

УДК 681.5: 68.004.8

DOI 10.36910/10.36910/6775-2313-5352-2023-23-08

Матіко Ф.Д., Чабан В.Я., Масняк О.Я.

Національний університет «Львівська політехніка»

АНАЛІЗ МЕТОДІВ ТА МОДЕЛЕЙ ДЛЯ АВТОМАТИЗАЦІЇ ПРОГНОЗУВАННЯ ОБСЯГІВ СПОЖИВАННЯ ЕНЕРГОНОСІЇВ

В статті розглянуто застосування для прогнозування обсягів споживання енергоносіїв статистичних моделей, штучних нейронних мереж, адаптивних нейро-нечітких систем. Показано, що використання штучних нейронних мереж дає можливість моделювати складні залежності між вхідними та вихідними параметрами. Виділено недоліки застосування нейромереж для прогнозування обсягів споживання газу, зокрема, великий обсяг даних для тренування мережі, наявність експертних знань та досвіду у дослідника, висока обчислювальна складність навчання та застосування мережі. Визначено також переваги математичних моделей для прогнозування обсягів споживання газу, що дозволяє отримати більш точні результати, забезпечує можливість урахування експертного досвіду, дозволяє адаптувати модель до змінних умов та встановлювати причинно-наслідкові зв'язки. Обґрунтовано доцільність розроблення автоматизованої системи прогнозування обсягів споживання природного газу на основі комбінованого методу прогнозування, який поєднує детерміновані залежності обсягів споживання від основних вхідних параметрів та застосування нейромережі для опису впливу багатьох випадкових факторів.

Ключові слова: математична модель, обсяги споживання, природний газ, методи прогнозування, фактори впливу, нейронна мережа.

Постановка проблеми. Природний газ є важливою сировиною для промисловості та найбільш споживаним енергоносієм, і його використання з належним плануванням є надзвичайно важливим для суспільства. Потрібно також підкреслити, що природний газ це ресурс, дія якого на довкілля може призвести до незворотних екологічних наслідків. Тому прогнозоване, економне, дбайливе використання природного газу є головною турботою газової промисловості, інших галузей діяльності та уряду [1].

Україна, як великий споживач природного газу, постійно стикається з викликами його ефективного використання. Залежність від імпорту та обмежені власні запаси природного газу вимагають постійного вдосконалення систем управління та прогнозування споживання газу. Для реалізації автоматизованих систем прогнозування обсягів споживання природного газу важливу роль відіграє наявність математичних моделей процесів розподілу та споживання природного газу. Використання таких моделей дає можливість аналізувати тенденції споживання природного газу, передбачати пікові навантаження, виявляти потенційні економічні збитки та розробляти стратегії зменшення його витрат.

Розроблення точних моделей прогнозування обсягів споживання енергоносіїв є складною проблемою, яка ще недостатньо досліджена. Зокрема для прогнозування обсягів споживання природного газу така модель повинна враховувати вплив температури, вологості атмосферного повітря, соціальних та багатьох інших факторів. Тому глибокий аналіз процесів споживання природного газу, виявлення всіх впливових факторів та розроблення моделей і методів для прогнозування споживання газу є важливими та актуальними завданнями.

Наявність моделей та методів прогнозування обсягів споживання енергоносіїв дає можливість розробити автоматизовані системи прогнозування їх споживання, які надають учасникам ринку енергоносіїв можливість динамічно в реальному часі реагувати на впливи техногенних, соціальних та економічних факторів, що надзвичайно важливо для економіки нашої держави в умовах воєнного стану.

Метою статті є аналіз методів та моделей для автоматизації прогнозування обсягів споживання енергоносіїв, визначення їх області застосування, переваг та недоліків, на основі чого виокремлення методів та моделей для прогнозування обсягів споживання природного газу. Удосконалення виділених методів та моделей дасть можливість у подальшому розробити автоматизовану систему прогнозування обсягів споживання природного газу.

Аналіз методів та моделей для прогнозування показників детермінованих та випадкових процесів. Аналіз детермінованих процесів передбачає використання

математичних моделей, які враховують закономірності та фактори, що впливають на процес. Наприклад, лінійна регресія, аналіз часових рядів та аналіз факторів є добре відомими методами прогнозування детермінованих процесів. Ці методи базуються на залежностях між показниками та їх факторами, та дозволяють прогнозувати майбутні значення з високою точністю. Такі методи застосовані авторами у роботах [2, 3] для прогнозування подового обсягу споживання на основі відомого обсягу споживання за місяць.

У випадку випадкових процесів, прогнозування є складнішим завданням, оскільки показники змінюються випадковим чином. Для таких процесів використовують статистичні методи та моделі, такі як ARIMA, GARCH, ANFIS та VAR [4 - 9]. Ці методи дозволяють враховувати статистичні характеристики процесу, такі як середнє значення, дисперсія та кореляція.

