

УДК 004.942:620.9

DOI <https://doi.org/10.36994/2788-5518-2026-01-11-02>

КРОС-КЛІМАТИЧНИЙ АНАЛІЗ ВАЖЛИВОСТІ ОЗНАК ДЛЯ ПРОГНОЗУВАННЯ ЕНЕРГОСПОЖИВАННЯ БУДІВЕЛЬ

Войтех Д. В., аспірант, Відкритий міжнародний університет розвитку людини «Україна», Київ, Україна. <https://orcid.org/0009-0003-8997-5495>, d.voitek@gmail.com

Тимошенко А. Г., к.т.н., проф., Відкритий міжнародний університет розвитку людини «Україна», Київ, Україна. <https://orcid.org/0000-0003-0954-3186>, timoshag@i.ua

Анотація. У роботі перевіряється гіпотеза про те, що структура важливості ознак для короткострокового прогнозування енергоспоживання будівель не залежить від кліматичної зони. Для цього побудовано єдиний обчислювальний конвеєр, який охоплює лаги навантаження, метеорологічні прогнози, циклічні, календарні та інші групи ознак, і застосовано його до двох відкритих наборів даних із протилежними кліматичними умовами: норвезького COFACTOR Drammen, що містить дані 45 публічних будівель із переважанням опалення, та каліфорнійського CityLearn із 15 житловими будівлями та переважанням охолодження.

Порівняно три моделі зростаючої складності – від наївної базової до градієнтного бустингу на деревах рішень. Інтерпретацію виконано за допомогою методу SHAP, який дозволяє кількісно оцінити внесок кожної ознаки у прогноз. Статистичну значущість відмінностей між моделями перевірено за допомогою тесту Дібольда–Маріано. Додатково проведено експерименти з холодного старту та абляції ознак для оцінки мінімально необхідного обсягу даних і кількості ознак.

Встановлено, що рейтинг груп ознак залишається стабільним незалежно від клімату: лаги навантаження домінують в обох випадках, тоді як метеорологічні прогнози відіграють порівняно другорядну роль. Водночас точність прогнозу суттєво різниться: будівлі з опаленням прогнозуються значно краще, ніж будівлі з охолодженням. Несподівано, для охолоджувальних навантажень проста лінійна модель виявилася точнішою за градієнтний бустинг, що пояснюється перенавчанням складнішої моделі на стохастичному компоненті навантаження. Сформульовано практичні рекомендації: для будівель з опаленням достатньо трьох–шести місяців даних, а помірне скорочення набору ознак за рейтингом важливості зберігає основну частину точності. Для українського контексту, де клімат аналогічний норвезькому, результати безпосередньо застосовні.

Ключові слова: прогнозування енергоспоживання, машинне навчання, енергоефективність будівель, кліматичний аналіз, інтерпретація моделей.

CROSS-CLIMATE ANALYSIS OF FEATURE IMPORTANCE FOR SHORT-TERM BUILDING ENERGY FORECASTING

Dmytro Voitek, PhD student, Open International University of Human Development "Ukraine", Kyiv, Ukraine. <https://orcid.org/0009-0003-8997-5495>, d.voitek@gmail.com

Anatolii Tymoshenko, Ph.D., Associate Professor, Open International University of Human Development "Ukraine", Kyiv, Ukraine. <https://orcid.org/0000-0003-0954-3186>, timoshag@i.ua

Abstract. The paper tests the hypothesis that the feature importance structure for short-term building energy forecasting is independent of climate zone. A unified computational pipeline covering load lags, weather forecasts, cyclical, calendar, and other feature groups was applied to two open datasets with contrasting climatic conditions: the Norwegian COFACTOR Drammen dataset, comprising 45 public buildings with heating-dominated loads, and the Californian CityLearn dataset, comprising 15 residential buildings with cooling-dominated loads.

Three models of increasing complexity were compared, ranging from a naive baseline to gradient boosting on decision trees. Interpretation was performed using SHAP, which quantifies each feature's contribution to the forecast. Statistical significance of model differences was verified using the Diebold–Mariano test. Additional experiments on cold start and feature ablation were conducted to assess the minimum required training data and optimal number of features.

