

Міністерство освіти і науки України
Національний технічний університет «Дніпровська політехніка»

Міністерство освіти і науки України
Національний технічний університет «Дніпровська політехніка»

Кваліфікаційна наукова
праця на правах рукопису

ЛЮБАРЦЕВ ВАДИМ ВОЛОДИМИРОВИЧ

УДК 621.311

ДИСЕРТАЦІЯ


**ПРОГНОЗУВАННЯ ТА ОПТИМІЗАЦІЯ РЕЖИМІВ РОБОТИ СИСТЕМ
ЕЛЕКТРОПОСТАЧАННЯ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ**

141 Електроенергетика, електротехніка та електромеханіка

14 Електрична інженерія

Подається на здобуття наукового ступеня доктора філософії

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

 В.В. Любарцев

Наукові керівники:

Саєнко Юрій Леонідович, доктор технічних наук, професор;

Папайка Юрій Анатолійович, доктор технічних наук, професор.

Дніпро – 2025

АНОТАЦІЯ

Любарцев В.В. Прогнозування та оптимізація режимів роботи систем електропостачання з розподіленою генерацією. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 141 – Електроенергетика, електротехніка та електромеханіка. – НТУ «Дніпровська політехніка», Дніпро, 2025.

Робота присвячена розробці методів прогнозування режимів роботи мережі з розподіленою генерацією. Розвиток відновлюваних джерел електроенергії (ВДЕ) зумовлений як здешевленням сонячних та вітрових електростанцій, так і загальносвітовим трендом на «зелену» енергію, що у сукупності з державною підтримкою та можливістю автономного використання дає поштовх до розвитку так званих мереж з розподіленою генерацією. Учасники таких мереж (просьюмери) не тільки споживають, а і генерують надлишок електроенергії в мережу, що змінює весь принцип централізованого електропостачання від великих енерговузлів до споживачів. Окремим фактором, який став актуальним для України є постійні удари по великих енергетичних об'єктах і саме розподілення генерації може частково зменшити негативні наслідки для енергосистеми.

Перший розділ присвячений методам оцінки ефективності моделей для прогнозування електричних навантажень, а також аналізу існуючих досліджень по темі дисертаційної роботи. Під час оцінки ефективності прогнозування одним із ключових показників є *MAPE* (*Mean Average Percentage Error*) — середнє абсолютне відсоткове значення похибки у %. Дослідження та публікації в області статистичних методів показують, що *MAPE* статистичних моделей перевищує 10%, у той час як у моделей машинного навчання та штучних нейронних мереж *MAPE* від 2% до 10%. Але налаштування штучних нейронних мереж є складнішим та вимагає попередньої підготовки та нормалізації даних для їх коректної роботи.

Більшість існуючих досліджень з прогнозування енергоспоживання зосереджені на прогнозуванні навантажень окремих споживачів або енерговузлів, або ж прогнозуванні генерації ВДЕ. Це підходить для великих учасників енергоринку, але зростання кількості просьюмерів (споживачів, які генерують власну енергію) призводить до створення розподілених мереж генерації. Окремі елементи таких мереж не взаємодіють один з одним і не беруть участі в регулюванні роботи мережі, що покладається на постачальників послуг або диспетчерські центри. Проте, просьюмери здатні впливати на загальний режим роботи мережі. Їх вплив можна опосередковано оцінити, враховуючи ключові зовнішні фактори, такі як метеорологічні дані.

У другому розділі досліджено, що впровадження ВДЕ в енергосистему має як позитивні, так і негативні наслідки. З одного боку, це дозволяє зменшити тривалість пікового навантаження на підстанції. Наприклад, згідно досліджень, при 15% інтеграції ВДЕ пікове навантаження в жовтні може скоротитися з 100 до 82 годин. З іншого боку, зростає рівень коливання навантаження. При 15% інтеграції він сягає 8,1%, а при 60% може досягати 29,4%. Ці та інші особливості розподілених мереж генерації слід враховувати при розробці методів прогнозування навантажень.

Прогнозування режимів роботи мереж з розподіленою генерацією (МРГ) відрізняється від прогнозування для традиційних електромереж. Це пов'язано з мінливістю генерації в МРГ, залежністю від погодних умов, часткою ВДЕ в енергосистемі та можливостями використання їх потенціалу.

Існуючі методи прогнозування генерації та споживання електроенергії не завжди підходять для МРГ. Наприклад, при використанні змодельованого графіка електричних навантажень промислового підприємства, прогнозування за середнім значенням дає значну похибку ($MAPE_{сер.} = 18,28\%$), тоді як статистичні методи ($MAPE_{стат.} = 4,97\%$) та нейронні мережі ($MAPE_{НМ} = 1,08\%$) значно точніші.

Зростання мінливості навантажень у МРГ ще більше знижує точність прогнозування застарілими методами. Тому для МРГ, особливо з високим коефіцієнтом інтеграції потужності, крім ймовірнісних характеристик

навантажень, важливо враховувати й зовнішні фактори (температура, швидкість вітру тощо).

У третьому розділі проведено аналіз прогнозування виробництва електроенергії сонячними електростанціями з використанням нейронних мереж. Дослідження включало як використання значень виміряної інсоляції на місці встановлення сонячних панелей, так і використання розрахованих значень за допомогою "Моделі чистого неба". *MAPE* при використанні "Моделі чистого неба" як джерела вихідних даних коливається від $-3,86\%$ до $5,74\%$, тоді як при використанні виміряної інсоляції *MAPE* знаходиться у діапазоні від $-0,97\%$ до $4,91\%$. Ця різниця може бути викликана похибками, які вводить "Модель чистого неба" у визначення рівня інсоляції в певних погодних умовах. Також під час експериментування з розміром навчальних вибірок було встановлено, що для отримання досить точного прогнозу потрібно від 2000 до 3000 вимірів у навчальній вибірці даних.

З метою створення загальної моделі мережі з розподіленою генерацією були розраховані коефіцієнти кореляції між виробництвом електроенергії за допомогою сонячних електростанцій та метеопараметрами. Найвищі коефіцієнти кореляції були зафіксовані для наступних параметрів: час (0,82), температура панелей (0,82), середнє значення сонячної радіації (0,92). Проте враховані показники можуть не досить точно відображати реальні зв'язки між метеопараметрами та виробництвом електроенергії, оскільки спостерігається значна перевага кореляції з інсоляцією, яка вимірюється безпосередньо на місці розташування сонячних панелей. З цієї причини були оцінені коефіцієнти кореляції між метеопараметрами та відносною виробленою енергією на одиницю інсоляції ($\text{кВт}/(\text{Вт}/\text{м}^2)$), як більш об'єктивного показника кореляційної залежності. За результатами оцінки, найбільш значущими параметрами є час, температура повітря (0,35), температура панелей (0,57) і швидкість вітру (0,42). Окрім цього, виконане прогнозування генерації СЕС з різними наборами метеопараметрів із подальшою оцінкою похибки, яке довело, що використання відносної виробленої енергії на одиницю інсоляції найбільше

впливає на точність прогнозу, як параметр, який акумулює в собі інші залежності, які не завжди можуть бути враховані в моделі.

У наступній частині третього розділу проведено дослідження щодо можливості прогнозування виробництва електроенергії вітровими електростанціями за допомогою нейронних мереж. Була розроблена нейронна мережа, в якій в якості входних параметрів використовувалися час, температура, швидкість та напрямок вітру, а також атмосферний тиск. Середні значення *MARE* коливалися від $-2,46\%$ до $4,91\%$. Також встановлено, що середній розмір вибірки для тренування, необхідний для отримання надійного прогнозу, повинен містити не менше 2000 значень. Отримані результати дозволяють оцінити ефективність використання нейронних мереж для прогнозування різних видів генерації та подальшого формулювання комплексної методології прогнозування та оптимізації рівнів потужності в мережі розподіленої генерації.

У четвертому розділі в середовищі Simulink / MATLAB була створена модель мережі з розподіленою генерацією, що включає в себе побутових споживачів ($S_{побут} = 2500$ кВА), промислових споживачів ($S_{пром} = 1800$ кВА), вітрові електростанції для побуту (5 кВА) та промисловості (150 кВА), а також сонячні електростанції для побуту (30 кВА) та промисловості (250 кВА). Для моделювання використовувалися реальні набори даних з навантаженням та генерацією електроенергії, а також метеопараметри (швидкість вітру та рівень сонячної інсоляції), прив'язані до часу. Під час моделювання роботи цієї мережі протягом 180 днів (з кроком дискретизації 1 година, загалом 4320 годин) були побудовані графіки електричних навантажень підстанції, що живила цю мережу. Моделювання включало різний рівень інтеграції відновлюваних джерел енергії (*CP*, змінюваний від 5% до 50%), що впливало на зміну споживаної електроенергії в мережі. Дані були розділені на навчальну та тестувальну вибірки. Навчальна вибірка (3600 годин) використовувалась для навчання тришарової нейронної мережі з трьома входами, 30 нейронами в прихованому шарі та виходом у вигляді прогнозу електричних навантажень на наступну добу. Метод тренування використовував алгоритм Левенберга-Маркварта з використанням зворотнього поширення

помилки. В результаті отриманого прогнозу на 30 діб були розраховані середні абсолютні похибки (*MAPE*), які для представленої моделі склали від 7,67% (для $CP=5\%$) до 10,51% (для $CP=50\%$).

Отримані результати похибок прогнозування свідчать про можливість використання штучних нейронних мереж для прогнозування режимів роботи не лише окремих складових мережі, але й мережі з розподіленою генерацією в цілому. Це досягається за рахунок використання додаткових вхідних параметрів, таких як метеодані, а також імовірнісних параметрів графіків електричних навантажень.

Розроблені методи прогнозування можуть бути використані для оптимізації режимів роботи мережі з розподіленою генерацією. Це дозволить прогнозувати їхні робочі режими, використовуючи більш доступні дані. Це спростить їх використання в першу чергу для невеликих мереж та їхніх операторів, але також може бути масштабоване для регіональних або національних мереж.

Ключові слова: розподілена генерація, відновлювані джерела електроенергії, прогнозування, моделювання, штучні нейронні мережі, похибка прогнозування.

Список публікацій здобувача

Статті у наукових фахових виданнях України

1. Саєнко Ю. Л., Любарцев В. В. Аналіз методів прогнозування реактивних навантажень промислових підприємств. *Вісник Приазовського державного технічного університету: зб. наук. праць*. Вип. 30. Т. 2. – Маріуполь: ДВНЗ «Приазов. держ. техн. ун-т». – (Технічні науки). – 2015р. – с.129-137.

2. Саєнко Ю. Л., Любарцев В. В. Застосування нейронних мереж при оптимізації режиму реактивної потужності у розгалужених електричних мережах. *Науковий журнал «Електрифікація транспорту»*. Вип. 12. – Дніпро: ДВНЗ «Дніпропетровський національний університет залізничного транспорту імені академіка В. Лазаряна». – 2017р. – с.53-58.

Наукові праці у виданнях іноземних держав або виданнях України, які включені до міжнародних наукометричних баз

3. Y. Sayenko, R. Pawelek, T. Baranenko, and V. Liubartsev, "The impact of meteorological data on the accuracy of solar electricity generation forecasting using neural networks," *Energies*, vol. 18, no. 9, Art. no. 2309, 2025, doi: 10.3390/en18092309.

4. Y. Sayenko, V. Sychenko, and V. Liubartsev, "Development of methods for optimizing reactive power modes based on neural network technologies," in *Proc. 2019 IEEE 6th Int. Conf. Energy Smart Systems (ESS)*, Apr. 2019, pp. 98–103, doi: 10.1109/ESS.2019.8764220.

5. Y. Sayenko, T. Baranenko, and V. Liubartsev, "Forecasting of electricity generation by solar panels using neural networks with incomplete initial data," in *Proc. Int. Conf. on Intelligent Energy and Power Systems (IEPS)*, Sep. 2020, pp. 140–143, doi: 10.1109/IEPS51250.2020.9263085.

6. Y. Sayenko, R. Pawełek, and V. Liubartsev, "Wind power forecasting based on meteorological data using neural networks," *Przegląd Elektrotechniczny*, vol. 97, no. 11, 2021.

Праці апробаційного характеру

7. Саєнко Ю. Л., Любарцев В. В. (2024) *Прогнозування режимів роботи мереж з розподіленою генерацією за допомогою штучних нейронних мереж. Підвищення рівня ефективності енергоспоживання в електротехнічних пристроях і системах: зб. матеріалів X Міжнар. наук.-техн. інтернет-конф., 19–21 верес. 2024 р., м. Луцьк / Луцький нац. техн. ун-т. – Луцьк: ЛНТУ, 2024. – с. 84–88.*

8. Саєнко Ю. Л., Любарцев В. В., Любарцева Ю.І. (2024) *Дослідження впливу ступені інтеграції ВДЕ на режими роботи мереж з розподіленою генерацією. Університетська наука – 2024 : тези доп. Міжнар. науково-техн. конф. (Дніпро, 23–24 травня 2024 р) : в 3 т. Т. 1: факультети: Навчально-науковий інститут сучасних технологій, машинобудування та зварювання, транспортний, інформаційних технологій / ДВНЗ «ПДТУ». – Дніпро: ДВНЗ «ПДТУ», 2024. – с.61–63.*

9. Саєнко Ю. Л., Любарцев В. В., Любарцева Ю. І. (2023). *Аналіз впливу метеорологічних даних на якість прогнозування генерації електроенергії сонячними панелями*. Університетська наука – 2023 : тези доп. Міжнар. науково-техн. конф. (Дніпро, 25-26 травня 2023 р) : в 3 т. Т. 1: факультети: Навчально-науковий інститут сучасних технологій, машинобудування та зварювання, транспортний, інформаційних технологій / ДВНЗ «ПДТУ». – Дніпро: ДВНЗ «ПДТУ», 2023. – с. 56–58.

10. Саєнко Ю. Л., Любарцев В. В. (2020) *«Прогнозування генерації електроенергії сонячними панелями за допомогою нейронних мереж при неповних вихідних даних»* Університетська наука - 2020 : тези доп. Міжнар. науково-техн. конф. (Маріуполь, 20-21 травня 2020 р.) : в 4 т. Т. 1: факультети: металургійний, енергетичний / ДВНЗ «ПДТУ». – Маріуполь: ПДТУ, 2020. с.236–238.

11. Саєнко Ю. Л., Любарцев В. В. (2020) *«Використання нейронних мереж з неповними вихідними даними для прогнозування виробництва електроенергії за допомогою поновлювальних джерел»* Підвищення рівня ефективності енергоспоживання в електротехнічних пристроях і системах: збірник матеріалів VIII Міжнародної науково-технічної інтернет-конференції, 24 грудня, 2020 р., м. Луцьк : Луцький НТУ, 2020. – с. 194–196

12. Саєнко Ю. Л., Любарцев В. В. (2020) *«Прогнозування виробництва електроенергії за допомогою сонячних панелей при використанні нейронних мереж з неповними вихідними даними»* Збірник тез доповідей Міжнародної науково-практичної on-line конференції “Проблеми енергоефективності та автоматизації в промисловості та сільському господарстві”. – Кропивницький: ЦНТУ, 2020. – с. 27-29.

13. Саєнко Ю. Л., Бараненко Т. К., Любарцев В. В. (2019) *«Використання нейронних мереж для вирішення задачі оптимізації режимів реактивної потужності»* International Ukraine-Poland Seminar „Power quality in distribution networks with distributed generation” Kyiv, July 4–5, 2019. pp 179–187

14. Саєнко Ю. Л., Любарцев В. В. (2015) *«Прогнозування електричних навантажень за допомогою нейронних мереж»*. Електрифікація транспорту «ТРАНСЕЛЕКТРО – 2015»: Матеріали VIII Науково – практичної конференції (Одеса, 29.09 – 2.10.2015р.) – Д.:ДНУЗТ, 2015. – с. 80 – 81.

ABSTRACT

Liubartsev V.V. Forecasting and Optimization of Operating Modes of Power Supply Systems with Distributed Generation. – Manuscript.

Dissertation for the degree of Doctor of Philosophy in specialty 141 – Electrical Power Engineering, Electrotechnics and Electromechanics. – "Dnipro University of Technology", Dnipro, Ukraine, 2025.

The dissertation is devoted to the development of forecasting methods for the operating modes of electrical networks with distributed generation. The development of renewable energy sources (RES) is driven by both the reduction in the cost of solar and wind power plants and the global trend toward green energy. Combined with government support and the possibility of autonomous operation, these factors stimulate the development of so-called distributed generation networks. Participants in these networks, known as prosumers, not only consume electricity but also generate surplus energy and feed it into the grid, fundamentally transforming the traditional paradigm of centralized electricity supply from large energy hubs to consumers. An additional factor especially relevant for Ukraine is the repeated attacks on major energy infrastructure, making distributed generation a means to partially mitigate the negative impacts to the power system.

The first chapter focuses on methods for evaluating the effectiveness of models used for forecasting electrical loads along with an analysis of existing research in the field. One of the key for forecasting accuracy is the *Mean Absolute Percentage Error (MAPE)*. Studies show that *MAPE* values for statistical models exceed 10%, while machine learning and artificial neural network (ANN) models achieve *MAPE* values between 2% and 10%. However, ANNs require more complex configuration and prior data preprocessing and normalization for accurate operation.

Most existing studies on energy forecasting concentrate on predicting the load of individual consumers or energy hubs, or the generation by RES. While this approach suits major players in the energy market, the growing number of prosumers—consumers who

generate their own electricity—leads to the formation of distributed generation networks. The elements of these networks typically do not interact or participate in network control, which remains the responsibility of service providers or dispatch centers. Nevertheless, prosumers can influence the overall operational state of the network. Their impact can be indirectly assessed through key external factors, such as meteorological data.