Також існують інші методи та моделі, які поєднують у собі як детерміновані, так і стохастичні елементи. Наприклад, нейронні мережі та генетичні алгоритми можуть використовуватись для прогнозування як детермінованих, так і випадкових процесів. Авторами проаналізовано особливості кожної моделі, представлені в науково-технічних джерелах, а також область їх застосування.

СТАТИСТИЧНІ МОДЕЛІ.

1) Моделі ARIMA (autoregressive integrated moving average – авторегресійне інтегроване ковзне середнє) визначають лінійний зв'язок між послідовними даними [4]. Це найпоширеніший клас моделей для прогнозування часових рядів. Випадкові величини, які є часово-змінними рядами, якщо їх статистичні характеристики залишаються сталими в часі, то моделі ARIMA можуть бути найбільш відповідним вибором. Ці моделі покладені в основу різноманітних застосунків для прогнозування споживання природного газу. Джунхуї Гуо (2019) використовував дані цін на нафту WTI за останні тридцять три роки для навчання моделі ARIMA [5]. Проте, навчальні дані містили відмінності у цінах нафти між 2000 і 2013 роками, що ускладнило навчання за допомогою примітивних моделей ARIMA. Дослідники зауважили, що часово-змінні дані часто називають стаціонарними, якщо протягом заданого періоду T логарифм ціни на нафту WTI має однаковий розподіл протягом часу T . Додатково вони додали, що стаціонарність часто перевіряють за допомогою тесту Дікі-Фулера. Крім того, вони розклали дані логарифму ціни на нафту на тренд сезонності встановивши частоту сезонної декомпозиції на 360 днів. Порівняно з іншими моделями, модель ARIMA має найнижче значення R^2 порівняно з іншими алгоритмами прогнозування і мало придатна для опрацювання даних з великими варіаціями [4].

Модель Вох-Дженкінса є статистичним методом прогнозування, який успішно використовують для прогнозування часових рядів з однією змінною на короткий і середній терміни [6]. Підхід Вох-Дженкінса став популярним завдяки таким особливостям, як можливість використання для опрацювання часових рядів з різними характеристиками, наявне теоретичне обґрунтування та досвід успішного застосування для різних задач. Підхід Вох-Дженкінса є інтеграцією авторегресійного методу (AR) та методу ковзного середнього (MA) і може бути застосований до стаціонарних часових рядів. Для забезпечення стаціонарності в нестаціонарних часових рядах використовують диференційний метод. Зазвичай цю модель позначають як ARIMA (p, d, q). Тут p та q – це, відповідно, порядок авторегресійної (AR) моделі та моделі ковзного середнього (MA), а d - порядок диференціювання. Основне рівняння ARIMA-моделі можна записати у вигляді [4]:

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q}, \quad (1)$$

де δ - стала, $Z_t, Z_{t-1}, \dots, Z_{t-p}$ і $\Phi_1, \Phi_2, \dots, \Phi_p$ є, відповідно, диференційованими спостереженнями та коефіцієнтами цих спостережень; $a_t, a_{t-1}, \dots, a_{t-q}$ представляють похибки, а $\Theta_1, \Theta_2, \dots, \Theta_q$ - це коефіцієнти впливу похибок [4].

У моделях ARIMA прогнозування здійснюють за чотири етапи. По-перше, перевіряють стаціонарність ряду та забезпечують стаціонарність нестаціонарного ряду, визначають відповідну моделі Бокса-Дженкінса. По-друге, прогнозують параметри моделі. Потім перевіряють статистичними методами відповідність моделі набору даних. Якщо відповідність моделі, отриманої на попередньому етапі, підтверджено, то переходять до четвертого етапу, якщо ні, то повертаються до першого етапу. Під час четвертого етапу застосовують отриману модель для прогнозування [6].

2) Модель MLR (Multiple Linear Regression - множинна лінійна регресія) застосовують для визначення зв'язку між багатьма випадковими характеристиками прицесу або змінними.

Інакше кажучи, MLR аналізує, наскільки тісно декілька незалежних змінних пов'язані або взаємозв'язані з однією залежною змінною. MLR передбачає наявність лінійного відношення між залежними та незалежними змінними, а також відсутність значної кореляції між незалежними змінними. М. Козельський (2019) [7] запропонували мета-модель, яка відтворює взаємозв'язок між моделями та характеристиками споживання LPG газу клієнтами та враховує багато факторів. Мета-модель може бути виражена у вигляді лінійної комбінації базових залежностей і має вигляд: $y = a_1 * x_1 + \dots + a_m * x_m + b$, де: m - загальна кількість розглянутих впливних величин [7].

Надані дані включали в себе щогодинні виміри з трьохсот LPG балонів. Кожний запис містив дату і час, відсоток рівня газу у балонах і температуру приміщення. Дослідники прийшли до висновку, що ця модель працює добре, коли горизонт прогнозування є щотижневим або щомісячним.

