавши відібрані статті, можна виділити такі завдання для обслуговування будівель: виявлення та діагностика несправностей, виявлення та аналіз аномалій, прогнозоване обслуговування, оцінювання зайнятості та підвищення енергоефективності.

Досягнення доволі точних прогнозів часових рядів є дуже важливим, але складним завданням. Авторегресійне інтегроване ковзне середнє (ARIMA) і штучні нейронні мережі – дві дуже популярні та ефективні моделі прогнозування. ARIMA передбачає лінійну функцію генерації даних, тоді як ANN найбільше підходить для нелінійних часових рядів. Однак встановити точну природу часового ряду практично неможливо, він найчастіше містить як лінійну, так і нелінійну кореляцію структур. З урахуванням цього у статті [6] запропоновано нову методологію для прогнозування часових рядів за допомогою розділення датасету на лінійні та нелінійні компоненти за рахунок дискретної вейвлет-трансформації (DWT) з подальшим відповідним використанням вказаних двох моделей. Отже, запропонований гібридний метод прогнозування отримує комбіновані прогнози як середні значення прогнозів через вейвлети viz, harr, db2 і db4. Одержані результати з чотирма часовими рядами продемонстрували, що цей метод дав помітно кращі прогнози, ніж окремо ARIMA та ANN.

Markoska [7] розробила фреймворк для оптимального прогнозування характеристик будівлі за допомогою оцінювання очікуваного енергоспоживання та клімату в приміщенні. Система допомогла менеджерам виявити численні несправності електропроводки в лічильниках та давачах. Фреймворк реалізував нейронну мережу довгої короткочасної пам'яті за допомогою бібліотеки Keras для глибокого навчання, яка додатково використовує бібліотеки TensorFlow, ML з відкритим кодом. Шари LSTM уможливають послідовне оброблення даних (часових рядів), що стосуються температури або споживання енергії.

Wang та Hong [8] досліджували прогнозування температурного навантаження на будівлю на основі машинного навчання. Порівняння 12 моделей (семи моделей машинного навчання, двох моделей глибокого навчання і трьох евристичних моделей) показало найкращі результати для прогно-

зування короткострокового навантаження (одна година наперед) для моделі на основі нейронної мережі LSTM порівняно з лінійною регресією, методом опорних векторів, методом випадкових дерев і алгоритмом XGB. А для довгострокового прогнозування (24 години наперед) модель на базі алгоритму XGB показала кращі результати.

Guss і Linus [9] дослідили підвищення енергоефективності із виявленням аномалій. Вони розробили дві моделі: перша ґрунтувалася на методі кластеризації k -середніх для створення профілів електроенергії зі схожими моделями споживання, а друга використовувала регресію процесу Гауса (Gaussian process regression, GPR) для прогнозування споживання електроенергії з 24-годинним часовим інтервалом. Хоча обидві моделі виявляли аномалії в даних про споживання електроенергії, модель на основі k -середніх виявилася швидшою та надійнішою. Аномалія в цьому контексті є, по суті, нетиповим явищем, яке зазвичай вимагає від керівництва об'єкта вживання коригувальних заходів. Виявлення аномалій може стати проблематичним для систем опалення, вентиляції та кондиціонування, оскільки іноді через нормальну роботу системи можуть виникати дивні шаблони в даних. Мінливість даних зазвичай спричинена загальними змінами в різних робочих умовах.

У статті [10] запропоновано модель глибокого навчання LSTM для прогнозування енергоспоживання будівлі інституту в Малакка. Спрогнозовано щоденне споживання енергії на добу наперед за допомогою прогнозних даних про погоду місцевої метеорологічної організації (Метеорологічного департаменту Малайзії, MET). Прогнозну модель навчено з урахуванням залежності між споживанням енергії та даними про погоду. Продуктивність цієї моделі порівнювали з двома іншими моделями: SVR і GPR. Експериментальні результати перевершили SVR і GPR. Запропонована модель досягла найкращих показників похибки у метриці RMSE (561,692–592,319) порівняно з SVR (3135,590–3472,765) і GPR (1243,307–1334,919). За рахунок методу відсіювання (dropout) вдалося істотно зменшити перенавчання моделі.

У статті [11] подано модель прогнозування електричного навантаження на базі алгоритму вейвлет-трансформації (*Empirical wavelet transform, EWT*) та Автоформера для нестационарних і нелінійних часових рядів. У цій моделі алгоритм EWT використали для підвищення точності прогнозування, отримуючи стабільні підсерії нестационарних часових рядів. Після цього використано модель прогнозування часових рядів Автоформер для прогнозування кожної підсерії. Підсерії, розкладені методом EWT, більше підходять для виконання вимог гладкості моделі Автоформер. Унікальний механізм автокореляції Автоформера дає змогу агрегувати інформацію між подібними послідовностями, забезпечуючи точніше виділення характеристик часових рядів і підвищуючи продуктивність моделі. Модель застосовано до різних типів наборів даних і здійснено порівняння із декомпозицією емпіричного режиму (*Empirical mode decomposition, EMD*). Основна ідея EMD полягає в тому, щоб розкласти нестационарний і нелінійний часовий ряд на майже ортогональну комбінацію простих часових рядів. Ці компоненти відомі як функції внутрішнього режиму (*intrinsic mode functions, IMF*) і залишкові (*residual, r*). Експериментальні результати продемонстрували, що модель на основі EWT та Автоформера перевершує інші комбіновані з EMD моделі (Автоформера, Інформера, RNN і LSTM). Запропонована модель забезпечує найкращі результати прогнозування та точнішу відповідність між кривими прогнозованого та фактичного електричного навантаження.

У [12] розроблено метод побудови комбінованої моделі прогнозування часових рядів на основі базових моделей прогнозування. Під час побудови комбінованої моделі для кожної базової моделі визначається ваговий коефіцієнт, з яким вона входить у комбіновану модель. Вагові коефіцієнти базових моделей визначають на підставі їх точності прогнозування на часовому періоді, визначеному кроком передісторії. Вони відображають міру впливу базових моделей на точність прогнозування комбінованої моделі. Після побудови комбінованої моделі здійснюють її навчання та визначають ті базові моделі, які будуть внесені в остаточну комбіновану модель прогнозування. Внаслідок такого підходу, як показали результати, вдалося істотно підвищити точність прогнозування комбінованої моделі.

У низці робіт показано, що гібридна модель, яка поєднує кілька моделей, може забезпечити кращу точність прогнозу. Так, у роботі [13] запропоновано гібридну модель, яка поєднує у собі модель усереднення профілю та модель машинного навчання, а саме метод регресора випадкового лісу (RFR), для істотного покращення довгого періоду прогнозування (10 % поліпшення, коли період прогнозування становить один тиждень). Запропонована гібридна модель модульна, зрозуміла і не потребує великого набору даних. Аналіз функцій підкреслив важливість явного кодування часу із його подаванням як вхідної функції до моделі прогнозування (коефіцієнт важливості 35 %).

Традиційно використання всіх доступних історичних даних для навчання керованої даними моделі широко використовується для забезпечення ефективності прогнозування, оскільки можна отримати більше історичної інформації. Однак ця стратегія може створити більше шуму, особливо для короткострокового прогнозування навантаження. Chen Y. і Chen Z. [14] досліджували вплив кількості даних для навчання на точність прогнозу і запропонували новий підхід для вибіркового використання статистичних даних та визначення обсягу даних, необхідного для навчання моделі. За допомогою алгоритму LightGBM отримано криві CV та RMSE кожної будівлі, яка відображає зв'язок між довжиною навчальних даних і точністю прогнозування. Використано методи кластеризації k -середніх для ідентифікації будівель, чутливих до довжини навчальних даних на основі кривих CV та RMSE. Для кожної будівлі оцінюють оптимальну тривалість навчальних даних для прогнозування на добу наперед. Дослідження показує, що приблизно 20 % будівель у наборі навчальних даних позначені як чутливі до довжини, і прийняття для них відповідної довжини може зменшити помилку прогнозування до 15 %.