The second chapter investigates the dual impact of RES integration into the power system. On the one hand, it can reduce the duration of peak loads on substations. For example, with 15% RES integration, October peak load hours may decrease from 100 to 82 hours. On the other hand, load fluctuation increase significantly reaching 8.1% with 15% RES integration up to 29.4% at 60% integration. These and other features of distributed generation networks must be considered when developing load forecasting methods.

Forecasting in distributed generation networks (DGN) differs from that in traditional networks due to the variable nature of DGN generation, its dependence on weather conditions, the RES share in the system, and the ability to utilize its potential. Existing forecasting methods for energy consumption and generation are not always suitable for DGN. For example, using average load values to forecast a modeled industrial load profile results in a large error ($MAPE_{avg} = 18.28\%$), whereas statistical methods ($MAPE_{stat} = 4.97\%$) and neural networks ($MAPE_{ANN} = 1.08\%$) provide significantly better accuracy.

Increasing variability of load in DGN further reduces the forecasting accuracy of outdated methods. Therefore, in high-penetration DGN, it is crucial to incorporate not only the probabilistic characteristics of the loads but also external influencing factors such as temperature and wind speed.

The third chapter presents an analysis of solar power generation forecasting using neural networks. The study explored both direct measurements of solar irradiance at panel sites and estimated values obtained using the Clear Sky Model. $MAPE$ using the Clear Sky Model ranged from -3.86% to 5.74% , while for measured irradiance values, $MAPE$ was between -0.97% and 4.91% . This difference is likely due to the Clear Sky Model's inability to capture irradiance accurately under specific weather conditions.

Experiments with training dataset sizes showed that 2000–3000 samples are needed to achieve sufficient forecasting accuracy.

To create a general model of a distributed generation network, correlation coefficients between solar energy production and meteorological parameters were calculated. The highest correlations were observed for time (0.82), panel temperature (0.82), and average solar radiation (0.92). However, these indicators may not fully represent the actual relationships. To improve objectivity, correlations were also computed between meteorological variables and relative energy output per unit of irradiance ($\text{kW}/(\text{W}/\text{m}^2)$). The most significant parameters were time, air temperature (0.35), panel temperature (0.57), and wind speed (0.42). Forecasting experiments using various sets of meteorological parameters confirmed that relative energy output per irradiance unit provides the highest predictive accuracy, serving as an integrated parameter that captures other dependencies not explicitly modeled.

The second part of Chapter 3 explores wind power generation forecasting using neural networks. A neural network was developed with input parameters including time, temperature, wind speed and direction, and atmospheric pressure. The average MAPE values ranged from -2.46% to 4.91% . It was also established that at least 2000 training samples are required for reliable forecasting. These results demonstrate the effectiveness of neural networks for forecasting various types of generation, supporting the formulation of a comprehensive methodology for forecasting and optimizing power levels in distributed generation networks.

In Chapter 4, a model of a distributed generation network was developed using Simulink/MATLAB. The model includes residential consumers ($S_{RES} = 2500 \text{ kVA}$), industrial consumers ($S_{ind} = 1800 \text{ kVA}$), wind turbines for residential (5 kVA) and industrial use (150 kVA), and solar panels for residential (30 kVA) and industrial purposes (250 kVA). Real datasets of electrical loads, generation, and meteorological parameters (wind speed and irradiance) were used. The network was simulated for 180 days (1-hour resolution, totaling 4320 hours), producing load curves for the supplying substation. The simulations considered different levels of RES integration (penetration rate CP from 5% to 50%), affecting the total consumed power. The dataset was divided

into training (3600 hours) and testing samples. A three-layer neural network was trained using the Levenberg–Marquardt algorithm, with three inputs, 30 neurons in the hidden layer, and one output representing the next-day load forecast. The resulting MAPE values ranged from 7.67% ($CP = 5\%$) to 10.51% ($CP = 50\%$).

These forecasting results confirm the feasibility of using neural networks to predict not only individual network components but also the operational modes of entire distributed generation systems. This is achieved by incorporating additional input parameters such as meteorological data and probabilistic load characteristics.

The developed forecasting methods can be applied to optimize the operation of distributed generation networks, allowing prediction of operational states using accessible data. This makes the methods particularly applicable for small-scale networks and their operators, while also offering scalability for regional and national power grids.

Keywords: distributed generation, renewable energy sources, forecasting, modeling, artificial neural networks, forecasting error.

ЗМІСТ

АНОТАЦІЯ	2
ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ І СКОРОЧЕНЬ	16
ВСТУП.....	18
1. АНАЛІЗ СУЧАСНИХ ДОСЛІДЖЕНЬ В ОБЛАСТІ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ТА ОПТИМІЗАЦІЇ РЕЖИМІВ РОБОТИ ЕЛЕКТРИЧНИХ МЕРЕЖ.....	23
1.1 Визначення необхідності прогнозування електричних навантажень та режимів роботи електричних мереж	23
1.2 Огляд методів прогнозування електричних навантажень та режимів роботи електричних мереж	26
1.2.1 Статистичні методи прогнозування	29
1.2.2 Штучні нейронні мережі	34
1.2.3 Гібридні методи прогнозування	35
1.3 Аналіз комерційних рішень для прогнозування електричних навантажень	36
1.4 Визначення завдань дисертації	38
1.5 Висновки за першим розділом	40
2. ВИБІР МЕТОДІВ ДЛЯ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ТА РЕЖИМІВ РОБОТИ ЕЛЕКТРИЧНИХ МЕРЕЖ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ.....	43
2.1 Особливості мереж з розподіленою генерацією	43
2.2 Етапи інтеграції ВДЕ у енергосистему на прикладі фотоелектричних СЕС	45
2.3 Вплив ВДЕ на число годин використання максимумів навантажень у енергосистемі.....	46
2.4 Використання потенціалу ВДЕ	48
2.5 Рівні коливання навантаження у мережі з ВДЕ	50

2.6 Дослідження поширених методів прогнозування електричних навантажень на промислових підприємствах	53
2.6.2 Використання середніх значень електричних навантажень	54
2.6.3 Статистичні методи прогнозування	56
2.6.4 Методи прогнозування, на основі штучних нейронних мереж (ШНМ). 60	
2.6.5 Підготовка вихідних даних	70
2.6.6 Порівняння методів прогнозування електричних навантажень та режимів роботи електричних мереж.	72
2.7 Висновки за другим розділом	73
3. ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ТА ОПТИМІЗАЦІЇ РЕЖИМІВ У МЕРЕЖІ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ. ОПТИМІЗАЦІЯ РЕЖИМІВ РЕАКТИВНОЇ ПОТУЖНОСТІ	75
3.1 Прогнозування та оптимізація режимів реактивної потужності в електричних мережах.....	75
3.2 Використання нейронних мереж для прогнозування генерації електроенергії альтернативними джерелами в електромережах з розподіленою генерацією....	86
3.2.1 Прогнозування генерації сонячними панелями	87
3.2.2 Прогнозування генерації вітровими електростанціями	109
3.3 Висновки за третім розділом	115
4. РЕАЛІЗАЦІЯ МОДЕЛІ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ТА РЕЖИМІВ РОБОТИ ЕЛЕКТРИЧНИХ МЕРЕЖ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ	117
4.1 Збір вихідних даних для моделювання	117
4.2 Вибір програмної платформи та реалізація моделі МРГ	120
4.3 Опис складових елементів моделі МРГ	121
4.3 Створення та налагодження ШНМ для прогнозування режиму роботи МРГ	125

4.4 Результати тренування нейронної мережі	131
4.5 Оцінка результатів, визначення похибок.....	137
4.6 Висновки за четвертим розділом	140
ВИСНОВКИ	141
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	144
ДОДАТОК А Приклади графіків прогнозів генерації СЕС з різними наборами вхідних даних	156
ДОДАТОК Б Результати прогнозування активної потужності, що споживається МРГ, при різних частках встановленої потужності ВДЕ (СР, %).....	161
ДОДАТОК В Документи, що підтверджують практичне значення отриманих результатів роботи.....	179

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ І СКОРОЧЕНЬ

Скорочення	Пояснення
ВДЕ	відновлювані джерела електроенергії;
ВЕС	вітрова електростанція;
ГЕС	гідроелектростанція;
КП	компенсуючий пристрій;
МРГ	мережа з розподіленою генерацією;
ОСП	оператор системи передачі;
ОСР	оператор системи розподілу;
ПС	підстанція;
СЕС	сонячна електростанція;
ТЕЦ	теплоелектроцентрально;
ЦЖ	центр живлення;
ШНМ	штучні нейронні мережі;
AR	AutoRegressive – авторегресійна модель;
ARIMA	AutoRegressive Integrated Moving Average – авторегресійна інтегрована модель ковзного середнього;
ARIMAX	AutoRegressive Integrated Moving Average with eXogenous variables – авторегресійна інтегрована модель ковзного середнього з екзогенними змінними;
ARMA	AutoRegressive Moving Average – авторегресійна модель ковзного середнього;
CP	Capacity penetration – коефіцієнт інтеграції ВДЕ в мережу;
DL	Deep Learning – глибоке навчання;
FFNN	Feedforward Neural Network – нейронна мережа з прямим розповсюдженням похибки;
GRU	Gated Recurrent Unit – блок керованої рекурентної одиниці (варіант рекурентної нейронної мережі);

Скорочення	Пояснення
LSTM	Long Short-Term Memory – довготривала короткочасна пам'ять (архітектура рекурентних нейронних мереж);
LTF	Long-Term Forecasting – довгострокове прогнозування;
MA	Moving Average – модель ковзного середнього;
MAE	Mean Absolute Error – середня абсолютна похибка;
MAPE	Mean Absolute Percentage Error – середня абсолютна відсоткова похибка;
ML	Machine Learning – машинне навчання;
MTF	Multi-Timeframe Forecasting – прогнозування з урахуванням декількох часових рамок;
NARX	Nonlinear AutoRegressive with eXogenous inputs – нелінійна авторегресійна модель з екзогенними змінними;
NWP	Numerical Weather Prediction – числовий прогноз погоди;
PV	Photovoltaic panel – фотоелектрична панель;
RNN	Recurrent Neural Network – рекурентна нейронна мережа;
RMSE	Root Mean Squared Error – корінь середньоквадратичної похибки;
STM	Short-Term Memory – короткочасна пам'ять;
SVM	Support Vector Machine – метод опорних векторів;
VSTM	Very Short-Term Memory – дуже короткочасна пам'ять;
VSTLF	Very Short-Term Load Forecasting – дуже короткострокове прогнозування навантаження.

ВСТУП

Актуальність теми. Сьогодні зростає частка досліджень з прогнозування електричних навантажень і все більше уваги приділяється розвитку ВДЕ, та мережам з розподіленою генерацією. Це пов'язано як з законодавчими змінами, що збільшують відповідальність за небаланси, та здешевленням і розвитком пристроїв «зеленої» генерації. На жаль, важливим фактором необхідності розвитку розподіленої генерації в Україні є постійні удари по об'єктам критичної інфраструктури України (ТЕЦ, ГЕС, магістральні ПС, що забезпечують видачу генерації від АЕС, тощо). Поступовий відхід від централізованої генерації та розвиток розподіленої генерації частково зменшить негативний ефект від руйнування енергосистеми.

Розвиток технологій "розумних мереж" (smart grids) надає можливості для більшого залучення аналітичних методів та автоматизації управління електромережами. Прогнозування режимів роботи мереж стає ключовим елементом для ефективного впровадження таких технологій. Таким чином дослідження в галузі прогнозування режимів роботи мереж з розподіленою генерацією є важливим для забезпечення надійності, ефективності та стабільності електромереж у майбутньому.

Таким чином, **наукова задача** дисертаційної роботи полягає у визначенні закономірностей та прогнозування еволюції електромагнітних процесів генерації $P_{gen.RES}$ сонячними та вітровими електростанціями з урахуванням встановленої потужності ВДЕ $P_{inst.RES}$ енергосистеми з розподіленою генерацією, що забезпечує оптимізацію перетоків активної потужності при варіативних змінах генерації ВДЕ та споживання електроенергії просьюмерами.

Зв'язок з науковими програмами, планами та темами.

Теоретичні та практичні результати дисертаційної роботи були застосовані під час виконання державної бюджетної науково-дослідної роботи «Оптимізація режимів систем електропостачання в мережах з розподіленою генерацією» (ДР 0118U006918, 2020 р.).

Мета і завдання дослідження. Метою роботи є розробка методів прогнозування режимів електричних мереж з розподіленою генерацією (МРГ).

Відповідно до вказаної мети, в роботі поставлені наступні завдання:

1. Проаналізувати існуючі дослідження щодо прогнозування режимів роботи електричних мереж, графіків генерації СЕС та ВЕС.

2. Обрати методи прогнозування, а також програмні засоби їх реалізації в умовах використання для режимів роботи МРГ.

3. Для оцінки похибок існуючих методів прогнозування режимів роботи МРГ виконати прогнозування режиму роботи мережі електропостачання промислового підприємства та побутових споживачів (як основних елементів мережі) за допомогою найбільш розповсюджених методів та порівняти результати.

4. З метою оцінки можливості використання звичайного прогнозу погоди у якості вхідних даних виконати прогнозування графіка виробництва електроенергії за допомогою СЕС з використанням різних вхідних даних: при використанні метеопараметрів, вимірюваних безпосередньо у місці встановлення панелей та з урахуванням «Моделі чистого неба», що дозволяє опосередковано оцінити рівень інсоляції у районі встановлення СЕС та порівняти результати.

5. Створити модель та виконати моделювання роботи мережі з розподіленою генерацією, що включає як звичайних споживачів, так і СЕС, ВЕС, з різним коефіцієнтом інтеграції ВДЕ.

6. Виконати прогнозування режимів роботи мережі з розподіленою генерацією з урахуванням побутових, промислових споживачів, а також ВДЕ, що інтегровані в цю мережу із врахуванням метеофакторів, що здатні змінювати режими роботи елементів мережі.

7. Результати досліджень проаналізувати, порівняти з дослідженнями на схожу тематику та обрати напрями подальших досліджень.

Об'єктом дослідження є режими роботи мереж з розподіленою генерацією.

Предметом дослідження є методи та алгоритми, що дозволяють підвищити точність прогнозування режимів роботи мереж з розподіленою генерацією та спростити збір вихідних даних для прогнозування.

Методи дослідження. У дисертаційній роботі при прогнозуванні режимів роботи МРГ використано комплексний підхід, що включає в себе методи розрахунку електричних кіл, теорію ймовірності, математичну статистику, теорію похибок, методи нечіткої логіки, теорію штучних нейронних мереж та математичного моделювання. Для імітаційного моделювання використано програмний продукт MATLAB (Simulink). Експериментальні дослідження проведені з використанням методів обробки даних. Для перевірки достовірності розробленої моделі та отриманих результатів використано метод планування експерименту.

Наукові положення, що виносяться на захист:

1. Збільшення граничного значення встановленої потужності ВДЕ $P_{inst.RES}$ до 50% у електричній мережі з розподіленою генерацією викликає зростання похибки прогнозування перетоків потужності в електричній мережі до 30%, що зумовлено нестаціонарною варіативністю генерації ВДЕ $P_{gen.RES}$ та особливостями перебігу електромагнітних процесів у енергосистемі обмеженої потужності.

2. Використання питомої генерації на одиницю інсоляції P^* (кВт/(Вт/м²)) дозволяє врахувати комплексний ефект метеопараметрів, що впливає на генерацію СЕС та оптимізує вибір даних для навчання нейронних мереж, зменшуючи розбіжність між реальним та прогнозованим добовим графіком генерації ВДЕ $P_{gen.RES}$ на 20%.

Наукові результати дослідження:

1. Запропоновано метод прогнозування за допомогою ШНМ, що дозволяє спрогнозувати режим роботи МРГ, який, на відміну від існуючих, дозволяє спрогнозувати режими систем електропостачання одночасно з усіма складовими енергосистеми (споживачів, ВЕС, СЕС), з урахуванням метеопараметрів, які можуть впливати на генерацію ВДЕ у цій мережі.

2. Шляхом моделювання досліджено вплив частки встановленої потужності ($CP, \%$) ВДЕ на похибку прогнозування режимів роботи мережі. За підсумками досліджень було доведено, що її збільшенні похибка прогнозування зростає. Так при збільшенні CP з 5% до 50 % похибка прогнозування зросла з 7,67% до 10,51%.

3. Обґрунтовано використання питомої генерації на одиницю інсоляції P^* (кВт/(Вт/м²)), що дає змогу врахувати комплексний ефект всіх метеопараметрів,

які впливають на генерацію фотоелектричних СЕС. Це дозволяє істотно спростити набір даних для навчання ШНМ та підвищити точність прогнозування.

Практичне значення отриманих результатів:

1. Розроблена методика прогнозування може бути використана операторами системи передачі (ОСП) та операторами системи розподілу (ОСР) для підвищення точності управління режимами роботи МРГ. Основним практичним застосуванням є покращення балансування енергосистеми, оптимізація диспетчеризації та зменшення ризиків, пов'язаних із невизначеністю генерації ВДЕ.

2. Розроблені методи прогнозування режимів роботи МРГ впроваджені в промислову експлуатацію в АТ «Нікопольський завод феросплавів», та ТОВ «ДТЕК Покровська СЕС» що отримало позитивний відгук від представників компанії та дозволило спростити прогнозування та диспетчеризацію мереж з ВДЕ, що у перспективі дозволить знизити переплату за небаланси на енергоринку.

3. Матеріали досліджень використовуються в навчальному процесі кафедри електроенергетики НТУ «Дніпровська політехніка» а також кафедри автоматизації систем електропостачання та електроприводу ДВНЗ «Приазовський державний технічний університет».

Особистий внесок здобувача включає в себе проведення фундаментальних теоретичних і експериментальних досліджень, які були представлені у дисертаційній роботі. Це включало розробку теоретичних моделей, методик експериментальних досліджень, участь у виконанні експериментів, аналіз, інтерпретацію та узагальнення отриманих результатів. Основні наукові висновки та результати дисертаційної роботи були отримані автором самостійно.

