

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ПОЛІСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет інженерії та енергетики

Кафедра електрифікації, автоматизації виробництва та інженерної екології

Кваліфікаційна робота
на правах рукопису

Левандовська Вікторія Василівна

УДК 621.359.4

КВАЛІФІКАЦІЙНА РОБОТА

Сучасні тенденції виявлення аномалій в енергоспоживанні будівель на
основі штучного інтелекту
(тема роботи)

141 «Електроенергетика, електротехніка та електромеханіка»

(шифр і назва спеціальності)

Подається на здобуття освітнього ступеня бакалавр

Кваліфікаційна робота містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело

Левандовська В.В.

(підпис, ініціали та прізвище здобувача вищої освіти)

Керівник роботи

Савченко Л.Г.

(прізвище, ім'я, по батькові)

к.і.н., доцент кафедри електрифікації,
автоматизації виробництва та інженерної екології
(науковий ступінь, вчене звання)

Житомир – 2026

АНОТАЦІЯ

Левандовська В.В. Сучасні тенденції виявлення аномалій в енергоспоживанні будівель на основі штучного інтелекту. Кваліфікаційна робота на здобуття освітнього ступеня бакалавр за спеціальністю 141 – Електроенергетика, електротехніка та електромеханіка – Поліський національний університет, Житомир, 2026.

Робота присвячена огляду інноваційних підходів до моніторингу енергоефективності будівель через виявлення аномалій за допомогою штучного інтелекту. Досліджено перехід від традиційних статистичних методів до просунутих алгоритмів Deep Learning. Висвітлено роль інтелектуальних систем у завчасному виявленні несправностей обладнання та оптимізації енерговитрат. Наведено порівняльний аналіз популярних методів інтелектуального аналізу даних.

Ключові слова: ШІ, енергомоніторинг, аномалії, нейронні мережі, Smart Building.

ABSTRACT

Levandovska V.V. Modern trends in anomaly detection in building energy consumption based on artificial intelligence. Qualification work for obtaining a bachelor's degree in specialty 141 – Electrical Power Engineering, Electrical Engineering and Electromechanics – Polissia National University, Zhytomyr, 2026. The work is devoted to an overview of innovative approaches to monitoring building energy efficiency through the detection of anomalies using artificial intelligence. The transition from traditional statistical methods to advanced Deep Learning algorithms is investigated. The role of intelligent systems in the early detection of equipment malfunctions and optimization of energy consumption is highlighted. A comparative analysis of popular data mining methods is presented.

Keywords: AI, energy monitoring, anomalies, neural networks, Smart Building.

ЗМІСТ

ВСТУП	4
РОЗДІЛ 1 НЕОБХІДНІСТЬ ВПРОВАДЖЕННЯ СИСТЕМ МОНІТОРИНГУ АНОМАЛІЙ В ЕНЕРГОСПОЖИВАННІ БУДІВЕЛЬ У СУЧАСНОМУ СВІТІ	6
Висновок до першого розділу	10
РОЗДІЛ 2 ОГЛЯД МЕТОДІВ ВИЯВЛЕННЯ АНОМАЛІЙ	12
2.1 Методи виявлення аномалій в енергоспоживанні будівель на основі характеру реалізованих алгоритмів штучного інтелекту..	12
2.1.1 Неконтрольоване виявлення (U)	13
2.1.2 . Контрольоване виявлення (S)	17
Висновки до другого розділу	22
РОЗДІЛ 3 ОЦІНКА ЕФЕКТИВНОСТІ АЛГОРИТМІВ ШІ У ЗАДАЧАХ ПОШУКУ АНОМАЛІЙ: МЕТОДИ ОЦІНЮВАННЯ	24
3.1 Виявлення аномалій за допомогою прогнозування на основі штучного інтелекту	24
3.2 Виявлення аномалій за допомогою штучного інтелекту та аналізу мікро моментів	25
3.3 Виявлення аномалій за допомогою одно класової класифікації	27
3.4 Проблеми та обмеження	28
Висновок до третього розділу	30
ЗАГАЛЬНІ ВИСНОВКИ	32
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	34

ВСТУП

Необхідність виявлення аномалій в енергоспоживанні будівель зумовлена як економічними, так і безпековими та екологічними чинниками. Будівлі становлять значну частку загального споживання енергії, а тому навіть незначні відхилення від нормальних режимів роботи інженерних систем можуть призводити до суттєвих перевитрат, погіршення комфорту та прискореного зношення обладнання.

Аномалії в енергоспоживанні часто є ранніми ознаками технічної несправності: некоректної роботи систем опалення, вентиляції й кондиціонування, витоків теплоносія, збоїв у автоматичці, неправильних налаштувань або помилок обліку. Своєчасне їх виявлення дає змогу перейти від реактивного ремонту до превентивного обслуговування, скоротити простої, уникнути аварійних ситуацій та знизити витрати на експлуатацію.

Окреме значення має управлінський аспект. Моніторинг і аналіз аномалій забезпечують прозорість споживання, підвищують якість енергетичного менеджменту та дозволяють обґрунтовано планувати модернізацію, інвестиції й заходи з енергоефективності. Виявлення нераціональних режимів також підтримує виконання нормативних вимог і корпоративних цілей зі скорочення викидів.

Таким чином, системне виявлення аномалій є необхідним інструментом для забезпечення надійної роботи інженерних систем, оптимізації витрат та досягнення цілей сталого розвитку в експлуатації будівель.

Актуальність теми. Необхідність виявлення аномалій в енергоспоживанні будівель зумовлена економічними, безпековими та екологічними чинниками. Оскільки будівлі формують значну частку загального енергоспоживання, навіть незначні відхилення в роботі інженерних систем можуть призводити до суттєвих перевитрат, погіршення комфорту та прискореного зношення обладнання. Аномалії часто є ранніми ознаками технічної несправності (збоїв системи опалення, вентиляції та кондиціонування повітря (HVAC), виток теплоносія, помилки автоматики,

некоректні налаштування або облік), тому їх своєчасне виявлення підтримує перехід від реактивного ремонту до превентивного обслуговування, зменшує простої й ризики аварій.

Основна мета. Обґрунтувати підхід до системного виявлення аномалій в енергоспоживанні будівель для підвищення надійності роботи інженерних систем, оптимізації експлуатаційних витрат і підтримки цілей енергоефективності та сталого розвитку.

Об'єкт дослідження. Процес енергоспоживання будівель у межах експлуатації інженерних систем (опалення, вентиляції, кондиціювання, теплопостачання/електропостачання) та пов'язаний з ним моніторинг енергетичних показників.

Предмет аналізу. Методи, критерії та показники ідентифікації аномалій у даних енергоспоживання будівель, а також типові причини відхилень (несправності, некоректні налаштування, перебої автоматики, витoki, помилки обліку) і їх вплив на витрати, комфорт, надійність та екологічні показники.

Перелік публікацій автора за темою дослідження :

1. Левандовська В. В.

НЕОБХІДНІСТЬ ВПРОВАДЖЕННЯ СИСТЕМ МОНІТОРИНГУ АНОМАЛІЙ В ЕНЕРГОСПОЖИВАННІ БУДІВЕЛЬ У СУЧАСНОМУ СВІТІ
Наукові читання – 2026: збірник тез доповідей науково-практичної конференції за підсумками I-го туру Всеукраїнського конкурсу студентських наукових робіт з галузей знань і спеціальностей. 20 квітня 2026 р. Житомир: Поліський національний університет, 2026. Ч.2. 119 с.

