

DOI: <https://doi.org/10.36910/6775-2524-0560-2026-64-21>

УДК 004.032.26:519.246.8

Литвиненко Ярослав Володимирович, д.т.н., професор

<https://orcid.org/0000-0001-7311-4103>

Шимчук Григорій Валерійович, ст. викладач

<https://orcid.org/0000-0003-2362-7386>

Тернопільський національний технічний університет ім. Івана Пулюя, м. Тернопіль, Україна

РОЗРОБКА ТА ПОРІВНЯЛЬНИЙ АНАЛІЗ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ГАЗОСПОЖИВАННЯ НА ОСНОВІ БАГАТОШАРОВОГО ПЕРСЕПТРОНА З РІЗНИМИ НАБОРАМИ ВХІДНИХ ОЗНАК

Литвиненко Я. В., Шимчук Г. В. Розробка та порівняльний аналіз моделей прогнозування газоспоживання на основі багатошарового персеプトрона з різними наборами вхідних ознак. У роботі досліджено застосування багатошарового персептона для короткострокового прогнозування споживання природного газу з дискретністю 3 години на повному річному тестовому інтервалі. Сформовано п'ять послідовно розширених моделей MLP, у яких вхідний простір доповнювався метеорологічними, циклічними часовими, лаговими, ковзними та різницеовими ознаками. Для навчання і вибору конфігурації використано дані 2007-2018 років, а 2920 спостережень 2019 року зарезервовано для незалежного тестування. Застосовано хронологічний поділ даних, стандартизацію та формування авторегресійних характеристик без витоку цільової інформації. Якість моделей оцінено за R^2 , MAE, RMSE, MAPE та WAPE. Найвищу точність забезпечила модель MLP-5 з розширеною системою авторегресійних ознак. Для визначення внеску окремих предикторів використано permutation importance, що дало змогу оцінити роль різних груп ознак у формуванні прогнозу.

Ключові слова: багатошаровий персептон (MLP), природний газ, прогнозування газоспоживання, багатошаровий персептон, нейронні мережі, метеорологічні фактори, циклічний випадковий процес, авторегресійні ознаки, лагові ознаки.

Lytvynenko I., Shymchuk G. Development and Comparative Analysis of Natural Gas Consumption Forecasting Models Based on a Multilayer Perceptron with Different Sets of Input Features. The study investigates the application of a multilayer perceptron to short-term natural gas consumption forecasting at three-hour intervals over an annual test period. Five progressively extended MLP models were developed, with the input space expanded by meteorological, cyclical temporal, lagged, rolling, and differenced features. Data from 2007-2018 were used for training and configuration selection, whereas 2,920 observations from 2019 were reserved for independent testing. The experimental design employed chronological data splitting, standardization, and leakage-free construction of autoregressive features. Model performance was evaluated using R^2 , MAE, RMSE, MAPE, and WAPE. The highest forecasting accuracy was achieved by MLP-5 with an extended set of autoregressive features. Permutation importance was applied to quantify the contribution of individual predictors and assess the role of different feature groups in the forecasting process.

Keywords: multilayer perceptron (MLP), natural gas, natural gas consumption forecasting, multilayer perceptron, neural networks, meteorological factors, cyclic random process, autoregressive features, lagged features.

Постановка наукової проблеми. Споживання природного газу є складним динамічним процесом, для якого характерні сезонні, тижневі та внутрішньодобові коливання, а також залежність від метеорологічних умов і попереднього стану самого процесу. За умов короткого кроку прогнозування ці чинники діють одночасно, що ускладнює побудову моделей, здатних стабільно відтворювати зміну споживання впродовж тривалого періоду. Тому актуальним залишається питання формування такого інформаційного представлення часового ряду, яке забезпечувало б достатню повноту опису його поточної динаміки та циклічних закономірностей.

Одним із перспективних інструментів прогнозування є багатошаровий персептон, який дає змогу моделювати нелінійні залежності між сукупністю вхідних параметрів і прогнозованим значенням газоспоживання. Проте ефективність MLP у задачах прогнозування часових рядів суттєво залежить від інформаційного складу вхідних даних, оскільки така модель не має внутрішнього механізму збереження часової залежності. Тому важливим є формування ознак, які відображають попередні стани процесу, характер і швидкість зміни газоспоживання, його локальні статистичні властивості та циклічні закономірності.

Одним із невирішених питань є оцінювання впливу різних груп вхідних ознак на точність прогнозування газоспоживання за допомогою MLP. Для об'єктивного визначення цього впливу необхідно проводити порівняння за незмінного типу моделі, послідовно доповнюючи її вхідні дані метеорологічними, часовими та характеристиками попередніх станів процесу. Це дає можливість визначити, які саме компоненти інформаційного забезпечення моделі найбільше впливають на якість прогнозування.

Дана стаття присвячена дослідженню та оцінюванню впливу метеорологічних, часових та авторегресійних ознак на точність прогнозування газоспоживання за допомогою MLP та визначенню їх раціонального поєднання.

Аналіз досліджень. Точне прогнозування споживання природного газу є важливою умовою ефективного функціонування газорозподільних систем. Воно необхідне для оперативного балансування потоків газу, планування закупівель і резервів, формування заявок на транспортування, а також зменшення витрат, що виникають унаслідок відхилення фактичних обсягів споживання від запланованих протягом визначеного розрахункового періоду. На відміну від довгострокового прогнозування, орієнтованого переважно на врахування макроекономічних і демографічних тенденцій, короткострокове прогнозування з малою часовою дискретністю потребує одночасного врахування метеорологічних умов, календарних закономірностей, внутрішньодобової динаміки споживання та поточного стану досліджуваного процесу. Огляди публікацій [1, 2, 7] свідчать, що на точність прогнозування істотно впливають не лише вибраний алгоритм, а й горизонт прогнозу, рівень просторової агрегації даних та склад вхідних ознак.

Штучні нейронні мережі широко застосовуються для прогнозування газоспоживання завдяки здатності моделювати складні нелінійні залежності між температурою повітря, іншими метеорологічними параметрами, календарними характеристиками та рівнем попиту на природний газ [3–6]. Багатошаровий перцептрон не має внутрішнього механізму збереження часової інформації, притаманного рекурентним нейронним мережам. Водночас часові залежності можуть бути введені до моделі через спеціально сформовані вхідні ознаки, що характеризують попередні значення газоспоживання, їх зміну та статистичні властивості на попередніх часових інтервалах. За такого підходу прогнозування часового ряду реалізується як задача регресії на основі структурованого набору ознак. До переваг цього підходу належать можливість інтерпретації вхідних параметрів, відносно невисока обчислювальна складність та простота відтворення результатів.

Класичні дослідження із застосуванням багатошарового перцептрона (Multilayer Perceptron – MLP) показують, що температура повітря та календарні характеристики належать до основних факторів, які визначають динаміку міського газоспоживання [3]. У роботі [4] показано, що глибока нейронна регресійна модель забезпечує вищу точність порівняно з лінійною моделлю та традиційними неглибокими нейронними мережами на значній сукупності регіональних наборів даних. Рекурентні архітектури, зокрема LSTM, демонструють здатність ефективно враховувати довготривалі часові залежності [5], тоді як використання гібридних моделей із декомпозицією сигналу сприяє підвищенню точності прогнозування нестационарних часових рядів [6].