Апробація матеріалів дисертації. Основні положення та результати досліджень пройшли апробацію і отримали позитивну оцінку на таких вітчизняних і міжнародних науково-технічних конференціях:

– Підвищення рівня ефективності енергоспоживання в електротехнічних пристроях і системах: зб. матеріалів X Міжнар. наук.-техн. інтернет-конф., Луцьк, 19–21 вер. 2024 р.;

– Університетська наука – 2024: Міжнародна науково-технічна конференція, Дніпро, 23–24 трав. 2024 р.;

- Університетська наука – 2023: Міжнародна науково-технічна конференція, Дніпро, 25–26 трав. 2023 р.;
- Університетська наука – 2020: Міжнародна науково-технічна конференція, Маріуполь, 20–21 трав. 2020 р.;
- 2020 IEEE 4th International Conference on Intelligent Energy and Power Systems (IEPS), September 7–11, Istanbul, Turkey;
- Підвищення рівня ефективності енергоспоживання в електротехнічних пристроях і системах: збірник матеріалів VIII Міжнародної науково-технічної інтернет-конференції, Луцьк, 24 груд. 2020 р.;
- Збірник тез доповідей Міжнародної науково-практичної on-line конференції “Проблеми енергоефективності та автоматизації в промисловості та сільському господарстві”, Кропивницький, 2020 р.;
- International Ukraine-Poland Seminar „Power quality in distribution networks with distributed generation”, Київ, 4–5 липня, 2019;
- 2019 IEEE 6th International Conference on Energy Smart Systems (ESS), April 17–19, Kyiv, Ukraine;
- Електрифікація транспорту «ТРАНСЕЛЕКТРО – 2015», Одеса, 29 вер. – 2 жовт. 2015 р.

Публікації. Основні результати дисертаційної роботи опубліковано у 6 наукових працях, у тому числі двох статей у наукових фахових виданнях України, а також 4 публікації — у виданнях, що входять до міжнародної наукометричної бази Scopus, 8 публікацій у матеріалах і тезах наукових конференцій.

Структура та обсяг дисертації. Дисертаційна робота складається з анотації, переліку умовних позначень і скорочень, вступу, чотирьох розділів, висновків, списку використаних джерел та додатків. Загальний обсяг дисертації складає 180 сторінок, з яких основний зміст викладений на 125 сторінках друкованого тексту і містить 53 рисунки, 36 таблиць, список використаних джерел зі 107 найменувань та трьох додатків.

1. АНАЛІЗ СУЧАСНИХ ДОСЛІДЖЕНЬ В ОБЛАСТІ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ТА ОПТИМІЗАЦІЇ РЕЖИМІВ РОБОТИ ЕЛЕКТРИЧНИХ МЕРЕЖ

1.1 Визначення необхідності прогнозування електричних навантажень та режимів роботи електричних мереж

Електрика — це чисте та ефективне джерело енергії, яке відіграє незамінну роль у нашому повсякденному житті. Значення електроенергії останнім часом різко зростає, і тому вона стала важливим предметом досліджень. Крім того, електрична енергія є більш придатною та ефективною для задоволення вимог екологічно чистого суспільства порівняно з іншими традиційними джерелами енергії, такими як природний газ, вугілля та нафта. Однак електроенергія як товар має інші характеристики порівняно з матеріальними продуктами, оскільки її не можна зберігати у великих обсягах, вона повинна вироблятися, як тільки на неї виникає попит. Крім того, структура попиту на електроенергію є складною через дерегуляцію ринків збуту. Очікується, що світовий попит на електроенергію зростатиме зі збільшенням чисельності населення та підвищенням рівня життя [1], [2]. Крім того, світова економіка розширюється, а також збільшується використання потужних електроприладів і розвиваються технології, такі як інтелектуальні мережі, електромобілі та виробництво відновлюваної енергії. Всі ці фактори ускладнюють управління енергосистемою, що викликає необхідність прогнозувати генерацію/споживання електроенергії заздалегідь [3].

Прогнозування електричного навантаження є важливим процесом у плануванні електроенергетичної галузі та відіграє вирішальну роль у плануванні електричної потужності та управлінні енергосистемами, і тому привертає все більший науковий інтерес. Таким чином, точність прогнозування електричного навантаження має велике значення для планування генеруючих потужностей та управління енергосистемою.

Питанням прогнозування електричних навантажень поряд із проблемами енергоефективності та енергозбереження приділяється серйозна увага при

проектуванні та експлуатації систем електропостачання промислових підприємств. Прогнозування електричних навантажень дозволяє ефективно планувати та оперативно керувати роботою систем електропостачання. Достовірний прогноз дозволяє розраховувати оптимальні режими роботи систем, підвищувати їхню економічність і надійність. За наявності власних джерел електроенергії на промислових підприємствах від точності прогнозу залежить планування витрат енергоресурсів, економічність завантаження генераторів, отже, і собівартість виробленої електроенергії.

Енергоефективність електричних мереж та енергосистем з ВДЕ (в першу чергу сонячними і вітровими електростанціями), окрім безпосередньо природних явищ, сильно залежить від режиму роботи енергосистеми, наявності та залучення резервних генеруючих одиниць, рівня маломаневреної атомної генерації, тощо. По-перше, це часто призводить до обмеження генерації ВДЕ за вказівкою ОСП, особливо влітку, коли сонячна генерація найбільша. Однак окрім неповного використання потенціалу ВДЕ і як наслідок використання вуглецевого палива для маневрування при зміні споживання в енергосистемі, забруднення повітря, тощо, це ще й призводить до відшкодування державою виробникам ВДЕ вартості електроенергії, яка була невідпущена через обмежувальну команду ОСП (згідно ст. 68 Закону «Про ринок електричної енергії») [4].

Таким чином, Державне підприємство «Гарантований покупець» на ринку електричної енергії має платити одночасно двом учасникам енергоринку: як маневреним (наприклад вугільним) так і «зеленим» електростанціям за послуги балансування у енергосистемі, коли самі ВДЕ не повністю реалізують свій потенціал [5].

Небаланс також має інші фінансові наслідки, наприклад, необхідність для НЕК "Укренерго" терміново купувати електроенергію, якщо виробник постачає менше електроенергії, ніж очікувалося. І навпаки, якщо виробник виробляє більше, ніж очікувалося, НЕК "Укренерго" має зменшити виробництво на іншій електростанції. Ці дії вимагають значних коштів, і виробники, які спричиняють небаланси, несуть відповідальність за покриття витрат. [6]

Другою проблемою, окрім завищених фінансових втрат з боку держави, є відповідальність ВДЕ за небаланси — відхилення фактичного виробництва електроенергії від прогнозного. Відповідно до статті 71 Закону України "Про ринок електричної енергії" [4], виробники ВДЕ повинні відшкодовувати частину вартості небалансу електричної енергії Гарантованому покупцю за погодинні відхилення відпуску електричної енергії від прогнозних графіків. З 1 січня 2021 року ВДЕ мають відшкодовувати 10% вартості врегулювання небалансу ДП "Гарантований покупець" [7]. Надалі ця частка підвищується на 10% кожного року — до 100% в 2030 році. Але на відміну від традиційних джерел електроенергії (наприклад на вугільному паливі, або АЕС), на ВДЕ досить складно спрогнозувати генерацію електроенергії через мінливість погодних умов, сучасні системи прогнозують погодинну генерацію на ВДЕ з середньою похибкою 10 – 20% [8], [9], [10], [11], що виходить за межі допустимої, тому з кожним роком втрати виробників «зеленої» енергії будуть рости, що впливатиме на вартість електроенергії [12].

Таким чином, гостро стає проблема більш точного прогнозування виробництва електроенергії за допомогою ВДЕ, причому як великих електростанцій, так і невеликих приватних генеруючих одиниць. Правильне прогнозування дозволить ОСП максимально використовувати потенціал ВДЕ, уникаючи обмеження генерації, знижуючи необхідність утримувати застарілі електростанції на вуглецевому паливі в «гарячому» резерві, а також підвищуючи енергоефективність мереж завдяки більш точному плануванню перетоків потужності від різних ВДЕ [13], [14], [15].

Але окрім питань, пов'язаних з ВДЕ, гостро стоять питання, щодо перетоків та рівнів реактивної потужності в мережі. Оскільки реактивна потужність не несе корисної роботи вона має бути компенсована як можна ближче до її споживачів. Проведені раніше дослідження показали, що за рахунок прогнозування та подальшим керуванням згідно з прогнозом компенсуючими пристроями вдається значно знизити потоки реактивної потужності в мережі, та відповідно полегшити режими роботи обладнання [16]. Окрім цього, від реактивної потужності залежать рівні напруги у мережі, що є важливою складовою вирішення питання якості

електроенергії. Враховуючи мінливість розподіленої генерації, що може впливати на якість електроенергії в мережі, підвищується вимоги і до підтримки оптимального коефіцієнту потужності в такій мережі з урахуванням можливих режимів роботи МРГ.

Нажаль, окрім економічних і технічних чинників, які зумовлюють прискорення переходу до розвитку нових джерел електроенергії є руйнування енергосистеми України внаслідок бойових дій та умисних обстрілів. Руйнування генерації та ключових енерговузлів призводить до перебоїв електропостачання, а при його відновленні — до зниження надійності та збільшення кількості «вузьких місць» при її передачі від об'єктів генерації, що вціліли [17], [18].

1.2 Огляд методів прогнозування електричних навантажень та режимів роботи електричних мереж

Проблема прогнозування електричних навантажень на сьогодні не нова. Існує багато досліджень, які пропонують різні методи прогнозування електричних навантажень, які постійно вдосконалюються, а також створюються більш нові методи, які відповідають сучасному рівню розвитку технологій. Огляд сучасних методів прогнозування навантажень в мережах дозволяє зробити висновок, що одного універсального методу, який буде відповідати усім вимогам, не існує [19].

Також наразі не існує чіткого стандарту класифікації діапазону прогнозів навантаження. Однак багато авторів [20], [21], [22] поділяють прогнозування навантаження з точки зору тривалості прогнозування на чотири групи: довгострокові прогнози, середньострокові прогнози, короткострокові прогнози та дуже короткострокові прогнози (рис. 1.1):

- довгострокове прогнозування навантаження (Long Term Forecasting, LTF): на період від одного року до 20 років наперед. Цей тип прогнозу є основоположним для стратегічного планування, будівництва нових генеруючих потужностей, а також для розвитку системи постачання та доставки електроенергії;

- середньострокове прогнозування навантаження (Medium Term Forecasting, MTF): зазвичай на період від тижня до року, використовується для планування технічного обслуговування та закупівель палива, а також для торгівлі електроенергією та оцінки доходів для комунальних підприємств;
- короткострокове прогнозування навантаження (Short Term Forecasting, STM): для інтервалів від однієї години до тижня, дуже важливе для повсякденної роботи енергокомпанії, планування виробництва та передачі електроенергії;
- ультра/дуже короткострокове прогнозування навантаження (Very short-term forecasting, VSTM): охоплює інтервали від декількох хвилин до години і використовується для управління в режимі реального часу.

З наукової точки зору, LTF відноситься до довгострокового прогнозування, яке охоплює часовий проміжок від місяців до років і має вирішальне значення для операцій з планування виробництва та зростання навантаження [23], [24]. Перевага LTF полягає в тому, що він усуває випадкові коливання, які відбуваються в короткостроковій перспективі, тим самим дозволяючи робити точні прогнози довгострокових тенденцій. За останні два десятиліття кількість публікацій про системи енергетичного прогнозування була найвищою для STF, за якою слідує LTF [22].

Останнім часом короткострокове прогнозування (STF) стало найбільш широко використовуваним методом для управління та планування роботи енергосистеми. Вибір часового масштабу прогнозування має вирішальне значення для визначення параметрів методу прогнозування.

Наразі існує лише обмежена кількість методів для дуже короткострокового прогнозування навантаження (VSTLF), які зазвичай передбачають оцінку найближчого майбутнього навантаження на основі нещодавніх вимірювань без явного моделювання взаємозв'язку між часом, погодними умовами та навантаженням. Деякі з доступних методів VSTLF включають генетичні алгоритми, авторегресійні моделі ковзного середнього та штучні нейронні мережі. Короткострокове прогнозування навантаження (STLF) зазвичай використовується для часових горизонтів від хвилин до годин і є важливим джерелом інформації для

щоденних операцій [25]. Для того, щоб підвищити точність короткострокових моделей, важливо мати точне знання факторів, які впливають на попит на навантаження, оскільки миттєвий попит може відрізнятися від довгострокових тенденцій. Середньострокове прогнозування навантаження (MTLF) зазвичай використовується для прогнозування навантаження на період від кількох днів до кількох місяців, тоді як довгострокове прогнозування навантаження (LTLF) використовується для прогнозування навантаження на період від кількох тижнів до багатьох років. Моделі LTLF враховують такі фактори, як погодні дані, характеристики пристроїв у певних районах, історичні дані про навантаження та кількість споживачів. Економічні фактори також враховуються при довгостроковому прогнозуванні навантаження.




Рис. 1.1. Класифікація прогнозів електричних навантажень з точки зору тривалості прогнозування

На сьогодні розроблена велика кількість різних підходів та методів прогнозування, але як основними з них можна виділити статистичні методи, штучні

нейронні мережі, а також різні комбінації цих методів, які можна об'єднати у гібридні методи прогнозування (рис. 1.2) [20], [26]. Кожен підхід і метод має свої переваги, недоліки, межі використання.




Рис. 1.2. Структурна таблиця найпоширеніших методів прогнозування електричних навантажень

1.2.1 Статистичні методи прогнозування

Статистичні методи широко застосовуються для прогнозування електричних навантажень завдяки своїй ефективності та простоті використання [26], [27]. Перевагами статистичних методів є їхня гнучкість у пристосуванні до різних типів даних, включаючи часові ряди, а також здатність давати точні прогнози за умови належного навчання на репрезентативних наборах даних. Крім того, ці моделі надають результати, які можна інтерпретувати, що дозволяє зрозуміти основні закономірності та фактори, що впливають на електричні навантаження [19], [26], [28].

Однак статистичні методи можуть стикатися з проблемами через їхню залежність від припущень про лінійність, чутливість до відхилень та обмежений діапазон даних. Ці обмеження можуть вплинути на точність прогнозів, особливо коли вони застосовуються до наборів даних зі складними взаємозв'язками між змінними [29], [30]. Тому при виборі та застосуванні статистичних методів для прогнозування навантаження необхідно ретельно підходити до вибору та застосування статистичних методів, беручи до уваги компроміс між простотою, точністю та можливістю інтерпретації.

Для аналізу ефективності прогнозування за допомогою різних методів є різні методи оцінки середніх похибок як у іменованих так і відносних одиницях. Найбільш поширені на сьогодні методи представлені у таблиці 1.1 [22], [31]:

Таблиця 1.1. Розповсюджені методи оцінки похибки прогнозування

Середня абсолютна похибка Mean Absolute Error (<i>MAE</i>)	$\frac{1}{n} \sum_{i=1}^n y'_i - y_i $
Середньоквадратична похибка Root Mean Squared Error (<i>RMSE</i>)	$\sqrt{\frac{\sum_{i=1}^n (y'_i - y_i)^2}{n}}$
Середня абсолютна похибка у % Mean Average Percentage Error (<i>MAPE</i>)	$\frac{1}{n} \sum_{i=1}^n \left \frac{y'_i - y_i}{y_i} \right \cdot 100\%$

де n – величина вибірки даних;

y'_i - прогнозоване значення;

y_i - реальне значення.