3) Експоненційне згладжування (Exponential Smoothing). Експоненційне згладжування є методом прогнозування часових рядів, який використовує попередні дані з ваговими коефіцієнтами. Цей метод заснований на усередненні попередніх значень з певними ваговими коефіцієнтами, де більший ваговий коефіцієнт надає більшу вагу ближчим даним. У випадку дослідження Альдіни Корреї [8] використовувалася модель експоненційного згладжування для прогнозування споживання газу з LPG балонів португальської газової компанії.

Дослідники аналізували деталі, такі як кількість продажів та повернень балонів, запаси різних типів балонів. Вони враховували те, що споживання з газових балонів LPG зазвичай зростає в холодні місяці через збільшений попит на приготування їжі та нагрівання води. Дослідники використовували ковзне середнє та обчислювали сезонні індекси для визначення кількості споживання газу в різні місяці. Після цього вони «десезонізували» дані, використовуючи отримані сезонні коефіцієнти, та застосували метод Холта для прогнозування продажів та повернень газових балонів. Важливо відзначити, що ефективність цієї моделі прогнозування може залежати від обсягу доступних даних, оскільки в іншому випадку сезонні коефіцієнти можуть значно відрізнятися від фактичних значень, що може вплинути на точність прогнозів [8].

4) Модель ANFIS (Adaptive Network Fuzzy Inference System - адаптивна мережева система з нечітким висновком). Це система з нечіткою (fuzzy) логікою висновку, яка розроблена в рамках нейронних мереж. Цей метод був представлений Jang [9]. Алгоритм ANFIS можна навчати за допомогою методу градієнтного спуску в поєднанні з методом найменших квадратів. Загальну структуру ANFIS показано на рисунку 1 [9].




Рисунок 1 – Загальна структура моделі ANFIS з двома вхідними змінними: x , y – вхідні змінні; A_1 , A_2 , B_1 , B_2 – рівняння нечітких множин; Π – шар формування добутків зважених входів; N – шар нормалізації; ω_1 , ω_2 – вихідні вагові функції шару Π ; $\bar{\omega}_1$, $\bar{\omega}_2$ – нормалізовані ступені активації; $\bar{\omega}_1 f_1$, $\bar{\omega}_2 f_2$ – вихідні дефазифіковані сигнали; f – загальна вихідна функція ANFIS

Різні змінні впливають на споживання природного газу, такі як кількість населення, температура атмосферного повітря, ВВП, обсяг використання інших видів енергії тощо. У

роботі [9] населення та ВВП вважаються найбільш важливими факторами, а отже вважаються вхідними змінними для ANFIS. Збір даних – один з головних головний крок у процесі прогнозування, тому дані для вхідних змінних (кількість населення та ВВП) і вихідних змінних (споживання газу) зібрані з 1993 по 2012 рік. Також всі дані введення та виведення перед обробкою були нормалізовані. Це дуже важлива процедура, оскільки якість відповіді моделі безпосередньо залежить від якості формування даних, і незважаючи на високу якість моделі, якщо зібрані дані не мають необхідної якості, кінцева відповідь моделі не буде надійною. Авторами [9] дані були зібрані від British Petroleum та Всесвітнього банку. Всі дані були розділені на дві групи: навчальні дані та тестові дані. Зазвичай навчальні дані складають від 70% до 90% всіх даних, а решта даних використовується для тестування. Відповідно в роботі [9] дані з 1993 по 2007 рік вважаються навчальними даними, а дані з 2008 по 2012 рік – тестовими даними.

Усі моделі ANFIS формують відповідно до двох основних параметрів: типу функції належності та кількості лінгвістичних змінних. Кількість лінгвістичних змінних може бути від 2 до 20. Було сформовано багато ANFIS-моделей з одинадцятьма функціями належності, проте моделі з шістьма функціями належності мають прийнятну відповідь. Застосовують такі функції належності: узагальнену дзвоноподібну вбудовану функцію належності (gbell), вбудовану функцію належності з гаусівською кривою (gauss), функцією приналежності з комбінованою гаусівською кривою (gauss2), з різницею між двома сигмоїдними функціями належності (dsig), з добутком двох сигмоїдних функцій належності (psig), вбудовану функцію належності з формою "π" (pi) [9].

Для вибору прийнятної моделі ANFIS потрібно знайти критерій середньої абсолютної відсоткової похибки (Mean Absolute Percentage Error, MAPE) для кожної моделі з кожною функцією приналежності та кожною лінгвістичною змінною. Критерій MAPE обчислюють за формулою [9]:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_t - x'_t}{x_t} \right|}{n} \quad (2)$$

У роботі [9] значення кількості населення та ВВП з 2013 по 2020 рік прогнозуються за допомогою авторегресійної моделі. Вони подаються на вхід до навченої моделі ANFIS, яка обчислює значення споживання газу з 2013 по 2020 рік як вихідний параметр. За результатами досліджень навчених моделей ANFIS з різними ваговими функціями встановлено [9], що модель із вбудованою функцією належності "gauss" та трьома лінгвістичними змінними є кращою серед інших моделей, оскільки має найменшу відсоткову помилку (MAPE).