The feature group ranking proved stable regardless of climate: load lags dominate in both cases, while weather forecasts play a comparatively secondary role. At the same time, forecast accuracy differs substantially: heating-dominated buildings are predicted much more accurately than cooling-dominated ones. Unexpectedly, a simple linear model outperformed gradient boosting for cooling loads, an outcome attributed to the more complex model overfitting the stochastic component of cooling demand. Practical

recommendations are provided: three to six months of data suffice for heating-dominated buildings, and a moderate reduction in the feature set based on importance rankings preserves most of the model's accuracy. The results are directly applicable to the Ukrainian context, where the climate is similar to Norway's.

Key words: building energy forecasting, machine learning, energy efficiency, climate analysis, model interpretation.

Вступ

Постановка проблеми. Короткостроковий прогноз енергоспоживання (від 1 до 24 годин наперед) потрібен для планування генерації, управління акумуляторними системами та інтеграції відновлюваних джерел [1]. Коли оператор розгортає систему прогнозування на новому об'єкті, він неминуче стикається з практичними питаннями: які саме ознаки включити до моделі, скільки історичних даних зібрати перед запуском і чи можна використати напрацювання, отримані на будівлях в іншій кліматичній зоні.

Більшість існуючих робіт оцінює моделі лише на одному датасеті, що не дає змоги судити про стабільність отриманих висновків під час переходу до іншого кліматичного контексту. Зокрема, відкритим залишається питання: чи зберігається рейтинг важливості ознак під час переходу від будівель із переважанням опалення до будівель із переважанням охолодження?

Для України питання ефективного прогнозування енергоспоживання має безпосередню практичну значущість. Руйнування приблизно двох третин довоєнної генеруючої потужності [2] робить ефективне управління кожною кіловат-годиною критично важливим. Енергетична стратегія України до 2050 року [12] визначає індикативну ціль - 27% енергії з відновлюваних джерел у валовому кінцевому споживанні до 2030 року та передбачає розвиток розподіленої генерації, що потребуватиме масового впровадження прогнозування на рівні окремих будівель. Українські міста переважно належать до континентального клімату Dfb за класифікацією Кеппена – того ж типу, що й Драммен (Норвегія), дані якого використано в цьому дослідженні.

Аналіз останніх досліджень і публікацій. Серед моделей машинного навчання для табличних енергетичних даних градієнтний бустинг на деревах рішень, зокрема LightGBM [3], показує найкращі результати у порівняльних дослідженнях. Змагання ASHRAE Great Energy Predictor III, у якому взяли участь 4370 команд із даними 2380 лічильників, було виграно виключно ансамблями LightGBM, XGBoost і CatBoost [5]. Нещодавня робота Shiblee та Koukaras [6] на грецьких даних електророзподілу підтвердила, що LightGBM перевершує нейромережеві архітектури (CNN, LSTM, GRU) за всіма метриками точності.

Для інтерпретації прогнозних моделей в енергетиці широко застосовується метод SHAP [4], який дозволяє кількісно оцінити внесок кожної ознаки в конкретний прогноз. Втім, переважна більшість робіт аналізує важливість ознак лише на одному наборі даних, тому переносимість отриманих рейтингів між кліматичними зонами досі не досліджена.

Окрему увагу привертає задача холодного старту – прогнозування за мінімуму накопичених даних. У рамках CityLearn Challenge 2023 [9] учасникам надавали лише 1 місяць навчальних даних. Langtry та ін. [10] встановили, що три місяці даних достатньо для досягнення похибки, що лише на 10% більша за модель із повною історією. Проте жодна з відомих нам робіт не порівнювала криві навчання для будівель із різними типами домінуючого навантаження.

Щодо метрик оцінювання, слід зазначити, що популярна MAPE непридатна для будівельних даних через нульові або близькі до нуля значення нічного споживання. Стандарт ASHRAE Guideline 14 [13] рекомендує CVRMSE < 30% для годинних даних. Для статистичного порівняння прогнозів використовується тест Дібольда–Маріано [11].

Наукова новизна. На відміну від існуючих робіт, які аналізують важливість ознак на одному наборі даних в одній кліматичній зоні, у цьому дослідженні вперше виконано крос-кліматичне порівняння структури важливості ознак із використанням єдиного обчислювального конвеєра. Це дозволяє відповісти на практичне питання: чи можна перенести напрацювання з одного кліматичного контексту в інший. Крім того, вперше порівняно криві навчання для будівель із протилежними типами домінуючого навантаження, що дає обґрунтовані рекомендації щодо мінімального обсягу даних для нових об'єктів.