Аналізуючи інші дослідження про використання статистичних методів прогнозування електричних навантажень, була складена таблиця 1.2 з величинами середніх абсолютних похибок у % (*MAPE*), як більш показовий для аналізу:

Таблиця 1.2. Порівняння статистичних методів прогнозування

Метод	Особливості	MAPE
Лінійна регресія (Linear Regression)	Регресія — це популярний статистичний підхід, який використовується для дослідження зв'язку між різними незалежними змінними (предикторами) та залежною змінною (критерієм). Множинна регресія, зокрема, має на меті глибше зрозуміти зв'язок між кількома предикторами та критеріальною змінною. Цей статистичний метод використовує метод найменших квадратів для моделі, при цьому метою є мінімізація різниці між спостережуваними і прогнозованими значеннями. У контексті прогнозування електричного навантаження регресійні методи зазвичай використовуються для створення моделі, яка описує зв'язок між навантаженням і різними іншими	4,92 % [32]; 12,59 – 18.07% [33] ; 9,95-23,7 % [34];

Таблиця 1.2. Порівняння статистичних методів прогнозування

Метод	Особливості	MAPE
	факторами, такими як погода, тип дня і клас споживача. Ця модель виражає навантаження як лінійну функцію однієї або декількох пояснювальних змінних разом з похибкою. $S_t = a_0 + a_1 L_t^{(1)} + \dots + a_k L_t^{(k)} + \varepsilon_t, \quad [1.1]$ де S_t – навантаження; $L_t(1), \dots, L_t(k)$ – пояснювальні змінні, що корелюють з навантаженням; $a_1, \dots, a_k$ – коефіцієнти регресії та ε_t - шум [26].	
Авторегресія (AR)	Моделі часових рядів базуються на припущенні, що дані мають внутрішню структуру, таку як автокореляцію, тренд або сезонні коливання. Методи прогнозування виявляють і досліджують таку структуру. Якщо передбачається, що навантаження S_t є лінійною комбінацією попередніх навантажень, то для прогнозування майбутніх значень навантаження можна використовувати авторегресійну модель (AR). Авторегресія p-го порядку, AR(p), визначається так: $S_t - \sum_{i=1}^p \phi_i S_{t-i} = \varepsilon_t, \quad [1.2]$ де ε_t – випадкове збурення навантаження (або помилка прогнозування); ϕ_i – коефіцієнти авторегресії, що показують вагу впливу попередніх значень.	13,03% [30];
Ковзаюче середнє (MA)	Ковзаюче середнє (MA) – це модель, в якій часовий ряд розглядається як ковзаюче середнє (нерівномірно зваженого) випадкового ряду ε_t. Модель ковзного середнього порядку q, або $MA(q)$, задається формулою: $S_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}. \quad [1.3]$ Існує "дуальність" між процесом ковзного середнього та авторегресійним процесом, а саме тобто модель ковзного середнього може бути переписана (інвертована) в авторегресійну форму (нескінченного порядку). Окрім своїх фільтруючих властивостей, моделі ковзного середнього (MA) не застосовуються для прогнозування навантаження.	11,03% [30];

Таблиця 1.2. Порівняння статистичних методів прогнозування

Метод	Особливості	MAPE
Авторегресія з ковзаючим середнім (ARMA)	У поєднанні з авторегресійними (AR) моделями моделі ковзного середнього (MA) стають потужним інструментом, відомим як модель авторегресійного ковзного середнього (ARMA). Модель ARMA представляє поточне значення часового ряду S_t як лінійну функцію його попередніх значень, а також попередніх значень члена похибки. Ця модель має вигляд $ARMA(p,q)$, де p - порядок частини авторегресії, а q - порядок частини ковзного середнього. $S_t - \sum_{i=1}^p \phi_i S_{t-i} = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}. \quad [1.4]$	17,7% [29]; 5,42% [35]; 9,13% [36];
Моделі ARMAX	Модель авторегресії ковзного середнього з екзогенними змінними $v_1, \dots, v_k$, або $ARMAX(p, q, r_1, \dots, r_k)$, визначається наступним чином: $\phi(B)S_t = \theta(B)\varepsilon_t + \sum_{i=1}^k \psi^i(B)v_t^i, \quad [1.5]$ де $\psi^i(B)$ - скорочене позначення для $\psi^i(B) = \psi_0^i + \psi_1^i B + \dots + \psi_{r_i}^i B^{r_i}, \quad [1.6]$ де ψ_j^i – відповідні коефіцієнти; r_i – порядкові номери екзогенних факторів.	3,6% [29]; 2.94 -3.35 % [37]; 7,51% [35];
Авторегресійна модель інтегрованого ковзного середнього (ARIMA)	Клас моделей ARIMA, які інтегрують авторегресійну компоненту $AR(p)$ та компоненту ковзного середнього $MA(q)$ наступним чином [38]: $S_t = \phi_1 S_{t-1} + \dots + \phi_p S_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}, \quad [1.7]$ де ϕ_i – коефіцієнт при спостереженні S_{t-i}; ε_t – похибка, розподілена як білий шум; p – порядок виражає найбільш раннє включене значення; θ_i – коефіцієнт при похибці ε_{t-i}; q – порядок ряду, залежить від найпершої попередньої помилки. Стандартний процес моделювання ARIMA охоплює шість послідовних етапів: (I) попередній аналіз, (II) перетворення в стаціонарну модель, (III) ідентифікація компонентів, (IV) оцінка параметрів, (V) тестування та (VI) застосування.	4 % [29]; 5,65% [39]; 6,15% [30]; 6,53% [35];

Таблиця 1.2. Порівняння статистичних методів прогнозування

Метод	Особливості	MAPE
Експоненційне згладжування (ES)	Експоненціальне згладжування — це підхід до прогнозування, при якому прогноз будується на основі експоненційно зваженого середнього значення минулих спостережень. Надійність і точність експоненційного згладжування призвела до його широкого використання в різних сферах застосування. Експоненційне згладжування досягає такого зважування, де експоненційно менші ваги присвоюються старішим спостереженням: $S_t = \alpha S_t + (1 - \alpha) S_{t-1}. \quad [1.8]$ де α – ступінь згладжування.	5,05% [39] (для прогнозування середньої тривалості); 10,13% [40]; 11,41% [41].

Представлені у таблиці 1.2 статистичні методи прогнозування, як показали дослідження, можуть бути застосовані для прогнозування електричних навантажень з досить високою точністю. Але при цьому, їх можна розділити на дві групи:

– традиційні методи прогнозування, які використовують давно відомі методи математичної статистики (AR, MA, ARMA, Linear Regression, ES) для виявлення залежностей у самому графіку та його ймовірнісних характеристиках. Вони більш прості, краще працюють для прогнозування відносно «спокійних» навантажень, в яких відсутня різкозмінна складова. Але їх точності вже може бути недостатньо в умовах сучасного ринку електричної енергії.

– більш сучасні методи прогнозування, що використовують для прогнозування не тільки інструменти математичної статистики для оцінки ймовірнісних характеристик графіків електричних навантажень, але і зовнішні (екзогенні) фактори, наприклад про погодні дані, тощо. (ARIMAX, ARIMA). Ці методи прогнозування, виходячи з досліджень інших авторів (таблиця 1.2) показують більш високу точність прогнозування, особливо для різкозмінних навантажень.

1.2.2 Штучні нейронні мережі

Штучні нейронні мережі — використання техніки машинного навчання для моделювання складних взаємозв'язків між входами та виходами [42]. ШНМ це моделі машинного навчання, що структурою та функціями подібні до людського мозку, хоч і значно простіші. Вони використовуються для моделювання складних взаємозв'язків між входами та виходами, що робить їх корисними для задач прогнозування та класифікації.

У ШНМ взаємопов'язані вузли, які називаються штучними нейронами, обробляють і передають інформацію за допомогою зважених зв'язків. Модель навчається шляхом тренування, де ваги зв'язків коригуються, щоб мінімізувати похибку між прогнозованим і фактичним виходом. Аналіз досліджень використання ШНМ для прогнозування режимів роботи електричних мереж представлений у таблиці 1.3.

Таблиця 1.3. Аналіз досліджень методів прогнозування електричних навантажень на основі штучних нейронних мереж

Метод	Структура нейронної мережі	MAPE
Feedforward Neural Network (FFNN)	Нейронна мережа з прямим розповсюдженням похибки (FFNN) має архітектуру, де інформація рухається лише в одному напрямку, від вхідного шару до вихідного через один чи більше прихованих шарів. Перший рівень має зв'язання з входом мережі. Кожен наступний шар має зв'язок з попереднім. Останній рівень забезпечує вихід мережі.	1,42% [43]; 4,76-27,8% [44]; 1,39 % [45]; 1,78 – 1,98 % [46];
Nonlinear Autoregressive Exogenous model (NARX)	Нелінійна авторегресійна мережа з екзогенними входами (NARX) - це рекурентна динамічна мережа зі зворотними зв'язками, що охоплюють кілька рівнів мережі. Модель NARX базується на лінійній моделі ARX, яка широко використовується в моделюванні часових рядів.	4-10% [47]; 0,85-2,04% [48];
Recurrent neural network (RNN)	Рекурентна нейронна мережа (RNN) - це мережева структура глибокого навчання, яка використовує інформацію з минулого для покращення продуктивності мережі на поточних та майбутніх вхідних даних. Унікальність RNN полягає в тому, що мережа містить прихований стан і петлі. Циклічна структура дозволяє мережі зберігати минулу інформацію в прихованому стані та оперувати послідовностями.	1,30% [43]; 1,48 % [49]; 3,38% [50]; 2,47 % [51].

Одні з перших публікацій, в яких продемонстровано високу ефективність нейронних мереж для прогнозування електричних навантажень з'явилися більше 30 років тому [52]. Штучні нейронні мережі підходять для прогнозування електричних навантажень, які демонструють складні, нелінійні зв'язки із зовнішніми змінними, такими як погода, час доби, день тижня та інші фактори впливу. Нейронні мережі можуть фіксувати і моделювати ці складні взаємозв'язки, підвищувати точність прогнозування і надавати цінну інформацію про динаміку електричного навантаження, що розглядається [13], [16]. Отже, нейронні мережі є ефективним інструментом для прогнозування електричних навантажень, що характеризуються складними взаємозв'язками із зовнішніми змінними. Їх застосування здатне значно підвищити точність прогнозних оцінок та сприяти покращенню процесів прийняття рішень [42].

1.2.3. Гібридні методи прогнозування

Гібридні методи прогнозування електричних навантажень — це поєднання декількох методів або моделей для підвищення точності прогнозів навантаження. Ці методи використовують сильні сторони кожного окремого методу [26].

Одним з поширених підходів є поєднання моделей часових рядів з методами машинного навчання, такими як штучні нейронні мережі або дерева рішень [21], [39]. Моделі часових рядів використовують історичні дані для моделювання тенденцій, сезонності та інших закономірностей у даних, тоді як методи машинного навчання можуть вловлювати нелінійні зв'язки та взаємодію між різними змінними. Поєднання цих двох типів моделей може призвести до підвищення точності прогнозів навантаження.

Інший гібридний підхід полягає у поєднанні статистичних моделей з фізичними моделями. Статистичні моделі використовують історичні дані для виявлення закономірностей і тенденцій, тоді як фізичні моделі включають знання про основні фізичні процеси, що визначають електричні навантаження, такі як погода, температура і вологість. Поєднуючи ці два типи моделей, спеціалісти можуть підвищити точність прогнозів навантаження, беручи до уваги як історичні

закономірності, так і фізичні фактори, які можуть вплинути на майбутні навантаження [31].

При аналізі публікацій щодо гібридних методів прогнозування електричних навантажень гібридні моделі, як правило, показують майже однакову точність прогнозування, у порівнянні з ШНМ (величина *MAPE* складає 5,46–9,8% [25], або 4,51–7,77% [34] та ін.). За таких умов гібридні методи прогнозування досить складні і «масивні» для налагодження, що робить їх більш складними у порівнянні з іншими методами прогнозування електричних навантажень.

1.3 Аналіз комерційних рішень для прогнозування електричних навантажень

Одним із перспективних напрямів є використання комерційних програмних рішень для моделювання та прогнозування виробітку сонячних фотоелектричних станцій (СЕС). У статті [53] проведено аналіз продуктивності великомасштабної дахової сонячної електростанції потужністю 6,9 МВт за допомогою програмних платформ Helioscope, PVsyst і PVSOL, які широко застосовуються в галузі для оцінки продуктивності та оптимізації роботи СЕС. У таблиці 1.4 представлено значення похибки *MAPE* для цих продуктів:

Таблиця 1.4. Порівняння точності прогнозування програмами Helioscope, PVsyst і PVSOL у дослідженні [53]

Програма	PVsyst	Helioscope	PVSOL
MAPE	0,12%	4,50%	6,96%

У статті [54] представлено детальний бенчмарк восьми комерційних рішень для детерміністичного прогнозування генерації сонячної енергії на короткостроковий період (1–6 годин). Дослідження охоплювало дані з семи різних фотоелектричних станцій, розташованих у чотирьох країнах, протягом шести місяців зимового періоду в Північній півкулі. Для оцінки точності прогнозів використовувалися метрики MAE, RMSE та MBE, які дозволяють оцінити середню абсолютну помилку, середньоквадратичну помилку та середнє зміщення відповідно.

Результати показали значну залежність точності прогнозування від місця розташування станції та кліматичних умов. Наприклад, станція Silves у Португалії демонструвала найкращу точність прогнозів (середнє нормалізоване RMSE близько 27%), тоді як станція Leeuwarden у Нідерландах мала найгірші показники – 49%. Також спостерігалася значна варіативність між учасниками: деякі алгоритми були більш ефективними для коротких часових горизонтів (до 3 годин), тоді як інші краще справлялися з довгими періодами. Важливим фактором стала інтеграція супутникових даних та реальних вимірювань на місці, що впливало на якість прогнозів.

Для прогнозування генерації СЕС одним із провідних прикладів є система прогнозування Solcast [55], яка використовує супутникові зображення в реальному часі та чисельні моделі прогнозування погоди (NWP). Дослідження точності прогнозів, проведене на основі даних 33 високоякісних вимірювальних станцій, показало, що середня абсолютна похибка (*MAPE*) для добових прогнозів генерації енергії становить 5,9% для Solcast, що значно перевищує точність альтернативних моделей, таких як Smart Persistence (13,2%) та GFS (7,7%). Порівняння похибок більш детально наведено у таблицях 1.5, 1.6.

Таблиця 1.5. Похибки *MAPE*, % при прогнозуванні на добу наперед, загальне виробництво енергії за добу, з дослідження [55]

Програма	Solcast	Smart Persistence	GFS
MAPE	5,9% (2,1–9,4%)	13,2%(2,7–21,2%)	7,7% (2,4–13,2%)

Таблиця 1.6. Похибки *MAPE*, % при прогнозуванні на добу наперед та протягом доби, з дослідження [55]

Програма	Solcast	Smart Persistence	GFS
MAPE	5,1% (2,9–8,2%)	9,0% (3,8–14,0%)	6,0% (3,3–9,2%)

У технічному звіті [56] Національної лабораторії відновлюваної енергії (NREL) присвяченому першій фазі проєкту Wind Plant Performance Prediction (WP3), який спрямований на зменшення розбіжностей між очікуваною та фактичною генерацією енергії вітрових електростанцій. Згідно з її результатами,

середня похибка прогнозування річної генерації становить 1,2%, а стандартне відхилення дорівнює 4,8%, що свідчить про значну варіативність серед консультантів. Похибки *MAPE*, % представлені у таблиці 1.7.

Таблиця 1.7. Порівняння похибок прогнозування *MAPE* деперсоніфікованих учасників дослідження [56]

№ учасника	1	2	3	4	5	6	7	8
<i>MAPE</i>	5,46%	4,11%	3,08%	4,89%	4,50%	3,27%	4,18%	2,90%

Загалом ці дослідження підкреслюють складність прогнозування генерації ВДЕ через вплив кліматичних умов та технічних обмежень. Використання комбінованих методів, таких як поєднання чисельних погодніх прогнозів (NWP) із супутниковими даними та машинним навчанням, показує перспективу для покращення точності. Однак навіть найкращі комерційні рішення демонструють значну дисперсію результатів, що вказує на необхідність подальших досліджень і вдосконалення алгоритмів.

1.4 Визначення завдань дисертації

При аналізі робіт з прогнозування електричних навантажень за допомогою статистичних методів (таблиця 1.2), а також за допомогою ШНМ (таблиця 1.3) наведених вище, більшість робіт присвячена прогнозуванню навантажень у електричних мережах з централізованим виробництвом енергії. Такий тип мереж використовується вже багато років і є односпрямованою системою, в якій електроенергія виробляється централізовано на електростанціях і розподіляється через ОСП та ОСР до споживачів. Управління мережею централізоване, а споживачі мають обмежений контроль над використанням електроенергії.

Розвиток ВДЕ, особливо у невеликих домогосподарствах призводить до появи так званих "розумних" мереж (Smart Grid), або мереж з розподіленою генерацією. Ключовими відмінностями між класичними та "розумними" мережами є двосторонній зв'язок, інтеграція відновлюваних джерел енергії, вдосконалений облік, автоматизоване управління відключеннями та підвищена безпека мережі. Ці

функції дозволяють більш ефективно та раціонально використовувати енергетичні ресурси, краще інтегрувати відновлювані джерела енергії, швидше виявляти та ізолювати перебої в електропостачанні, а також підвищити безпеку від кіберзагроз та інших небезпек [57], [58], [59].

МРГ мають ряд недоліків, таких як високі початкові витрати на встановлення та обслуговування відновлюваних джерел енергії, (сонячні панелі та вітрові турбіни, які вимагають значних початкових інвестицій). Під час інтеграції в мережу можуть виникнути технічні проблеми, такі як модернізація мережевої інфраструктури та впровадження схем захисту. Також можуть існувати регуляторні бар'єри, оскільки комунальні підприємства та регуляторні органи можуть не поспішати інтегрувати розподілені джерела в електромережу через занепокоєння щодо стабільності, надійності та безпеки. Ще однією проблемою є обмеженість потужностей для зберігання енергії, що може призвести до марних витрат енергії в пікові періоди та труднощів із задоволенням попиту під час низького рівня виробництва. Переривчастий і непостійний характер виробництва електроенергії з таких джерел, як сонячна і вітрова енергія, може створювати нестабільність в електромережі, що призводить до потенційних відключень електроенергії та інших проблем.

В умовах конкурентних ринків електроенергії прогнозування навантаження набуває все більшого значення через потенційні фінансові втрати, пов'язані з надмірним або недостатнім генерацією/споживанням при укладанні контрактів на продаж або купівлю електроенергії на балансуєчому ринку в режимі реального часу. Статистичні методи, а також нейронні мережі, розглянуті в цьому розділі, пропонують різноманітні інструменти, які можна застосовувати для короткострокового прогнозування навантаження, кожен з яких має різну складність та ефективність прогнозування, при цьому, як правило, нейронні мережі показують більш високу точність прогнозування, ніж статистичні методи.

На основі проведеного аналізу визначено, що актуальною науковою проблемою є розробка ефективних методів короткострокового прогнозування електричного навантаження в умовах функціонування електричних мереж з

розподіленою генерацією, які характеризуються динамічною структурою, високим рівнем невизначеності та нестабільністю виробництва електроенергії з відновлюваних джерел. У зв'язку з цим завданнями дисертаційної роботи є: аналіз існуючих підходів до прогнозування навантаження в класичних та «розумних» електричних мережах; виявлення факторів, що впливають на точність прогнозування в умовах розподіленої генерації; розробка та обґрунтування моделей прогнозування з використанням статистичних методів і штучних нейронних мереж; експериментальна перевірка ефективності запропонованих моделей для типових сценаріїв функціонування сучасних енергосистем з ВДЕ.