2. Тинщук Д. А., Левандовська В. В.

МОДЕЛЮВАННЯ ОБЛАДНАННЯ МІКРО МЕРЕЖІ
Наукові читання – 2026: збірник тез доповідей науково-практичної конференції за підсумками I-го туру Всеукраїнського конкурсу студентських наукових робіт з галузей знань і спеціальностей. 20 квітня 2026 р. Житомир: Поліський національний університет, 2026. Ч.2. 119 с.

РОЗДІЛ 1

НЕОБХІДНІСТЬ ВПРОВАДЖЕННЯ СИСТЕМ МОНІТОРИНГУ АНОМАЛІЙ В ЕНЕРГОСПОЖИВАННІ БУДІВЕЛЬ У СУЧАСНОМУ СВІТІ

Зміна клімату – це небезпечне явище, яке впливає на населення світу. Майже 80% світової енергії виробляється з викопного палива . Окрім пошуку джерел зеленої енергії, вкрай важливо зменшити загальний відсоток споживання енергії [1]. Важливим підходом до досягнення цієї мети є інформування кінцевих користувачів про їхні моделі споживання енергії. Відповідно, споживачі можуть покращити свою поведінку та змінити свої споживчі звички з метою зменшення втрат енергії та сприяння розвитку стійких та зелених енергетичних екосистем. Це цілком можливо, особливо якщо системи рекомендацій поєднуються з модулями виявлення аномалій . Таким чином, персоналізовані та контекстні рекомендації будуть генеруватися та передаватися кінцевому користувачеві, щоб допомогти йому прийняти більш стійку поведінку щодо використання енергії. У цьому напрямку уряди всього світу усвідомили важливість енергоефективності та важливу роль, яку кінцеві користувачі можуть відігравати у скороченні всіх витрат на енергію [2].

З іншого боку, будівельний сектор є основним споживачем енергії в усьому світі. Зокрема, будівлі відповідають за понад 40% загального обсягу енергії, що виробляється в усьому світі, що перетворюється на понад 30% усіх світових викидів CO₂. Таким чином, скорочення споживання енергії в будівлях може безумовно підтримати вкрай необхідне скорочення світового споживання енергії та пов'язані з цим екологічні інтереси. Тим не менш, скорочення споживання енергії в будівлях не є простим і є складним завданням, оскільки кожна будівля потребує електроенергії для роботи [3]. Незважаючи на зростання інтересу до розробки будівель з нульовим енергоспоживанням, відповідні ідеї лише зароджуються та перевіряються лише в обмежених регіонах розвинених країн . У цьому контексті потенційним варіантом, доступним наразі, є підвищення обізнаності про енергію та оптимізація роботи

приладів, що використовуються в будівлях, враховуючи, що останні ретельно побудовані для споживання кількості енергії, необхідної для їх очікуваних цілей, тобто запобігання втратам енергії. Згідно з нещодавніми дослідженнями, люди можуть проводити до 80–90% свого часу в приміщенні (і значною мірою за деяких непередбачених обставин, таких як пандемія COVID-19), що може суттєво вплинути на рівень споживання енергії, особливо якщо вони виявляють недбалість та неухважність [4] .

Ефективний зворотний зв'язок може допомогти у зменшенні споживання енергії в будівлях та зменшенні викидів CO₂ . Відповідно, надання оновленої інформації та персоналізованих рекомендацій кінцевим користувачам і керівникам будівель є початковим етапом до впровадження інноваційних підходів до оптимізації використання енергії. Крім того, для ефективного використання енергії необхідно фіксувати аномальну поведінку споживання [5]. Тому, шляхом впровадження систем моніторингу енергії та стратегій бенчмаркінгу, можна зменшити аномальну поведінку та вплив на навколишнє середовище.

Системи моніторингу енергії та стратегії бенчмаркінгу є ключовими інструментами підвищення енергоефективності в промисловості, комунальному господарстві та сфері послуг. Їхнє поєднання забезпечує не лише фіксацію фактичного споживання, а й обґрунтоване управління витратами, виявлення втрат та планування модернізацій на основі порівняльних показників.

Система моніторингу енергії передбачає збирання, передавання та аналіз даних щодо споживання електроенергії, тепла, газу чи води в режимі, наближеному до реального часу. Вона базується на приладах обліку, датчиках, програмних платформах і аналітичних модулях, що дозволяють виявляти аномалії, формувати профілі навантаження та контролювати виконання енергетичних регламентів. Практична цінність моніторингу полягає у прозорості: управлінські рішення спираються на вимірювані показники, а не на припущення.



Рисунок 1.1 Види бенчмаркінгу

Бенчмаркінг у сфері енергетики полягає в порівнянні енерговитрат із еталонними значеннями: внутрішніми (між підрозділами одного підприємства), зовнішніми (з аналогічними об'єктами галузі) або нормативними (відповідно до стандартів та найкращих практик) (див. рис.1.1). Застосування стратегій бенчмаркінгу дає змогу визначати реалістичні цілі, оцінювати ефективність заходів та встановлювати пріоритети інвестицій. Важливою умовою є коректна нормалізація даних — з урахуванням обсягів виробництва, площі, погодних факторів та режимів роботи.

Отже, слід розробити інтелектуальні методи виявлення аномалій споживання енергії для виявлення нових форм аномальної поведінки споживання. У будівлях аномальна поведінка електричного пристрою або кінцевого користувача може виникнути через несправну роботу пристрою, недбалість кінцевого користувача (наприклад, втрата холоду в кімнаті через відчинене вікно, коли кондиціонер увімкнений, або витік холодоагенту в холодильнику через відчинені дверцята холодильника), крадіжку, нетехнічні втрати тощо[5]. Виникнення аномальної поведінки може призвести до підвищеного споживання енергії, тривалішого часу роботи, ніж його звичайна

поведінка/час роботи, та/або може призвести до постійної несправності пристрою.

У різних дослідницьких роботах було продемонстровано, що використання штучного інтелекту (ШІ) для виявлення аномальної поведінки споживання енергії, спричиненої кінцевими користувачами, пошкодженнями приладів або іншими потенційними причинами. Спільнота ШІ протягом останнього десятиліття доклала всіх можливих зусиль для точного та швидкого виявлення аномального споживання енергії. Однак також дуже важливо виявити, коли прилад працює неправильно та які причини. Більше того, події споживання енергії, що відбуваються у вихідний день, можуть бути справжніми або складнішими для обробки порівняно з повторюваними подіями, і таким чином алгоритм виявлення аномалій може розглядати повторювану несправність як «нормальну». Це робить виявлення аномалій у споживанні енергії дуже відмінним від інших сценаріїв застосування, наприклад, виявлення вторгнень, виявлення аномалій у сфері охорони здоров'я тощо. Це пояснюється тим, що а) інші застосування різюче відрізняються, оскільки вони мають гострі, серйозні наслідки, якщо аномалію не виявити, тоді як аномалії в побутовій енергії можуть спричинити витрати на видобуток електроенергії та стрибки рахунків за електроенергію щомісяця, але навряд чи будуть небезпечними для життя; та б) виявлення аномального споживання має супроводжуватися запуском набору індивідуальних рекомендацій, які допоможуть кінцевим користувачам скоригувати свої звички споживання енергії, замінити несправні прилади, виявити кіберзлочинців на енергетичну інфраструктуру та продовжити правові процедури й вжити інших заходів, пов'язаних з недбалістю кінцевих користувачів (наприклад, закрити дверцята холодильника, закрити двері та вікна кімнат, поки працює кондиціонер тощо) [6]. Такі заходи можуть бути досить корисними по-різному, оскільки вони призводять до значної економії витрат на енергію та можуть додатково запобігти різним видам катастроф (наприклад, пожежі в будинку).