У праці [8] встановлено сезонний характер впливу похибок прогнозування температури на якість прогнозу, у [9] показано переваги ансамблю різномірних моделей прогнозування, а у [10] підтверджено ефективність методів машинного навчання для короткострокового прогнозування попиту. Результати дослідження, наведені у праці [11], безпосередньо підтверджують доцільність спільного використання метеорологічних характеристик і попередніх значень газоспоживання. У гібридній системі [12] поєднано функціональну авторегресію, LSTM та оптимізаційні компоненти, що також свідчить про важливість урахування попередніх станів процесу при формуванні прогнозу.

Результати, наведені у праці [13], вказують на залежність точності прогнозування від статистичного розподілу даних та режиму споживання природного газу. Для прогнозування на річних і довгострокових інтервалах застосовуються штучні нейронні мережі (ANN), метод опорних векторів (SVM) та гібридні моделі [14, 15], однак у таких дослідженнях переважно використовуються агреговані річні значення. У даній роботі річний часовий інтервал розглядається інакше: він використовується як тривалий незалежний період тестування моделі, тоді як часовий крок прогнозування становить 3 години. Такий підхід дає змогу оцінити не лише загальну точність прогнозування протягом року, а й стійкість моделі в різні сезони та за різних режимів газоспоживання.

Сучасні дослідження спрямовані на подальший розвиток моделей LSTM, методів інкрементального навчання та глибоких нейронних мереж із регуляторними обмеженнями [16–18]. Разом з тим результати попередніх робіт авторів, присвячених моделюванню газоспоживання на основі циклічного випадкового процесу та методів машинного навчання з урахуванням кліматичних показників [19–21], підтверджують наявність вираженої багатомасштабної циклічності цього процесу. Це обґрунтовує необхідність урахування в моделях MLP не лише календарних

закономірностей, а й інформації про попередні стани газоспоживання на різних часових масштабах – короткостроковому, добовому, дводобовому та тижневому.

Виклад основного матеріалу й обґрунтування отриманих результатів дослідження. У межах дослідження сформовано послідовність етапів побудови та оцінювання моделей прогнозування газоспоживання на основі багатошарового персептрона, що охоплює підготовку вихідних даних, формування системи вхідних ознак, вибір архітектури моделі та аналіз точності прогнозування. Для кількісного оцінювання впливу різних груп ознак на результат прогнозу розглянуто п'ять послідовно розширених моделей MLP та проведено їх незалежне тестування на річному часовому інтервалі.

Нехай Q_t – обсяг споживання природного газу за трьохгодинний інтервал t , а x_t – вектор доступних на момент прогнозування метеорологічних, часових та авторегресійних характеристик. Необхідно побудувати нелінійне відображення $f(\cdot)$, яке формує оцінку $\hat{Q}_t=f(x_t)$ і мінімізує похибку на майбутньому хронологічному відрізку. Оскільки авторегресійні ознаки утворюються лише з попередніх значень Q , прогноз є однокроковим і не використовує поточного цільового значення.

Наукова новизна роботи полягає у проведенні контрольованого порівняння п'яти моделей багатошарового персептрона з послідовно розширюваними наборами вхідних ознак. За незмінного типу прогновної моделі окремо оцінено вплив метеорологічних, часових та авторегресійних характеристик на точність прогнозування газоспоживання. Оцінювання моделей виконано на незалежному річному тестовому інтервалі з часовою дискретністю 3 години. Для формування ознак, що характеризують попередню динаміку газоспоживання, використано лише дані, доступні до моменту прогнозування, що унеможливило витік інформації з майбутніх часових відліків. Додатково проведено інтерпретацію фінальної моделі за допомогою методу permutation importance, що дало змогу визначити найбільш значущі вхідні ознаки та оцінити їхній вплив на результат прогнозування.

Основні завдання дослідження:

- Синхронізувати ряди газоспоживання та метеорологічних спостережень за часовою міткою;
- Сформувати п'ять послідовно розширених наборів ознак MLP-1–MLP-5;
- Виконати хронологічний поділ на навчальний, валідаційний і незалежний тестовий періоди;
- Підібрати архітектуру MLP та параметри регуляризації без використання даних 2019 року;
- Порівняти моделі за похибками: R^2 , MAE, RMSE, MAPE та WAPE, проаналізувати помісячну стійкість і важливість ознак.

В дослідженні використано два синхронізовані набори даних: ряд споживання природного газу та метеорологічні спостереження за 2007–2019 рр. Часова сітка містить вісім відліків на добу: 00:00, 03:00, 06:00, 09:00, 12:00, 15:00, 18:00 та 21:00. Після об'єднання за часовою міткою отримано 37984 спостереження. Цільова змінна Q характеризує обсяг газу за відповідний трьохгодинний інтервал. В таблиці 1 подано хронологічний поділ даних.

Таблиця 1. Хронологічний поділ даних

Період	Призначення	Кількість відліків	Примітка
2007–2017	навчання під час вибору моделі	32144	початковий хронологічний період
2018	валідація архітектури	2920	не використовується для первинного навчання
2007–2018	фінальне навчання	35064	після вибору конфігурації
2019	незалежне тестування	2920	повний річний інтервал

Зовнішній поділ виконувався виключно за часом, що відповідає реальним умовам експлуатації та рекомендаціям щодо позавибіркової перевірки часових прогнозів [27, 28]. Дані 2019

року не використовувалися ні для стандартизації, ні для вибору архітектури. Після визначення оптимальної конфігурації модель повторно навчалася на всіх доступних спостереженнях 2007–2018 рр.

Метеорологічний вектор містив 16 числових показників: температуру повітря T , атмосферний тиск на рівні станції P_o , тиск P і його зміну P_a , відносну вологість U , середню швидкість вітру Ff , максимальні пориви $ff10$ і $ff3$, мінімальну та максимальну температуру T_n і T_x , видимість VV , точку роси T_d , опади RRR , тривалість/період опадів tR , температуру ґрунту T_g та снігову/поверхневу характеристику sss . Позначення збережено відповідно до структури вихідної бази даних.

Модель MLP-1 використовувала чотири ознаки, які на нашу думку, є ключовими при формуванні прогнозу: T , P_o , $ff10$ та U . MLP-2 отримувала всі 16 метеорологічних параметрів. Для MLP-3 додано шість циклічних змінних, які описують годину доби, день тижня та день року. Звичайне цілочислове кодування створює штучну відстань між кінцем і початком циклу; синусно-косинусне подання зберігає топологію кола:

$$z_{\sin}(t) = \sin\left(\frac{2\pi z_t}{P}\right), z_{\cos}(t) = \cos\left(\frac{2\pi z_t}{P}\right), \quad (1)$$

де z – значення циклічної змінної, а P – її період. Для години використовувався добовий період, для дня тижня – сім діб, для дня року – тривалість календарного року. У результаті сформовано $Hour_{\sin}$, $Hour_{\cos}$, $DayOfWeek_{\sin}$, $DayOfWeek_{\cos}$, $DayOfYear_{\sin}$, та $DayOfYear_{\cos}$.

Для MLP-4 введено «лагові значення» Q_{lag_1} , Q_{lag_2} , Q_{lag_8} , Q_{lag_16} та Q_{lag_56} , що «характеризують пам'ять процесу» 3 години, 6 годин, 1 доба, 2 доби і 1 тиждень:

$$Q_{lagk}(t) = Q_{t-k}, \quad (2)$$

де Q_{t-k} – значення споживання природного газу за k часових кроків до моменту прогнозування t .