1.5 Висновки за першим розділом

1. У більшості досліджень, що були опрацьовані, завдання прогнозування розглядається тільки для прогнозування електричних навантажень окремих споживачів або енерговузла, або тільки для прогнозування генерації за допомогою ВДЕ. Це себе виправдовує для окремих великих гравців енергетичного ринку, але збільшення частки просьюмерів у мережі призводить до створення так званих мереж з розподіленою генерацією, окремі елементи яких не взаємодіють один з одним і не мають можливості або мотивації приймати участь у регулюванні режиму роботи мережі, це завдання покладене на постачальника послуг або місцевий диспетчерський центр. Але просьюмери здатні впливати на загальний режим роботи мережі, і враховуючи основні зовнішні фактори (як правило, метеопараметри) можна опосередковано оцінювати їх вплив на режим роботи мережі.

2. У більшості проаналізованих досліджень поділяють прогнози навантаження на чотири групи з точки зору тривалості прогнозування: довгострокові, середньострокові, короткострокові та дуже короткострокові. Короткострокове прогнозування навантаження (STLF) важливе для щоденних операцій, але наразі існує обмежена кількість методів для дуже короткострокового прогнозування навантаження (VSTLF). Ці методи, як правило, передбачають оцінку найближчого майбутнього навантаження на основі нещодавніх вимірювань

без явного моделювання взаємозв'язку між часом, погодними умовами та навантаженням. Для покращення точності короткострокових моделей прогнозування необхідно збільшити розуміння факторів, що впливають на попит на навантаження, оскільки миттєвий попит може відрізнятися від довгострокових тенденцій.

3. Статистичні методи прогнозування базуються на зборі, обробці та аналізі історичних даних про споживання електроенергії, параметри режиму, та інші фактори, що впливають на роботу електромережі. Традиційні методи (AR, MA, ARMA, Linear Regression, ES) виявляють залежності у графіку імовірностей. Вони простіші, але менш точні, особливо в сучасних умовах ринку електроенергії. Сучасні методи (ARIMAX, ARIMA) використовують зовнішні фактори, такі як погодні умови, для прогнозування. При аналізі наявних досліджень та публікацій у статистичних методів прогнозування $MAPE_{stat} > 10\%$.

4. Штучні нейронні мережі (ШНМ) — це моделі машинного навчання, які аналізують вхідні дані та генерують прогнози, використовуючи набір зважених зв'язків між штучними нейронами. ШНМ навчаються за допомогою процесу тренування, в якому ваги зв'язків адаптуються для мінімізації помилок між прогнозованими та фактичними результатами. ШНМ дещо складніші у налаштуванні, вимагають підготовки та нормалізації вхідних даних, більш вимогливі до розрахункових потужностей, але здатні враховувати зовнішні фактори, які прямо, або опосередковано впливають на режими роботи електричних мереж. При цьому ШНМ точніші за статистичні методи, середня похибка $MAPE_{шнм} \approx 2-10\%$.

5. Гібридні методи прогнозування електричних навантажень об'єднують моделі часових рядів з методами машинного навчання або статистичними моделями з фізичними моделями. Ці методи прогнозування мають порівняно високу точність прогнозування $MAPE_{гіб} \approx 4,51-9,8\%$, але вимагають складнішого налагодження порівняно з іншими методами.

6. Проаналізувавши попередні дослідження, пов'язані з прогнозуванням режимів роботи електричних мереж відкритим залишається питання

прогнозування та оптимізації як електричних навантажень, так і виробництва електроенергії у мережі з розподіленою генерацією, в якій суміщені як традиційні виробництва електроенергії, так і ВДЕ. Тому в плані досліджень в даній дисертації ставиться за мету розробка методів для короткострокового (STF) та ультра короткострокового (VSTF) прогнозування навантажень та виробництва електроенергії з подальшим об'єднанням у єдиний інструмент для оптимізації режимів роботи такої мережі.

2. ВИБІР МЕТОДІВ ДЛЯ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ТА РЕЖИМІВ РОБОТИ ЕЛЕКТРИЧНИХ МЕРЕЖ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ

Упродовж останнього десятиліття спостерігається стійке зростання впровадження ВДЕ на глобальному рівні, що зумовлено як екологічними, так і технологічними чинниками. Їхнє широке розповсюдження стало можливим завдяки істотному зниженню вартості відповідного обладнання та підвищенню його ефективності. Зростання частки ВДЕ вже справляє помітний вплив на структуру енергетичних систем, змінюючи підходи до планування, управління та балансування енергоресурсів.

2.1 Особливості мереж з розподіленою генерацією

У мережі з розподіленою генерацією є кілька особливостей, які можуть впливати на графіки електричного навантаження. Ці особливості виникають через децентралізовану природу розподіленої генерації, коли виробництво електроенергії відбувається в різних точках мережі, а не лише на централізованих електростанціях. У таблиці 2.1 приведені ключові особливості мереж з розподіленою генерацією:[58], [60], [61].

Таблиця 2.1. Ключові особливості мереж з розподіленою генерацією

Особливість ВДЕ	Опис
Мінливість	Розподілена генерація, така як сонячні фотоелектричні панелі або вітрові турбіни, залежать від погодних умов і природних ресурсів. Як наслідок, вихідна потужність цих джерел може значно змінюватися протягом дня і сезону. Ця мінливість спричиняє коливання доступної потужності, що може впливати на планування навантаження. Приклад графіка генерації СЕС за різних погодних умов приведено на рис. 2.1.
Локалізована генерація	Розподілені системи генерації зазвичай встановлюються ближче до точок споживання, таких як житлові або комерційні будівлі. Така локалізована генерація зменшує втрати при передачі та дозволяє більш ефективно використовувати енергію. Однак це також означає, що при плануванні попиту та пропозиції енергії необхідно враховувати наявність та обмеження місцевих ресурсів розподіленої генерації.

Таблиця 2.1. Ключові особливості мереж з розподіленою генерацією

Особливість ВДЕ	Опис
Двосторонній потік електроенергії	Розподілені системи генерації, особливо ті, що оснащені двонаправленими інверторами, передбачають можливість двостороннього потоку електроенергії. Це означає, що в періоди надлишкової генерації надлишок електроенергії може бути повернутий в мережу. І навпаки, коли місцевої генерації не вистачає, додаткова потужність може бути отримана з мережі. Такий двонаправлений потік електроенергії вимагає прогнозування графіків навантаження, щоб врахувати і збалансувати як імпорт, так і експорт електроенергії.

Слід підкреслити, що характер графіків електричного навантаження у мережах із розподіленою генерацією залежить від специфічних особливостей технологій розподіленої генерації, структури мережевої інфраструктури, а також від чинної нормативно-правової бази. Вказані аспекти потребують детального аналізу та розробки удосконалених стратегій управління з метою забезпечення надійного та ефективного функціонування енергосистеми.




Рис. 2.1. Приклад виробництва електроенергії за допомогою СЕС при різних погодних умовах

2.2 Етапи інтеграції ВДЕ у енергосистему на прикладі фотоелектричних СЕС

Падіння вартості генерації фотоелектричними станціями нижче рівня ціни електроенергії з мережі може спонукати споживачів надавати перевагу використанню енергії з фотоелектричних установок, що, у свою чергу, здатне призвести до суттєвого зменшення навантаження на електричну мережу. Це створює значні виклики для операторів систем розподілу та комунальних підприємств. Водночас, через нестабільний характер генерації фотоелектричної енергії, пропускна здатність електричних мереж обмежує можливість підключення великої кількості фотоелектричних електростанцій. У разі відсутності належного управління надмірне впровадження таких станцій може спричинити коливання напруги та інші технічні проблеми в мережі.

Отже, дослідження інтеграції ВДЕ у конкретні розподільчі мережі є вкрай важливим. Розробка оптимальних методів управління та експлуатації дозволить максимально використовувати потенціал ВДЕ, забезпечуючи при цьому стабільність та надійність роботи енергосистеми. Основні етапи інтеграції ВДЕ до енергосистеми представлені у таблиці 2.2.

Таблиця 2.2. Етапи інтеграції ВДЕ у енергосистему [60], [62]:

Етап 1 (0-15 %)	Етап 2 (15-30 %)	Етап 3 (30-60%)
Потужність ВДЕ повністю поглинається місцевим навантаженням; зворотні потоки потужності не виникають, і мають лише незначний вплив на розподільчу мережу.	Попит на місцеве навантаження може бути меншим, ніж вихідна потужність ВДЕ. Надлишок фотоелектричної енергії передається назад в мережу і впливатиме на роботу, захист та якість електроенергії в розподільчій мережі.	Значна частина енергії для місцевого споживання буде надходити від ВДЕ, реверс електроенергії може відбуватися частіше і мати великий вплив на існуючу розподільчу мережу.

На рис. 2.2 приведено приклад графіку електричних навантажень при різних рівнях інтеграції ВДЕ в енергосистему.




Рис. 2.2. Різниця між графіками електричних навантажень при різних рівнях частки ВДЕ у енергосистемі [60]

2.3 Вплив ВДЕ на число годин використання максимумів навантажень у енергосистемі

Розглянемо взаємозв'язок частки встановленої потужності ВДЕ ($CP, \%$) на тривалість годин максимального навантаження системи. Так, у дослідженні [60] на прикладі найбільш навантаженого місяця липня однієї з підстанцій регіону зі значною інтеграцією ВДЕ на рис. 2.3 зображено місячні криві тривалості для різних потужностей ВДЕ, виражені у відсотках від липневого максимуму навантаження. Рис. 2.3 демонструє, що розподілена фотоелектрична генерація може зменшити як пікове навантаження, так і середнє навантаження системи. Зі збільшенням фотоелектричних потужностей зниження пікового навантаження стає поступовим, тоді як долинне навантаження зменшується швидше. Ця розбіжність виникає через те, що пікове навантаження в розподільчій мережі не збігається з піковою годиною фотоелектричної генерації. Більше того, зі збільшенням потужності ВДЕ час піку мережевого навантаження зміщується. Наприклад, коли потужність ВДЕ досягає

свого піку опівдні, чисте навантаження системи може бути в найнижчій точці кривої добового навантаження, як показано на рис. 2.2.

Таблиця 2.3 демонструє, що підключення фотоелектричної генерації ефективно зменшує години пікового навантаження, і чим більша потужність фотоелектричних станцій, тим менша тривалість пікових навантажень.

Таблиця 2.3. Тривалість пікового навантаження підстанції

% інтеграції ВДЕ	Січень	Квітень	Липень	Жовтень
0	44	133	154	100
15	32	117	126	82
30	25	104	78	60
60	24	70	44	53

Виходячи з цього аналізу, розподілена фотоелектрична генерація має такі переваги, як зменшення пікового попиту, збільшення пропускної здатності енергосистеми та зменшення потреби в резервній генерації в енергосистемі.




Рис. 2.3. Місячні впорядковані графіки навантажень, при різних частках встановленої потужності ВДЕ в енергосистемі

2.4 Використання потенціалу ВДЕ

Частка встановленої потужності ВДЕ (CP , %) — це показник, який відображає співвідношення між максимальною встановленою потужністю ВДЕ та встановленою потужністю генерації в електромережі. Енергетичні компанії зазвичай використовують CP для оцінки частки розподіленої потужності ВДЕ по відношенню до регіонального навантаження.

$$CP = \frac{P_{inst.RES}}{P_{inst.SYS}} \cdot 100\%, \quad (2.1)$$

де $P_{inst.RES}$ — встановлена потужність генерації ВДЕ, кВт;

$P_{inst.SYS}$ — встановлена потужність всієї генерації в електромережі, кВт.

Таким чином, ступінь інтеграції фотоелектричної енергії визначається як відношення доступної PV-енергії до річного енергоспоживання навантаження в межах досліджуваної енергосистеми. На рис. 2.4 представлено співвідношення між установленою потужністю ВДЕ та максимальним річним навантаженням, яке становить 43%. Водночас, у розглянутий день частка електроенергії, виробленої з ВДЕ, склала лише 27,6% від загального навантаження. Вироблена фотоелектрична потужність була повністю задіяна, що відповідає 100% коефіцієнту використання встановленої PV-потужності. Енергопостачання навантаження здійснювалося з двох джерел — електричної мережі та фотоелектричних систем. Пунктирні похилі лінії на рис. 2.4 ілюструють частину навантаження, що покривається фотоелектричними системами, тобто так звану "доступну PV-потужність". Сіра заштрихована область відповідає залишковому навантаженню, яке споживається з мережі, та відображає чисте навантаження. З графіка можна спостерігати, що генерація фотоелектричних систем у денний період суттєво зменшує пікове навантаження на розподільчу мережу.




Рис. 2.4. Крива навантаження на підстанцію при $CP = 43\%$

Припустимо, що потужність ВДЕ подвоюється, а навантаження та умови сонячного випромінювання залишаються незмінними. Співвідношення між електроенергією від СЕС та загальним навантаженням того ж дня зростає до 55,2%. Однак фактичний коефіцієнт використання потужності ВДЕ знижується до 76,47%, як показано на рис. 2.5. Порівнюючи рис. 2.4 та 2.5, видно, що вихідна потужність ВДЕ падає нижче нульової лінії, що не відповідає вимогам регулювання системи. Ця частина називається "недоступною фотоелектричною потужністю". Недоступна потужність ВДЕ часто виникає опівдні, коли вихідна потужність ВДЕ дуже висока, а мережеве навантаження досягає найнижчої точки. Встановлення більшої кількості фотоелектричних модулів призводить до збільшення недоступної потужності.

За умов високої частки встановленої потужності відновлюваних джерел енергії спостерігається втрата лінійної залежності між доступною потужністю ВДЕ та загальним обсягом установлених генерувальних потужностей.




Рис. 2.5. Крива навантаження на підстанцію при $CP = 86\%$

2.5 Рівні коливання навантаження у мережі з ВДЕ

Попит на електроенергію в мережі формується під впливом різноманітних чинників і характеризується стохастичними коливаннями, аналіз яких є важливим для налаштування та вдосконалення методів прогнозування.

Функція щільності розподілу ймовірностей — це математична функція, яка використовується для опису відносної ймовірності того, що випадкова величина набуває певного значення. Вона дозволяє обчислити ймовірність того, що випадкова величина потрапить в певний діапазон значень, інтегруючи функцію щільності в цьому діапазоні.

Функція густини ймовірності зазвичай позначається як $f(x)$ і математично визначається таким чином:

$$f(x) = \frac{dF(x)}{dx}, \quad (2.2)$$

де $F(x)$ — функція розподілу випадкової змінної X .

Функція густини ймовірності дає відносну ймовірність того, що випадкова змінна X прийме певне значення x . Щоб розрахувати ймовірність того, що X потрапить у певний діапазон $[a, b]$, ми інтегруємо функцію густини ймовірності за цим діапазоном:

Обчислення ймовірностей:

$$P(a \leq X \leq b) = \int_a^b f(x) dx. \quad (2.3)$$

Важливо зазначити, що функція густини ймовірності невід'ємна для всіх значень x , а інтеграл від функції густини ймовірності по всьому простору дорівнює одиниці:

Інтегрування функції густини ймовірності:

$$\int_{-\infty}^{\infty} f(x) dx = 1. \quad (2.4)$$

Його інтеграл являє собою загальну ймовірність того, що X знаходиться в усьому діапазоні.

З рис. 2.6 видно, що 99,6% 5-хвилинних коливань навантаження не перевищують 2% від пікового навантаження, а 90,0% коливань знаходяться в межах 1% від пікового навантаження [60]. Це свідчить про те, що з точки зору коливань навантаження, розподільча мережа в цій області може значною мірою пристосуватися до дуже випадкових і мінливих джерел розподіленої генерації, таких як фотоелектрична генерація.

З таблиці 2.4 та рис. 2.7 видно, що зі збільшенням частки розподіленої PV-генерації розширюється діапазон коливань мережевого навантаження системи. Ця підвищена мінливість створює проблеми для прогнозування навантаження та необхідність у додатковій резервній потужності. Щоб відповідати вимогам регулювання пікового навантаження, коливання між послідовними 5-хвилинними навантаженнями повинні становити менше 25% від максимального навантаження. Іншими словами, максимальна швидкість зміни навантаження не повинна перевищувати 25% [63].




Рис. 2.6. Функція густини ймовірності 5-хв. коливань навантаження

Як показано в таблиці 2.4, коли частка встановленої потужності ВДЕ становить 50% або нижче, темпи коливань навантаження здебільшого не перевищують 25%, а вплив на регулювання пікового навантаження є мінімальним. Однак, якщо частка встановленої потужності ВДЕ досягає 60% від максимального навантаження, величина коливання потужності навантаження може становити близько 30%.




Рис. 2.7. Частота варіацій мережевого навантаження системи при різних частках встановленої потужності ВДЕ

Таблиця 2.4. Максимальні коливання рівня навантаження в мережі при різних частках встановленої потужності ВДЕ

% інтеграції ВДЕ	0	15	30	40	50	60
Максимальні коливання рівня навантаження	5,1	8,1	16,4	21,9	24,6	29,4

2.6 Дослідження поширених методів прогнозування електричних навантажень на промислових підприємствах

У переважній більшості випадків графіки електричних навантажень промислових підприємств являють собою випадкові процеси. Електричні навантаження ТП 6(10)/0,4 кВ, РП 6(10) кВ, як за активною, так і за реактивною потужністю, як правило, підпорядковуються нормальному закону розподілу. Одним із головних чинників, що впливає на якість прогнозування будь-якого випадкового процесу, є його автокореляційна функція. Тип і параметри автокореляційних функцій електричних навантажень тісно пов'язані з характером технологічного процесу. Найпоширенішим типом автокореляційної функції є експоненційно-косинусна [64]:

$$K(\tau) = De^{-\alpha|\tau|} \cos(\omega_0 \tau); \quad (2.5)$$

де α – коефіцієнт загасання кореляційної функції;

D – дисперсія;

ω_0 – власна частота кореляційної функції.