Ефективні системи енергозбереження, засновані на схемах виявлення аномалій, повинні вирішити різні проблеми, перш ніж досягти широкого впровадження. Серед викликів є те, як розробити масштабовані та недорогі рішення, зберігаючи при цьому децентралізацію та безпеку. Інші сучасні проблеми включають збереження конфіденційності, анонімність споживачів та впровадження систем на основі виявлення аномалій у режимі реального часу. В останні роки було докладено значних зусиль для впровадження інноваційних стратегій виявлення аномалій, велика кількість проектів та фреймворків перебуває в процесі розробки, які були описані в наукових журнальних статтях, патентах, звітах та промислових офіційних документах і створені переважно академічною спільнотою та промисловими партнерами. Крім того, різні методи виявлення аномалій на основі штучного інтелекту стали предметом нових рішень для енергозбереження. Однак, для дослідження викликів, проблем та майбутніх перспектив застосування машинного навчання для виявлення аномалій у споживанні енергії все ще потрібен системний та всебічний огляд, проведений на основі різних джерел.

Висновок до першого розділу

Зміна клімату та домінування викопного палива роблять скорочення енергоспоживання критично важливим, а будівлі як найбільші споживачі енергії (і значне джерело викидів CO₂) є ключовою сферою для таких дій. Реалістичний шлях до швидких результатів сьогодні — це підвищення енергетичної обізнаності користувачів, якісний зворотний зв'язок і оптимізація роботи приладів, доповнені інтелектуальним виявленням аномалій (несправності, недбалість, крадіжки, нетехнічні втрати тощо). Водночас саме енергетичні сценарії виявлення аномалій мають специфіку: повторювані «ненормальні» події можуть маскуватися під норму, а виявлення повинно супроводжуватися персоналізованими рекомендаціями та подальшими діями. Для широкого впровадження таких систем необхідно подолати виклики масштабованості, вартості, децентралізації, безпеки, конфіденційності та роботи в реальному часі. Отже, необхідно аргументувати

потребу в системному, всебічному огляді методів машинного навчання для виявлення аномалій енергоспоживання, щоб узагальнити напрацювання, порівняти підходи та окреслити майбутні перспективи.

РОЗДІЛ 2

ОГЛЯД МЕТОДІВ ВИЯВЛЕННЯ АНОМАЛІЙ

2.1. Методи виявлення аномалій в енергоспоживанні будівель на основі характеру реалізованих алгоритмів штучного інтелекту

У цьому розділі описано існуючі методи виявлення аномалій на основі характеру реалізованих алгоритмів штучного інтелекту, що використовуються для виявлення аномалій. Рис. 2.1 ілюструє запропоновану таксономію методів виявлення аномалій у споживанні енергії будівлями з урахуванням різних аспектів. Розглянемо деякі з них.




Рисунок 2.1 Таксономія схем виявлення аномалій у споживанні енергії на основі різних аспектів: алгоритми штучного інтелекту, сценарії застосування, рівні виявлення та обчислювальні платформи.

2.1.1 . Неконтрольоване виявлення (U)

Він спрямований на виявлення раніше невідомих рідкісних спостережень або закономірностей споживання без використання будь-яких апріорних знань про ці спостереження. Як правило, цей вид виявлення припускає, що кількість аномальних закономірностей у загальних даних споживання невелика, тобто менше 20%. Оскільки аномалії являють собою викиди, невідомі споживачеві на етапі навчання, виявлення аномального споживання зводиться до моделювання нормальної поведінки споживання у переважній більшості випадків, на додаток до визначення конкретних вимірювань у цьому просторі з метою класифікації спостережень споживання як аномальних або нормальних.

Кластеризація: це схема машинного навчання, яка використовується для розділення даних про споживання енергії на різні кластери, що допомагає класифікувати їх на нормальні або аномальні в немаркованих наборах даних (навіть з багатьма вимірами). Ця стратегія виявлення аномалій викликала великий інтерес у різних дослідницьких темах завдяки своїй простоті, таких як виявлення вторгнень у мережі інтернет речей (IoT), сенсорні мережі, виявлення підозрілої поведінки у відеоспостереженні, виявлення аномальних транзакцій у банківських системах та виявлення підозрілих облікових записів в онлайн-соціальних мережах. Крім того, кластеризація має можливість навчання та виявлення аномалій з часових рядів споживання без явних описів.

Прагнучи розрізнити фактичні аномалії та справжні зміни, спричинені сезонними коливаннями, автори в [7] пропонують двоетапний алгоритм кластеризації. На першому кроці періодично оцінюється оцінка аномалії, що стосується кожного користувача, лише з урахуванням його споживання енергії та його коливань у минулому, тоді як на другому кроці ця оцінка коригується з урахуванням даних про споживання енергії в околицях. У замість подій, що відносяться до аномалії, вводиться поняття «колективної аномалії» для зображення наборів елементів подій, які, залежно від їх закономірностей появи, можуть бути аномальними. Для досягнення цієї мети до потоків даних

інтелектуальних лічильників були застосовані підходи частого аналізу наборів елементів та категоріальної кластеризації з пороговим значенням силуєту кластеризації. У прийнято інтегровану масштабовану структуру, яка поєднує методи кластеризації та класифікації з можливостями паралельних обчислень, шляхом накладання моделі k-середніх для розділення аномальних та нормальних подій у високо когерентних кластерах. Далі, обрано часовий ряд для дослідження виявлення аномалій у часовій області, а потім класифікували аномалії на пов'язані з амплітудою та формою. Введено єдину структуру для виявлення обох типів аномалій, використовуючи нечіткий алгоритм кластеризації C-середніх для виявлення доступних нормальних структур у підпоследовностях, а також критерій реконструкції, реалізований для вимірювання несхожості кожної підпоследовності з різними центрами кластерів. Дані потужності обробляються за допомогою алгоритмів взаємного k-найближчих сусідів (MNN) та кластеризації k-середніх для зменшення кількості вибірок вимірювань, потім аналізуються моделі споживання для виявлення аномальної поведінки та зловмисних клієнтів. Нарешті, методи виявлення аномалій на основі ентропії представляють собою ще одну категорію кластеризації, в якій було докладено незначних зусиль для повного розуміння сили виявлення за допомогою аналізу на основі ентропії, такого як [8].

Одно класова класифікація: також відома як одно класове навчання (OCL), базується на розгляді початкових моделей споживання енергії як частин двох груп: позитивної (нормальної) та негативної (аномальної), а потім намагається розробити алгоритми класифікації, причому негативна група може бути відсутньою, погано дискредитованою або нечіткою. Відповідно, OCL є складною задачею класифікації, яку важче вирішити, ніж звичайні задачі класифікації, які намагаються розрізнити дані з двох або більше категорій, використовуючи дані про споживання енергії під час навчання, що стосуються всіх груп.