МОДЕЛІ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ. Штучні нейронні мережі (Artificial neural networks - ANN) розроблені на основі результатів вивчення активності мозку та мають характеристики продуктивності, подібні до біологічних нейронних мереж. ANN має багато важливих можливостей, таких як навчання на основі даних, узагальнення, робота з необмеженою кількістю змінних. ANN зазвичай складається з кількох шарів багатьох обчислювальних елементів, які називаються вузлами. Кожен вузол отримує вхідний сигнал від інших вузлів або зовнішніх вхідних сигналів, а потім після обробки сигналів локально через функцію переносу, він виводить перетворений сигнал до інших вузлів або до вузла формування кінцевого результату [6].

На сьогодні розроблено багато моделей штучних нейронних мереж для використання в різних галузях діяльності (MLP, RBF, LVQ, Hopfield, Recurrent, FCNN, SOM, LSTM, ART тощо). Нижче розглянуто детальніше деякі з них:

1) Conventional Neural Network (звичайна нейронна мережа). Звичайна штучна нейронна мережа (ANN) є аналітичним методом, інспірованим біологічними процесами в людському мозку, який використовують для аналізу та прогнозування даних у часових рядах. ANN складається з простих обчислювальних елементів, які працюють разом, і має здатність вчитися на основі наданих прикладів, створюючи певні зв'язки з даними. У дослідженні, проведеному Ногасіо Рaggi (2014), була використана штучна нейронна мережа для прогнозування споживання пропану у газових балонах [10]. Аналізовані дані включали щоденні споживання газу, атмосферну температуру, погодні умови тощо. Щоб прогнозувати щотижневе споживання, дослідники об'єднали щоденні дані з понеділка по суботу. У іншому дослідженні Прабод Кумар Прадхан (2018) також застосував ANN для прогнозування споживання природного газу [11]. Він використав п'ять різних вхідних параметрів для навчання мережі,

включаючи щоденний попит, температуру, вологість, опади та інші показники. Результати досліджень показали, що використання штучних нейронних мереж (ANN) дозволило отримати кращі прогнози в порівнянні з класичними моделями прогнозування. Застосування ANN виявилось ефективним у прогнозуванні споживання природного газу за різних погодних умов [11].

2) Нечітка когнітивна нейронна мережа (Fuzzy Cognitive Neural Network, FCNN) дає можливість створювати складні та нелінійні моделі процесів. У дослідженні, проведеному Katarzyna Poczeta (2018), була запропонована модель, яка комбінує техніку нечіткої моделі кластеризації (FCM) зі звичайною штучною нейронною мережею (ANN) для створення каскадної моделі [12]. Оптимізація структури цієї моделі здійснюється за допомогою генетичних алгоритмів, які вибирають найважливіші концепції (вузли) для нечітких когнітивних карт. Ці обрані концепції потім використовуються у FCM як вхідні дані для навчання штучних нейронних мереж. Після подання цих обраних атрибутів даних у формі вузлів як вхідних даних для штучних нейронних мереж, модель може вчитися за допомогою методів зворотнього поширення. Гібридна модель FCM-ANN, яку було запропоновано, показала відмінні прогностичні здатності та здатність адаптуватися до складних структур даних у порівнянні зі стандартними моделями штучних нейронних мереж (ANN). Це дозволяє застосовувати цей метод для прогнозування в різних областях, де потрібна висока точність та гнучкість у моделюванні складних систем [12].

3) Мережа LSTM (Long Short-Term Memory - довга короткочасна пам'ять) - це тип рекурентної нейронної мережі (RNN), розроблений для вирішення завдань, пов'язаних з моделюванням довгострокових залежностей в послідовних даних. LSTM є корисним інструментом для прогнозування часових рядів та використовується в різноманітних галузях, де необхідно аналізувати та прогнозувати дані на основі минулих інформаційних шаблонів. У дослідженні, проведеному Athanasios Anagnostis (2019), LSTM використовувалася для прогнозування потреби в природному газі на наступний день у трьох центрах розподілу в Греції [13]. Для побудови моделі використовувалися історичні дані попиту на природний газ протягом понад 5 років. LSTM навчали на попередніх 4 роках даних, використовуючи дані зазначених 364 днів для прогнозування наступних 364 днів. Отримані результати показали, що модель LSTM успішно вирішує завдання прогнозування природного газу при невеликій кількості вхідних змінних. Проте зі збільшенням кількості вхідних змінних, продуктивність LSTM може зменшуватись. Це вказує на те, що у деяких випадках збільшення складності моделі може призвести до зниження її ефективності [13].