Крім того, використовувалися ковзні середні за 8, 16 і 56 попередніх відліків та стандартне відхилення за останні 8 інтервалів. Перед обчисленням будь-якої ковзної характеристики ряд Q зсувався на один крок:

$$\bar{Q}_{t,w} = \frac{1}{w} \sum_{i=1}^w Q_{t-i}, \quad (3)$$

де w – ширина ковзного вікна; Q_{t-i} – попередні значення газоспоживання.

У формулі (4) використовуються лише значення, відомі до моменту t , тому поточне значення Q_t не входить до ковзного вікна.

$$s_{t,w} = \sqrt{\frac{1}{w-1} \sum_{i=1}^w (Q_{t-i} - \bar{Q}_{t,w})^2}, \quad (4)$$

де $s_{t,w}$ характеризує локальну мінливість споживання природного газу в межах вікна шириною w .

Фінальна MLP-5 містила 47 входів. До 16 метеорологічних і 6 часових ознак додано 11 лагів Q_{lag_1} , Q_{lag_2} , Q_{lag_3} , Q_{lag_8} , Q_{lag_15} , Q_{lag_15} , Q_{lag_16} , Q_{lag_17} , Q_{lag_55} , Q_{lag_56} , Q_{lag_57} , ковзні середні та стандартні відхилення за вікнами 8, 16 і 56, мінімум, максимум і медіану за попередню добу, п'ять різницевих характеристик. Різниця двох лагів визначалася як:

$$Q_{diff(a,b)}(t) = Q_{t-a} - Q_{t-b}, \quad (5)$$

де a і b – номери лагів, між якими обчислюється різниця.

Різницеві ознаки у моделі MLP-5 використовуються для кількісного опису напряму та інтенсивності зміни газоспоживання між попередніми часовими інтервалами. Використання цих ознак дає змогу моделі враховувати локальну динаміку процесу на різних часових масштабах та точніше відтворювати короткострокові зміни газоспоживання.

$$Q_{diff1_2}(t) = Q_{t-1} - Q_{t-2},$$

$$Q_{diff2_3}(t) = Q_{t-2} - Q_{t-3},$$

$$Q_{diff8_16}(t) = Q_{t-8} - Q_{t-16},$$

$$Q_{diff16_56}(t) = Q_{t-16} - Q_{t-56},$$

$$Q_{diff55_57}(t) = Q_{t-55} - Q_{t-57}.$$

Q_{t-k} – значення споживання природного газу за k трьохгодинних інтервалів до моменту прогнозування t . Сформовані різницеві ознаки відображають зміну газоспоживання на короткостроковому, добовому та тижневому часових масштабах і використовуються для врахування локальної динаміки процесу.

Симетричні лаги навколо добової та тижневої позицій (8 ± 1 , 16 ± 1 , 56 ± 1) дають мережі інформацію про локальну форму профілю, а різниці безпосередньо описують напрям і швидкість зміни. Для MLP-4 на початку всього набору відкидаються перші 56 спостережень, для MLP-5 – перші 57, на межі валідаційного й тестового років лаги формуються з попереднього історичного періоду, тому всі 2 920 відліків 2019 року залишаються доступними для оцінювання. В таблиці 2 наведено послідовне розширення вхідного простору моделей.

Таблиця 2. Послідовне розширення вхідного простору

Модель	Кількість ознак	Додана інформація	Основна гіпотеза
MLP-1	4	T, P _o , ff10, U	поточна погода визначає навантаження
MLP-2	16	повний метеорологічний вектор	додаткові погодні фактори уточнюють попит
MLP-3	22	6 циклічних часових компонент	попит має добову, тижневу та річну періодичність
MLP-4	31	5 лагів, 3 середні, 1 стандартне відхилення	процес має коротку, добову і тижневу пам'ять
MLP-5	47	11 лагів, 9 ковзних і 5 різницевих ознак	локальна динаміка й багатомасштабна пам'ять визначають точність

Багатошаровий персептрон реалізує послідовність афінних перетворень і нелінійних активацій. Для l -го прихованого шару:

$$h^{(l)} = \text{ReLU}(W^{(l)}h^{(l-1)} + b^{(l)}), l = 1, \dots, L, \quad (6)$$

де: $h^{(l)}$ – вихід l -го прихованого шару, $h^{(l-1)}$ – вихід попереднього шару, $W^{(l)}$ – матриця ваг, $b^{(l)}$ – вектор зміщень, L – кількість прихованих шарів.

Для першого шару $h^{(0)} = x_t$, де x_t – вхідний вектор ознак у момент часу t .

$$ReLU(a) = \max(0, a). \quad (7)$$

Функція активації $ReLU$ набуває нульового значення для від'ємних аргументів і зберігає значення аргументу без змін, якщо він є додатним.

Вихідний шар для задачі регресії є лінійним:

$$\hat{Q}_t = W^{(L+1)}h^{(L)} + b^{(L+1)}, \quad (8)$$

де $\hat{Q}_t$ – прогнозоване значення споживання природного газу, $h^{(L)}$ – вихід останнього прихованого шару, $W^{(L+1)}$ – ваги вихідного шару, $b^{(L+1)}$ – зміщення вихідного шару.

Параметри мережі оцінювалися мінімізацією середньоквадратичної функції втрат із L2-регуляризациєю. Оптимізацію виконано алгоритмом, який використовують для навчання нейронних мереж Adam [23] (Adaptive Moment Estimation – «адаптивне оцінювання моментів»), а ReLU обрано як активацію прихованих шарів [24]. Реалізація базувалася на MLPRegressor бібліотеки scikit-learn [22].

Усі входи та цільова змінна стандартизувалися окремо. Для довільної ознаки x :

$$\tilde{x} = \frac{x - \mu_{train}}{\sigma_{train}}, \quad (9)$$

де $\tilde{x}$ – початкове значення ознаки або цільової змінної, x – стандартизоване значення, μ_{train} – середнє значення, визначене за навчальною вибіркою, σ_{train} – стандартне відхилення, визначене за навчальною вибіркою.

Параметри μ_{train} і σ_{train} , отримані за навчальними даними, без змін застосовувалися до валідаційної та тестової вибірок.

Такий порядок запобігає непрямому використанню статистики майбутнього періоду. В таблиці 3 зведені вибрані конфігурації моделей.

Таблиця 3. Вибрані конфігурації MLP

Модель	Вибрана архітектура	α	Початкова швидкість	Фактичні ітерації
MLP-1	(256, 128)	0,0001	0,0005	349
MLP-2	(128, 64, 32)	0,0001	0,001	135
MLP-3	(128, 64, 32)	0,0001	0,001	234
MLP-4	(256, 128)	0,0001	0,001	124
MLP-5	(256, 128)	0,0001	0,001	129

Для всіх досліджуваних конфігурацій максимальну кількість ітерацій встановлено на рівні 5000, розмір пакета – `batch_size` = 128, частку внутрішньої валідаційної вибірки – `validation_fraction` = 0,15, кількість ітерацій без покращення функції втрат для активації ранньої зупинки –

$n_iter_no_change = 100$, допустиме значення похибки збіжності – $tol = 10^{-7}$. Для забезпечення відтворюваності результатів використано фіксоване значення $random_state = 42$.