Для оцінки ефективності прогнозування за допомогою представлених методів (прогнозування по середньому значенню, статистичні методи та ШНМ) виконано моделювання графіка електричних навантажень. Ймовірнісні характеристики графіка (математичне очікування, автокореляційна функція, тощо) відповідали характеристикам графіків навантажень реальних споживачів вузла навантаження промислового підприємства м. Маріуполь за 2020 рік.

Моделювання, на відміну від використання реальних даних на цьому етапі досліджень дозволило більш гнучко змінювати параметри графіка, досліджуючи

можливості кожного з методів прогнозування. Приклад змодельованого графіка представлений на рис. 2.8.

Для моделювання випадкового процесу змін навантаження було використано випадкову послідовність значень $X(i)$ з нормальним законом розподілу, що є білим шумом, з нульовим математичним очікуванням і одиничним середньоквадратичним відхиленням. Для того щоб отримати випадковий процес із кореляційною функцією (2.5), математичним очікуванням M і середньоквадратичним відхиленням σ , кроком дискретизації Δt , необхідно пропустити випадкову послідовність $X(i)$ через фільтр із наступними параметрами [64]:

$$Q(i) = M + a_0 X(i) + a_1 X(i-1) + b_1 Q(i-1) + b_2 Q(i-2), \quad (2.6)$$

де a_0, a_1, b_1 і b_2 - коефіцієнти, що задають характеристику фільтра (2.6), які визначаються як:

$$a_0 = \sigma b_0; \quad a_1 = \frac{\sigma c_0}{b_0}; \quad b_1 = 2e^{-\alpha \Delta t} \cos \omega_0 \Delta t; \quad b_2 = -e^{-2\alpha \Delta t};$$

$$b_0 = \sigma \sqrt{c_1 + \frac{\sqrt{(c_1^2 - 4c_0^2)}}{2}}; \quad c_0 = e^{-\alpha \Delta t} (e^{-2\alpha \Delta t} - 1) \cos \omega_0 \Delta t.$$

У результаті отримано вектор значень потужності P , що складається з 820 значень із дискретністю $\Delta t = 1$ год, математичним очікуванням $M = 6000$ кВт і середньоквадратичним відхиленням $\sigma = 3620$ кВт. Результат моделювання графіка навантаження наведено на рис. 2.8, а його автокореляційна функція – на рис. 2.9.

2.6.2 Використання середніх значень електричних навантажень

Метод прогнозування по середньому є найпростішим з представлених. Суть методу полягає в тому, що знаходиться середня деяка кількість попередніх значень (у розглянутому випадку вона дорівнює $t = 24$, тобто за попередню добу), а потім будується вектор прогнозних значень, причому на інтервалі, що розглядається, всі вони рівні між собою, а графік даного прогнозу представляє пряму лінію. Даний

метод прогнозування є найбільш застарілим на сьогодні, але завдяки його простоті він знайшов широке застосування практично експлуатації систем електропостачання ряду промислових підприємств.




Рис. 2.8. Приклад змодельованого графіка активної потужності




Рис. 2.9. Автокореляційна функція змодельованого графіка активної потужності

Метод середніх значень є загальноживаним і простим підходом для прогнозування електричних навантажень. Процес включає збір історичних даних про електричні навантаження протягом періоду, що нас цікавить, розрахунок середнього навантаження на основі зібраних даних, поправку на сезонні коливання та врахування будь-яких відомих змін, які можуть вплинути на прогноз.

Прогнозоване навантаження розраховується шляхом множення середнього навантаження на тривалість періоду, що нас цікавить.

$$P_{mean} = \frac{\sum_{i=1}^n P}{n}; \quad (2.7)$$

де P_{mean} – прогнозоване значення електричного навантаження, кВт;

P – значення навантажень за попередні години, кВт;

n – кількість годин.

Порівняння змодельованого графіка реактивного навантаження та прогнозу на його основі по середньому представлений на рис. 2.10.




Рис. 2.10. Змодельовані частини графіка навантаження та прогнози за середнім значенням на їх основі на 5 дослідів

2.6.3 Статистичні методи прогнозування

Методи прогнозування з використанням статистичних методів є одними з найбільш поширених та досліджених на сьогодні. Статистичні методи прогнозування електричних навантажень ґрунтуються на аналізі історичних даних про споживання електроенергії. Основні підходи включають у себе:

– Часові ряди. Цей метод використовує історичні дані про споживання електроенергії в певний період часу для прогнозування майбутніх значень. Він може використовувати різні моделі, такі як модель ARIMA (авторегресійна інтегрована ковзаюча середня), модель експоненційного згладжування тощо. Часові ряди ефективні у прогнозуванні короткострокових та середньострокових тенденцій та здатні виявляти сезонність електроспоживання та циклічні зміни у режимах роботи мереж. Але вони не здатні до урахування впливу зовнішніх факторів, які не включені в історичні дані та складних нелінійних залежностей;

– Регресійний аналіз. В цьому методі враховується вплив різних факторів на споживання електроенергії, таких як погода, економічні показники, населення тощо. Модель регресії може бути складеною з декількох змінних. Цей підхід має можливість включення різних факторів, таких як погода, економічні показники, що може підвищити точність прогнозів, але при цьому потребує достатньої кількості даних для побудови точної моделі. Також регресійний аналіз має ризики недооцінки впливу факторів, які можуть бути непрогнозовані або змінюватися з часом;

– Аналіз сезонності та циклів. Цей підхід враховує повторювані патерни у споживанні електроенергії, такі як денна та нічна сезонність, сезонність за місяцями, а також циклічні тенденції. Він відрізняється здатністю виявлення рекурентних закономірностей у споживанні електроенергії. Але при цьому вони обмежені в урахуванні непередбачуваних змін у споживанні електроенергії, таких як зміни у виробництві. Циклічний аналіз спрямований на виявлення довших циклів у часовому ряді, які можуть мати тривалість кілька років або більше;

При аналізі публікацій у розділі 1.2.1 серед статистичних методів прогнозування авторегресійні методи продемонстрували меншу похибку прогнозування ($MAPE \approx 5\text{--}10\%$), ніж наприклад, регресійний аналіз ($MAPE \approx 10\text{--}15\%$). Одним з найбільш досліджуваних статистичним методом прогнозування режимів роботи електромереж з використанням авторегресії є ARIMA (авторегресійна модель інтегрованого ковзного середнього) .

ARIMA — це традиційна модель часових рядів, яка враховує компоненти авторегресії (AR), ковзного середнього (MA) та інтегрування (I) в даних [38], [65], [66].

Компонента авторегресії (AR) визначає, наскільки поточне значення ряду залежить від його минулих значень. У моделі $AR(p)$ (де p - порядок авторегресії), поточне значення ряду y_t представляється як лінійна комбінація його p минулих значень, помножених на відповідні вагові коефіцієнти:

Авторегресійна частина: $AR(p)$:

$$y_t = c + \sum_{i=1}^p f_i y_{t-i} + \epsilon_t; \quad (2.8)$$

де y_t - значення часового ряду в момент часу t ;

c - константа;

f_i - параметри моделі авторегресії порядку p ;

ϵ_t - випадкова помилка в момент часу t .

Компонента інтегрування (I) використовується для стабілізації ряду і приведення його до стаціонарного вигляду. У моделі $ARIMA(d)$ (де d - порядок інтегрування), ряд y_t проходить диференціювання d разів, що призводить до видалення тренду або сезонності.

Інтегруюча частина $I(d)$:

$$y_t = \Delta^d y_t; \quad (2.9)$$

де Δy_t - оператор різниці.

$$\Delta y_t = y_t - y_{t-1}; \quad (2.10)$$

де d - порядок інтегрування, який визначає, скільки разів потрібно диференціювати часовий ряд для отримання стаціонарного часового ряду.

Компонента ковзної середньої (MA) описує взаємозв'язок між поточним значенням ряду та його випадковими помилками в минулому. У моделі $ARIMA(q)$ (де q - порядок ковзного середнього), поточне значення ряду y_t подається як лінійна комбінація його q минулих випадкових помилок, помножених на відповідні вагові коефіцієнти.

Частина ковзаючого середнього $MA(q)$:

$$y_t = c + \epsilon_t + \sum_{i=1}^q \theta_i \epsilon_{t-i}; \quad (2.11)$$

де θ_i – параметри моделі ковзного середнього порядку q .

Загальна модель $ARIMA(p,d,q)$:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \epsilon_t + \sum_{i=1}^q \theta_i \epsilon_{t-i} + \Delta^d y_t; \quad (2.12)$$

p - порядок моделі авторегресії;

d - порядок інтегрування;

q - порядок моделі ковзного середнього.

Цей метод прогнозування реалізується у коді MATLAB за допомогою команди:

$$y_f = \text{forecast}(\text{model}, \text{past_data}, K)$$

де y_f – часовий ряд прогнозних значень;

$model$ – статистична модель авторегресії з інтегрованим ковзним середнім (ARIMA), яка використовується для прогнозування. Ця модель містить інформацію про порядок моделі (AR, MA, інтегровані члени) та оцінені параметри на основі історичних даних;

$past_data$ – вибірка входів-виходів, необхідних для оцінки параметрів закону розподілу та кореляційної функції;

K – кількість кроків для прогнозування, ця величина, що визначає кількість значень, на яку здійснюється прогнозування.

Порівняння змодельованого графіка реактивного навантаження та прогнозу на його основі за допомогою статистичних методів представлені на рис.2.11.




Рис. 2.11. Змодельовані частини графіка активного навантаження P та прогнози за допомогою статистичних методів на їх основі

2.6.4 Методи прогнозування, на основі штучних нейронних мереж (ШНМ)

На сьогоднішній день нейронні мережі є одним з найбільш прогресивних і точних методів прогнозування та оцінки різноманітних процесів в енергетиці.

Прогресивність нейронних мереж з точки зору прогнозування електричних навантажень виявляється у їх здатності до ефективного моделювання та прогнозування складних та змінних патернів споживання електроенергії. Нейронні мережі дозволяють виявляти та використовувати внутрішні залежності та взаємозв'язки в даних, що дозволяє їм пристосовуватися до змін у зовнішніх умовах, таких як погода, графік роботи та звички споживачів електроенергії. Крім того, з використанням нейронних мереж можна досягти високої точності в прогнозуванні, що є важливим у вирішенні проблем енергоефективності та оптимізації режимів електроенергетичних систем.

Доцільність їх використання підтверджується попередніми дослідженнями [13], [14], [16], в яких визначено їх основні переваги: висока точність, універсальність, гнучкість.

Нейрон — це одиниця обробки інформації, яка є фундаментальною для роботи нейронної мережі. На блок-схемі (рис. 2.11) показана модель нейрона, яка є основою для проєктування великого сімейства нейронних мереж, що розглядаються в наступних розділах. Можна виділити три основні елементи нейронної мережі [42]:

– набір синапсів, або з'єднувальних ланок, кожна з яких характеризується власною вагою. Зокрема, сигнал x_j на вході синапсу j , з'єданого з нейроном k , множиться на синаптичну вагу w_{kj} .

– суматор для підсумовування входних сигналів, зважених на відповідні синаптичні сили нейрона;

– функція активації для обмеження амплітуди вихідного сигналу нейрона. Функція активації обмежує допустимий діапазон амплітуди вихідного сигналу до деякого цільового значення;

– модель нейрона на рис. 2.12 також включає зовнішній зсув, який позначається b_k . Зсув b_k впливає на збільшення або зменшення чистого входу функції активації, залежно від того, чи є він додатним або від'ємним, відповідно.




Рис.2.12. Модель штучного нейрона

Математично нейрон k , зображений на рис. 2.11, можна описати парою рівнянь [42], [67] :

$$u_k = \sum_{j=1}^m \omega_{kj} x_j; \quad (2.13)$$

також

$$y_k = \phi(u_k + b_k). \quad (2.14)$$

де $x_1, x_2, \dots, x_m$ — вхідні сигнали;

$w_{k1}, w_{k2}, \dots, w_{km}$ — відповідні синаптичні ваги нейрона k ;

u_k — вихід лінійного суматора, обумовлений вхідними сигналами;

b_k — зсув;

ϕ — функція активації;

y_k — вихідний сигнал нейрону.

Ці особливості і створили передумови для успішного застосування нейронних мереж для прогнозування. Нейронна мережа на підставі вхідних параметрів намагається оцінити стан прогнозованого значення на даний момент і максимально точно відтворити його поведінку в майбутньому.

Навчання нейронної мережі — це процес ітеративної оптимізації параметрів мережі, таких як ваги та зсуви, з використанням маркованого набору даних для вивчення та узагальнення закономірностей на основі даних. Він включає в себе коригування цих параметрів з метою мінімізації заздалегідь визначеної цільової функції, яку часто називають функцією втрат. У таблиці 2.5 представлені основні алгоритми навчання нейронних мереж.

Таблиця 2.5. Алгоритми навчання нейронних мереж

Метод навчання	Опис	Математичне рівняння
Гradientний спуск	Метод мінімізації функції втрат шляхом ітеративного оновлення ваг нейронної мережі в напрямку найкрутішого спадання функції втрат. Правило оновлення пропорційне від'ємному градієнту функції втрат по відношенню до ваг. Цей метод є обчислювально ефективним, але може бути повільним у збіжності, особливо для великих нейронних мереж або неопуклих функцій втрат.	$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}$
Стохастичний gradientний спуск	Варіант gradientного спуску, який оновлює ваги після кожного навчального прикладу, а не після кожної повної партії. Це може призвести до швидшої збіжності та кращого узагальнення, але також може призвести до зашумлених оновлень, які є менш стабільними.	$\Delta w_{ij} = -\eta \frac{\partial E_n}{\partial w_{ij}}$
Міні-пакетний gradientний спуск	Компроміс між пакетним і стохастичним gradientним спуском, де ваги оновлюються після обробки невеликої партії навчальних прикладів. Це може забезпечити переваги обох методів, такі як швидша збіжність і більш стабільні оновлення.	$\Delta w_{ij} = -\eta \frac{1}{m} \sum_{n=1}^m \frac{\partial E_n}{\partial w_{ij}}$
Gradientний спуск на основі імпульсу	Варіант gradientного спуску, який додає компонент імпульсу до оновлення ваг, що допомагає прискорити збіжність за рахунок зменшення коливань і навігації по плоских ділянках функції втрат. Правило оновлення включає біжуче середнє значення градієнтів і гіперпараметр γ , який контролює імпульс.	$v_t = \gamma v_{t-1} + \eta \frac{\partial E}{\partial w}$ $\Delta w_t = -v_t$

де E – функція помилки або функція втрат;

w_{ij} – вага між i -им та j -им нейронами;

n – індекс навчальної вибірки;

m – розмір партії;

η – швидкість навчання;

γ – імпульсний коефіцієнт,

β_1 та β_2 – експоненціальні швидкості спаду для першого та другого моментів;

ϵ – константа, додана до знаменника для чисельної стабільності;

Δw_{ij} – оновлення ваги між i -им та j -им нейронами.

Зворотне поширення помилки – це алгоритм для обчислення градієнтів багат шарової нейронної мережі щодо її ваг, які використовуються для оновлення ваг у напрямку зменшення втрат. Алгоритм працює шляхом поширення помилки у зворотному напрямку від вихідного шару до вхідного, використовуючи правило ланцюгових обчислень для обчислення похідної помилки щодо ваг на кожному шарі. Це дозволяє мережі навчитися коригувати свої ваги у відповідь на сигнал про помилку, покращуючи її здатність робити точні прогнози на нових даних.

Створимо багат шарову нейронну мережу з L шарів, де $z^{(l)}$ та $a^{(l)}$ – вхідні та вихідні вектори для шару l відповідно. Якщо $w^{(l)}$ та $b^{(l)}$ – вагова матриця та вектор зсуву для шару l , а $f^{(l)}$ – функція активації на шарі l , то приймаємо E як функцію втрат:

$$z^{(l)} = w^{(l)} a^{(l-1)} + b^{(l)}; \quad (2.15)$$

$$a^{(l)} = f^{(l)}(z^{(l)}); \quad (2.16)$$

$$E = \text{Loss}(a^{(L)}). \quad (2.17)$$

У прямому розповсюдженні вхідний вектор $a^{(l-1)}$ множиться на вагову матрицю $w^{(l)}$ шару l і додається до вектора зсуву $b^{(l)}$ для отримання проміжного входу $z^{(l)}$. Потім функція активації $f^{(l)}$ застосовується до $z^{(l)}$ для отримання вихідного вектора $a^{(l)}$ шару l . Цей процес повторюється для кожного шару мережі.

Функція втрат E кількісно оцінює розбіжність між прогнозованим виходом $a^{(L)}$ і бажаним виходом, зазвичай використовуючи відповідну функцію втрат, таку як середньоквадратична помилка.

Ці рівняння відображають фундаментальні операції прямого проходу та обчислення втрат у багат шаровій нейронній мережі.