4) Багатошарові перцептрони (Multiple Layer Perceptron, MLP). Нейрони та шари у мережах MLP організовані у прямому напрямку. У MLP перший шар є вхідним, де отримують зовнішню інформацію про проблему, яку потрібно вирішити. Останній шар є вихідним, де отримують оброблену в мережі інформацію. Шар, який знаходиться між вхідним та вихідним, називається прихованим. У MLP мережах може бути більше одного прихованого шару. На рисунку 2 показано архітектуру типової MLP мережі [6].

Головна роль штучної нейронної мережі (ANN) полягає в тому, щоб навчитися та сформувати структуру набору вихідних даних для їх узагальнення. Для цього мережу навчають, використовуючи вибірку вхідних даних. Під час процесу навчання, приклади вхідних даних або шаблони подають до вхідного шару мережі. Значення активації вхідних вузлів зважуються за допомогою коефіцієнтів v_{ij} та накопичуються в кожному вузлі прихованого шару. Зважена сума передається відповідною функцією, щоб створити значення активації вузла. Вихід прихованого шару j можна обчислити за наступною формулою [6]:

$$z_j = f\left(v_{oj} + \sum_{i=1}^N v_{ij}x_i\right) \quad (3)$$

5) Радіальна базисна функційна мережа (RBFN). Традиційно використовується для вирішення інтерполяційних проблем в багатовимірному просторі та має схожі можливості з MLP нейронною мережею, яка вирішує будь-яку проблему апроксимації функції.

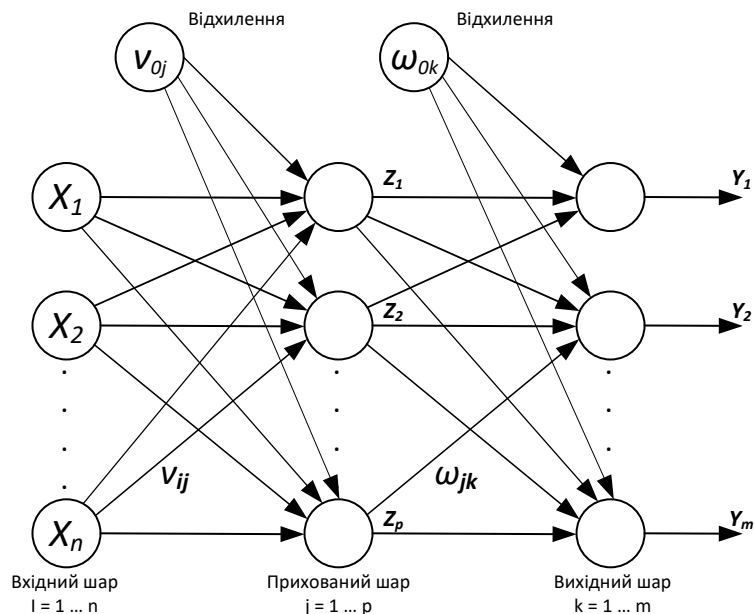


Рисунок 2 – Нейронна мережа з багатьма шарами [6], де X_1, X_2, \dots, X_n – вхідні величини; v_{ij} – ваговий коефіцієнт зв'язку, що з'єднує i -тий вхід з прихованим вузлом j ; ω_{jk} – ваговий коефіцієнт, що з'єднує j -ий вхід прихованого шару з вихідним вузлом k ; v_{0j}, ω_{0k} – відхилення; Z_1, Z_2, \dots, Z_p – вихідні величини прихованого шару; Y_1, Y_2, \dots, Y_m – вихідні величини мережі

RBF-функції були вперше використані для проектування нейронної мережі Брумхедом і Лоу, які показали, як RBF нейронна мережа моделює нелінійний зв'язок та вирішує проблеми інтерполяції. Перевагами RBFN є те, що вона може бути навчена протягом короткого часу порівняно з MLP та наближати найкраще рішення без проблеми з локальними мінімумами. Крім того, RBFN це локальні мережі порівняно з мережами прямого поширення, які виконують глобальне відображення. Це означає, що RBFN використовує один набір обчислювальних одиниць, кожна з яких найбільш чутлива до локальної області вхідного простору. Завдяки цим особливостям RBFN були широко застосовані як альтернативна модель нейронних мереж у таких застосуваннях як апроксимація функцій, прогнозування часових рядів, а також завданнях класифікації [6].

RBFN складається з трьох шарів, як показано на рисунку 3. Основною відмінністю між MLP та RBFN є те, що у RBFN є один прихований шар, який містить вузли, що називаються RBF-блоками [6].

Вхідний шар служить лише для розподілу вхідних сигналів до прихованого шару. На відміну від MLP, значення з вхідного шару передаються без множення на вагові коефіцієнти. Одиниця прихованого шару вимірює відстань між вектором входу та центром радіальної функції і формує значення на виході в залежності від відстані. Центр радіальної базисної функції називається опорним вектором. Чим ближче вхідний вектор до опорного вектора, тим більше значення буде сформоване на виході прихованого вузла. Хоча для використання в прихованому шарі запропоновано багато радіальних базисних функцій (Гауса, мультікватратична, узагальнена мультікватратична), у більшості випадків в застосуваннях використовують гаусівську функцію. Функція активації окремих прихованих вузлів, визначена гаусівською функцією [6].