У літературі запропоновано різні схеми для виявлення аномальних слідів споживання, одним із перспективних підходів до ідентифікації відхилень у процесах споживання є використання мови об'єктних обмежень (Object Constraint Language, OCL). У [9] представлено одну класову машину опорних векторів (OCSVM) для ідентифікації найменшої гіперсфери, що охоплює всі спостереження потужності. Запропоновано одну класову нейронну мережу на основі ядра (OCNN) для виявлення аномального споживання потужності. Вона поєднує можливості глибоких нейронних мереж (DNN) отримувати прогресивні збагачені представлення сигналів потужності з OCL, створюючи щільну обвідну навколо нормальних моделей споживання потужності. У роботі [8] запропоновано два різні підходи до класових загорткових нейронних мереж (OCCNN). Вони поділяють одну й ту ж ідею використання гаусового шуму з нульовим центром у латентному просторі як псевдо негативний клас та навчання моделі на основі втрат перехресної ентропії для вивчення точного представлення разом з межею прийняття рішення для розглянутого класу. Також пропонується одна класовий випадковий ліс (OCRf) для виявлення аномального споживання, коли відсутні позначені дані, він базується на використанні фундаментальних принципів рандомізації ансамблю класифікаторів.

Зменшення розмірності: у різних програмах машинного навчання зменшення розмірності може бути використане як підхід до класифікації з низькими обчислювальними витратами, оскільки воно може видалити нерелевантні шаблони потужності та надмірність. Досліджуються різні методи класифікації даних потужності як нормальних або аномальних, такі як аналіз головних компонент (PCA), лінійний дискримінантний аналіз (LDA), квадратичний дискримінантний аналіз (QDA) та множинний дискримінантний аналіз (MDA).

Незважаючи на те, що PCA було запропоновано головним чином для зменшення розмірності вихідних даних, максимально зберігаючи зв'язки між даними, його також використовували як класифікатор. Наприклад, у задачі

виявлення аномалій, яка розглядається як задача класифікації двох класів, класифікатор PCA оцінює головні компоненти як нормальних, так і аномальних класів. Далі класифікатор розроблено з урахуванням проєкції енергетичних шаблонів у підпросторах, охоплених цими головними компонентами, як для нормального, так і для аномального класу. Крім того, PCA також може бути застосований для випадку виявлення аномалій у кількох класах, як це відбувається з підходом до виявлення аномалій на основі мікро моментів, описаним у [9]. Відповідно, клас нормального споживання енергії був розділений на три нові класи, тоді як клас аномального споживання енергії був розділений на два нові класи. Загалом, задача виявлення аномалій стала проблемою класифікації 5 різних класів. Загалом, PCA підходить для випадку, коли спостереження за енергією різних категорій розподілені в різних просторах і напрямках.

Для виявлення аномального споживання енергії використовується PCA на основі перетворення Кархунена-Лоева. Він спирається на оцінку головних компонентів кожної категорії споживання, а потім створює класифікатор шляхом проєктування шаблонів потужності на підмножини, розподілені цими головними компонентами, що відносяться до двох основних категорій (тобто нормального та аномального). LDA використовується для класифікації шаблонів споживання енергії шляхом розрізнення окремих підкатегорій та розробки моделі для автоматичного позначення шаблонів споживання енергії з посиленням на відповідні їм категорії. Це було досягнуто за допомогою використання дискримінанти ваг для розділення гіперплощини, згенерованих статистичним навчанням LDA. У роботі [10] QDA, що є варіантом LDA, використовується для забезпечення нелінійного розділення шаблонів споживання енергії, що стосуються як нормальних, так і аномальних ансамблів. Нарешті, MDA в основному використовується для побудови дискримінантних осей (функцій) з лінійних комбінацій початкових даних про споживання енергії. Кожна вісь розроблена таким чином, щоб максимізувати

різницю між нормальними та аномальними категоріями, вважаючи їх некорельованими[10].

2.1.2 . Контрольоване виявлення

Виявлення аномалій у споживанні енергії з учителем вимагає навчання класифікаторів машинного навчання (бінарних або багато класових) з використанням анотованих наборів даних, де позначено як нормальне, так і аномальне споживання енергії. Хоча виявлення аномалій з учителем може досягти високоточних результатів ідентифікації, як продемонстровано в академічних рамках, його впровадження в реальному світі все ще обмежене порівняно з методами без учителя через відсутність анотованих наборів даних про споживання енергії. На рис. 3 ілюструються основні кроки для реалізації підходу до виявлення аномалій з учителем.




Рисунок 2.2 Основні кроки, що використовуються для виконання контрольованого виявлення аномалій споживання енергії в будівлях.

Нейронні мережі: стосуються використання глибокого навчання або звичайних штучних нейронних мереж (ШНМ) для виявлення нормальних та аномальних моделей споживання. Наразі глибоке навчання на основі аномалій (DAD) використовується в різних дослідницьких темах, таких як виявлення

шахрайських транзакцій у сфері охорони здоров'я, виявлення аномалій у потоковому відео та виявлення шахрайства з кредитними картками. Однак, продуктивність рішень на основі DAD може бути неоптимальною в деяких випадках через властивість дисбалансу наборів даних про споживання енергії (тобто моделі споживання енергії не рівномірно розподілені між нормальними та аномальними категоріями).

Автоенкодер. (Автоенкодер — це спеціалізований тип штучної нейронної мережі прямого поширення, основною метою якої є навчання ефективному представленню вхідних даних у стислому вигляді без використання розмічених вибірок). В основі концепції автоенкодера лежить принцип некерованого навчання, де мережа намагається відтворити на виході дані, що максимально відповідають вхідним) та нейронні мережі з довгою короткочасною пам'яттю (LSTM) об'єднані для виявлення аномалій у незбалансованих та часово корельований набор даних про споживання енергії. Аналогічно, у роботі [11] автори виявляють аномалії в часових рядах показників споживання енергії за допомогою варіаційної- рекурентного автоенкодера . Далі, Юань та Цзя використовують стековий розріджений автоенкодер для вилучення високорівневих представлень з великомасштабних наборів даних про споживання енергії, отриманих за допомогою вимірювальної мережі на основі інтернету речей. Далі вони використовують SoftMax на етапі класифікації для фіксації аномалій споживання перед надсиланням сповіщень та оповіщень кінцевим користувачам за допомогою веб-додатків[13].

З іншого боку, згорткові нейронні мережі (ЗНМ) продемонстрували свою ефективність у різних дослідницьких застосуваннях, і вони мають вищу продуктивність порівняно з алгоритмами штучних нейронних мереж (ШНМ) для виявлення аномалій у даних часових рядів. У статті [14] автор обрав поєднання ЗНМ та випадкового лісу для відстеження аномалій споживання енергії через атаки крадіжки енергії, тим самим допомагаючи постачальникам

енергії вирішувати проблеми, пов'язані з нерегулярним використанням енергії та неефективним контролем електроенергії.