У статті [15] запропоновано самоадаптивну модель глибокого навчання для прогнозування електричного навантаження у будівлях з рухомим горизонтом прогнозу. Алгоритм оптимізації рою частинок (PSO) на основі ранжирування дав можливість вибрати оптимальну архітектуру мережі, яка містить дискретні змінні (тобто кількість нейронів на кожному шарі та кількість прихованих шарів) і категоріальні змінні (тобто функцію активації на кожному рівні та підхід до навчання). Виявлено, що збільшення тривалості навчальних наборів даних не обов'язково підвищує точність прогнозу. Статистичних даних за один останній рік достатньо, щоб охопити характеристики енергоспоживання будівлі. Незбалансована кількість даних (наприклад, за два місяці "липень") може призвести до упередженого навчання. Крім того, більша кількість даних означає більший час обчислення. Отже, запропоновано використовувати статистичні дані за попередні 12 місяців як постійні набори даних для навчання запропонованої моделі.

Wang і Liu [16] застосували кластеризацію клієнтів з подібним профілем споживання на основі методу k -середніх. Вони запропонували модель на базі графової нейронної мережі (GNN) для прогнозування теплового навантаження. GNN – це клас моделей глибокого навчання, які можуть навчатися на графоструктурованих даних, таких як молекули та соціальні мережі. Зазначено, що досі GNN нечасто застосовували для прогнозування часових рядів, особливо для теплового навантаження. GNN підходять для вирішення цієї проблеми, оскільки можуть моделювати складні відносини між споживачами, тепловим навантаженням і метеорологічними факторами в графічному поданні. Крім того, вони можуть подолати обмеження відомих методів, фіксуючи як локальні, так і глобальні закономірності в даних часових рядів. Експерименти показали, що така модель має вищу точність і ефективність порівняно з 15 іншими популярними методами.

У статті [17] застосовано стратегію передавання навчання (*transfer learning*) на основі рівнів LSTM для виявлення та ідентифікації несправностей та прогнозу енергоефективності. Процедура передавання вирішила ініціалізацію вагових коефіцієнтів за допомогою часткового заморожування шару перед налаштуванням (*fine-tuning*) додаткової частини моделі.

Granderson і Fernandes [18] відзначили важливість аналізу впливу гнучкості попиту (*demand flexibility*) на споживання. Оцінено шість різних базових моделей, що представляють два різні підходи – усереднення та регресію. Підходи до усереднення передбачали зіставлення за днями та погодою, а підходи регресії – час тижня та температуру (TOWT) і машину підвищення градієнта

(GBM) та їх варіанти. Аналіз виявив, що такі статистичні дані, як години доби (у другій половині дня), періоди тижня (вихідні) і пори року (літо), були передбачені точніше, ніж інші періоди часу. Крім того, аналіз показав тенденції до завищеного або заниженого прогнозу навантаження. Це перше опубліковане дослідження ерозії базової лінії внаслідок повторного переміщення навантаження будівлі.

Вибір ознак (*feature selection*) – знаходження найкращого поєднання ознак для навчання моделі машинного навчання. González-Vida і Jiménez [19] запропонували методологію на основі восьми різних методів вибору вхідних функцій, яка покращила показники прогнозу MAE на 59,97 % і RMSE на 40,75 % на даних навчання та на 42,28 % і на 36,62 % відповідно на даних тестування, в середньому для першого кроку наперед, другого кроку наперед і третього кроку наперед порівняно із прогнозом без застосування жодної методології вибору функцій. У [20] досліджено, що вибір вхідних функцій для окремих сезонів року є дуже істотним для підвищення точності прогнозу. Розроблено модель на базі рекурсивного методу вибору вхідних функцій із кросвалідацією (*Recursive feature elimination with cross-validation, RFECV*). Показано, що ця модель може досягти вищої точності прогнозування, ніж звичайна модель прогнозування. Серед розглянутих моделей машинного навчання дерево рішень із посиленням градієнта, випадковий ліс і штучна нейронна мережа продемонстрували вищу продуктивність, досягнувши понад 85 % точності влітку, восени та взимку та понад 80 % навесні. Розроблений фреймворк є цінним щодо вибору стратегій для оцінювання енергоспоживання будівлі та прогнозування його рівня з урахуванням впливу пір року. Qiao і Yunusa-Kaltungo [21] поєднали конструювання функцій EMD із вибором функцій Борута (BFS), що дало змогу підвищити точність всіх протестованих алгоритмів машинного навчання для трьох будівель.

Результати аналізу опрацьованих джерел, порівняння різних підходів та методів для прогнозування енергоспоживання будівель та їхніх обчислювальних особливостей подано в табл. 1. Здійснені дотепер дослідження здебільшого зосереджені на визначенні та аналізі аномалій [9], оцінюванні зайнятості [20], аналізі важливості чинників для прогнозування [19, 21] та підвищенні енергоефективності [18, 22].

Вдалося знайти лише декілька праць із описанням цілісної інформаційної системи, зокрема проєкт ENTROPY [23]. Тому створення та описання архітектури автономної інформаційної системи для формування стратегії підвищення енергоефективності будівель є актуальним завданням.

Таблиця 1

Порівняння обчислювальних особливостей основних підходів до енергетичного прогнозування

Рік	Автори		Методи	Підхід	ПЗ/набір даних
1	2	3	4	5	6
2015	Khandelwal I., Adhikari, R. Verma, G	[6]	DWT, ARIMA, ANN	Комбінований прогноз для лінійної та нелінійної частини часового ряду	Matlab
2019	González-Vida, A. Jiménez, F.	[19]	Wrapper Multivariate, Wrapper Univariate, Filter Multivariate, Filter Univariate	Визначення вхідних функцій	Waikato Environment for Knowledge Analysis (Weka) /годинні дані університету в м. Murcia з 2016-02-02 до 2016-09-06
2021	Yang, B. & Haghghat, F	[20]	RFECV	Визначення вхідних функцій для окремих сезонів для підвищення точності прогнозу	Scikit / будівля 'HIKARI' в м. Ліон, Франція, дані за 2016 р.

Продовження табл. 1

1	2	3	4	5	6
2021	Shapi, M. & Ramli, N.	[24]	SVM, ANN, k-Nearest Neighbour	Виконано порівняння метрик трьох методів щодо прогнозу споживання кількох користувачів	AzureML
2021	Lei, L. & Wei Chen, W.	[25]	Rough set theory	Порівняно теорію нечітких множин і методи глибокого навчання	Дані 100 будівель університету в Dalian за 1 рік
2022	Jogunola, O.	[26]	Convolutional neural network (CNN), Autoencoder (AE), bidirectional long short-term memory (BLSTM)	Запропонована комбінована архітектура	Датасети з університетів у California, Canada, UK
2022	Amalou, I & Mouhni N.	[27]	RNN, LSTM, Gated Recurrent Unit (GRU)	Порівняно різні архітектури рекурентних мереж. Модель GRU перевершила базові RNN і LSTM через її здатність справлятися з проблемою градієнта, який зникає	Smart Grid Smart City (SGSC) project (2010–2014) energy Dataset
2022	Luo, X. & Oyedele, L.	[15]	Particle swarm optimisation (RPSO), Deep neural network	Самоадаптивна модель глибокого навчання на основі оптимізації рою частинок та ранжування для прогнозування електричного навантаження наступного місяця в будівлях із рухомими горизонтами прогнозу	Годинні значення будівлі University of the West of England Northavon, Великобританія (липень 2018 – грудень 2019)
2022	Chen Y., Chen Z.	[14]	k-means, k-means (DTW), k-means (soft DTW), k-means (Gaussian kernel), k-shape, LightGBM	Кластеризація багатьох будівель для визначення оптимальної тривалості періоду даних для навчання	Building Data Genome/ годинні дані за 2016–2017 рр.
2022	Hammoudeh A. & Dupont S.	[13]	Profile averaging, DNN, CNN, LSTM, Transformers, Decision Tree, XGB, RFR	Гібридна модель середнього профілювання (вища точність для прогнозу більше ніж 6 год) і регресії випадкових дерев (вища точність для короткотермінового прогнозу)	Дев'ять приміщень у Бельгії, дані за півтора року
2023	Wang Z. & Liu X.	[16]	k-means, DTW, DTW Barycenter Averaging (DBA), RNN, GNN	Кластеризація клієнтів з подібним профілем споживання. Використання графових і рекурентних нейронних мереж	Pytorch/годинні дані за три роки з 3021 теплових лічильників у житлових будівлях Данії