Під час навчання мережі RBF можуть виникати дві проблеми: проблема обчислювальної складності при великому розмірі набору даних та проблема перенавчання, яка виникає, коли тренувальні дані містять шум. Для зменшення обчислювальної складності та вирішення проблеми перенавчання кількість нейронів у прихованому шарі встановлюють менше, ніж кількість прикладів у вхідному наборі даних. В цьому випадку центральні вектори вибирають з вхідних векторів випадковим чином [6].

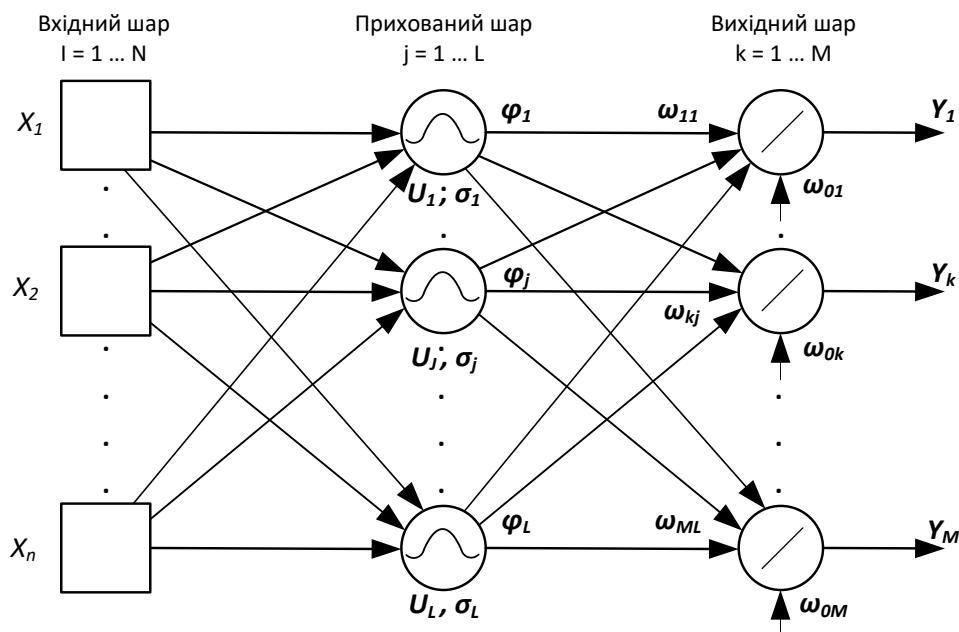


Рисунок 3 - Радіальна базисна функційна мережа, де X_1, X_2, \dots, X_n – вхідні величини; v_{ij} – вагове значення, що з'єднує i -тий вхід з прихованим вузлом j ; ω_{jk} – вагове значення, що з'єднує j -тий вхід прихованого шару з вихідним вузлом k ; $\omega_{01}, \omega_{0k}, \omega_{0M}$ – відхилення; $\varphi_1, \varphi_j, \dots, \varphi_L$ – вихідні величини прихованого шару; Y_1, Y_k, \dots, Y_M – вихідні величини мережі; $\omega_{11}, \omega_{kj}, \dots, \omega_{ML}$ – лінійні вагові значення; U_1, U_j, \dots, U_L – центральні вектори функції Гауса; $\sigma_1, \sigma_j, \dots, \sigma_L$ – радіус-функції Гауса

КОМБІНОВАНІ МОДЕЛІ. Окрім традиційних методів прогнозування, деякі вчені експериментують з використанням комбінації двох чи більше моделей для передбачення споживання природного газу. Це спроба покращити результати, перевірити ефективність різних моделей та порівняти їх з традиційними методами. У своїй роботі Aldina Correia (2020) запропонувала використання методу ансамблю, де моделі для прогнозування щомісячного споживання природного газу поєднуються разом [8]. Вона використовувала модель експоненційного згладжування (формула Холта), модель лінійної регресії (MLR) для урахування різних факторів і штучні нейронні мережі (ANN) з одним шаром та чотирма прихованими вузлами. Ці моделі були об'єднані, кожній з них надавалася вага, щоб створити комплексну модель. Zlatan Sicanica (2018), в свою чергу, провів порівняльне дослідження алгоритмів машинного навчання та нейронних мереж для прогнозування попиту на природний газ [14]. Він порівнював різні моделі, такі як нейронні мережі, дерева рішень, регресія методом опорних векторів та інші за допомогою опрацювання тривалих даних споживання природного газу в Хорватії. Отримані результати вказують на те, що комбінація моделей може дати більш точний прогноз навіть при обмежених вхідних даних. Також, важливо враховувати, що порівняльне оцінювання різних моделей машинного навчання важливе для виявлення їх ефективності та уникнення перенавчання моделей на етапі навчання.