Мета статті. Метою цього дослідження:

1. Визначити, чи є рейтинг груп ознак стабільним при зміні кліматичного контексту (переважання опалення проти переважання охолодження),
2. Кількісно оцінити різницю у прогнозованості енергоспоживання будівель різних кліматичних зон,
3. Сформулювати практичні рекомендації щодо мінімально необхідного обсягу даних і кількості ознак для розгортання системи прогнозування.

Дослідження

Датасети. Використано два відкриті набори даних із протилежними кліматичними характеристиками (табл. 1).

Таблиця 1
Характеристики наборів даних

Параметр	Drammen	CityLearn
Розташування	Норвегія	Каліфорнія, США
Клімат (Кеппен)	Dfb (континентальний)	Csb (середземноморський)
Домінуючий тип	Опалення	Охолодження
Кількість будівель	45 (публічні)	15 (житлові)
Категорії	Kdg, Sch, Nsh, Off	Res
Загальний період	2018–2022	Лип 2021 – Чер 2022
Тренувальний період	2018–2020 (3 роки)	Лип 2021 – Бер 2022 (8 міс)
Тестовий період	2021 (1 рік)	Квіт – Чер 2022 (3 міс)
Джерело	COFACTOR, Zenodo	CityLearn Challenge 2022

Набори даних обрано за принципом максимального кліматичного контрасту за умови збереження порівнянності структури: обидва містять погодинні вимірювання температури, сонячної радіації, швидкості вітру та електроспоживання. COFACTOR Drammen [7] охоплює 45 норвезьких публічних будівель (дитячі садки, школи, будинки для людей похилого віку, офіси). CityLearn [8] надає дані про 15 житлових будівель у місті Фонтані, штат Каліфорнія, США. Обидва набори приведені до єдиного формату для забезпечення коректності порівняння.

Конструювання ознак. Для забезпечення коректності порівняння обидва набори даних оброблено ідентичним обчислювальним конвеєром, який генерує уніфікований набір із 291 ознаки. Ознаки організовано в 8 груп, наведених у табл. 2.

Таблиця 2
Групи ознак (291 загалом)

Група	Кількість	Опис
Лаги навантаження	168	Споживання за попередні 168 годин (1 тиждень)
Метеопрогноз	96	Прогноз температури, сонячної радіації, вітру на 24 год
Циклічні	8	Синус/косинус для години, дня тижня, тижня року, місяця
Календарні	5	Година, день тижня, місяць, вихідний, свято
Метадані будівель	4	Ідентифікатор, площа, рік побудови, тип опалення
Ковзні статистики	2	Середнє та стандартне відхилення за останню добу
Поточна погода	4	Температура, сонячна радіація, швидкість і напрям вітру
Похідні	4	Зміна температури, зміна радіації, вітровий холод, градусо-доба

Для кожної будівлі та кожної години створюється вектор із 291 ознаки. Цільова змінна – електроспоживання протягом наступних 24 годин. Таким чином, задача формулюється як багатовихідна регресія: кожна модель одночасно прогнозує 24 горизонти.

Моделі. Порівнюються три моделі, що утворюють ієрархію зростаючої складності:

1. Persistence (наївна базова модель): прогноз дорівнює значенню електроспоживання рівно 24 години тому.

2. Ridge Regression (лінійна базова модель): лінійна регресія з L2-регуляризациєю після нормалізації вхідних даних. Для кожного горизонту прогнозування навчається окрема модель.

3. LightGBM: градієнтний бустинг на деревах рішень – 200 дерев із регуляризациєю. Аналогічно до Ridge, навчаються 24 окремі моделі.

Метрики та статистичні тести. Для оцінки якості прогнозів обрано метрики, рекомендовані для енергетичних даних [1]. Основною метрикою точності слугує середня абсолютна похибка (MAE), яка вимірює відхилення прогнозу від фактичного значення у тих самих одиницях, що й цільова змінна:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Оскільки MAE залежить від масштабу даних і не дає змоги порівнювати набори із різним рівнем споживання, додатково обчислено коефіцієнт варіації середньоквадратичної похибки (CVRMSE). Ця метрика нормує похибку на середнє значення цільової змінної і рекомендована стандартом ASHRAE Guideline 14 [13] для оцінки моделей енергетики:

$$CVRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{\bar{y}} \quad (2)$$

Нарешті, для оцінки практичної цінності моделі порівняно з найпростішим прогнозом використано Skill Score, який показує відносне покращення точності щодо базової моделі Persistence:

$$SS = 1 - \frac{RMSE(model)}{RMSE(persistence)} \quad (3)$$

Значення $SS = 0$ означає, що модель не краща за повторення вчорашнього значення, а $SS = 1$ відповідає ідеальному прогнозу. Для перевірки статистичної значущості відмінностей між прогнозами застосовано тест Дібольда–Маріано [11] з HAC-оцінкою дисперсії за Newey–West, що враховує автокореляцію похибок під час багатокрокового прогнозування. Метрика MAPE не використовується, оскільки вона дає неадекватно завищені значення за близького до нуля нічного споживання енергії будівель.