Архітектури багатошарового перцептрона, що містили від двох до чотирьох прихованих шарів, порівнювали за результатами прогнозування на хронологічно відокремленій валідаційній вибірці 2018 року. Після вибору оптимальної архітектури й налаштування гіперпараметрів (архітектура прихованих шарів – кількість шарів і нейронів, коефіцієнт L2-регуляризації α , швидкість навчання $learning_rate_init$ та інші) модель повторно навчали на об'єднаних даних за 2007–2018 роки. Дані за 2019 рік не використовувалися на етапах навчання, вибору архітектури та налаштування гіперпараметрів і були повністю зарезервовані для незалежного тестування сформованої моделі.

Нехай y_i – фактичне значення, $\hat{y}_i$ – прогноз, $\bar{y}$ – середнє фактичне значення, n – кількість тестових відліків. Використано такі метрики:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (11)$$

MAE показує середню абсолютну величину відхилення прогнозу від фактичного споживання.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (12)$$

RMSE сильніше штрафує великі прогнозні похибки порівняно з MAE.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad (13)$$

MAPE характеризує середню абсолютну похибку прогнозування у відсотках від фактичних значень.

$$WAPE = 100\% \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n |y_i|}, \quad (14)$$

WAPE визначає відношення сумарної абсолютної похибки до сумарного фактичного обсягу газоспоживання.

MAE і RMSE вимірюються в одиницях Q, RMSE сильніше реагує на великі локальні помилки. MAPE може різко зростати в періоди малого споживання, тому для річного порівняння основною відносною метрикою є WAPE [26]. R^2 оцінює частку відтвореної дисперсії. Важливо, що помісячне R^2 обчислюється відносно дисперсії конкретного місяця, тому може бути значно нижчим за річне навіть за помірної абсолютної похибки.

Для інтерпретації застосовано permutation importance [25]. Для кожної ознаки j її значення випадково переставлялися, після чого вимірювалося падіння базового R^2 :

$$I_j = R_{base}^2 - \frac{1}{K} \sum_{k=1}^K R_{j,k}^2, \quad (15)$$

де I_j – перестановочна важливість j -ї ознаки, R_{base}^2 – коефіцієнт детермінації початкової моделі, $R_{j,k}^2$ – значення R^2 , отримане після k -ї випадкової перестановки значень j -ї ознаки, K – кількість повторень перестановки.


Чим більше значення I_j , тим істотніше погіршується якість прогнозування після руйнування зв'язку відповідної ознаки з цільовою змінною. Від'ємні значення не слід тлумачити як причинний негативний вплив, вони можуть виникати через корельованість входів і статистичну варіативність перестановок.

В таблиці 4 зведені результати прогнозування на незалежній вибірці 2019 року.

Таблиця 4. Якість прогнозування на незалежній вибірці 2019 року

Модель	Набір входів	Архі-тектура	R ²	MAE, м ³	RMSE, м ³	MAPE, %	WAPE, %
MLP-1	T, Po, ff10, U	(256, 128)	0,4577	21777,26	31604,13	85,64	43,64
MLP-2	16 метеорологічних	(128, 64, 32)	0,5600	18179,98	28466,60	67,21	36,43
MLP-3	Метеорологічні + 6 часових	(128, 64, 32)	0,6498	15146,90	25398,28	52,93	30,35
MLP-4	MLP-3 + базові лаги/ковзні	(256, 128)	0,8997	7408,67	13594,20	24,09	14,85
MLP-5	MLP-3 + розширені AR-ознаки	(256, 128)	0,9536	5143,22	9245,08	17,64	10,31

MLP-1 відтворює загальну сезонну форму, але пояснює лише 45,77 % річної дисперсії. Розширення погодного вектора в MLP-2 збільшує R^2 на 0,1023 та зменшує MAE на 16,52 %. Додавання циклічних ознак у MLP-3 дає ще 0,0897 за R^2 і підтверджує значущість календарної структури. Водночас WAPE=30,35 % залишається недостатньою для точного оперативного прогнозування.

Рис. 1. Зростання тестового R^2 зі розширенням системи ознак

На рис. 1 представлено зміну коефіцієнта детермінації R^2 для моделей MLP-1–MLP-5 у процесі послідовного розширення системи вхідних ознак. Найбільш суттєве підвищення точності спостерігається при переході від MLP-3 до MLP-4: введення п'яти лагових ознак і статистичних характеристик попередніх значень газоспоживання забезпечує збільшення R^2 на 0,2499, зменшення MAE на 51,09 %, а RMSE – на 46,48 %. Отримані результати свідчать про те, що врахування попередніх значень і динаміки газоспоживання надає моделі додаткову інформацію про часові закономірності процесу, яка не повною мірою відображається метеорологічними та календарними ознаками.




Рис. 2. Зменшення WAPE для моделей MLP-1–MLP-5

На рис. 2 представлено зміну зваженої абсолютної відносної похибки WAPE для моделей MLP-1–MLP-5 у процесі послідовного розширення системи вхідних ознак. Перехід від MLP-4 до MLP-5 забезпечує додаткове зменшення MAE та WAPE на 30,58 %. Порівняно з базовою моделлю

MLP-1, для MLP-5 значення MAE та WAPE зменшилися на 76,38 %, RMSE – на 70,75 %, тоді як коефіцієнт детермінації R^2 зріс на 0,4959. Оскільки моделі MLP-4 і MLP-5 мають однакову архітектуру прихованих шарів (256, 128), подальше підвищення точності прогнозування зумовлене насамперед розширенням набору вхідних ознак, зокрема лагових і різницевих характеристик, а не збільшенням кількості шарів або нейронів.




Рис. 3. Динаміка абсолютних похибок MAE та RMSE для моделей MLP-1–MLP-5

На рис. 3 представлено динаміку абсолютних похибок MAE та RMSE для моделей MLP-1–MLP-5 на тестовій вибірці 2019 року. Значення обох показників послідовно зменшуються в міру розширення системи вхідних ознак, причому найбільш суттєве зниження спостерігається при переході від MLP-3 до MLP-4. Це свідчить про те, що введення базових лагових характеристик і статистичних показників попередніх значень газоспоживання істотно підвищує точність моделі та її здатність відтворювати коливання процесу протягом річного інтервалу. Подальший перехід до MLP-5 забезпечує додаткове зменшення MAE та RMSE завдяки використанню розширеного набору лагових і різницевих ознак.




Рис. 4. Зменшення середньої абсолютної відсоткової похибки MAPE для моделей MLP-1–MLP-5

На рис. 4 представлено зміну середньої абсолютної відсоткової похибки MAPE для моделей MLP-1–MLP-5. Значення MAPE послідовно зменшується від 85,64 % для MLP-1 до 17,64 % для MLP-5. Найбільш суттєве зниження спостерігається при переході від MLP-3 до MLP-4, коли значення MAPE зменшується більш ніж удвічі внаслідок урахування лагових і ковзних ознак. Це свідчить про те, що авторегресійні характеристики мають суттєвий вплив на підвищення точності та стабільності прогнозування газоспоживання.




Рис. 5. Еволюція системи предикторів від MLP-1 до MLP-5

На рис. 5 представлено послідовне розширення системи вхідних ознак для моделей MLP-1–MLP-5 та зміну їх загальної кількості. Наведені дані свідчать, що підвищення точності прогнозування пов'язане не лише зі збільшенням кількості вхідних параметрів, а насамперед із включенням ознак, які відображають часову структуру процесу газоспоживання. Найбільш суттєве покращення спостерігається на етапі переходу до MLP-4, коли до моделі додаються лагові характеристики та статистичні показники попередніх значень газоспоживання. Це підтверджує важливість урахування інерційності та повторюваних часових закономірностей досліджуваного процесу.