Рекурентна нейронна мережа (RNN) дуже компетентна в аналізі даних часових рядів і дозволяє демонструвати часову динамічну поведінку. Вона використовувалася для прогнозування аномалій, що виникають під час споживання енергії, та їх розрізнення від відхилень, що виникають через сезонність, погодні та святкові залежності. Наприклад, у роботі [12] розроблено систему виявлення аномалій на основі RNN, яка може видалити сезонність та тенденції з моделей споживання енергії, що призводить до кращого відображення реальних аномалій.

Проект, який виконується з використанням моделі DNN [15]. У цій структурі дані про споживання енергії різними приладами та моделі наповненості збираються за допомогою сублічильників та інтелектуальних датчиків (див рис.2.3).




Рисунок 2.3. Блок-схема схеми контрольованого виявлення аномалій на основі глибокої нейронної мережі (DNN), що використовується для виявлення двох різних аномалій, тобто надмірного споживання та споживання на вулиці.

Далі зібрані дані маркуються за допомогою парадигми мікро моментів, в якій сліди споживання поділяються на п'ять категорій споживання. Після цього

модель DNN розробляється та навчається з використанням маркованого набору даних, перш ніж тестувати її на нових записаних, немаркованих даних на етапі тестування[14].

З іншого боку, використання ШНМ для виявлення аномалій у споживанні енергії головним чином підтверджується її здатністю навчатися та узагальнювати дані про минуле споживання для виявлення нормальної та аномальної поведінки. Крім того, ШНМ може допомогти у вирішенні проблеми виявлення аномалій, коли записані дані мають шум з різних причин, наприклад, шум, що генерується під час передачі даних або від електроприладів, підключених до інтелектуальної мережі[17].

Більше того, аномалії споживання відстежуються за допомогою багат шарового перцептора (MLP) та методів класифікації. Аналогічно, з метою прогнозування шкідливої поведінки в незбалансованих даних, рішення на основі MLP ефективно тестується на двох різних наборах даних для здійснення потокового керування, яке зберігає конфіденційність кінцевих користувачів[16].

Регресія: стосується визначення зв'язку між двома або більше класами змінних потужності з метою створення ансамблю параметрів моделі для прогнозування генерації аномальних спостережень потужності. У цьому контексті генерацію аномальних моделей споживання енергії можна передбачити на основі інших зібраних аномальних слідів. У літературі було представлено різні моделі регресії для виявлення аномалій у споживанні енергії будівлями, включаючи лінійну регресію, регресію опорних векторів (SVR), авторегресивні моделі, дерева регресії та апроксимацію регресії. Автори в роботі [18] пропонують застосовувати підходи на основі лінійної регресії для визначення аномальних періодів для окремих приміщень та очищення їх від даних приміщення, щоб забезпечити точну оцінку моделей споживання енергії. У тому ж напрямку в [19] розроблено модель для пошуку аномальних моделей споживання енергії шляхом аналізу потоків часових даних інтелектуальних лічильників. Зокрема, для виконання прогнозування та

відображення нелінійності даних зберігається регресія опорних векторів з радіальною базисною функцією, яка відповідно оцінює невідповідність між фактичним та очікуваним споживанням енергії[20].

Через велику кількість збережених даних інтелектуальних лічильників, виявлення аномалій за допомогою такої інформації вивело на перший план проблему великих даних, особливо з огляду на дефіцит адекватних та ефективних систем виявлення аномалій у реальному часі, здатних обробляти такий величезний обсяг даних. Щоб виправити це та полегшити прийняття рішень, пов'язаних з енергетикою, дослідження зображують масштабовану архітектуру, що поєднує метод виявлення на основі авто регресивного прогнозування з новою лямбда-схемою для ітеративного оновлення моделі разом з виявленням аномалій у реальному часі. У роботі [21] розглядається структура розпізнавання аномалій у потокових великомасштабних даних, що є типовим сценарієм виникнення у розгорнутих датчиках. У цій сфері як статистичні (тобто ARIMA), так і CNN підходи були інтегровані залишковим чином, таким чином, що об'єднання, як було показано, компенсує слабкі сторони кожного з них та посилює їхні сильні сторони.

Ймовірнісні моделі: є одними з найважливіших інструментів машинного навчання, вони були запроваджені як ефективна ідіома для опису реальних проблем виявлення аномалій у споживанні енергії з використанням випадково згенерованих змінних, таких як побудова моделей, представлених ймовірнісними співвідношеннями. Профілі аномалій шаблонів часових рядів ідентифікуються за допомогою байєсівських моделей максимальної правдоподібності для чистих даних та зашумлених даних, тоді як байєсівські мережеві моделі реалізуються для виявлення аномалій на основі категоріальних та змішаних даних про споживання енергії. У роботі [22] представлено підхід статистичного прогнозування, заснований на узагальненій адитивній моделі, для своєчасного виявлення аномальної поведінки споживання енергії.

Традиційна класифікація: означає моделі, які спираються на визначення, до якої категорії споживання енергії належить нова вибірка споживання енергії, з посиланням на навчальний ансамбль слідів споживання, які мають позначки як нормального, так і аномального споживання. К-найближчі сусіди (KNN), метод опорних векторів (SVM), дерево рішень та логістична регресія – це добре відомі традиційні алгоритми класифікації, вони широко використовуються в сучасних енергетичних програмах або інших дослідницьких темах.

У дослідженні [23] запропоновано евристичні на основі KNN для виявлення аномального споживання енергії, тоді як у [24] автори досліджують ефективність KNN порівняно з іншими класифікаторами машинного навчання для виявлення аномальних спостережень за потужністю.

Висновок до другого розділу

Виявлення аномалій у енергоспоживанні «розумних» будівель є багатофакторною задачею, де результат визначається не лише вибором алгоритму, а й сценарієм застосування, рівнем моніторингу (прилад/зона/будівля), якістю даних і обмеженнями обчислювальної платформи.

Найбільш практичними в реальних умовах часто є неконтрольовані та напів контрольовані підходи, оскільки вони не вимагають повної розмітки: кластеризація (k-середніх, C-середніх, MNN) ефективно відокремлює типові та нетипові патерни, а гібридизація з аналізом околиць і часової динаміки дає змогу відрізнити справжні аномалії від сезонних або поведінкових коливань. Важливу роль відіграє одно класова класифікація (OCL) (OCSVM, OCN, OCCNN), яка формує межу «нормальної» роботи; використання глибоких мереж у цьому класі підсилює здатність автоматично виділяти складні ознаки й виявляти приховані збоїв чи втручання. Для масштабних систем моніторингу критичним є зменшення розмірності (PCA, LDA, QDA), що знижує обчислювальні витрати та може слугувати інструментом виявлення аномалій через проекцію даних у інформативні підпростори.

Контрольовані (supervised) методи забезпечують найвищу точність завдяки навчанню на розмічених даних і охоплюють глибинні моделі (AE, LSTM/RNN, CNN тощо), регресійні підходи (SVR, AR/ARIMA, дерева/ліси), ймовірнісні/байєсівський та традиційні класифікатори (KNN, SVM, логістична регресія). Проте їхнє широке впровадження стримується дефіцитом анотованих датасетів і дисбалансом класів, характерним для енергетичних часових рядів.