Висновки. В статті розглянуто застосування для прогнозування обсягів споживання енергоносіїв статистичні моделі, штучні нейронні мережі (ANN), адаптивні нейро-нечіткі системи (ANFIS), моделі ARIMA та інші.

З проведеного аналізу видно, що використання штучних нейронних мереж дає можливість моделювати складні залежності між вхідними та вихідними параметрами. Моделі MLP (multilayer perceptron) та RBF (radial basis function) були успішно застосовані для прогнозування випадкових процесів. MLP показала незначно кращі результати порівняно з RBF, але обидві моделі забезпечили адекватні прогнози [6].

Адаптивні нейро-нечіткі системи (ANFIS) є поєднанням нейромережі та нечіткої логіки. Відомі приклади застосування алгоритму групування для генерації початкової структури у ANFIS, що дозволило зменшити кількість нечітких правил та параметрів та поліпшити продуктивність моделі [4, 6]. Більшість дослідників підтверджують, що модель ARIMA виявилася ефективною для прогнозування детермінованих процесів. Застосування

диференціювання для досягнення стаціонарності часового ряду і вибір оптимальної ARIMA моделі дозволили отримати достовірні прогнози.

Отже всі розглянуті методи та моделі показали добрі результати прогнозування показників детермінованих та випадкових процесів. Вибір конкретного методу залежить від конкретного завдання та обсягу даних для опрацювання.

Однак застосування нейромереж для прогнозування споживання газу має такі недоліки:

1) нейромережі часто вимагають великого обсягу даних для тренування та налагодження; отримання достатньої кількості точних даних про споживання газу може бути складним завданням.

2) налаштування нейромереж вимагає експертних знань та досвіду у галузі машинного навчання та може забрати у дослідника багато часу.

3) висока обчислювальна складність: нейромережі можуть вимагати значних обчислювальних ресурсів, особливо для великих та складних моделей; це може стати проблемою при застосуванні нейромереж на малопотужних обчислювальних пристроях.

Натомість, застосування математичних моделей для прогнозування обсягів споживання газу має певні переваги:

1) математичні моделі (аналітичні чи статистичні) можуть враховувати взаємозв'язки між вхідними та вихідними параметрами, що робить їх зрозумілими та детермінованими, а також допомагає менеджерам приймати обґрунтовані рішення під час планування споживання газу;

2) математичні моделі можуть враховувати експертні знання та правила, що визначають взаємозв'язки між змінними, тобто експерти в галузі споживання газу можуть застосувати свої знання та досвід під час розроблення моделі.

3) математичні моделі можуть бути легко модифіковані та адаптовані до нових умов газового ринку та зміни впливних факторів;

4) можлива реалізація математичних моделей на пристроях з обмеженими обчислювальними ресурсами; особливо це актуально для прогнозування в реальному часі.

Отже, використання математичних моделей для прогнозування споживання газу дозволяє отримати більш точні результати, забезпечує можливість урахування експертного досвіду, дозволяє адаптувати модель до змінних умов та встановлювати причинно-наслідкові зв'язки. Це допомагає управляти споживанням газу більш ефективно, планувати ресурси та розробляти стратегії зменшення споживання, що є важливим аспектом у сучасному енергетичному секторі.

У роботі [4] представлено результати кількісного аналізу застосування різних моделей та методів для прогнозування споживання газу. Навчання усіх моделей виконано на основі одних і тих самих масивів даних про споживання газу. Для оцінювання методів застосовано квадрат коефіцієнта кореляції фактичних та прогнозованих значень споживання газу R^2 та середньоквадратичне відхилення (RMSE). За результатами аналізу встановлено, що модель LSTM показала найкращі результати. Також комбінований метод, що складався з нейронних мереж, лінійної регресії Lasso, SVR та дерева рішень, дав майже ті ж результати, що і LSTM. Для комбінованого методу отримано $RMSE = 4.8621$ і R-квадрат 0.9437. Якщо б обсяг тренувальних даних був ще більшим, то комбінований метод міг би забезпечити найкращий результат завдяки його адаптивним алгоритмам навчання. Інші неромережеві методи (крім LSTM) а також метод експоненційного згладжування показали гірші результати. Цей аналіз показує, що зі збільшенням кількості вхідних параметрів комбіновані моделі та методи досягають кращої ефективності порівняно з класичними моделями [4].

В роботі [6] порівняння моделей ARIMA, MLP, RBF та ANFIS виконано на основі значення середньої абсолютної відсоткової похибки (MAPE). Отримано такі значення MAPE відповідно для моделей ARIMA, MLP, RBF та ANFIS: 6,410%, 5,477%, 6,186% та 5,468%. Тобто найкращий результат отриманий за допомогою моделі ANFIS, яка використовує алгоритм групування для генерації початкової структури FIS.