1	2	3	4	5	6
2023	Faiq, M., Tan, K.	[10]	LSTM, SVR, GPR	Прогноз споживання на один день наперед, із використанням даних метеорологічного прогнозу	Scikit / Будівля Multimedia University, Malacca Campus, денні дані споживання із січня 2018 р. до липня 2021 р., метеорологічні дані від Malaysian Meteorological Department (MET)
2023	Panjarompon, C. Santi Bardeeniz, S.	[17]	Transfer learning, LSTM	Стратегія передавання навчання на основі рівнів LSTM	MATLAB/дані симульовані UniSim Design Suite
2023	Granderson J. & Fernandes, S	[18]	GBM	Аналіз впливу гнучкості попиту, порівняно шість різних базових моделей, що представляють два підходи: усереднення (зіставлення за днями та погодою) та регресію (час тижня та температуру (TOWT) і машину підвищення градієнта (GBM) та їх варіанти)	Дані з 120 комерційних будівель, розташованих у двох кліматичних зонах ASHRAE
2023	Avendano, I., Javan, F.	[28]	Sliding-window	Оцінка впливу прогнозування базового навантаження на основі рухомого проміжку на запропоновану оцінку гнучкості для різних категорій будівель	Building Data Genome 2, двогодинні дані за 2016–2017 рр.
2023	Liu, D., Wang, H.	[11]	EWT, Autoformer	Комбінований метод прогнозування на основі емпіричного вейвлетного перетворення і моделі прогнозування часових рядів Autoformer для нестационарних і нелінійних часових рядів електричного навантаження	Годинні дані з 1 січня 2016 р. до 31 грудня 2018 р., Австрія
2023	Qiao, Q., Yunusa- Kaltungo, A.	[21]	feature construction (EMD), feature selection (BFS)	Поєднує конструювання функцій (декомпозицію емпіричного режиму) і вибір функцій (вибір функцій Боруга)	Три будівлі різного типу з університету Манчестера, споживання електрики за два роки, годинні дані
2023	Schmida, L. & Roidl, M.	[28]	RF, XGB, ARIMA	Порівняно класичні методи з методами машинного навчання	Згенеровані дані

Основні підходи до енергетичного прогнозування та відповідні їм моделі

Проблем прогнозування енергоспоживання на підставі ретроспективних даних, які відображені у часових рядах, стосується низка сучасних наукових досліджень. У багатьох роботах аналіз часових рядів спирається на розроблені методи статистичних моделей: економетричні, регресивні та авторегресивні.

Економетричні моделі ґрунтуються на згладжуванні, експонентному згладжуванні й ковзному середньому. Серед них розрізняють такі: “наївна” модель прогнозу, модель обчислення прогнозу на основі середнього згладжування, модель обчислення прогнозу на основі експонентного згладжування. Моделі першого типу найпростіші й передбачають, що деякий основний період часового ряду найкраще описує майбутнє прогнозованого ряду, тому в них прогноз, як правило, є дуже простою функцією від значень прогнозованої змінної в недалекому минулому. Моделі другого типу роблять прогнози на основі лінійних комбінацій значень споживання від “подібних” днів. Модель на основі експонентного згладжування визначає залежність прогнозу від усіх розглянутих даних, причому вплив даних на прогноз експоненціально зменшується із “віком” даних. Розвитком моделей цього типу є моделі двопараметричного згладжування Хольта і Брауна, а також трипараметричної моделі Вінера.

Регресивні моделі, поєднуючи кілька незалежних функцій, утворюють лінійну функцію, яка допомагає інтерпретувати залежності між різними факторами. Для прогнозування електроспоживання від альтернативних джерел живлення, таких як фото- та вітрогенератори, будують модель дерева із використанням даних про погоду і графік даних для прогнозування споживання енергії, який оцінює вплив різних комбінацій ознак на точність прогнозування. Зазначимо, що, використовуючи лінійні регресивні моделі, результат прогнозування можна отримати швидше, ніж за допомогою інших моделей. Нелінійні регресивні моделі характеризуються великою трудомісткістю визначення параметрів моделі.

Автогресивні моделі (Бокса-Дженкінса) – найпопулярніші зі статистичних моделей. У відкритому доступі легко знайти приклади застосування таких моделей (ARIMA, ARIMAX, GARCH, ARDLN), щоб одержати розв’язки задач прогнозування часових рядів у різних предметних областях. Моделі спираються тільки на інформацію, що міститься в передісторії прогнозованих рядів, що обмежує можливості алгоритму. ARIMA не передбачає якої-небудь чіткої моделі для прогнозування цієї часової серії. Задається лише загальний клас моделей, що описують часовий ряд і дають змогу якимось виражати поточне значення змінної через її попередні значення. Потім алгоритм, підлаштовуючи внутрішні параметри, сам вибирає найвідповіднішу модель прогнозування. Моделі прогнозування на основі ланцюгів Маркова припускають, що майбутній стан процесу залежить тільки від його поточного стану і не залежить від попередніх. Моделі використовують матрицю ймовірностей переходів системи з одного стану в інший. Структура ланцюга Маркова та ймовірності переходу станів визначають залежність між майбутнім значенням процесу та його поточним значенням.

Американське товариство інженерів з опалення, охолодження та кондиціонування повітря, (American Society of Heating, Refrigerating, and Air Conditioning Engineers, ASHRAE) є некомерційною організацією, яка розробляє та публікує стандарти для промисловості опалення, вентиляції та кондиціонування повітря, налічує понад 50 000 членів. Згідно зі стандартом ASHRAE [29] виділяють два підходи до прогнозування, а саме прямий (класичний) і зворотний (керований даними). Batish та Agrawal [30] здійснили поглиблений аналіз моделей прогнозування споживання енергії будівлею на основі 25 статей, сформувавши класифікацію підходів до прогнозування й описали методи, які використовують у кожному з підходів. У цій статті виділено три широко використовувані підходи до прогнозування, а саме: побудова фізичних енергетичних моделей (*white box*), керовані даними моделі (*black box*) і гібридні моделі (*gray box*).

Класичний (прямий) підхід описує рівняння фізичної поведінки систем та їх вхідні параметри для прогнозування результату. Інженерні методи використовують фізичні принципи розрахунку теплодинаміки та енергетичної поведінки. Серед них можна виділити деталізовані комплексні методи – на основі розроблення фізичних функцій чи теплової динаміки розраховують крок за кроком споживання енергії. Деталізовані моделі теплових характеристик будівель ґрунтуються на розв’язуванні рівнянь теплопровідності, до них належать, зокрема, обчислювальна гідродинаміка (CFD), зональний і багатозональний (вузловий) підходи. Використовують також спрощені методи – методи стаціонарного стану, такі як метод Degree Day і температурно-частотний метод (Bin).