Рис. 6. Фактичний і прогнозований ряд MLP-5 на повному річному інтервалі 2019 року

На рис. 6 представлено порівняння фактичних і прогнозованих моделлю MLP-5 значень споживання природного газу на повному річному інтервалі 2019 року. Графік демонструє, що модель відтворює основні сезонні закономірності газоспоживання, зокрема високі зимові

навантаження, поступове весняне зниження, літній мінімум та подальше зростання споживання в осінньо-зимовий період. Значне накладання фактичного і прогнозованого рядів свідчить про здатність MLP-5 відтворювати не лише загальний сезонний рівень, а й короткострокові коливання між послідовними трьохгодинними інтервалами.




Рис. 7. Деталізація фактичного та прогнозованого ряду у січні 2019 року

На рис. 7 представлено деталізоване порівняння фактичних і прогнозованих моделлю MLP-5 значень газоспоживання у січні 2019 року. Графік свідчить, що модель достатньо точно відтворює внутрішньодобові коливання, амплітуду добових циклів і більшість локальних піків споживання. Для січня, який характеризується високим рівнем і значною мінливістю газоспоживання, модель забезпечує $R^2=0,9101$ та $WAPE=2,81$ %. Найбільші відхилення прогнозу спостерігаються під час різких короткочасних змін навантаження, що можуть бути зумовлені чинниками, не представленими у сформованому наборі метеорологічних, часових та авторегресійних ознак.

Сумарний фактичний обсяг газоспоживання за 2019 рік становив 145 711 052,12 м³, тоді як сумарне прогнозоване значення для MLP-5 – 151 721 414,68 м³. Таким чином, модель завищила річний обсяг на 6 010 362,56 м³, або на 4,12 %. Середнє значення залишку, визначеного як $Q-\hat{Q}$, становило $-2\,058,34$ м³ на один трьохгодинний інтервал. Для моделі MLP-4 відносна похибка річного агрегованого прогнозу була дещо меншою і становила 3,24 %, однак значення MAE, RMSE та WAPE для окремих трьохгодинних прогнозів були вищими. Це свідчить про необхідність урахування цільового критерію під час вибору моделі: точності прогнозування на окремих трьохгодинних інтервалах або точності оцінювання сумарного річного обсягу газоспоживання.

В таблиці 5 наведені похибки для фінальної моделі MLP-5.

Таблиця 5. Помісячні метрики фінальної моделі MLP-5

Місяць	R^2	MAE, м³	RMSE, м³	MAPE, %	WAPE, %
Січень	0,9101	3584,79	4719,62	2,86	2,81
Лютий	0,8930	4082,72	5247,59	4,23	3,89
Березень	0,8737	5449,75	6841,62	7,75	6,82
Квітень	0,9326	3511,34	4710,95	10,36	8,87
Травень	0,8961	2034,36	2674,38	10,32	9,35
Червень	0,7913	1651,45	2335,52	12,22	11,03
Липень	0,9161	1217,94	1535,12	8,77	8,06
Серпень	0,8914	1420,86	1772,75	10,67	9,74
Вересень	0,3305	5103,64	7460,70	37,51	24,55

Місяць	R^2	MAE, м ³	RMSE, м ³	MAPE, %	WAPE, %
Жовтень	0,4247	7772,86	9735,54	44,19	27,43
Листопад	0,5412	7405,83	10311,40	35,43	23,45
Грудень	0,5427	18286,89	24928,97	26,95	17,93




Рис. 8. Помісячне R^2 моделі MLP-5

На рис. 8 представлено помісячні значення коефіцієнта детермінації R^2 для моделі MLP-5 протягом 2019 року. Найвищі значення R^2 спостерігаються у січні–серпні, що свідчить про високу здатність моделі відтворювати мінливість газоспоживання в цей період. У вересні–грудні значення коефіцієнта детермінації помітно знижуються, що вказує на зменшення точності відтворення динаміки споживання в перехідний та початковий опалювальний періоди. Така зміна може бути пов'язана з посиленням впливу додаткових чинників, не повністю врахованих у сформованому наборі вхідних ознак.




Рис. 9. Помісячна WARE моделі MLP-5

На рис. 9 представлено помісячні значення зваженої абсолютної відносної похибки WARE для моделі MLP-5 протягом 2019 року. У січні–серпні модель демонструє відносно стабільні результати: коефіцієнт детермінації R^2 перебуває в межах 0,7913–0,9326, при цьому найвище його значення отримано у квітні, а найменше значення WARE – у січні. У вересні–грудні спостерігається погіршення точності прогнозування: R^2 знижується до 0,3305–0,5427, а WARE зростає до 17,93–27,43 %. Цей період відповідає переходу від літнього режиму газоспоживання до опалювального сезону, коли динаміка навантаження визначається не лише метеорологічними умовами, а й інерційністю теплових процесів у будівлях, режимами роботи підприємств, організаційними рішеннями та іншими чинниками, не врахованими у сформованому наборі вхідних ознак.

Показник MAPE є чутливим до низьких фактичних значень газоспоживання, оскільки вони використовуються у знаменнику при обчисленні відносної похибки. Тому навіть за порівняно невеликих абсолютних відхилень значення MAPE може залишатися підвищеним у періоди низького споживання. Водночас у грудні MAE досягає 18 286,89 м³, що пов'язано зі значно більшими обсягами газоспоживання, тоді як WARE становить 17,93 %. Таким чином, для об'єктивного оцінювання якості прогнозування доцільно одночасно аналізувати абсолютні та відносні показники похибки.

В таблиці 6 наведено основні ознаки які впливають на результат прогнозування за допомогою моделі MLP-5.

Таблиця 6. П'ятнадцять найважливіших ознак MLP-5

Ознака	Permutation importance
Q_diff_1_2	0,07067
Q_lag_1	0,05932
Q_lag_16	0,04606
Q_lag_8	0,04003
Q_lag_56	0,03933
Q_lag_2	0,03918
Q_lag_3	0,03864
Q_lag_9	0,03033
Q_lag_57	0,02513

Продовження таблиці 6

Ознака	Permutation importance
Q_lag_17	0,02065
Q_lag_55	0,01160
Q_roll_mean_8	0,00882
Q_roll_max_8	0,00808
Hour_sin	0,00797
Tx	0,00717




Рис. 10 – Найважливіші ознаки фінальної моделі MLP-5

На рис. 10 представлено результати оцінювання важливості вхідних ознак фінальної моделі MLP-5 методом permutation importance. Найвищу перестановочну важливість має різницева ознака $Q_{diff}(t) = Q_{t-1} - Q_{t-2}$, яка характеризує зміну споживання природного газу між двома останніми доступними трьохгодинними інтервалами. Наступними за значущістю є короткострокова лагова ознака Q_{lag_1} , ознаки добового циклу Q_{lag_8} і Q_{lag_9} , дводобового циклу Q_{lag_16} і Q_{lag_17} , а також тижневого циклу Q_{lag_55} , Q_{lag_56} і Q_{lag_57} . Такий розподіл важливості ознак підтверджує одночасний вплив короткострокової інерційності процесу, повторюваного добового профілю та тижневої циклічності газоспоживання.

З урахуванням трьохгодинної дискретності часового ряду ознака Q_{lag_1} характеризує попереднє значення газоспоживання зі зміщенням на 3 години, Q_{lag_8} і Q_{lag_9} – на 24 і 27 годин, Q_{lag_16} і Q_{lag_17} – на 48 і 51 годину, Q_{lag_55} , Q_{lag_56} і Q_{lag_57} – на 165, 168 і 171 годину відповідно.