Інтерпретація через SHAP. Для кожного набору даних обчислено внесок кожної ознаки у прогноз на чотирьох горизонтах (1, 6, 12 та 24 години наперед) із подальшим усередненням. Ознаки згруповано за типом для порівняння відносної важливості груп у різних кліматах.

Додаткові експерименти. Крім основного порівняння, було проведено два додаткові експерименти. По-перше, дослідження холодного старту: модель послідовно навчалася на зростаючих обсягах даних – від 1 до 36 місяців для Drammen та від 1 до 8 місяців для CityLearn – для побудови кривих навчання. По-друге, абляція ознак: набір ознак поступово скорочувався з 291 до 100, 50, 20 і 10 (за SHAP-рейтингом) для оцінки деградації точності під час спрощення моделі.

Порівняння моделей. Усі три моделі оцінено на тестових даних обох наборів. Зведені результати наведено в табл. 3.

Таблиця 3
Порівняння моделей на двох наборах даних

Модель	MAE (Dr)	CVRMSE (Dr)	SS (Dr)	MAE (CL)	CVRMSE (CL)	SS (CL)
Persistence	16,66	68,8%	–	1,019	112,8%	–
Ridge	6,57	26,9%	0,609	0,586	66,3%	0,412
LightGBM	5,28	24,9%	0,639	0,594	67,0%	0,406

Вже на рівні основних метрик видно два ключові спостереження. По-перше, усі моделі машинного навчання суттєво перевершують наївну базову модель, що підтверджує наявність прогнозованої структури в даних. По-друге, CVRMSE для Drammen (25%) значно нижчий, ніж для CityLearn (67%), що свідчить про принципово різну складність задачі прогнозування в обох кліматах.

Звертає на себе увагу і несподіваний результат: для CityLearn проста лінійна модель Ridge виявилася точнішою за LightGBM. Щоб переконатися, що ці відмінності є статистично значущими, а не випадковими, застосовано тест Дібольда–Маріано (Табл. 4).

Таблиця 4
Тести Дібольда–Маріано (додатний DM = перша модель краща)

Порівняння	DM (Dr)	p (Dr)	DM (CL)	p (CL)
LightGBM vs Ridge	17,17	<0,001	–12,58	<0,001
Ridge vs Persistence	174,87	<0,001	125,73	<0,001
LightGBM vs Persistence	177,15	<0,001	125,49	<0,001

Тест підтверджує значущість усіх порівнянь. Для Drammen LightGBM значущо перевершує Ridge, покращившись на 20% за MAE, тоді як для CityLearn ситуація протилежна – Ridge значущо кращий, хоча абсолютна різниця в похибці становить менше ніж 2%.

Причини такої різниці в кліматах можна пояснити характером навантажень. Опалювальне навантаження значною мірою визначається температурним режимом та графіком роботи будівлі, що робить його відносно передбачуваним і дає перевагу складнішим моделям, здатним вловити нелінійні залежності. Навантаження на охолодження, натомість, більше залежить від індивідуальної поведінки мешканців – відкривання вікон, використання жалюзі, приготування їжі – і тому містить значний стохастичний компонент. Градієнтний бустинг, маючи надлишкову гнучкість, починає моделювати випадковий шум замість корисного сигналу, і лінійна модель виявляється стійкішою.

SHAP-аналіз важливості ознак. Для розуміння того, які саме ознаки визначають прогноз, було обчислено SHAP-значення для кожної ознаки на обох наборах даних. Візуальне порівняння відносної важливості груп ознак між кліматами наведено на рис. 1.

Уже на рівні візуального порівняння помітно, що розподіл важливості між групами ознак для двох кліматів є надзвичайно схожим. Лаги навантаження домінують з великим відривом, тоді як решта груп формує лише «хвіст» розподілу. Для кількісного порівняння точні значення SHAP-важливості кожної групи наведено в табл. 5.