Керований даними (зворотний, емпіричний) підхід визначає математичний опис системи на основі вже відомих вхідних і вихідних змінних, що регулюють продуктивність системи, використовує методи співвідношення енергоспоживання або енергетичного індексу з факторами впливу. Оскільки постійно збирають нові дані з лічильників, можливо вивчати особливості та закономірності зміни статистичних даних і на підставі цього робити прогнози. У цьому підході виділяють емпіричні моделі, розроблені на основі статистичних даних, та машинне навчання. До перших, зокрема, належать: лінійна регресія, аналіз основних компонентів (PCA), авторегресія з додатковими входами (ARX), авторегресивне інтегроване ковзне середнє (ARIMA), ARIMA із зовнішніми входами (ARIMAX), аналіз умовного попиту (CDA).

Гібридний підхід передбачає поєднання названих вище обох підходів з використанням їхніх найкращих рис. Для описання фізичних характеристик особливостей будівлі, які впливають на його енергоспоживання, розробляють математичну модель. Для ідентифікації параметрів і визначення їхніх значень використовують статистичні методи.

Щоб оцінити придатність різних методів прогнозування для застосування в інструментах підтримки раннього проєктування, важливо розуміти можливості, обмеження та підходи до моделювання [31]. У табл. 2 подано загальне порівняння основних методологій і підходів до моделювання, необхідних вхідних даних і точності отриманих результатів. Складність моделей із використанням деталізованих та спрощених інженерних методів висока, водночас вони забезпечують високу точність результатів. Інформація (детальна чи спрощена) про геометрію будівлі й погоду потрібна в обох випадках. Однак висока трудомісткість моделювання поряд з необхідністю детальної інформації та вхідних даних про будівництво є фактором, який стримує їх використання у засобах раннього проєктування і підтримки прийняття рішень.

Натомість складність і точність статистичних методів є середніми через припущення про лінійність, якої може не бути в реальності. Швидкість виконання цих методів висока для спрощених інженерних методів та штучних нейронних мереж. Складність моделі та точність передбачення ANN також високі. З погляду придатності як раннього інструменту підтримки прийняття рішень щодо проєктування керовані даними методи дають можливість знизити складність процесу моделювання для кінцевого користувача, оскільки потребують лише статистичних даних про зміну прогнозованої змінної й не вимагають комплексних параметрів геометрії будівлі. Значна частина інформації щодо геометрії будівлі взагалі недоступна на етапі раннього проєктування. Порівняння характерних особливостей основних методів енергетичного прогнозування згідно із [31] подано у табл. 2.

Таблиця 2

Порівняння трьох основних підходів до енергетичного прогнозування

Методи/ характеристики	Інженерні (описові, теоретичні, фізичні або класичні) методи	Керовані даними (емпіричні) методи	Гібридні методи
Методологія і підхід прогнозування	Використовується рівняння термодинаміки для розрахунку поведінки енергії (деталізовані методи) або рівняння стаціонарного стану (спрощені методи)	Співвідносять пов'язані з енергією вихідні (залежні) змінні із вхідними (незалежними) змінними і виражають енергію як функцію цих змінних	Поєднання інженерних методів з керованими даними методами
Інформація про геометрію будівлі	Потрібна детальна або спрощена	Не потрібна	Достатньо приблизного опису
Дані про навчання (або справжні, або змодельовані)	Не потрібні	Необхідна велика кількість протягом тривалого періоду	Достатньо невеликої кількості протягом короткого періоду
Інтерпретація результатів у фізичних термінах	Можлива	Ускладнена	Можлива

Зазначимо, що методам та моделям, керованим даними, притаманні такі обмеження:

- вони можуть не дати точних прогнозів, якщо вхідні значення перебувають за межами діапазону даних навчання;
- моделі на основі штучного інтелекту, такі як ANN, є моделями “чорної скриньки”, вони не підлягають інтерпретації та не забезпечують детального розуміння основних співвідношень між предикторами та прогнозованими змінними.

Таблиця 3

Порівняння характеристик основних методів енергетичного прогнозування

Методи	Складність моделі	Легкість використання	Швидкість виконання	Вхідні дані	Точність
Деталізовані інженерні методи	Доволі висока	Ні	Низька	Детальні дані про будівлю	Доволі висока
Спрощені інженерні методи	Висока	Так	Висока	Спрощені дані про будівлю	Висока
Статистичні методи	Середня	Так	Досить висока	Дані споживання за попередні періоди	Середня
Машинне навчання	Висока	Ні	Висока	Дані споживання за попередні періоди	Висока

Залежно від періоду прогнозу згідно із [32] виділяють такі два типи моделей прогнозування споживання:

1. *Short-term load forecasting (STLF)* – прогнозування на короткий термін (секунди, години, дні, тижні) – використовується для балансування попиту і пропозиції споживання енергії (*energy demand response*) та оптимізації системи за рахунок відкладеного споживання поза межами часу пікового навантаження. Графік залежності пропозиції енергетичної системи від часу і попиту наведено на рис. 1.

2. *Long-term load forecasting (LTLF)* – прогнозування на довгий термін (місяць, рік, десятиліття) для торгівлі енергією, системного планування та розроблення енергетичної політики.




Рис. 1. Балансування попиту і пропозиції споживання енергії (*energy demand response*) [32]

Програмні засоби, що враховують класичний (прямий) підхід до оцінювання енергоефективності будівель, такі: DOE-2, Energyplus, BLAST, ESP-r, DeST, eQuest, TRNSYS, Dymola. Згідно з [30] такі інструменти моделювання, як TRNSYS і Dymola, добре підходять для створення енергетичних систем, тоді як EnergyPlus – для моделювання будівельної оболонки. Крім того, деякі керувані даними моделі, такі як XGB, кращі для LTLF, тоді як RNN добре підходить для STLF, а ANN і RF можна використовувати для обох часових проміжків.

У статті [33] проаналізовано 116 наукових робіт щодо прогнозування споживання енергії будівлями на основі керуваних даними моделей. Висвітлено фактори, які впливають на прогнозування, і підсумовано ключові підходи залежно від часу, рівнів будівель і типів енергії. Виявлено, що метеорологічні дані є найчастіше вживаним набором функцій (до 42 %) порівняно з внутрішніми параметрами будівлі (12 %) та параметрами конструкції (7 %). У більшості робіт здійснено короткострокові прогнози: одноденні (34 %), одногодні (28 %), а довгострокові лише такі: один рік (5 %) та один місяць (3 %). Серед трьох сегментів (попереднє оброблення, вибір даних і навчання) виявлено, що попереднє оброблення даних щодо споживання енергії може підвищити ефективність прогнозування моделі, тоді як алгоритми MLP та множинної лінійної регресії (MLR) можуть підвищити точність прогнозування моделі за допомогою інтеграції кількох алгоритмів і оптимізації гіперпараметрів. Розподіл за типами алгоритмів машинного навчання показав переважне використання LSTM (16 %), ANN (10 %), XGB (6 %) та SVR (6 %) (рис. 2).