Серед метеорологічних змінних найвище місце займає максимальна температура Tx, але її importance=0,00717 суттєво нижча за значення провідних авторегресійних характеристик. Hour_sin має importance=0,00797 і відображає внутрішньодобову фазу. Погодні та календарні змінні не є непотрібними, вони коригують прогноз при зміні режиму, однак основний рівень і локальна траєкторія визначаються історією Q.

Порівняння MLP-4 і MLP-5 також показове. У MLP-4 Q_{lag_1} має importance=0,5776 і домінує над усіма іншими входами. У MLP-5 інформація розподіляється між корельованими лагами, різницями та ковзними статистиками, тому індивідуальні значення importance стають меншими. Це не означає зменшення сукупної ролі авторегресії; навпаки, модель використовує більш надлишкове і стійке подання часової пам'яті. Через корельованість permutation importance слід трактувати як важливість конкретної ознаки в контексті заданого набору, а не як причинний ефект.

Серед метеорологічних ознак найбільше значення permutation importance має максимальна температура $T_x = 0,00717$, однак воно істотно нижче за відповідні значення провідних авторегресійних характеристик. Циклічна часова ознака Hour_sin має permutation importance $0,00797$ і відображає внутрішньодобову фазу процесу. Таким чином, метеорологічні та часові ознаки залишаються важливими для уточнення прогнозу за різних режимів споживання, проте основний внесок у відтворення поточного рівня та локальної динаміки газоспоживання забезпечують ознаки, сформовані на основі попередніх значень Q .

Порівняння моделей MLP-4 і MLP-5 також демонструє відмінності у розподілі важливості вхідних ознак. У моделі MLP-4 ознака Q_lag_1 має permutation importance $0,5776$ і суттєво переважає інші характеристики. У MLP-5 інформація про попередню динаміку процесу розподіляється між корельованими лаговими, різницевиими та ковзними ознаками, унаслідок чого індивідуальні значення permutation importance для окремих характеристик зменшуються. Це не свідчить про зниження загальної ролі авторегресійної інформації, а, навпаки, вказує на її більш розподілене та стійке представлення у вхідному просторі моделі. З огляду на корельованість ознак результати permutation importance доцільно інтерпретувати як оцінку відносної важливості конкретної характеристики в межах заданого набору входів, а не як міру її причинного впливу на газоспоживання.

Висновки та перспективи подальшого дослідження. Проведене дослідження підтвердило доцільність застосування багатошарового персептрона для короткострокового прогнозування споживання природного газу з трьохгодинною дискретністю та показало визначальний вплив структури вхідних даних на точність прогнозу. На основі 37 984 синхронізованих трьохгодинних спостережень за 2007–2019 рр. було побудовано та послідовно досліджено п'ять моделей MLP із розширюваними наборами вхідних ознак. Дані 2019 року використовувалися як незалежний річний тестовий інтервал, що дало змогу оцінити роботу моделей упродовж усіх сезонів та за різних режимів газоспоживання.

Результати експериментального дослідження засвідчили поступове підвищення точності прогнозування зі збільшенням інформативності вхідного набору. Використання чотирьох базових метеорологічних показників у моделі MLP-1 забезпечило значення коефіцієнта детермінації $R^2=0,4577$. Розширення набору до повного метеорологічного вектора підвищило R^2 до $0,5600$, а введення циклічних часових ознак у MLP-3 – до $0,6498$. Найбільше покращення було отримано після включення інформації про попередні стани процесу газоспоживання. Модель MLP-4, що враховувала базові лагові характеристики та статистичні показники попередніх значень ряду, досягла $R^2=0,8997$ та $WAPe=14,85\%$. Саме на цьому етапі зафіксовано найбільший приріст точності між послідовними моделями.

Подальше розширення набору вхідних характеристик у моделі MLP-5 дало змогу досягти $R^2=0,9536$, $MAE=5143,22\text{ м}^3$, $RMSE=9245,08\text{ м}^3$, $MAPE=17,64\%$ та $WAPe=10,31\%$. Порівняно з базовою моделлю MLP-1 значення MAE і $WAPe$ зменшилися на $76,38\%$. Важливо, що моделі MLP-4 і MLP-5 мали однакову архітектуру прихованих шарів (256, 128), тому подальше підвищення точності пов'язане насамперед не зі збільшенням глибини нейронної мережі, а з розширенням та уточненням системи вхідних ознак. Це підтверджує, що для досліджуваної задачі ефективне формування вхідних характеристик процесу має більший вплив на результат прогнозування, ніж механічне ускладнення архітектури MLP.

Аналіз важливості ознак методом permutation importance показав, що найбільшу прогнозу цінність мають характеристики, які описують попередню динаміку газоспоживання. Зокрема, істотний вплив виявлено для різницевої ознаки $Q_diff_1_2$ та лагових значень, що характеризують короткострокові, добові, дводобові й тижневі залежності. Різницеві характеристики дають змогу врахувати не лише поточний рівень споживання, а й напрям його зміни, що є важливим для розрізнення режимів зростання та зниження навантаження. Використання лагів на різних часових масштабах, своєю чергою, забезпечує відображення інерційних та циклічних властивостей досліджуваного процесу. Метеорологічні параметри та календарні характеристики також залишаються важливими складовими моделі, однак їх роль переважно пов'язана з формуванням сезонного рівня та регулярних часових закономірностей газоспоживання.

Отримані результати узгоджуються з висновками досліджень [8, 10–13], у яких показано ефективність спільного використання історичних значень попиту, метеорологічної та календарної інформації. При цьому значення $WAPe=10,31\%$ для моделі MLP-5 необхідно розглядати з

урахуванням особливостей проведеного експерименту: оцінювання виконувалося не на окремому сезонному відрізку, а на повному річному інтервалі, який охоплює зимові максимуми, літні мінімуми та перехідні періоди зі зміною характеру споживання. Такий підхід дає змогу більш об'єктивно оцінити стійкість моделі до сезонної зміни режимів функціонування системи.

Подальша робота передбачає порівняння розробленої моделі MLP-5 з іншими підходами до моделювання часових рядів, зокрема LSTM, GRU, Temporal Convolutional Network, XGBoost, SARIMAX та моделлю на основі циклічного випадкового процесу. Важливим напрямом є застосування rolling-origin validation для оцінювання стабільності моделей у різні роки, дослідження методів прогнозування квантилів і невизначеності, використання SHAP та накопичених локальних ефектів для поглибленої інтерпретації впливу вхідних характеристик, а також розроблення механізмів адаптивного перенавчання моделей за умов зміни статистичних властивостей процесу газоспоживання.

Отримані результати також свідчать про можливість практичного використання MLP-5 як основи оперативної системи прогнозування, у якій оцінка споживання оновлюється кожні 3 години після надходження нових даних. Формування необхідних вхідних характеристик не потребує складних обчислювальних процедур, а архітектура моделі є достатньо компактною для оперативного застосування без спеціалізованих графічних обчислювачів. Для практичного впровадження доцільно здійснювати постійний контроль WAPE та систематичного зміщення прогнозу, окремо аналізувати точність у перехідні сезонні періоди та передбачити резервну схему прогнозування у випадку відсутності необхідних метеорологічних або історичних даних.