Числові дані підтверджують візуальне враження: лаги навантаження забезпечують близько 79% сумарної важливості в обох випадках, а максимальна різниця між кліматами за будь-якою групою становить лише 2,3 процентного пункту (для ковзних статистик), що є несуттєвим.




Рис. 1. Порівняння відносної важливості груп ознак між кліматами

Таблиця 5
SHAP-важливість груп ознак (%)

Група ознак	Drammen	CityLearn	Δ
Лаги навантаження	79,0%	78,3%	-0,7%
Метеопрогноз	8,2%	7,1%	-1,1%
Циклічні	6,3%	7,6%	+1,3%
Календарні	2,9%	1,8%	-1,1%
Ковзні статистики	0,9%	3,2%	+2,3%
Метадані будівель	1,3%	1,5%	+0,1%
Похідні погодні	1,0%	0,3%	-0,7%
Поточна погода	0,4%	0,3%	-0,2%

Цей результат можна було б вважати очевидним, якби не поширене переконання, що для будівель у жарких кліматах метеодані (насамперед сонячна радіація) мають підвищену вагу. Наші дані цього не підтверджують: попри те, що метеопрогнози представлені 96 ознаками, їхній сукупний внесок становить лише 7–8%. В обох випадках модель покладається насамперед на власну нещодавню історію споживання.

Криві навчання (холодний старт). Одне з ключових практичних питань – скільки даних потрібно зібрати, перш ніж модель почне давати прийнятні прогнози. Для відповіді на це питання навчено серію моделей із поступово зростаючим обсягом даних для тренування. Отримані криві навчання наведено на рис. 2.

Для Drammen Skill Score зростає від 0,505 за 1 місяць навчальних даних до 0,645 за 12 місяців, після чого виходить на плато – додаткові 2 роки даних (до 36 місяців) не дають помітного покращення. Таким чином, точка насичення для будівель з опаленням припадає на 6–12 місяців. Крива CityLearn значно пологіша: SS зростає з 0,376 лише до 0,406 за 8 місяців, що відображає принципово меншу передбачуваність охолоджувальних навантажень.

З практичної точки зору це означає, що для будівель у кліматі Dfb (включаючи більшість українських міст) достатньо 3–6 місяців даних, щоб досягти 90% максимальної точності моделі.

Чутливість до скорочення набору ознак (абляція ознак). Інше практичне питання – чи справді потрібні всі 291 ознака, чи можна обмежитися меншим набором без суттєвої втрати точності. Для перевірки цього послідовно видаляли найменш важливі за SHAP ознаки, а модель перенавчали на залишку (Рис. 3, табл. 6).

На графіку чітко видно, що криві деградації для двох кліматів мають принципово різну крутизну. Для Drammen якість прогнозу стрімко падає при скороченні нижче 50 ознак, тоді як для CityLearn крива значно пологіша. Точні числові значення наведено в табл. 6.




Рис. 2. Криві навчання: Skill Score залежно від обсягу тренувальних даних




Рис. 3. Деградація MAE при скороченні набору ознак

Таблиця 6
Абляція ознак: деградація MAE від повної моделі (%)

Кількість ознак	SS (Dr)	Δ MAE (Dr)	SS (CL)	Δ MAE (CL)
291 (повна)	0,637	0%	0,406	0%
100	0,605	+7,3%	0,392	+2,6%
50	0,593	+12,9%	0,368	+7,6%
20	0,534	+36,3%	0,332	+13,2%
10	0,488	+53,0%	0,313	+18,2%

При зменшенні до 10 ознак точність для Drammen падає на 53%, тоді як для CityLearn – лише на 18%. Це узгоджується з попереднім спостереженням: опалювальне навантаження має складнішу структуру залежностей і справді використовує різноманіття лагів, метеопрогнозів і календарних ефектів. Охолоджувальне навантаження, навпаки, визначається переважно кількома найближчими лагами.

Для практичного розгортання це означає, що модель для будівель із переважанням охолодження можна значно спростити: 50 ознак (замість 291) дають деградацію MAE менше ніж на 8%, що може бути прийнятним компромісом між точністю та складністю системи.

Висновки

У роботі виконано систематичне порівняння структури важливості ознак для прогнозування енергоспоживання будівель у двох протилежних кліматичних зонах із використанням єдиного обчислювального конвеєра.