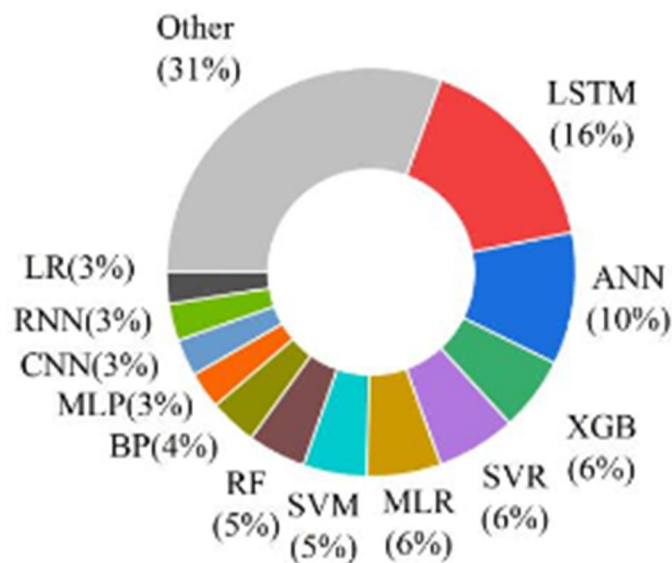


Рис. 2. Розподіл за типами алгоритмів машинного навчання [33]

Упродовж останніх років все популярнішим стає глибоке машинне навчання із глибокими нейронними мережами. Основна відмінність між неглибоким і глибоким машинним навчанням полягає у кількості лінійних і нелінійних трансформацій вхідних даних у вихідні дані. Неглибокі моделі переважно виконують перетворення лише один чи два рази. Глибокі моделі можуть вивчати складніші шаблони і закономірності, даючи змогу навчатися без ручного визначення функцій, які визначають особливості (feature engineering), вони виявились ефективними для аналізу числових рядів.

У табл. 4 подано основні підходи до енергетичного прогнозування за методами та програмними засобами (зазначеними в квадратних дужках), використаними в цих підходах, згідно із [30].

Таблиця 4

Класифікація основних підходів до енергетичного прогнозування за методами та програмними засобами, які в них використовують

Підходи до прогнозування споживання енергії будівлями				
Інженерні (описові, теоретичні, фізичні або класичні) методи		Керовані даними (емпіричні) методи		Гібридні методи
Деталізовані методи	Спрощені методи	Статистичні методи	Машинне навчання	
<ul style="list-style-type: none"> • обчислювальна гідродинаміка (CFD) (3D) [FLUENT, COMSOL Multiphysics, MIT-CFD, PHOENICS-CFD etc.] • зональний підхід (2D) [SPARK] • багатозональний (вузловий) підхід (1D) [TRNSYS, EnergyPlus, ESP-r, eQUEST, IDA-ICE etc.] • метод Conduction Transfer Function (CTF) [BLAST, TRNSYS & Energyplus] • факторний метод теплової реакції [DOE-2] • метод променевих часових рядів (RTF) • моделі Lumped Parameter 	<ul style="list-style-type: none"> • метод Degree Day • температурно-частотний метод 	<ul style="list-style-type: none"> • лінійна регресія • аналіз основних компонентів (PCA) • авторегресійне ковзне середнє (ARMA) • авторегресійне інтегроване ковзне середнє (ARIMA) • множинна лінійна регресія (MLR) або аналіз умовного попиту (CDA) • інші інструменти: звичайна регресія найменших квадратів (OLSR), поліноміальна регресія, експоненціальна регресія, сплайн багатовимірної адаптивної регресії (MARS), вирішення проблем на основі прецедентів (CBR) тощо. 	<ul style="list-style-type: none"> • штучна нейронна мережа (ANN) • рекурентна нейронна мережа (RNN) • графова нейронна мережа (GNN) • метод опорних векторів (SVM) • генетичний алгоритм (GA) • оптимізація рою частинок (PSO) • трансформери (Transformer, Informer, Autoformer) • моделі ансамблю з використанням комбінації методів III 	<ul style="list-style-type: none"> • поєднання інженерних та керованих даними методів для оцінювання фізичних параметрів • моделювання з використанням симуляції Монте-Карло

Модель машинного навчання для прогнозування енергоспоживання

Для розроблення моделей машинного навчання в проаналізованих літературних джерелах використано такі інструменти, як мова Python, за допомогою бібліотек TensorFlow, Keras і PyTorch, система MATLAB за допомогою Deep Learning Toolbox (Mathworks) і мови R, Microsoft Azure Machine Learning studio (AzureML).

Надзвичайно важливим етапом для побудови керованої даними моделі є вибір ознак (*feature selection*). Широко використовують як вхідні змінні характеристики часових рядів (наприклад, тип дня, рівень зайнятості та розклад, графік роботи обладнання), метеорологічні умови (наприклад, температура, вологість, сонячне випромінювання), а також фізичні параметри будівлі (наприклад, кількість поверхів, площа стін, площа скління, коефіцієнт теплопередачі стін). П'ятьма найважливішими та часто використовуваними вхідними функціями в моделях, керованих даними, є зовнішня температура, зовнішня відносна вологість, сонячна радіація, день тижня та година доби. Згідно з дослідженням [34], у 25 публікаціях основними характеристиками були зовнішня температура й вологість.

Перед початком машинного навчання важливе попереднє опрацювання даних: їх очищення, знаходження пропущених значень, визначення аномалій, трансформація до формату, зрозумілого

для машинного навчання, оскільки від цього істотно залежать результати навчання. Вже опрацьовані дані поділяють на дві групи – набір для тренування (80 %) і набір для тестування (20 %).

Блок-схему процесу енергетичного прогнозування за допомогою машинного навчання наведено на рис. 3. Вихідними змінними, як правило, є навантаження на опалення або охолодження та споживання електроенергії.

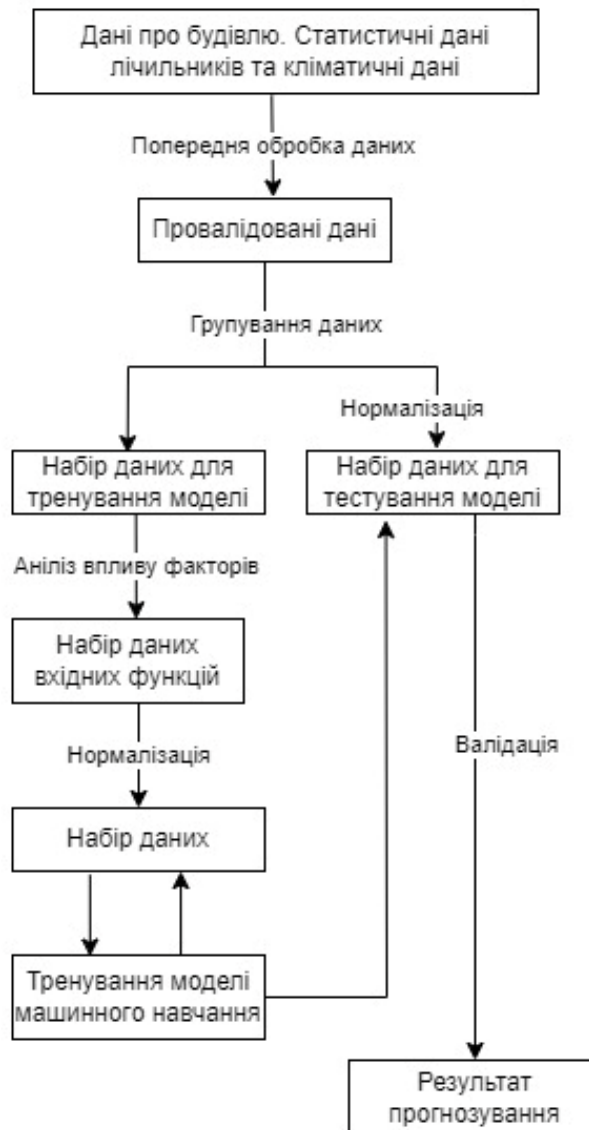


Рис. 3. Блок-схема розроблення і валідації моделі машинного навчання для прогнозування споживання

В умовах комерційного проєкту надходження нових даних у систему є постійним процесом із певним інтервалом (наприклад, щогодини), тому потрібно постійно перенавчати модель із появою нових даних.