Таким чином, результати дослідження підтверджують, що точність прогнозування газоспоживання за допомогою багатопарового персептрона значною мірою визначається не ускладненням архітектури нейронної мережі, а обґрунтованим формуванням системи вхідних ознак, яка відображає метеорологічні умови, часові закономірності, інерційність та багатомасштабну циклічність процесу. Найбільше підвищення точності забезпечує введення характеристик попередньої динаміки газоспоживання, що обґрунтовує перспективність подальшого розвитку моделей, орієнтованих на комплексне врахування часової структури процесу та адаптацію до змін умов його функціонування.

Список бібліографічного опису

1. Liu J., Wang S., Wei N., Chen X., Xie H., Wang J. Natural gas consumption forecasting: A discussion on forecasting history and future challenges. *Journal of Natural Gas Science and Engineering*. 2021. Vol. 90. Article 103930. DOI: 10.1016/j.jngse.2021.103930.
2. Šebalj D., Mesarić J., Dujak D. Analysis of methods and techniques for prediction of natural gas consumption: A literature review. *Journal of Information and Organizational Sciences*. 2019. Vol. 43, No. 1. P. 99–117. DOI: 10.31341/jios.43.1.6.
3. Szoplik J. Forecasting of natural gas consumption with artificial neural networks. *Energy*. 2015. Vol. 85. P. 208–220. DOI: 10.1016/j.energy.2015.03.084.
4. Merkel G. D., Povinelli R. J., Brown R. H. Short-Term Load Forecasting of Natural Gas with Deep Neural Network Regression. *Energies*. 2018. Vol. 11, No. 8. Article 2008. DOI: 10.3390/en11082008.
5. Laib O., Khadir M. T., Mihaylova L. Toward efficient energy systems based on natural gas consumption prediction with LSTM Recurrent Neural Networks. *Energy*. 2019. Vol. 177. P. 530–542. DOI: 10.1016/j.energy.2019.04.075.
6. Wei N., Li C., Peng X., Li Y., Zeng F. Daily natural gas consumption forecasting via the application of a novel hybrid model. *Applied Energy*. 2019. Vol. 250. P. 358–368. DOI: 10.1016/j.apenergy.2019.05.023.
7. Karabiber O. A., Xydis G. A review of the day-ahead natural gas consumption in Denmark: starting point towards forecasting accuracy improvement. *International Journal of Coal Science & Technology*. 2021. Vol. 8. P. 1–22. DOI: 10.1007/s40789-020-00331-2.
8. Fabbiani E., Marziali A., De Nicolao G. Forecasting residential gas demand: machine learning approaches and seasonal role of temperature forecasts. *International Journal of Oil, Gas and Coal Technology*. 2021. Vol. 26, No. 2. P. 202–224. DOI: 10.1504/IJOGCT.2021.112881.
9. Marziali A., Fabbiani E., De Nicolao G. Ensembling methods for countrywide short-term forecasting of gas demand. *International Journal of Oil, Gas and Coal Technology*. 2021. Vol. 26, No. 2. P. 184–201. DOI: 10.1504/IJOGCT.2021.112874.
10. Sharma V., Cali Ü., Sardana B., Kuzlu M., Banga D., Pipattanasomporn M. Data-driven short-term natural gas demand forecasting with machine learning techniques. *Journal of Petroleum Science and Engineering*. 2021. Vol. 206. Article 108979. DOI: 10.1016/j.petrol.2021.108979.
11. Panek W., Włodek T. Natural Gas Consumption Forecasting Based on the Variability of External Meteorological Factors Using Machine Learning Algorithms. *Energies*. 2022. Vol. 15, No. 1. Article 348. DOI: 10.3390/en15010348.
12. Petkovic M., Chen Y., Gamrath I., Gotzes U., Hadjidimitrou N. S., Zittel J., Xu X., Koch T. A hybrid approach for high precision prediction of gas flows. *Energy Systems*. 2022. Vol. 13, No. 2. P. 383–408. DOI: 10.1007/s12667-021-00466-4.
13. Smajla I., Vulin D., Karasalihović Sedlar D. Short-term forecasting of natural gas consumption by determining the

- statistical distribution of consumption data. *Energy Reports*. 2023. Vol. 10. P. 2352–2360. DOI: 10.1016/j.egy.2023.09.051.
14. Singh S., Bansal P., Hosen M., Bansal S. K. Forecasting annual natural gas consumption in USA: Application of machine learning techniques—ANN and SVM. *Resources Policy*. 2023. Vol. 80. Article 103159. DOI: 10.1016/j.resourpol.2022.103159.
15. Gao F., Shao X. Forecasting annual natural gas consumption via the application of a novel hybrid model. *Environmental Science and Pollution Research*. 2021. Vol. 28, No. 17. P. 21411–21424. DOI: 10.1007/s11356-020-12275-w.
16. Ceylan Z. Comparative analysis of deep learning and classical time series methods to forecast natural gas demand during COVID-19 pandemic. *Energy Sources, Part B: Economics, Planning, and Policy*. 2023. Vol. 18, No. 1. Article 2241455. DOI: 10.1080/15567249.2023.2241455.
17. Wang H., Gao X., Zhang Y., Yang Y. Natural Gas Consumption Forecasting Model Based on Feature Optimization and Incremental Long Short-Term Memory. *Sensors*. 2025. Vol. 25, No. 10. Article 3079. DOI: 10.3390/s25103079.
18. Pavlov K., Pavlova O., Wołowicz T., Slobodian S., Tymchyshak A., Vlasenko T. Robust Gas Demand Prediction Using Deep Neural Networks: A Data-Driven Approach to Forecasting Under Regulatory Constraints. *Energies*. 2025. Vol. 18, No. 14. Article 3690. DOI: 10.3390/en18143690.
19. Lytvynenko I., Lupenko S., Kunanets N., Nazarevych O., Shymchuk G., Hotovych V. Simulation of gas consumption process based on the mathematical model in the form of cyclic random process considering the scale factors. *CEUR Workshop Proceedings*. 2021. Vol. 3039. P. 97–106.
20. Lytvynenko I., Lupenko S., Nazarevych O., Shymchuk H., Hotovych V. Additive mathematical model of gas consumption process. *Scientific Journal of TNTU*. 2021. Vol. 104, No. 4. P. 87–97. DOI: 10.33108/visnyk_tntu2021.04.087.
21. Shymchuk G., Lytvynenko I., Hromyak R., Lytvynenko S., Hotovych V. Gas Consumption Forecasting Using Machine Learning Methods and Taking Into Account Climatic Indicators. *CEUR Workshop Proceedings*. 2023. Vol. 3468. P. 156–163.
22. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.
23. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*. San Diego, CA, USA, 2015.
24. Nair V., Hinton G. E. Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*. Haifa, Israel, 2010. P. 807–814.
25. Altmann A., Tološi L., Sander O., Lengauer T. Permutation importance: a corrected feature importance measure. *Bioinformatics*. 2010. Vol. 26, No. 10. P. 1340–1347. DOI: 10.1093/bioinformatics/btq134.
26. Hyndman R. J., Koehler A. B. Another look at measures of forecast accuracy. *International Journal of Forecasting*. 2006. Vol. 22, No. 4. P. 679–688. DOI: 10.1016/j.ijforecast.2006.03.001.
27. Bergmeir C., Benítez J. M. On the use of cross-validation for time series predictor evaluation. *Information Sciences*. 2012. Vol. 191. P. 192–213. DOI: 10.1016/j.ins.2011.12.028.
28. Tashman L. J. Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting*. 2000. Vol. 16, No. 4. P. 437–450. DOI: 10.1016/S0169-2070(00)00065-0.