Головний результат полягає в тому, що рейтинг груп ознак виявився стабільним для обох досліджених кліматів: лаги навантаження домінують із часткою близько 79%, метеопрогнози забезпечують близько 8%, циклічні ознаки – близько 7%. Ця стабільність зберігається як для клімату з переважанням опалення (Dfb), так і для клімату з переважанням охолодження (Csb), що дає підстави припускати можливість перенесення уніфікованого конвеєра між кліматичними зонами без зміни структури набору ознак. Для остаточного підтвердження, втім, потрібна валідація на більшій кількості кліматів.

Водночас точність прогнозу суттєво різниться залежно від клімату: CVMSE становить 25% для будівель із переважанням опалення та 67% – для будівель із переважанням охолодження. Ця різниця може частково пояснюватися не лише кліматом, а й типом будівель та обсягом навчальних даних. Цікаво, що складність моделі не завжди є перевагою: LightGBM значущо перевершує лінійну модель Ridge для опалення, проте для охолодження, навпаки, Ridge виявляється точнішим. Це свідчить про те, що вибір моделі має відповідати характеру залежностей у конкретних даних.

З практичної точки зору дослідження пропонує кілька конкретних рекомендацій щодо розгортання систем прогнозування. Мінімальний обсяг навчальних даних становить 3–6 місяців для будівель із переважанням опалення та щонайменше 4 місяці для охолодження. Набір із 50–100 ознак, відібраних за SHAP-рейтингом, забезпечує від 90 до 97% точності повної моделі, що дає змогу значно спростити систему. Метеопрогнози, попри інтуїтивну очікувану важливість, забезпечують лише близько 8% внеску, і система здатна працювати прийнятно навіть без них.

Для українського контексту (клімат Dfb, аналогічний до Drammen) результати є безпосередньо застосовними: рекомендується використовувати обчислювальний конвеєр із фокусом на лагових ознаках навантаження, циклічних та календарних ознаках, із LightGBM як основною моделлю.

Обмеження дослідження. По-перше, висновок про стабільність рейтингу ознак базується на двох наборах даних із двома кліматичними типами, що є достатнім для первинної перевірки гіпотези, але недостатнім для остаточної генералізації. По-друге, набори даних відрізняються не лише кліматом, а й типом будівель (публічних проти житлових) та обсягом навчальних даних (трьох років проти восьми місяців), що створює змішувальні змінні. По-третє, обчислювальний конвеєр для конструювання ознак частково перетинається з нашою попередньою роботою [1], хоча дослідницьке питання та набори даних принципово різні.

Напрями подальших досліджень: валідація на додаткових кліматичних зонах (Cfa, BWh, Dfa) та типах будівель, порівняння з фундаментальними моделями часових рядів (TimesFM, Chronos) у режимі нульового навчання, дослідження впливу точності прогнозу на якість оптимізаційних рішень. Код дослідження доступний за запитом у авторів.

Література

1. Войтех Д. В., Тимошенко А. Г. Використання машинного навчання та мережевих наборів даних для моделювання енергосистем. Інфокомунікаційні та комп'ютерні технології. 2024. № 1(07). С. 35–45. DOI: 10.36994/2788-5518-2024-01-07-05.
2. World Bank. Ukraine – Fifth Rapid Damage and Needs Assessment (RDNA5): February 2022 – December 2025. Washington, DC, 2025. URL: <https://documents.worldbank.org/en/publication/documents-reports/documentdetail/099022026094036395>
3. Ke G. et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems*. 2017. Vol. 30.
4. Lundberg S. M., Lee S.-I. A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*. 2017. Vol. 30.
5. Miller C. et al. The ASHRAE Great Energy Predictor III Competition: Overview and Results. *Science and Technology for the Built Environment*. 2020. Vol. 26(10). P. 1427–1447. DOI: 10.1080/23744731.2020.1795514.
6. Shiblee M. F. H., Koukaras P. Short-Term Load Forecasting in the Greek Power Distribution System: A Comparative Study of Gradient Boosting and Deep Learning Models. *Energies*. 2025. Vol. 18(19). Article 5060. DOI: 10.3390/en18195060.
7. Lien S. K., Walnum H. T., Sørensen A. L. COFACTOR Drammen dataset – 4 years of hourly energy use data from 45 public buildings in Drammen, Norway. *Scientific Data*. 2025. Vol. 12(1). Article 393. DOI: 10.1038/s41597-025-04708-3
8. Nweye K. et al. CityLearn v2: Energy-flexible, resilient, occupant-centric, and carbon-aware management of grid-interactive communities. *Journal of Building Performance Simulation*. 2024. Vol. 18(1). DOI: 10.1080/19401493.2024.2418813.
9. Nweye K. et al. The CityLearn Challenge 2023. *NeurIPS 2023 Competition Track*.