Семантична модель енергоспоживання та запропонована методологія

Семантичні вебтехнології розроблено для автоматичного опрацювання вебданих без втручання людини. Пошук даних оснований на семантичних зв'язках між категоріями даних і класами, а не лише на числових значеннях. Це покращує обмін знаннями та інтеграцію однорідних джерел даних. У семантичному веб-онтологія є ключовим елементом для формального та явного опису основних концепцій або класів домену, який зберігає дані та зв'язки між цими концепціями.

Однією із поширених мов для опису онтологій є мова вебонтології (OWL). Інші мови, такі як Semantic Web Rule Language (SWRL), можуть виражати правила (це механізми виведення неявних знань на основі явних фактів) та логіку безпосередньо в моделі.

Пропонуємо семантичну модель для багатоклієнтської системи енергоуправління будівлями з урахуванням кількох доменів, ураховуючи лічильники та характеристики будівель, поведінку мешканців, тарифи, вплив клімату та енергозбереження. На рис. 4 показано основні домени, класи предметної області та онтологічний граф залежностей. Використано Web Protégé – програмне забезпечення із відкритим вихідним кодом, незалежне від домену, для створення OWL-представлення онтології. Візуалізацію зв'язків графів онтології реалізовано за допомогою програмного забезпечення WebVOWL. Визначено чотири основні домени в семантичній моделі, які мають такі класи та підкласи:

1) Клієнт, Місцезнаходження (масток, будівля, квартира), Орендар, Пристрій (лічильник, датчик) – для опрацювання зв'язків із кількома клієнтами та їхнім маєтком (будівлею, квартирою, власністю), ураховуючи інформацію про геолокацію;

2) Тариф, Інтервал, Метеостанція, Сезон (зима, весна, літо, осінь) – для обґрунтування того, як низькі (пікові) тарифи, погода, час, день, тиждень і сезонна інформація впливають на споживання енергії;

3) Одиниця вимірювання, Виміри (покази лічильника, споживання, вологість, зовнішня температура) – для даних часових рядів;

4) Типи енергії (гаряча вода, охолодження, опалення, електроенергія, природний газ, холодна вода), Кількість (енергія, об'єм, маса, температура, потік).

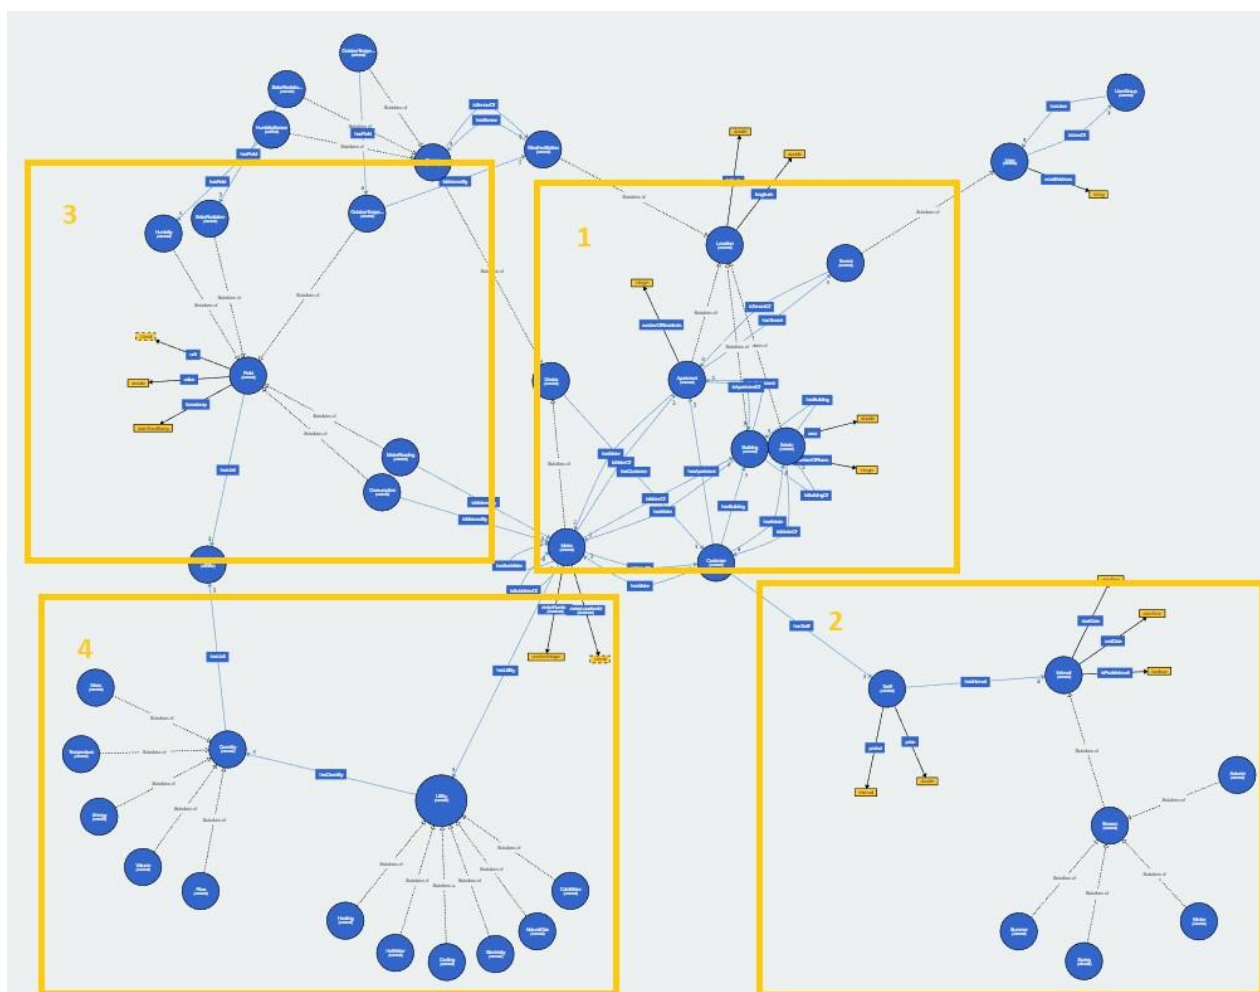


Рис. 4. Основні домени запропонованої онтологічної моделі

Низка досліджень у домені енергії будівель окремо розглядає семантичне моделювання та машинне навчання. Пропонуємо новий підхід до поєднання цих технологій для надання допомоги в системах управління енергією розумних будівель, використовуючи систему знань розробленої семантичної моделі (рис. 5).