Отже, вибір методу III має базуватися на доступності історичних/розмічених даних, вимогах до точності, потребі в роботі в реальному часі та доступних ресурсах. З огляду на практичні обмеження, неконтрольовані підходи (кластеризація, OCL, зменшення розмірності) та їхні гібриди наразі є найбільш перспективним напрямком для створення адаптивних і масштабованих систем моніторингу енергоспоживання в сучасних будівлях.

РОЗДІЛ 3

ОЦІНКА ЕФЕКТИВНОСТІ АЛГОРИТМІВ ШІ У ЗАДАЧАХ ПОШУКУ АНОМАЛІЙ: МЕТОДИ ОЦІНЮВАННЯ.

Щоб пояснити, як аномалії споживання енергії розглядалися в літературі та як штучний інтелект може бути використаний для виявлення аномального використання, представимо три різні сценарії виявлення аномалій з використанням:

- прогнозування на основі штучного інтелекту;
- класифікації мікро моментів енергії та даних про наповненість за допомогою штучного інтелекту;
- одно класової класифікації даних про енергію.

Варто зазначити, що завдяки використанню штучного інтелекту стає можливим виявляти більш складні види аномалій, використовуючи інші типи даних, такі як моделі наповненості та умови навколишнього середовища [25].

3.1. Виявлення аномалій за допомогою прогнозування на основі штучного інтелекту.

У роботі [26] наведено набір даних про споживання енергії для перевірки алгоритмів виявлення аномалій. Інструменти штучного інтелекту для прогнозування майбутнього споживання енергії поєднуються з алгоритмом на основі правил для виявлення аномального споживання енергії. Цей метод базується на використанні моделі RNN для прогнозування споживання енергії для наступної позначки часу, а потім розраховується різниця між реальним та прогнозованим споживанням для вимірювання рівня «несподіванки». У зв'язку з цим, якщо виявлено значний розрив, це означає, що а) мала місце аномальна поведінка споживання енергії, або б) модель допустила помилку. Надалі дослідження продовжується з використанням алгоритму на основі правил та шляхом фільтрації аномалій, виявлених системою прогнозування, з посиленням на набір статистичних критеріїв. Алгоритм на основі правил допомагає визначити процентиль споживання енергії для кожної позначки часу

з урахуванням а) години, б) зовнішньої температури в) типу дня (робочий день проти святкового). На рис. 4 показано приклад аномалій, виявлених під час аналізу споживання енергії часових рядів[27].

3.2. Виявлення аномалій за допомогою штучного інтелекту та аналізу мікро моментів.




Рисунок 3.1 Приклад виявлення аномалій у часових рядах споживання енергії за допомогою прогнозування на основі штучного інтелекту, застосованого до набору даних виявлення аномалій

Згідно з фреймворком [28], аномальне споживання енергії виявляється шляхом аналізу слідів споживання енергії та моделей зайнятості за допомогою аналізу мікро моментів (див.рис.3.1) Після цього розгортається модель DNN для автоматичної класифікації кожного спостереження споживання як нормального або аномального.




Рисунок 3.2. Приклад виявлення аномалій на основі DNN та аналізу мікромоментів з урахуванням даних про енергію та моделей наповненості. Ці графіки візуалізації отримані з використанням набору даних DRED (для випадку телевізора): часові ряди кривих споживання енергії та (знизу) схема виявлення мікро моментів на основі глибокого навчання[29]

Зокрема, зразки споживання енергії згруповані у п'ять класів; три з них називаються «клас 0: належне використання», «клас 1: увімкнення пристрою» та «клас 2: вимкнення пристрою», що представляють нормальне використання; а два інші класи називаються «клас 3: надмірне споживання» та «клас 4: споживання на вулиці», що відносяться до аномального використання. На рис.3.2 показано приклад часових рядів енергетичних трас, зібраних у наборі даних DRED для випадку телевізора [30], та відповідні нормальні та аномальні енергетичні моделі, ідентифіковані за допомогою моделі DNN та

аналізу мікромоментів. Завдяки врахуванню даних про зайнятість на етапі виявлення аномалій, стало можливим виявити нову аномалію споживання, яка відповідає відсутності кінцевого користувача, коли телевізор увімкнений (цю аномалію також можна було враховувати для інших конкретних приладів, таких як кондиціонер, обігрівач, вентилятор тощо). Це було неможливо за допомогою традиційних методів виявлення аномалій, які базуються лише на аналізі енергетичних відбитків.

3.3. Виявлення аномалій за допомогою одно класової класифікації.




Рисунок 3.3 Приклад виявлення аномалій у споживанні енергії за часовими рядами за допомогою автоенкодерів, застосованих до набору даних DRED

Ще одне важливе рішення для виявлення аномалій базується на традиційній одно класовій класифікації, яка широко використовується в інших застосуваннях. На рис. 3.3 показано приклад виявлення аномалій споживання енергії, застосованого до набору даних DRED з використанням одно класового автоенкодера. Чітко видно, що ця схема поділяє спостереження за енергією на два основні класи на основі аналізу рівнів споживання енергії в новому просторі представлення, в якому потужність і час нормалізовані[31].

3.4 . Проблеми та обмеження.

Існує кілька поширених та специфічних для кожної галузі проблем і обмежень систем виявлення аномалій у споживанні енергії, які перешкоджають розробці ефективних рішень, роблять їх впровадження дорогим та обмежують їхнє широке поширення. Їх можна окреслити в наступних пунктах:

- Відсутність анотованих наборів даних: серед серйозних підводних каменів для розробки та перевірки схем виявлення аномалій є відсутність анотованих наборів даних, які надають мітки як для нормального, так і для аномального споживання. Більшість контрольованих алгоритмів перевіряються на невеликій кількості даних, які не можна вважати вичерпними наборами даних і недоступні для дослідницької спільноти в галузі енергетики. Зокрема, репозиторіїв, які позначають події аномального споживання та їх типи, майже не існують, а їх створення є складним і дорогим. Тому створення різних наборів даних для різних типів будівель, які відображають реальну поведінку споживання, ефективно допоможе дослідницькій спільноті в галузі енергетики в тестуванні та покращенні виявлення аномалій споживання в різних сценаріях застосування [32] .

- Незбалансований набір даних: стосується розподілу аномалій за класами даних, тобто аномальні дані зазвичай можуть бути меншістю серед загального набору даних. Дійсно, дані про аномалії насправді дуже рідкісні, утворюючи разом з основними нормальними даними надзвичайно незбалансований набір. Характеристика класової незбалансованості більшості наборів даних для виявлення аномалій призводить до неоптимальної продуктивності алгоритмів. Тому для вирішення цієї проблеми потрібні деякі методи попередньої обробки, серед яких а) використання процедур повторної вибірки для надмірної вибірки менших класів або недостатньої вибірки більшості класів , та б) генерація синтетичних даних про споживання енергії [33] . Більше того, в інших темах класи аномалій зазвичай представлені як другорядні класи, але в споживанні енергії це не завжди так, особливо якщо

спостерігається висока витрата енергії. У зв'язку з цим застосування методів виявлення аномалій без нагляду є менш ефективним[34].