10. Langtry M. et al. Impact of data for forecasting on performance of model predictive control in buildings with smart energy storage. *Energy and Buildings*. 2024. Vol. 320. Article 114605. DOI: 10.1016/j.enbuild.2024.114605.
11. Diebold F. X., Mariano R. S. Comparing predictive accuracy. *Journal of Business & Economic Statistics*. 1995. Vol. 13(3). P. 253–263. DOI: 10.1080/07350015.1995.10524599.
12. Кабінет Міністрів України. Про схвалення Енергетичної стратегії України на період до 2050 року: розпорядження від 21 квітня 2023 р. № 373-р. URL: <https://zakon.rada.gov.ua/laws/show/373-2023-p>
13. ASHRAE. Guideline 14-2014: Measurement of Energy, Demand, and Water Savings. Atlanta, GA: ASHRAE, 2014. URL: <https://www.ashrae.org/technical-resources/standards-and-guidelines>

References

1. Voitek, D. V., Tymoshenko, A. H. (2024). Vykorystannia mashynnoho navchannia ta merezhevykh naboriv danykh dlia modeliuвання enerhosystem [Using machine learning and network datasets for power system modeling]. *Infokomunikatsiini ta komp'uterni tekhnologii* [Infocommunication and Computer Technologies], 1(07), 35–45. DOI: 10.36994/2788-5518-2024-01-07-05 [in Ukrainian].
2. World Bank (2025). Ukraine – Fifth Rapid Damage and Needs Assessment (RDNA5): February 2022 – December 2025. Washington, DC. <https://documents.worldbank.org/en/publication/documents-reports/documentdetail/099022026094036395>
3. Ke, G. et al. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. *Advances in Neural Information Processing Systems*, 30.
4. Lundberg, S. M., Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, 30.
5. Miller, C. et al. (2020). The ASHRAE Great Energy Predictor III Competition: Overview and Results. *Science and Technology for the Built Environment*, 26(10), 1427–1447. DOI: 10.1080/23744731.2020.1795514.
6. Shiblee, M. F. H., Koukaras, P. (2025). Short-Term Load Forecasting in the Greek Power Distribution System: A Comparative Study of Gradient Boosting and Deep Learning Models. *Energies*, 18(19), 5060. DOI: 10.3390/en18195060.
7. Lien, S. K., Walnum, H. T., Sørensen, A. L. (2025). COFACTOR Drammen dataset – 4 years of hourly energy use data from 45 public buildings in Drammen, Norway. *Scientific Data*, 12(1), 393. DOI: 10.1038/s41597-025-04708-3
8. Nweye, K. et al. (2024). CityLearn v2: Energy-flexible, resilient, occupant-centric, and carbon-aware management of grid-interactive communities. *Journal of Building Performance Simulation*, 18(1). DOI: 10.1080/19401493.2024.2418813.
9. Nweye, K. et al. (2023). The CityLearn Challenge 2023. *NeurIPS 2023 Competition Track*.
10. Langtry, M. et al. (2024). Impact of data for forecasting on performance of model predictive control in buildings with smart energy storage. *Energy and Buildings*, 320, 114605. DOI: 10.1016/j.enbuild.2024.114605.
11. Diebold, F. X., Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business & Economic Statistics*, 13(3), 253–263. DOI: 10.1080/07350015.1995.10524599.
12. Cabinet of Ministers of Ukraine (2023). Pro skhvalennia Enerhetychnoi stratehii Ukrainy na period do 2050 roku [On approval of the Energy Strategy of Ukraine for the period until 2050]: Order No. 373-r, April 21, 2023. <https://zakon.rada.gov.ua/laws/show/373-2023-r> [in Ukrainian].
13. ASHRAE (2014). Guideline 14-2014: Measurement of Energy, Demand, and Water Savings. Atlanta, GA: ASHRAE. <https://www.ashrae.org/technical-resources/standards-and-guidelines>

Дата першого надходження статті до видання: 23.04.2026
Дата прийняття статті до друку після рецензування: 29.07.2026
Дата публікації (оприлюднення) статті: 05.10.2026