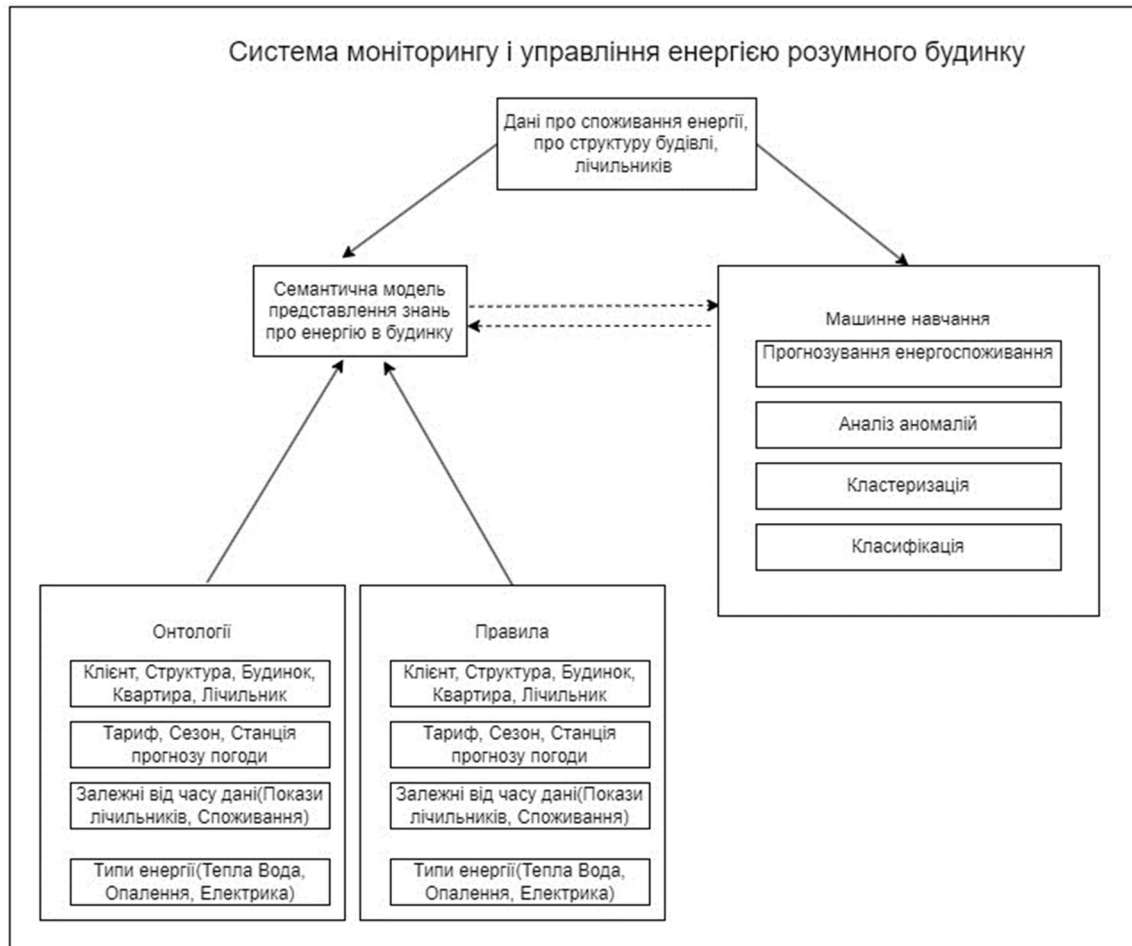


Рис. 5. Блок-схема архітектури системи моніторингу й управління енергією розумного будинку, яка поєднує машинне навчання із використанням семантичної моделі знань

Висновки

Оскільки прогнозування витрат енергії будівлями нині є надзвичайно актуальним завданням для нашої країни, зважаючи на обмеженість ресурсів і постійне підвищення цін на електроенергію, розроблення рекомендацій їхнім власникам та проєктувальникам житлових і офісних об'єктів дасть змогу приймати обґрунтовані рішення щодо зменшення її споживання.

Враховуючи, що точне прогнозування енергоспоживання будівлі забезпечити нелегко, а то й неможливо, оскільки наперед не відомо, скільки споживатимуть енергії мешканці будівель чи працівники офісів, які фізичні особливості приміщень та впливу метеорологічних факторів, в останнє десятиліття для визначення енергоефективності будівель та оцінювання потенціалу енергозбереження все частіше використовують математичні моделі та обчислювальні методи, зокрема, штучні нейронні мережі як один з найвідоміших алгоритмів машинного навчання для прогнозування. Останні повинні опрацьовувати все більші обсяги даних і забезпечувати прийнятну для споживача точність.

Ґрунтовний аналіз сучасних наукових досліджень у цій галузі дав змогу порівняти різні статистичні моделі (економетричні, регресивні та авторегресивні) та методи прогнозування

енергоспоживання будівель, зокрема, на підставі ретроспективних даних, які відображено у часових рядах. Здійснені дотепер дослідження здебільшого зосереджені на визначенні та аналізі аномалій, оцінюванні зайнятості, аналізі важливості чинників для прогнозування та підвищенні енергоефективності, зі складними нелінійними вхідними та вихідними взаємозв'язками. Моделі на основі глибокого навчання демонструють вищу продуктивність, ніж статистичні методи прогнозування часових рядів. Водночас точність результатів можна підвищити за допомогою комбінування вказаних підходів. Тому актуальним є розроблення нових інструментів для аналізу числових рядів та обчислення прогнозованих значень числових характеристик досліджуваних процесів і явищ для збільшення ефективності використання енергії в будівлях.

Ми розробили семантичну модель та запропонували, використовуючи систему знань цієї моделі, новий підхід до поєднання технологій семантичного моделювання та машинного навчання для системи управління енергією розумних будівель.

Подальші дослідження будуть спрямовані на описання архітектури і розроблення автономної інформаційної системи, яка використовуватиме запропонований підхід.

Список літератури

1. Dandotiya, B. (2020). *Climate Change and Its Impact on Terrestrial Ecosystems, Impacts of Climate Change on Agriculture and Aquaculture*, 140–157. IGI Global. <http://dx.doi.org/10.4018/978-1-7998-3343-7.ch007>
2. Popa A. (2022). *A Semantically Data-Driven Classification Framework for Energy Consumption in Buildings*. *Energies*, 2022, 15(9), 3155. <https://doi.org/10.3390/en15093155>
3. Runge J. & Zmeureanu R. (2019). *Forecasting Energy Use in Buildings Using Artificial Neural Networks: A Review*. *Energies*, 2019, 12(17), 3254. <https://doi.org/10.3390/en12173254>
4. Amasyali K. & El-Gohary N. M. (2018). *A review of data-driven building energy consumption prediction studies*. *Renewable and Sustainable Energy Reviews*, Vol. 81, Part 1, January 2018, 1192–1205. <https://doi.org/10.1016/j.rser.2017.04.095>
5. Sanzana M. R. & Maul T. (2022). *Application of deep learning in facility management and maintenance for heating, ventilation, and air conditioning*. *Automation in Construction*, Vol. 141, September 2022, 104445. <https://doi.org/10.1016/j.autcon.2022.104445>
6. Khandelwal, I., Adhikari, R. & Verma, G. (2015). *Time series forecasting using hybrid ARIMA and ANN models based on DWT decomposition*. *Procedia Computer Science*, 48, 173–179. <https://doi.org/10.1016/j.procs.2015.04.167>
7. Markoska E. (2019). *A Framework for Automated Real-Time Performance Evaluation of Smart Buildings*. <https://doi.org/10.21996/5hay-tm27>
8. Wang, Z. & Hong, T. *Building thermal load prediction through shallow machine learning and deep learning*. *Applied Energy*, Vol. 263, 1 April 2020, 114683. <https://doi.org/10.1016/j.apenergy.2020.114683>
9. Guss H. & Linus R. (2020). *Applying Machine Learning Algorithms for Anomaly Detection in Electricity Data: Improving the Energy Efficiency of Residential Buildings*. *Digitala Vetenskapliga Arkivet*. Batish A., Agrawal A. (2019). *Building Energy Prediction for Early-Design-Stage Decision Support: A Review of Data-driven Techniques*. *Conference: Building Simulation 2019, Rome, Italy, September 2019*. <http://dx.doi.org/10.26868/25222708.2019.211032>
10. Faiq, M & Tan, K. (2023). *Prediction of energy consumption in campus buildings using long short-term memory*. *Alexandria Engineering Journal*, Vol. 67, 15 March 2023, 65–76. <https://doi.org/10.1016/j.aej.2022.12.015>
11. Liu, D. & Wang, H. (2023). *Time series analysis model for forecasting unsteady electric load in buildings*. *Energy and Built Environment*, 15 July 2023. <https://doi.org/10.1016/j.enbenv.2023.07.003>
12. Гече, Ф., Мулеса, О. (2021). *Навчання комбінованої моделі прогнозування часових рядів*. *Український журнал інформаційних технологій*. Вип. 3, № 1 : 44–48. <https://doi.org/10.23939/ujit2021.03.044>
13. Hammoudeh A. & Dupont S. (2022). *The prediction of residential building consumption using profiling and time encoding*, *Procedia Computer Science*, Vol. 210, 7–11. <https://doi.org/10.1016/j.procs.2022.10.113>
14. Chen, Y. & Chen, Z. (2022). *Short-term load forecasting for multiple buildings: A length sensitivity-based approach*. *Energy Reports*, 8:14274–14288. <http://dx.doi.org/10.1016/j.egy.2022.10.425>