Отже для розроблення автоматизованої системи прогнозування обсягів споживання природного газу доцільно застосувати один з комбінованих методів. Причому залежності обсягів споживання від основних вхідних параметрів доцільно розробити у формі детермінованих математичних моделей. Вплив багатьох випадкових факторів доцільно врахувати за допомогою застосування нейромережі.

Інформаційні джерела

1. Енергетична стратегія України на період до 2050 року. Затверджено розпорядженням Кабінету міністрів України від 21 квітня 2023 р. № 373-р.
2. Матіко Ф.Д., Коробко І.В., Кузьменко Ю.В. Методика перетворення до стандартних умов об'ємів природного газу, виміряних побутовими лічильниками газу. Київ, ДП «Укрметртестстандарт» 2021. 28 с.
3. Description of the TDD Model Version 3.11 - Jakub Novak, Marcel Jirina, Petr Novak, 2020. - 26 p. (In Czech)
4. 10. Meenakshi Thalor, Ritesh Choudhary, Ajay Jangid et al. Forecasting Models of Natural Gas / International Journal of Scientific Research in Science and Technology, 2021, Volume 8, Issue 3. – p.251-258. doi : <https://doi.org/10.32628/IJSRST218375>
5. Junhui Guo. Oil price forecast using deep learning and ARIMA. International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI), 2019, Page 241- 247.
6. 4. Oguz Kaynar, Isik Yilmaz , Ferhan Demirkoparan. Forecasting of natural gas consumption with neural network and neuro fuzzy system / Energy Education Science and Technology Part A: Energy Science and Research. 2011, Volume (Issue) 26(2). – p. 221-238.
7. Michal Kozielski, Zbigniew Laskarzewki. Matching a Model to a User - Application of Meta-Learning to LPG Consumption Prediction: The 10th International Conference on Intelligent Networking and Collaborative Systems (INCoS-2018), January 2019. DOI:10.1007/978-3-319-98557-2_46
8. Correia, A., Lopes, C., Costa e Silva, E. et al. A multi-model methodology for forecasting sales and returns of liquefied petroleum gas cylinders. Neural Comput & Applic 32, 12643–12669 (2020). <https://doi.org/10.1007/s00521-020-04713-0>
9. 6. Mahdiah Qanbari1, Shahram Javadi, Reza Sabbaghi-Nadooshan. The Forecasting of Iran Natural Gas Consumption Based On Neural-Fuzzy System Until 2020 - International Journal of Smart Electrical Engineering, Vol.2, No.3, 2013. – p.181-184.
10. Horacio Paggi, Franco Robledo. A Neural Networks Based Model For The Prediction Of The Bottled Propane Gas Sales, International Conference on Mathematics and Computers in Sciences and in Industry, 2014, Page 69-74.
11. P. K. Pradhan, S. Dhal and N. K. Kamila. Artificial Neural Network Conventional Fusion Forecasting Model for Natural Gas Consumption, 2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI), Bangalore, India, 2018, pp. 2200-2205, doi: 10.1109/ICACCI.2018.8554500.
12. Katarzyna Poczeta, Elpiniki I. Papageorgiou. Implementing Fuzzy Cognitive Maps with neural networks for natural gas prediction, IEEE 30th International Conference on Tools with Artificial Intelligence, 2018, Pages 1026-1032.
13. A. Anagnostis, E. Papageorgiou, V. Dafopoulos and D. Bochtis. Applying Long Short-Term Memory Networks for natural gas demand prediction, 2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA), Patras, Greece, 2019, pp. 1-7, doi: 10.1109/IISA.2019.8900746.
14. Zlatan Sicanica, Zdravko Oklopcic. Countywide Natural Gas Consumption Forecast, a Machine Learning Approach, MIPRO 2018, May 21-25, 2018, Opatija Croatia, 2018, Page 1070-1073.

Matiko F., Chaban V., Masniak O.
Lviv Polytechnic National University

**ANALYSIS OF METHODS AND MODELS FOR AUTOMATION OF ENERGY
CARRIER CONSUMPTION FORECASTING**

The usage of statistical models, artificial neural networks, and adaptive neuro-fuzzy systems for forecasting energy carrier consumption is considered in the article. It is shown that the use of artificial neural networks makes it possible to model complex dependencies between input and output parameters. Disadvantages of the use of neural networks for forecasting gas consumption are highlighted, in particular, a large amount of data for training the network, availability of expert knowledge and experience of the researcher, high computational complexity of training and application of the network. The advantages of mathematical models for forecasting the volumes of gas

consumption are also determined, which allows to obtain more accurate results, provides the possibility of taking into account expert experience, allows to adapt the model to changing conditions and establish cause-and-effect relationships. The feasibility of developing the automated system for forecasting natural gas consumption volumes based on a combined forecasting method is substantiated. The combined method should combine the deterministic dependence of consumption volumes on the main input parameters and the use of a neural network to describe the influence of many random factors.

Keywords: *mathematical model, consumption volumes, natural gas, forecasting methods, influencing factors, neural network*