– Визначення аномалій: традиційне визначення аномалії означає, що аномальне спостереження є винятком або відхиленням. Однак цього визначення може бути недостатньо для визначення аномалій у споживанні енергії, оскільки можуть існувати інші форми аномалій, наприклад, утримання приладу ввімкненим (наприклад, кондиціонера, вентилятора, телевізора тощо), коли кінцеві користувачі знаходяться на вулиці, утримання вікон і дверей відкритими, коли кондиціонер/система опалення ввімкнена, що призводить до високого споживання енергії тощо. Тому для ефективного виявлення аномалій споживання енергії необхідно аналізувати не лише дані про споживання енергії, але й інші джерела інформації, включаючи моделі наповненості, умови навколишнього середовища, вплив зовнішніх погодних умов та параметри роботи приладів[35].

– Розріджені мітки: з одного боку, отримання міток, що позначають, чи є екземпляр нормальним чи аномальним, у багатьох застосуваннях займає багато часу та є надзвичайно дорогим. Це особливо типово для даних часових рядів, де частота дискретизації може досягати 1000 Гц або час може охоплювати десятиліття, генеруючи величезну кількість точок даних. З іншого боку, аномальні дані часто не відтворюються та не є повністю завершеними в реальності[36].

– Виявленню аномалій на рівні приладів досі не приділяється належної уваги, хоча це важливіше, ніж виявлення аномалій на агрегованому рівні. Фактично, збій в електроніці приладу може не тільки збільшити споживання енергії, але й у деяких випадках інші види збоїв можуть спричинити появу нових видів несправних приладів, які можуть бути фатальними, наприклад, несправний пристрій може спричинити коротке замикання, що спричиняє пожежу.[37]

– Дрейф концепцій: це явище зазвичай виникає в даних часових рядів,

де загальне припущення про незалежність та однаковий розподіл для моделей машинного навчання часто порушується через різні латентні умови. Оскільки спостереження та співвідношення в даних про споживання енергії змінюються з часом, їх слід аналізувати майже в режимі реального часу, інакше системи, що використовуються для аналізу таких даних, швидко застарівають з часом. У машинному навчанні та інтелектуальному аналізі даних це явище називається дрейфом концепцій[38].

– Відсутність платформ для відтворення емпіричних результатів: однією з головних проблем виявлення аномалій у споживанні енергії є відсутність платформ для відтворення результатів існуючих рішень. Це може перешкоджати порівнянню продуктивності між існуючими алгоритмами та ускладнювати розуміння сучасного стану справ[39].

– Більшість фреймворків розрізняють нормальні та аномальні показники споживання енергії загалом, поділяючи їх на два основні класи (нормальні та аномальні) без подальших деталей. Однак у реальних сценаріях існують різні види аномального споживання, наприклад, аномалії, спричинені надмірним споживанням приладу, відрізняються від аномалій, спричинених відчиненими дверцятами холодильника або відсутністю кінцевого користувача, як показано в статті [40]. У цьому сенсі, не надаючи кінцевому користувачеві інформацію про природу аномалій та їх джерела, дуже важко ініціювати зміну поведінки та сприяти енергозбереженню.

Висновок до третього розділу.

Розглянуті практичні приклади демонструють, що виявлення аномалій споживання енергії на основі ШІ може реалізовуватися щонайменше у трьох бенчмаркінгових сценаріях:

1. прогнозування (RNN + правила, де аномалія фіксується через значний прогнознний залишок і далі уточнюються статистичними критеріями);
2. класифікація “мікро моментів” із залученням даних про

наповненість/присутність (DNN, що дозволяє відрізняти типи подій і виявляти поведінкові аномалії на кшталт “прилад увімкнений за відсутності користувача”);

3. одно класова класифікація (автоенкодер, що відокремлює відхилення у просторі ознак без потреби в повній розмітці аномалій). Сукупно ці підходи підтверджують ключову перевагу ІІІ: можливість виявляти складні, контекстні аномалії не лише за енергетичними відбитками, а й за додатковими джерелами даних (зайнятість, довкілля, погодні фактори).

Водночас широке та надійне впровадження таких рішень стримується типовими обмеженнями: дефіцит анованих і відтворюваних датасетів, сильна незбалансованість класів, неоднозначність визначення аномалії в енергетиці (де “аномальне” не завжди є статистичним “викидом”), розріджені/дорогі мітки, недостатня увага до рівня окремих приладів, дрейф концепцій у часових рядах і брак платформ для реплікації результатів. Окремо важливо, що бінарне “норма/аномалія” часто є недостатнім: практична цінність зростає, коли система не лише визначає відхилення, а й пояснює тип і джерело аномалії, що безпосередньо підтримує управлінські рішення та енергозбереження.

ЗАГАЛЬНИЙ ВИСНОВОК

У кваліфікаційній роботі представлено системний та технічно обґрунтований огляд методів виявлення аномалій у споживанні енергії будівлями. Представлено таксономію, яка класифікує ці підходи з урахуванням різних аспектів, таких як моделі штучного інтелекту, сценарії застосування, рівень виявлення та обчислювальні платформи. На завершення, стратегії виявлення аномалій можуть бути очевидно корисними для систем енергозбереження, постачальників енергії, кінцевих користувачів та урядів, зменшуючи марнотратне споживання та витрати на енергію. Зокрема, вони надають аналітичну інформацію про аномальну поведінку споживання, аномальні прилади, нетехнічні втрати та кібератаки на крадіжку електроенергії, але найголовніше, що системи виявлення аномалій пропонують розумні та потужні рішення для сприяння енергозбереженню. Вони також відіграють важливу роль на ринку моніторингу енергії.

Показано, що більшість рішень для виявлення аномалій у споживанні енергії все ще перебувають на стадії зародження. Для сприяння їх широкому використанню та зрілості необхідно подолати низку проблем та обмежень, серед яких відсутність анотованих наборів даних, відсутність платформ відтворюваності та відсутність стандартних показників для оцінки ефективності розроблених рішень. З іншого боку, на споживання енергії впливають інші фактори, такі як зайнятість (наявність/відсутність кінцевого користувача), умови навколишнього середовища, температура зовнішнього повітря та уподобання кінцевого користувача. Тому вкрай важливо враховувати ці дані для розробки потужних та надійних моделей виявлення аномалій, які могли б виявляти більш просунуті види аномального споживання енергії. Загалом, найближчим часом необхідно докласти значних дослідницьких зусиль для вирішення вищезазначених проблем та покращення якості систем виявлення аномалій.