15. Luo, X. & Oyedele, L. (2023). A self-adaptive deep learning model for building electricity load prediction with moving horizon. *Mach Learn Appl.*, 7 (2022), Article 100257. <https://doi.org/10.1016/j.mlwa.2022.100257>
16. Wang Z. & Liu X. (2023). A multivariate time series graph neural network for district heat load forecasting. *Energy*, Vol. 278, Part A, 1 September 2023, 127911. <https://doi.org/10.1016/j.energy.2023.127911>
17. Panjapornpon, C. & Santi Bardeeniz, S. (2023). Explainable deep transfer learning for energy efficiency prediction based on uncertainty detection and identification. *Energy and AI*, Vol. 12, April 2023, 100224. <https://doi.org/10.1016/j.egyai.2022.100224>
18. Granderson J. & Fernandes, S. (2023). Accuracy of hourly energy predictions for demand flexibility applications. *Energy and Buildings*, Vol. 295, 15 September 2023, 113297. <https://doi.org/10.1016/j.enbuild.2023.113297>
19. González-Vida, A. & Jiménez, F. (2019). A methodology for energy multivariate time series forecasting in smart buildings based on feature selection. *Energy and Buildings*, Vol. 196, 1 August 2019, 71–82. <https://doi.org/10.1016/j.enbuild.2019.05.021>
20. Yang, B. & Haghghat, F. (2021). Season-Based Occupancy Prediction in Residential Buildings Using Machine Learning Models. *e-Prime – Advances in Electrical Engineering, Electronics and Energy*, Vol. 1, 100003. <https://doi.org/10.1016/j.prime.2021.100003>
21. Qiao, Q. & Yunusa-Kaltungo, A. (2023). Developing a machine learning based building energy consumption prediction approach using limited data: Boruta feature selection and empirical mode decomposition. *Energy Reports*, Vol. 9, December 2023, 3643–3660. <https://doi.org/10.1016/j.egy.2023.02.046>
22. Avendano, I. & Javan, F. (2023). Assessing the impact of employing machine learning-based baseline load prediction pipelines with sliding-window training scheme on offered flexibility estimation for different building categories. *Energy and Buildings*, Vol. 294, 1 September 2023, 113217. <https://doi.org/10.1016/j.enbuild.2023.113217>
23. Fotopoulou E. (2017). Providing Personalized Energy Management and Awareness Services for Energy Efficiency in Smart Buildings. *Sensors*, 17(9), 2054. <https://doi.org/10.3390/s17092054>
24. Shapi, M. & Ramli, N. (2021). Energy consumption prediction by using machine learning for smart building: Case study in Malaysia. *Developments in the Built Environment*, Vol. 5, March 2021, 100037. <https://doi.org/10.1016/j.dibe.2020.100037>
25. Lei, L. & Wei Chen, W. (2021). A building energy consumption prediction model based on rough set theory and deep learning algorithms. *Energy and Buildings*, Vol. 240, 1 June 2021, 110886. <https://doi.org/10.1016/j.enbuild.2021.110886>
26. Jogunola, O. (2022). CBLSTM-AE: A Hybrid Deep Learning Framework for Predicting Energy Consumption. *Energies*, 15(3), 810. <https://doi.org/10.3390/en15030810>
27. Amalou, I. & Mouhni N. (2022). Multivariate time series prediction by RNN architectures for energy consumption forecasting. *Energy Reports Volume 8, Supplement 9, November 2022*, 1084–1091. <https://doi.org/10.1016/j.egy.2022.07.139>
28. Schmida, L. & Roidl, M. (2023). Comparing statistical and machine learning methods for time series forecasting in data-driven logistics – A simulation study. *arXiv – STAT – Machine Learning*. March 2023. <https://doi.org/10.48550/arXiv.2303.07139>
29. ASHRAE Handbook (2023). <https://www.ashrae.org/technical-resources/ashrae-handbook>
30. Batish A., Agrawal A. (2019). Building Energy Prediction for Early-Design-Stage Decision Support: A Review of Data-driven Techniques. *Conference: Building Simulation 2019, Rome, Italy, September 2019*. <http://dx.doi.org/10.26868/25222708.2019.211032>
31. Zhao, H. & Magoulès, F. (2012). A Review on the Prediction of Building Energy Consumption. *Renewable and Sustainable Energy Reviews*, Vol. 16 (6): 3586–92. <https://doi.org/10.1016/j.rser.2012.02.049>
32. Encorp (2023). Balancing Energy Supply and Demand. <https://encorp.com/demand-response/>
33. Chen Y. & Guo M. (2022). Physical energy and data-driven models in building energy prediction: A review. *Energy Reports*, Vol. 8, November 2022, 2656–2671. <https://doi.org/10.1016/j.egy.2022.01.162>
34. Liu H. & Liang J. (2023). A Review of Data-Driven Building Energy Prediction, *Buildings* 2023, 13(2), 532. https://www.utn.uu.se/sts/student/wp-content/uploads/2020/07/2007_Linus_Rustas_Herman_Guss.pdf

MACHINE LEARNING METHODS TO INCREASE THE ENERGY EFFICIENCY OF BUILDINGS**Oleksandr Vyshnevskyy¹, Liubov Zhuravchak¹**Lviv Polytechnic National University, Software Development Department,
12, S. Bandery str., Lviv, Ukraine¹E-mail: oleksandr.k.vyshnevskyy@lpnu.ua, ORCID 0009-0005-4857-9669²E-mail: liubov.m.zhuravchak@lpnu.ua, ORCID 0000-0002-1444-5882© *Vyshnevskyy O., Zhuravchak L., 2023*

Predicting a building's energy consumption plays an important role as it can help assess its energy efficiency, identify and diagnose energy system faults, and reduce costs and improve climate impact. An analysis of current research in the field of ensuring the energy efficiency of buildings, in particular, their energy assessment, considering the types of models under consideration, was carried out. The principles, advantages, limitations, and practical application of the main data-based models are considered in detail, and priority future directions for forecasting the energy efficiency of buildings are highlighted. It is shown that the effectiveness of the methods is different for the main types of models and depends on the following factors: input data and parameters, the type and quality of available data for training, the suitability of the method for a specific type of model, etc. The need to consider the element of uncertainty when forecasting energy consumption due to the impossibility of accurate modeling of meteorological factors and the behavior of residents is emphasized. Therefore, machine learning methods, particularly deep learning-based models, are chosen to represent complex nonlinear input-output relationships, as they show higher performance than statistical time series forecasting methods. The analysis of published works revealed a lack of works describing a comprehensive energy forecasting information system for use in commercial projects. We proposed a new approach to combining semantic modeling and machine learning technologies for the energy management system of smart buildings, using the knowledge system of the semantic model we developed.

Key words: energy; buildings; energy efficiency; prognostication; time series; machine learning.