References

1. Liu J., Wang S., Wei N., Chen X., Xie H., Wang J. Natural gas consumption forecasting: A discussion on forecasting history and future challenges. *Journal of Natural Gas Science and Engineering*. 2021. Vol. 90. Article 103930. DOI: 10.1016/j.jngse.2021.103930.
2. Šebalj D., Mesarić J., Dujak D. Analysis of methods and techniques for prediction of natural gas consumption: A literature review. *Journal of Information and Organizational Sciences*. 2019. Vol. 43, No. 1. P. 99–117. DOI: 10.31341/jios.43.1.6.
3. Szoplik J. Forecasting of natural gas consumption with artificial neural networks. *Energy*. 2015. Vol. 85. P. 208–220. DOI: 10.1016/j.energy.2015.03.084.
4. Merkel G. D., Povinelli R. J., Brown R. H. Short-Term Load Forecasting of Natural Gas with Deep Neural Network Regression. *Energies*. 2018. Vol. 11, No. 8. Article 2008. DOI: 10.3390/en11082008.
5. Laib O., Khadir M. T., Mihaylova L. Toward efficient energy systems based on natural gas consumption prediction with LSTM Recurrent Neural Networks. *Energy*. 2019. Vol. 177. P. 530–542. DOI: 10.1016/j.energy.2019.04.075.
6. Wei N., Li C., Peng X., Li Y., Zeng F. Daily natural gas consumption forecasting via the application of a novel hybrid model. *Applied Energy*. 2019. Vol. 250. P. 358–368. DOI: 10.1016/j.apenergy.2019.05.023.
7. Karabiber O. A., Xydis G. A review of the day-ahead natural gas consumption in Denmark: starting point towards forecasting accuracy improvement. *International Journal of Coal Science & Technology*. 2021. Vol. 8. P. 1–22. DOI: 10.1007/s40789-020-00331-2.
8. Fabbiani E., Marziali A., De Nicolao G. Forecasting residential gas demand: machine learning approaches and seasonal role of temperature forecasts. *International Journal of Oil, Gas and Coal Technology*. 2021. Vol. 26, No. 2. P. 202–224. DOI: 10.1504/IJOGCT.2021.112881.
9. Marziali A., Fabbiani E., De Nicolao G. Ensembling methods for countrywide short-term forecasting of gas demand. *International Journal of Oil, Gas and Coal Technology*. 2021. Vol. 26, No. 2. P. 184–201. DOI: 10.1504/IJOGCT.2021.112874.
10. Sharma V., Cali Ü., Sardana B., Kuzlu M., Banga D., Pipattanasomporn M. Data-driven short-term natural gas demand forecasting with machine learning techniques. *Journal of Petroleum Science and Engineering*. 2021. Vol. 206. Article 108979. DOI: 10.1016/j.petrol.2021.108979.
11. Panek W., Włodek T. Natural Gas Consumption Forecasting Based on the Variability of External Meteorological

- Factors Using Machine Learning Algorithms. *Energies*. 2022. Vol. 15, No. 1. Article 348. DOI: 10.3390/en15010348.
12. Petkovic M., Chen Y., Gamrath I., Gotzes U., Hadjidimitrou N. S., Zittel J., Xu X., Koch T. A hybrid approach for high precision prediction of gas flows. *Energy Systems*. 2022. Vol. 13, No. 2. P. 383–408. DOI: 10.1007/s12667-021-00466-4.
13. Smajla I., Vulin D., Karasalihović Sedlar D. Short-term forecasting of natural gas consumption by determining the statistical distribution of consumption data. *Energy Reports*. 2023. Vol. 10. P. 2352–2360. DOI: 10.1016/j.egyr.2023.09.051.
14. Singh S., Bansal P., Hosen M., Bansal S. K. Forecasting annual natural gas consumption in USA: Application of machine learning techniques—ANN and SVM. *Resources Policy*. 2023. Vol. 80. Article 103159. DOI: 10.1016/j.resourpol.2022.103159.
15. Gao F., Shao X. Forecasting annual natural gas consumption via the application of a novel hybrid model. *Environmental Science and Pollution Research*. 2021. Vol. 28, No. 17. P. 21411–21424. DOI: 10.1007/s11356-020-12275-w.
16. Ceylan Z. Comparative analysis of deep learning and classical time series methods to forecast natural gas demand during COVID-19 pandemic. *Energy Sources, Part B: Economics, Planning, and Policy*. 2023. Vol. 18, No. 1. Article 2241455. DOI: 10.1080/15567249.2023.2241455.
17. Wang H., Gao X., Zhang Y., Yang Y. Natural Gas Consumption Forecasting Model Based on Feature Optimization and Incremental Long Short-Term Memory. *Sensors*. 2025. Vol. 25, No. 10. Article 3079. DOI: 10.3390/s25103079.
18. Pavlov K., Pavlova O., Wołowiec T., Slobodian S., Tymchyshak A., Vlasenko T. Robust Gas Demand Prediction Using Deep Neural Networks: A Data-Driven Approach to Forecasting Under Regulatory Constraints. *Energies*. 2025. Vol. 18, No. 14. Article 3690. DOI: 10.3390/en18143690.
19. Lytvynenko I., Lupenko S., Kunanets N., Nazarevych O., Shymchuk G., Hotovych V. Simulation of gas consumption process based on the mathematical model in the form of cyclic random process considering the scale factors. *CEUR Workshop Proceedings*. 2021. Vol. 3039. P. 97–106.
20. Lytvynenko I., Lupenko S., Nazarevych O., Shymchuk H., Hotovych V. Additive mathematical model of gas consumption process. *Scientific Journal of TNTU*. 2021. Vol. 104, No. 4. P. 87–97. DOI: 10.33108/visnyk_tntu2021.04.087.
21. Shymchuk G., Lytvynenko I., Hromyak R., Lytvynenko S., Hotovych V. Gas Consumption Forecasting Using Machine Learning Methods and Taking Into Account Climatic Indicators. *CEUR Workshop Proceedings*. 2023. Vol. 3468. P. 156–163.
22. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.
23. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*. San Diego, CA, USA, 2015.
24. Nair V., Hinton G. E. Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*. Haifa, Israel, 2010. P. 807–814.
25. Altmann A., Tološi L., Sander O., Lengauer T. Permutation importance: a corrected feature importance measure. *Bioinformatics*. 2010. Vol. 26, No. 10. P. 1340–1347. DOI: 10.1093/bioinformatics/btq134.
26. Hyndman R. J., Koehler A. B. Another look at measures of forecast accuracy. *International Journal of Forecasting*. 2006. Vol. 22, No. 4. P. 679–688. DOI: 10.1016/j.ijforecast.2006.03.001.
27. Bergmeir C., Benítez J. M. On the use of cross-validation for time series predictor evaluation. *Information Sciences*. 2012. Vol. 191. P. 192–213. DOI: 10.1016/j.ins.2011.12.028.
28. Tashman L. J. Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting*. 2000. Vol. 16, No. 4. P. 437–450. DOI: 10.1016/S0169-2070(00)00065-0.

Історія статті:

Отримано: 28.05.2026 Доопрацьовано: 21.09.2026 Прийнято до друку: 23.09.2026 Опубліковано: 29.09.2026