Алгоритм зворотного поширення обчислює градієнти функції втрат відносно ваг, використовуючи правило ланцюгових обчислень. Зокрема, градієнт функції втрат відносно ваг на шарі l можна виразити як:

$$\frac{\partial E}{\partial w^{(l)}} = \frac{\partial E}{\partial a^{(L)}} \frac{\partial a^{(L)}}{\partial z^{(L)}} \frac{\partial z^{(L)}}{\partial a^{(l)}} \frac{\partial a^{(l)}}{\partial z^{(l)}} \frac{\partial z^{(l)}}{\partial w^{(l)}}. \quad (2.18)$$

Це рівняння можна інтерпретувати як серію проміжних похідних, які обчислюються при прямому і зворотному проході через мережу. Кроки алгоритму наступні:

1. Прямий прохід: Обчислення виходу мережі $a^{(L)}$ шляхом поширення входу $z^{(0)}$ через мережу з використанням ваг $w^{(l)}$ та функцій активації $f^{(l)}$.
2. Обчислити вектор помилки $\delta^{(L)}$ на вихідному шарі, використовуючи похідну функції втрат відносно виходу:

$$\delta^{(L)} = \frac{\partial E}{\partial a^{(L)}} \frac{\partial a^{(L)}}{\partial z^{(L)}}. \quad (2.19)$$

3. Зворотний прохід: Поширення вектора помилки $\delta^{(l+1)}$ від вихідного шару до вхідного, обчислюючи похідні помилки за вагами та активаціями на кожному шарі:

$$\delta^{(l)} = \frac{\partial z^{(l+1)}}{\partial a^{(l)}} (\delta^{(l+1)} \cdot f'^{(l+1)}(z^{(l+1)})), \quad (2.20)$$

$$\frac{\partial E}{\partial w^{(l)}} = a^{(l)} (\delta^{(l+1)} \cdot f'^{(l+1)}(z^{(l+1)})). \quad (2.21)$$

Оновлення ваг, використовуючи обчислені градієнти та швидкість навчання η :

$$w^{(l)} \leftarrow w^{(l)} - \eta \frac{\partial E}{\partial w^{(l)}}. \quad (2.22)$$

Алгоритм зворотного поширення помилки [42], зображений на рис. 2.13, повторюється для кожного навчального прикладу або міні-партії, а ваги оновлюються ітеративно, поки не буде досягнуто збіжності або критерію зупинки. Цей алгоритм дозволяє нейронним мережам вивчати складні закономірності в даних і уможливив багато проривів у галузі глибокого навчання.




Рис. 2.13. Загальна схема нейронної мережі зі зворотним розповсюдженням помилки

Для аналізу прогнозу активного навантаження за допомогою нейронної мережі у програмному комплексі MATLAB була створена нейронна мережа прямого розповсюдження (Feedforward Neural Network) з наступними параметрами [16], (рис.2.14, 2.15):

- Кількість шарів – 2;
- Кількість нейронів у прихованому шарі – 7;
- Кількість нейронів у вихідному шарі – 1;
- Функція активації прихованого шару: *Hyperbolic tangent*;
- Функція активації вихідного шару: *Linear*;
- Алгоритм навчання – *Levenberg-Marquart*.

Визначення відповідної кількості нейронів у прихованому шарі нейронної мережі є критично важливим завданням, яке суттєво впливає на здатність мережі ефективно навчатися та узагальнювати надані дані. Один з найпоширеніших

підходів полягає у визначенні кількості прихованих нейронів в межах діапазону від вхідних нейронів до вихідних нейронів.

Далі проводиться перехресна перевірка, коли набір даних поділяється на навчальний і перевірочний. Кілька нейронних мереж навчаються з використанням різної кількості прихованих нейронів, а їхня продуктивність оцінюється на валідаційному наборі. Кількість нейронів, які показують найкращі результати на валідаційному наборі, обирається як оптимальний вибір. Цей метод допомагає зменшити проблеми перенавчання і забезпечує надійну оцінку ідеальної кількості нейронів. Визначення відповідної кількості прихованих нейронів може включати в себе певний ступінь спроб і помилок. В якості функції активації у схованому шарі використовувалася гіперболічна дотична функція активації.

Гіперболічна дотична функція активації, також відома як функція тангенса, визначається як:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad (2.23)$$

Вона приймає вхідне значення x і застосовує до нього експоненціальну функцію. Чисельник дробу віднімає експоненту від'ємного x від експоненти x . Знаменник додає ці два експоненціальні члени разом. Отримане значення є гіперболічним тангенсом кута нахилу x , який знаходиться в діапазоні від -1 до 1. Функція гіперболічного тангенса має S-подібну поведінку і є симетричною відносно початку координат. Вона зазвичай використовується як функція активації в нейронних мережах завдяки своїй здатності ефективно моделювати нелінійні зв'язки. Вона особливо корисна в прихованих шарах нейронних мереж. Вона стискає вхідні дані в діапазоні від -1 до 1, забезпечуючи сильніший градієнт порівняно з сигмоїдною функцією. Зазвичай використовується у прихованих шарах нейронних мереж.

У вихідному шарі — лінійна функція активації. Цілі та входи задаються у вигляді векторів. Лінійна функція активації, також відома як функція тотожності, є

простою функцією активації, яка зазвичай використовується в нейронних мережах. Вона визначається наступним чином:

$$f(x) = x. \quad (2.24)$$

На відміну від інших функцій активації, лінійна функція активації не вносить нелінійності в мережу. Вона просто пропускає вхідне значення без змін, що призводить до лінійної залежності між входом і виходом.

Лінійна функція активації часто використовується в певних сценаріях, таких як регресійні задачі, де мережа повинна виводити безперервні значення без будь-яких обмежень. Вона дозволяє мережі навчатися і представляти лінійні зв'язки між входом і виходом.




Рис. 2.14. Загальна модель нейронної мережі для прогнозування реактивних навантажень




Рис. 2.15. Модель прихованого шару нейронної мережі

Однак, коли лінійна функція активації використовується в більш глибоких нейронних мережах, загальна мережа стає еквівалентною одношаровій лінійній моделі. Це обмежує здатність мережі вловлювати складні нелінійні закономірності в даних. Як результат, у більшості випадків у прихованих шарах краще використовувати нелінійні функції активації, такі як сигмоїдальні або тангенціальні щоб мережа могла вивчати більш складні та нелінійні взаємозв'язки.

Запропонована нейронна мережа складається з вхідного шару, одного прихованого шару та вихідного шару. Вхідний шар отримує історичні дані про навантаження, в той час як вихідний шар надає прогнозовані значення навантаження. Функція активації, що використовується в цій мережі — це гіперболічна тангенціальна передавальна функція.

Порівняння змодельованого графіка реактивного навантаження та прогнозу на його основі за допомогою нейронних мереж представлені на рис. 2.16.




Рис. 2.16. Змодельовані частини графіка активного навантаження та прогноз за допомогою нейронних мереж на основі 5 дослідів

2.6.5 Підготовка вихідних даних

Для досягнення точних і надійних прогнозів необхідно належним чином підготувати вихідні дані, перш ніж застосовувати статистичні та нейронні методи для прогнозування. Початкові дані часто містять шум і пропущені значення, які можуть суттєво вплинути на ефективність моделей прогнозування. Тому кроки попередньої обробки даних є важливими для забезпечення якості та придатності даних для аналізу.

Статистичні та нейронні методи ґрунтуються на припущенні, що дані є репрезентативними, узгодженими та позбавленими викидів. Методи попередньої обробки даних, такі як обробка пропущених даних, виявлення викидів і нормалізація, є важливими для забезпечення цілісності вхідних даних (рис.2.17).

Методи нормалізації даних застосовуються для стандартизації масштабу і розподілу даних, що особливо важливо при використанні нейронних методів. Нормалізація гарантує, що всі ознаки мають однаковий масштаб, запобігаючи домінуванню певних змінних в аналізі виключно через їхні величини. Найпоширеніші підходи до нормалізації включають масштабування *min-max* або стандартизацію, які трансформують дані до заздалегідь визначеного діапазону або надають їм нульове середнє значення та одиничну дисперсію, відповідно. Нормалізуючи дані, нейронні мережі можуть краще обробляти вхідні характеристики і демонструвати покращену збіжність і здатність до узагальнення.

Масштабування даних, також відоме як нормалізація або стандартизація даних — це крок попередньої обробки в нейронних мережах, який передбачає перетворення вхідних даних до узгодженого масштабу. Його мета — привести всі характеристики або змінні даних до однакового діапазону, щоб полегшити ефективне навчання і підвищити продуктивність нейронної мережі.




Рис. 2.17. Приклад вихідних даних до та після підготовки

У цьому методі значення вхідних даних масштабуються до певного діапазону, найчастіше від 0 до 1. Це досягається шляхом віднімання мінімального значення ознаки з кожної точки даних, а потім ділення його на діапазон ознаки (тобто на різницю між максимальним і мінімальним значеннями). Формула для *min-max* масштабування виглядає наступним чином:

$$X_{\text{scaled}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}. \quad (2.25)$$

Масштабування *min-max* гарантує, що всі значення ознак лежать у фіксованому діапазоні, роблячи дані порівнянними і запобігаючи домінуванню якоїсь однієї ознаки в процесі навчання. Це може покращити швидкість збіжності та стабільність процесу навчання, запобігти чисельній нестабільності та гарантувати, що мережа здатна ефективно навчатися на всіх ознаках.

Варто зазначити, що параметри масштабування слід обчислювати на основі навчальних даних і послідовно застосовувати до навчальних, валідаційних і тестових наборів, щоб підтримувати цілісність даних і уникати внесення зсуву в модель.

2.6.6 Порівняння методів прогнозування електричних навантажень та режимів роботи електричних мереж.

Для зменшення впливу помилки вимірювання, а також для перевірки можливості кожного методу робити прогноз для нової вибірки даних операції моделювання графіка, прогнозування, обчислення помилки прогнозу, моделювання роботи мережі повторювалося по 5 разів для кожного методів. Загальне порівняння представлених у розділі методів прогнозування приведено у таблиці 2.6.

Таблиця 2.6. Порівняння методів прогнозування

Метод прогнозування	Переваги	Недоліки
Прогноз за середнім значенням	- Простота та обчислювальна ефективність; - Легко впроваджувати та розуміти.	- Ігнорує складні шаблони; - Не фіксує динамічні зміни.
Статистичні методи	- Враховує лінійні залежності в даних; - Добре підходить для стаціонарних даних.	- Припускає лінійність та стаціонарність даних; - Обмежена здатність фіксувати складні закономірності; - Одновимірне моделювання; - Може погано обробляти нелінійні зв'язки.
Нейронні мережі	- Відображає нелінійні та складні взаємозв'язки; - Здатність працювати з багатовимірними даними; - Може навчатися на основі послідовних і часових даних; - Адаптується до мінливих моделей.	- Обчислювальні витрати на навчання; - Потребує великої кількості даних.

У таблиці 2.7 представлені середні помилки кожного методу прогнозування з дискретністю $t = 1$ год. протягом доби. Середні добові похибки прогнозування представлені у таблиці 2.8.

Таблиця 2.7. Середні похибки за годинами, %

Години	Нейронна мережа	Статистичний метод	За середнім значенням
1	-1,7	-2	-11,3
2	-5,9	-7,7	-16,5
3	-4,3	-8,9	-19,1
4	-1,6	-5,4	-18,1
5	-0,7	-5,4	-18,1
6	4,3	-5,7	-16,8
7	5,6	-3,8	-17,4
8	-0,5	-3,3	-18,6
9	-1,8	-5,3	-19,5
10	-3,1	-5,2	-20,3
11	-2,2	-3,2	-21,7
12	-1,1	-3,7	-22,0

Таблиця 2.8. Середні похибки прогнозування кожним із методів, %

Нейронні мережі	Статистичні методи	За середнім значенням
-1,08	-4,97	-18,28

Згідно з отриманими результатами, прогнозування за допомогою нейронних мереж має найменшу середню добову похибку прогнозування (1,08 %), у порівнянні зі статистичними методами (4,97%) та прогнозуванням за середнім значенням (18,28%).

2.7 Висновки за другим розділом

1. Збільшення частки інтеграції ВДЕ у енергосистему має як позитивні, так і негативні фактори. Згідно досліджень збільшення частки встановленої потужності ВДЕ ($CP, \%$), до 15% знижує тривалість пікового навантаження підстанції в середньому зі 100 годин до 82 годин, але при цьому рівень коливання навантаження зростає з 5,1% до 8,1%, а при збільшенні CP до 60% максимальні рівні коливання навантаження можуть сягати 29,4%. Ці та інші особливості мереж з розподіленою генерацією мають бути враховані при розробці методів прогнозування навантажень у цих мережах.

2. Мережі з розподіленою генерацією мають ключові відмінності від традиційних електромереж, що зумовлює інший підхід до прогнозування їх режимів роботи. Це мінливість генерації, залежність від погодних умов, ступінь інтеграції ВДЕ у енергосистему, можливість використання всього потенціалу ВДЕ у мережі. Тому використання існуючих методів прогнозування генерації та/або споживання електроенергії теж потребують додаткової оцінки в умовах, що склались.

3. Результати попередніх досліджень на прикладі прогнозування реактивних навантажень [16] вказують, що використання прогнозування за середнім значенням навіть на змодельованому графіку реактивних навантажень з відомими ймовірнісними характеристиками є застарілим та дає найвищу з представлених методів середню похибку *MAPE* у 18,28 %. У цей же час статистичні методи показали *MAPE* у 4,97%, а нейронні мережі – 1,08%. При збільшенні мінливості графіка електричних навантажень очікувано зростатиме і похибка прогнозування при використанні вказаних методів прогнозування.

4. Для прогнозування режимів роботи мереж з ВДЕ, особливо зі зростанням коефіцієнту інтеграції потужності, необхідно враховувати не тільки ймовірнісні характеристики графіків електричних навантажень а й зовнішні фактори, такі як температура, швидкість вітру, тощо. З усіх методів прогнозування, що представлені у розділі, ці можливості представлені та переважно використовуються у нейронних мережах.

3. ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ТА ОПТИМІЗАЦІЇ РЕЖИМІВ У МЕРЕЖІ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ. ОПТИМІЗАЦІЯ РЕЖИМІВ РЕАКТИВНОЇ ПОТУЖНОСТІ

3.1 Прогнозування та оптимізація режимів реактивної потужності в електричних мережах

Реактивна потужність потребує компенсації поблизу її споживачів. Попередні дослідження показали, що передбачення та подальше керування компенсаційними пристроями відповідно до прогнозів може значно зменшити перетоки реактивної потужності в мережі, тим самим полегшуючи роботу обладнання [16]. Крім того, рівень напруги в мережі залежить від реактивної потужності, що є ключовим аспектом у вирішенні проблем якості електроенергії. Враховуючи мінливий характер розподіленої генерації, здатної впливати на якість електроенергії в мережі, вимоги до підтримання оптимального коефіцієнта потужності в таких мережах, враховуючи потенційні режими роботи розподіленої генерації, одночасно зростають. Сьогодні ведуться дослідження особливостей КРМ в мережах зі значною часткою ВДЕ. Так, наприклад, в дослідженні [68] було розглянуто методи корекції потужності пристроїв компенсації реактивної потужності, що знизило втрати енергії на 3-5%.

Компенсація реактивної потужності у мережах з відновлюваними джерелами енергії має низку специфічних особливостей, зумовлених нестабільністю генерації та змінними режимами роботи джерел. На відміну від традиційних систем, де реактивна потужність регулюється централізовано, у мережах з ВДЕ виникає необхідність децентралізованого управління, що забезпечує оперативну адаптацію до коливань виробництва енергії. Зокрема, інвертори сонячних і вітрових електростанцій повинні мати можливість швидкого перемикання між режимами генерації та споживання реактивної потужності для підтримання напруги у допустимих межах [69], [70].

Додатковою складністю є те, що розосереджений характер ВДЕ призводить до зміни профілю навантаження в мережі та нерівномірного розподілу реактивної

потужності. Це потребує впровадження адаптивних алгоритмів керування та засобів автоматизованого моніторингу параметрів електромережі в реальному часі. Ефективна КРМ у таких умовах має не лише зменшувати втрати електроенергії, а й підвищувати стабільність мережі, забезпечуючи координацію між численними джерелами генерації і споживачами [71].

Оптимізація режиму реактивної потужності в мережі, що моделюється, здійснюється за допомогою прогнозування реактивних навантажень, з наступним коригуванням потужності компенсуючих пристроїв відповідно до цього прогнозу. Згідно з попередніми дослідженнями [16] для прогнозування навантажень була розроблена нейронна мережа із зворотним розповсюдженням помилки. Параметри ШНМ:

- Кількість шарів – 2;
- Кількість нейронів у прихованому шарі – 9;
- Кількість нейронів у вихідному шарі – 1;
- Функція активації прихованого шару: *Hyperbolic tangent*;
- Функція активації вихідного шару: *Linear*;
- Алгоритм навчання – *Levenberg-Marquart*.

Часто навантаження кожного вузла кільцевої мережі невідомі. Проектування, створення та налагодження мереж для передачі даних про величини навантаження на кожному приєднанні кільцевої мережі в реальному масштабі часу потребує додаткових фінансових витрат.

Для досягнення мети зниження витрат, викликаних перебігом реактивної потужності по мережі, не можна визначити оптимальну потужність КП в кожному вузлі, розглядаючи його окремо. Установка КП в одному вузлі змінює показники ефективності КП в інших вузлах. Особливо це стосується складних мереж, де збільшення потужності КП в одній точці може призвести до збільшення перетоків потужності по інших ділянках до такої величини, що втрати, які збільшилися, можуть звести до мінімуму економічний ефект від установки КП.

Наведені витрати, пов'язані з передачею, компенсацією та платою за реактивну потужність, розраховуються таким чином:

$$C = C_{trans} + C_{comp} + C_{pay}, \quad (3.1)$$

де C_{trans} – витрати пов'язані із передачею реактивної потужності;

C_{comp} – витрати на компенсацію;

C_{pay} – витрати пов'язані з оплатою за перетоки реактивної потужності.

Розглянемо визначення економічного значення реактивної потужності Q_{ec} погляду мінімуму витрат, пов'язаних із купівлею, передачею та компенсацією реактивної потужності. Графіки визначення Q_{ec} представлені на рис.3.1.