Крім того, подальші дослідження все ще тривають у майбутніх напрямках, що може дозволити розробку систем виявлення аномалій живлення

з точки зору масштабованості, децентралізації, низького енергоспоживання , простоти впровадження та збереження конфіденційності. Необхідно проводити більше досліджень, проектів та співпраці з промисловими партнерами, щоб допомогти технології виявлення аномалій повністю реалізувати свій потенціал, довести її комерційну доцільність та сприяти її широкому впровадженню в житлових будівлях.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Кириленко О.В., Денисюк С.П., Блінов І.В. Цифрова трансформація енергетики: сучасні тенденції та завдання. Праці Інституту електродинаміки НАН України, Вип. 65, Серпень 2023, С. 5–14.
2. Rau H, Moran P, Manton R, Goggins J. Зміна енергетичних культур? Використання енергії в домогосподарстві до і після модернізації енергоефективності будівлі. *Sustain Cities Soc* 2020; 54:101983.
3. В.О. Гайдукевич, А.Ю. Дорошенко. Застосування моделей машинного навчання для прогнозування енергоспоживання в системах розумного дому. <https://doi.org/10.15407/pp2025.03.029>
4. Кириленко О.В., Денисюк С.П., Блінов І.В. Цифрова трансформація енергетики: сучасні тенденції та завдання. Праці Інституту електродинаміки НАН України, Вип. 65, Серпень 2023, С. 5–14.
5. Впровадження міжнародних та європейських стандартів для розвитку України згідно з концепцією smart grid
<https://harvester.nas.gov.ua/Record/oai:ojs2.prc.new-point.com.ua:article-80?sid=154098777>
6. Berezi Aski P, Jasiul B, Szpyrka M. An entropy-based network anomaly detection method. *Entropy* 2015;17(4):2367–408.
7. Ruff L, Vandermeulen R, Goernitz N, Deecke L, Siddiqui SA, Binder A, et al. Deep one-class classification. In: Dy J, Krause A, editors. In: *Proceedings of Machine Learning Research*, vol. 80, Stock Holm Massan, Stockholm Sweden: PMLR; 2018, p. 4393–402.
8. Brown CE. Multiple discriminant analysis. Berlin, Heidelberg: Springer Berlin Heidelberg; 1998, p. 115–28.
9. Wang X, Zhao T, Liu H, He R. Power consumption predicting and anomaly detection based on long short-term memory neural network. In: 2019 IEEE 4th international conference on cloud computing and big data analysis (ICCCBDA). 2019, p. 487–91.
10. Yuan Y, Jia K. A distributed anomaly detection method of operation energy

consumption using smart meter data. In: 2015 international conference on intelligent information hiding and multimedia signal processing (IIH-MSP). 2015, p. 310–3.

11. Santolamazza A, Cesarotti V, Introna V. Anomaly detection in energy consumption for condition-based maintenance of compressed air generation systems: an approach based on artificial neural networks. IFAC-Papers Online 2018;51(11):1131–6,

12. Mulongo J, Atemkeng M, Ansah-Narh T, Rockefeller R, Nguegnang GM, Garuti MA. Anomaly detection in power generation plants using machine learning and neural networks. Appl Arti Intel 2020;34(1):64–79.

13. Munir M, Siddiqui SA, Chattha MA, Dengel A, Ahmed S. Fusead: Unsupervised anomaly detection in streaming sensors data by fusing statistical and deep learning models. Sensors 2019;19(11).

14. Roberts E, Bassett BA, Lochner M. Bayesian anomaly detection and classification for noisy data. In: Abraham A, Sirry P, Ma K, Kazlauskas A, editors. Intelligent systems design and applications. Cham: Springer International Publishing; 2021, p. 426–35.

15. Rashidi L, Hashemi S, Hamzeh A. Anomaly detection in categorical datasets using Bayesian networks. In: Artificial intelligence and computational intelligence, Vol. 7003. 2011, p. 610–9.

16. Uttama Nambi AS, Reyes Lua A, Prasad VR. Loded: Location-aware energy disaggregation framework. In: Proceedings of the 2Nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments. BuildSys '15, New York, NY, USA: ACM; 2015, p. 45–54.

17. Xie X, Jin Z, Wang J, Yang L, Lu Y, Li T. Confidence guided anomaly detection model for anti-concept drift in dynamic logs. J Netw Comput Appl 2020; 162:102659.

18. Vexler J, Kramer S. Integrating lstms with online density estimation for the probabilistic forecast of energy consumption. Lecture Notes Computer Sci (including Sub Lecture Notes Artif Intell Lecture Notes Bioinform).

https://doi.org/10.1007/978-3-030-33778-0_40.

19. Johnson R, Zhang T. Accelerating stochastic gradient descent using predictive variance reduction. *Adv Neural Inform Process Syst*. 2013; 26:10.

20. Bottou L. Stochastic gradient descent tricks of the trade neural networks. Berlin: Springer; 2012.

21. Jothimurugesan E, Tahmasbi A, Gibbons PB, Tirthapura S. Variance-reduced stochastic gradient descent on streaming data. *Adv Neural Inform Process Syst*. 2018; 10:12.

22. Vrablecová P, Ezzeddine AB, Rozinajová V, Šárik S, Sangaiah AK. Smart grid load forecasting using online support vector regression. *Computers Electr Eng*. 2018.

23.b Kim TY, Cho SB. Predicting residential energy consumption using cnn-lstm neural networks. *Energy*. 2019; 182:72–81.
<https://doi.org/10.1016/J.ENERGY.2019.05.230>.

24. Ardabili S, Mosavi A, Várkonyi-Kóczy AR. Advances in machine learning modeling reviewing hybrid and ensemble methods. *Lecture Notes Netw Syst*. 2019. 2019. <https://doi.org/10.0944/PREPRINTS201908.0203.V1>.

25. Wu X, Wang Y, Bai Y, Zhu Z, Xia A. Online short-term load forecasting methods using hybrids of single multiplicative neuron model, particle swarm optimization variants and nonlinear filters. *Energy Rep*. 2021;

26. Gama JARF, E IZ, Bifet A, Pechenizkiy M, Bouchachia A. A survey on concept drift adaptation a survey on concept drift Adap-tation. *ACM Comput Surv*. 2017;10(1145/0000000):0000000.

27. Breiman L. Bagging predictors. *Machine Learn*. 1996;24(2):24.
<https://doi.org/10.1023/A:1018054314350>.

28. Freund Y, Schapire RE. A decision-theoretic generalization of on-line learning and an application to boosting. *J Computer Syst Sci*. 1997;55:119–39.
<https://doi.org/10.1006/JCSS.1997.1504>.

29. Wolpert DH. Stacked generalization. *Neul Netw*. 1992;10:12.

30. Zang W, Zhang P, Zhou C, Guo L. Comparative study between incremental

and ensemble learning on data streams: case study. *J Big Data*. 2014;1:1–16.
<https://doi.org/10.1186/2196-1115-1-5/TABLES/7>.

31. Zhang C, Ma Y. *Ensemble Machine Learning*. Berlin: Springer; 2012.

32. Hastie T, Tibshirani R, Friedman J. *The elements of statistical learning*
Berlin: Springer; 2009.

33. <https://doi.org/10.1162/neco.1997.9.8.1735>

34. (<https://direct.mit.edu/neco/articlepdf/9/8/1735/813796/neco.1997.9.8.1735.pdf>).37. Van Houdt G, Mosquera C, Nápoles G. A review on the long short-term memory model. *Artif Intell Rev*.2020;53(8):5929–55.

35.Kemker R, McClure M, Abitino A, Hayes T, Kanan C. Measuring catastrophic forgetting in neural networks. *Proc AAAI Conf Artif Intell*. 2018;32:10.

36. Chen T, Guestrin C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining*, pp. 785–794 2016.

37.Hadri S, Najib M, Bakhouya M, Fakhri Y, El Arroussi M. Performance evaluation of forecasting strategies for electricity consumption in buildings. *Energies*. 2021;14(18):5831.

38. Breiman L. Random forests *Machine learning*. 2001;45(1):5–32.

39. Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z, Citro C, Corrado GS, Davis A, Dean J, Devin M, Ghemawat S, Goodfellow

40.Chen T, Guestrin C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining*, pp. 785–794 2016.