Рис. 3.1. Графіки залежності наведених витрат від величини компенсації реактивної потужності

Для вирішення таких завдань зазвичай використовуються градієнтні методи оптимізації, що реалізують ітераційні алгоритми поступового наближення до

оптимального рішення [72]. Для визначення напрямку руху до мінімуму розраховують похідні сумарних витрат (цільової функції) за потужністю КП у кожному вузлі. Фізично вони є питомими парціальними зниженнями сумарних витрат, грн/кВАр на рік, при встановленні одиничної потужності КП в різних вузлах. Далі малу потужність КП (порцію КП) розподіляють між вузлами пропорційно до значення похідних. Вочевидь, що в такому розподілі більшість порцій КП потрапить у вузли з великими значеннями похідних, оскільки зниження реактивної потужності у цих вузлах найбільше знижує сумарні витрати. При нових значеннях реактивної потужності у вузлах знову визначають похідні, які матимуть менші значення, ніж на попередньому кроці. Наступну порцію сумарної потужності КП розподіляють між вузлами пропорційно до нових значень похідних і т.д.

На кожному етапі оптимізації розраховують рівень реактивної потужності мережі. До розрахунку залучаються також трансформатори зв'язку мереж різних класів напруги, вибір оптимальних коефіцієнтів трансформації яких дозволяє запровадити рівні напруги у вузлах у допустимі межі.

При реактивних навантаженнях вузлів, що змінилися через кілька ітерацій, деякі похідні можуть стати негативними, що говорить про завищену потужність КП, визначену для цих вузлів на попередніх ітераціях. При розподілі нової порції КП в ці вузли додаватиметься негативна порція потужності КП і потужність КП в них знизиться, а у вузлах з позитивними значеннями похідних продовжить збільшуватися. Розрахунок закінчується, коли похідні у вузлах з потужністю КП, що накопичилася, стають близькими до нуля, що говорить про те, що подальше збільшення або зменшення потужності КП призведе тільки до збільшення сумарних витрат.

Для побудови матриці вузлових реактивних потужностей необхідно знати значення реактивної потужності у вузлах мережі з певним інтервалом часу (наприклад, 1 година).

Витрати кожної з ітерацій розраховуються так:

$$3_Q = \frac{Q^2}{U^2} \cdot R \cdot c_{eq} + C_{comp}(Q_{init} - Q_{fin}), \quad (3.2)$$

де Q – реактивна потужність у вузлі, кВАр;

U - напруга, В;

R - матриця вузлових активних опорів, Ом;

c_{eq} – вартість втрат активної потужності, грн/кВт·год;

C_{comp} – витрати на компенсацію, грн.;

Q_{init} - початкове значення реактивної потужності, кВАр;

Q_{fin} - значення реактивної потужності після компенсації, кВАр.

У цьому випадку рядки є номерами вузлів досліджуваної мережі, а стовпці – годинами. Таким чином, ми отримуємо єдиний масив даних для електричної мережі.

$$Q = \begin{bmatrix} Q_{11} & Q_{12} & \dots & Q_{1n} \\ Q_{21} & Q_{22} & & Q_{2n} \\ \dots & \dots & \dots & \dots \\ Q_{m1} & Q_{m2} & & Q_{mn} \end{bmatrix}, \text{ВАр} \quad (3.3)$$

Матриця вузлових опорів радіальної мережі визначається безпосередньо за схемою мережі. Кожен діагональний елемент матриці являє собою суму опорів ділянок від вузла до центру живлення, а позадіагональний - суму опорів ділянок, загальних для проаналізованої пари вузлів.

Таблиця 3.1. Параметри схеми заміщення для СШ 6 кВ

№ вузла	$R_{\text{транс.}}$ Ом	$R_{\text{реакт.}}$ Ом	$R_{\text{каб.питом.}}$ Ом/км	$L_{\text{каб.}}$, м	$R_{\text{каб.}}$ Ом	$R_{\text{мережі}}$ мОм
2	2,60	0,04	0,04	2100	0,08	2,72
3	2,60	0,04	0,16	250	0,04	2,68
4	2,60	0,04	0,07	1960	0,14	2,78
5	2,60	0,04	0,04	250	0,01	2,65
6	2,60	0,04	0,41	500	0,20	2,84
7	2,60	0,04	0,10	1960	0,20	2,84
8	2,60	0,04	0,41	20	0,01	2,65
9	2,60	0,04	0,07	250	0,02	2,66
10	2,60	0,04	0,04	300	0,01	2,65
11	2,60	0,04	0,04	300	0,01	2,65
12	2,60	0,04	0,04	300	0,01	2,65

На основі даних таблиць складаються матриці вузлових опорів R для кожної секції шин. Для отримання матриці вузлових опорів радіальної мережі кожен діагональний елемент матриці являє собою суму опорів ділянок від вузла до ЦЖ, а позадіагональний - суму опорів ділянок, загальних для пари вузлів, що розглядається. Дана матриця представлена в таблиці 3.3.

Таблиця 3.2. Матриця реактивних навантажень для досліджуваної схеми за 5 годин

№ вузла.	Година				
	1	2	3	4	5
1	2734,5	2739,5	2737,0	2732,2	2722,5
2	2541,9	2536,3	2548,5	2553,7	2548,0
3	1531,3	1538,8	1549,6	1559,1	1570,3
4	2486,2	2482,6	2486,5	2476,2	2479,4
5	2861,6	2861,8	2870,8	2891,5	2904,5
6	929,5	934,4	944,8	951,8	958,1
7	2287,6	2298,2	2313,0	2325,4	2342,9
8	2520,0	2541,3	2551,7	2568,3	2584,0
9	238,8	238,8	239,5	239,2	239,6
10	0,0	0,0	0,0	0,0	0,0
11	0,0	0,0	0,0	0,0	0,0
12	0,0	0,0	0,0	0,0	0,0

Вектор похідних має вигляд:

$$\sigma = \frac{2c_{eq}}{U^2} \cdot R \cdot Q_t - C_{cost.comp}, \quad (3.5)$$

де Q_t - транспонована матриця величин реактивної потужності у вузлах;

$C_{cost.comp}$ - стовпцева матриця питомих річних витрат на КП.

На основі даних таблиць складаються матриці вузлових опорів R для кожної секції шин. Для отримання матриці вузлових опорів радіальної мережі кожен діагональний елемент матриці являє собою суму опорів ділянок від вузла до ЦЖ, а позадіагональний - суму опорів ділянок, загальних для пари вузлів, що розглядається. Дана матриця представлена в таблиці 3.3.

Отримані значення реактивних навантажень знову підставляємо у формулу 3.5 і визначають похідні в новій точці. Принаймні наближення похідних до нуля крок ітерації доводиться зменшувати, щоб не пропустити нульову точку. Як у будь-якому ітераційному процесі, що більше робиться ітерацій, то ближче до нульового значення можна навести похідні у зв'язку з зменшенням кроку потужності КП.

Таблиця 3.3. Матриця вузлових опорів для схеми, мОм

2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6
2,6	90,9	6,9	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6
2,6	6,9	46,9	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6
2,6	2,6	2,6	142,8	6,9	2,6	2,6	2,6	2,6	2,6	2,6	2,6
2,6	2,6	2,6	6,9	16,9	2,6	2,6	2,6	2,6	2,6	2,6	2,6
2,6	2,6	2,6	2,6	2,6	209,4	6,9	2,6	2,6	2,6	2,6	2,6
2,6	2,6	2,6	2,6	2,6	6,9	210,7	2,6	2,6	2,6	2,6	2,6
2,6	2,6	2,6	2,6	2,6	2,6	2,6	15	2,6	2,6	2,6	2,6
2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	24,2	2,6	2,6	2,6
2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	18,9	2,6	2,6
2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	18,9	2,6
2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	2,6	18,9

У зв'язку з тим, що в процесі послідовних наближень досягти точного приведення похідних до нуля неможливо (можна лише нескінченно наближатися

до нього), встановлюється припустима відмінність похідних від нуля, за якого процес ітерацій закінчений.

У цьому дослідженні розраховано два види плати за електроенергію - плата за спожиту реактивну потужність, розраховану за методикою [73], а також плата за втрати активної електроенергії, зумовлені протіканням реактивної потужності по елементах схеми. У таблиці 3.4 подано величини місячних оплат за спожиту реактивну потужність за 6 дослідів.

У таблиці 3.5 подано величини виплат за втрати активної потужності в елементах змодельованої електричної мережі, зумовлені протіканням реактивної потужності за 6 місяців. Графіки з величинами оплат за реактивну потужність, витратами, пов'язаними з перетоками активної потужності та загальними витратами на КРМ представлені на рис. 3.3–3.5.

У таблиці 3.6 вказано загальні витрати за місяць при застосуванні нових методів прогнозування, порівняно з прогнозуванням по середньому за 6 місяців.

Таблиця 3.4. Величини оплати за реактивну потужність за місяць

Плата за споживання реактивної потужності, грн	
ШНМ з алгоритмом оптимізації	По середньому
2904,8	31519,7
3108,2	25943,1
3050,1	25458,2
2772,8	27726,8
2520,7	33549,4
2291,6	32024,4

У середньому економія від впровадження сучасних методів прогнозування для управління потужністю компенсувальних пристроїв становить для нейронних мереж 349,1 тис.грн/рік. Таким чином використання нейронних мереж як методу прогнозування окупить себе досить швидко, а їх впровадження можливе на вже

встановлених компенсувальних пристроях і додаткові кошти на обладнання не потрібні.




Рис. 3.3. Порівняння величин оплати за реактивну потужність

Таблиця 3.5. Величини витрат за втрати активної потужності за місяць

Плата за втрати активної потужності, грн	
ШНМ з алгоритмом оптимізації	По середньому
82,0	2411,9
53,1	2078,3
107,1	3151,9
97,4	2865,4
88,5	2604,9
80,5	2368,1




Рис. 3.4. Порівняння величин оплати за втрати активної потужності

Середня річна економія розраховується таким чином:

$$P_{ек} = 2 \cdot \left(\sum_{i=1}^5 P_{ек i} \right), \quad (3.6)$$

де $P_{ек i}$ – сумарна економія коштів за оплату електроенергії за 6 дослідів кожним із методів.

Таблиця 3.6. Величини сумарних місячних витрат за 12 годин

Загальні витрати, грн	
ШНМ з алгоритмом оптимізації	По середньому
2986,8	33931,6
3161,2	28021,4
3157,2	28610,1
2870,2	30592,1
2609,3	36154,3
2372,0	34392,5




Рис. 3.5. Порівняння величин сумарних витрат на КРМ

3.2 Використання нейронних мереж для прогнозування генерації електроенергії альтернативними джерелами в електромережах з розподіленою генерацією.

Збільшення частки альтернативних джерел енергії, зокрема електростанцій на сонячних панелях у структурі генерації сучасних енергосистем, призводить до ускладнення управління такими енергосистемами через мінливість величини виробництва електроенергії, яка залежить від зовнішніх факторів. Також це призводить до збільшення ризиків під час укладання договорів на постачання електроенергії в умовах енергоринку. Вирішенням цієї проблеми може бути прогнозування виробництва електроенергії сучасними засобами, такими як нейронні мережі. При цьому за рахунок гнучкості та нелінійності нейронних мереж відсутня необхідність у вихідних даних, які прямо впливають на величину генерації, а є можливість використання непрямих даних, доступних більшості виробників альтернативної енергії та операторів мереж.

3.2.1 Прогнозування генерації сонячними панелями

Сьогодні багато уваги приділяється питанням прогнозування генерації електроенергії сонячними панелями. Незважаючи на наявність готових рішень для прогнозування та аналізу виробництва електроенергії за допомогою ВДЕ, активно ведеться робота над удосконаленням існуючих методів прогнозування з урахуванням сучасних вимог щодо точності та якості прогнозу. При прогнозуванні генерації сонячними панелями основний акцент робиться використання різних видів сонячної радіації (інсоляції), виміряних у місці установки сонячних панелей. Однак, сучасні дослідження у сфері прогнозування виробництва електроенергії сонячними фотоелектричними (PV) установками приділяють значну увагу використанню метеорологічних даних підвищення точності прогнозів [74], [75].

Методологія прогнозування PV генерації, представлена в [76], ґрунтується на використанні методу планування експерименту (DOE), який дозволяє суттєво скоротити кількість експериментальних прогонів, забезпечуючи високу точність та надійність прийняття рішень. Дослідження наголошує на необхідності врахування таких неконтрольованих факторів, як опади на панелях та пошкоджені датчики погоди, що може впливати на точність прогнозів. Огляд застосування методів машинного навчання (ML) і глибокого навчання (DL) для прогнозування PV потужності [77] підкреслює, що, хоча методи ML широко досліджені, застосування DL для цієї мети обмежене. Основна увага приділяється короткостроковим прогнозам, тоді як довгострокові прогнози досліджено недостатньо. Гібридні моделі, що поєднують фізичні та ML методи, показали найбільшу точність.

Систематичний огляд поточних тенденцій у технологіях прогнозування PV потужності [78] наголошує на необхідності розробки високоточних моделей прогнозування з мінімальною залежністю від погодних умов. Застосування методів машинного навчання та штучного інтелекту в цій галузі дозволяє покращити точність прогнозів. Дослідження [79] є методом короткострокового прогнозування PV потужності на основі рекурентних нейронних мереж (RNN). Модель показує високу точність прогнозів на 15-хвилинному та 30-хвилинному горизонтах. Це

свідчить про високу стабільність та надійність запропонованого методу для реальних PV станцій.

У роботі [80] проаналізовано різні методи прогнозування сонячної PV потужності, порівнюючи їх за методом прогнозування, горизонтом часу, похибкою вимірювань та обчислювальними витратами. ШНМ та методи векторної машини опорних векторів (SVM) є найбільш ефективними для вирішення складних нелінійних моделей прогнозування.

Крім застосування тільки ШНМ для прогнозування генерації за допомогою СЕС, представлені роботи пропонують застосування гібридних моделей, що поєднують як ШНМ, так і статистичні методи прогнозування сонячної інсоляції, наприклад дослідження представлене в [81], показало найкращу продуктивність у порівнянні з традиційними методами, особливо в сонячні дні. Майбутні дослідження можуть зосередитись на аналізі впливу помилок прогнозованих метеорологічних даних на загальну продуктивність моделі. Але варто відзначити складність створення та налаштування таких моделей прогнозування. Застосування штучних нейронних мереж для прогнозування електричних дисбалансів, представлене в [82], показало, що модель LSTM має найменші значення помилки порівняно з іншими методами, що свідчить про високу ефективність запропонованого підходу.

У [83] запропоновано архітектуру штучної нейронної мережі глибокого навчання для прогнозування обсягу поставок електроенергії виробниками з використанням ВДЕ, а також верхньої та нижньої меж інтервалу прогнозування, особливістю якої є використання блоків автокодування з короткозамкненими зв'язками. Це дозволило знизити середню помилку прогнозу на добу вперед до 4,46% та максимальну помилку до 12,81%.

У той самий час значну частку досліджень займають роботи, присвячені зв'язку метеопараметрів із виробництвом електроенергії на СЕС. Так, наприклад, дослідження взаємозв'язку між метеорологічними змінними та вихідною потужністю PV станції, представлене в [84], показало сильну кореляцію між температурою, іррадіацією та продуктивністю станції. Застосування методів

зменшення розмірності, таких як відбір ознак та аналіз основних компонентів, дозволяє значно скоротити час обчислень, забезпечуючи при цьому високу точність моделей. Крім цього, новаторський підхід до прогнозування PV потужності на основі супутникових зображень, описаний у [85], використовує модель, яка враховує нелінійний рух хмар, що дозволяє більш точно прогнозувати траєкторії їхнього руху. Цей метод дозволяє витягувати хмарні характеристики в будь-який встановлений момент часу, покращуючи короткострокові прогнози потужності. Робота [86] використовує штучну нейронну мережу для прогнозування генерації з урахуванням різних погодних параметрів. Результати показали, що використання комбінації трьох параметрів (температура, точка роси та відносна вологість) забезпечує найкращу точність прогнозів.

Крім метеопараметрів, також пропонується використовувати для прогнозування особливості розміщення станцій на місцевості, наприклад, [87] підкреслюється необхідність урахування географічного розподілу установок та поєднання різних типів ВДЕ для зниження дисперсії сукупної генерації. Оптимізований сценарій, що включає сонячні та вітрові установки, дозволяє знизити ймовірність високих та низьких значень генерації. Дослідження [88] пропонує використання моделі природного моделювання для покращення системи автоматичного прогнозування PV генерації. Це сприяє збільшенню обсягу PV генерації в електроенергетичних системах та покращенню управління розподіленою генерацією.

Крім технічних аспектів прогнозування режимів роботи СЕС, також ведуться дослідження, присвячені вивченню інтеграції сонячних PV станцій в електричні мережі різних країн. Так, результати, подані в [89], показали, що Німеччина та Іспанія демонструють найбільшу точність прогнозів. Прогнози потужності дозволяють операторам мереж та проєктувальникам систем оптимально планувати роботу станцій, керувати попитом та пропозицією енергії. Ще одне дослідження системи прогнозування на німецькому енергетичному ринку, представлене в [90], показало, що покращені прогнози фундаментальних змінних сприяють збільшенню доходів від вибору ринку для продажу енергії на 13,5%. В одному з досліджень [91]

обговорюється важливість прогнозування генерації СЕС для успішної інтеграції сонячної енергії в мережі та участі в енергетичних ринках.

Багато з розглянутих робіт представлено порівняння різних моделей прогнозування режимів роботи PV станцій. Так, у роботі [92] використовується ансамблевий метод прогнозування на основі даних про споживання енергії для планування операцій на ринку електроенергії. Майбутні кроки можуть включати інтеграцію додаткових даних, таких як погодні умови для покращення моделей. Порівняння моделей LSTM і GRU нейронних мереж для прогнозування PV потужності, представлене [93], показало, що GRU перевершує LSTM при використанні довгострокових даних навчання. Оптимальне налаштування параметрів рекомендується при зміні вхідних даних для покращення продуктивності моделей. Дослідження [94] пропонує метод прогнозування PV потужності розподільчих систем з високим ступенем проникнення PV, що ґрунтується на використанні невеликого набору представницьких сайтів для моніторингу. Застосування фільтра Калмана для прогнозування фактичного попиту показало високу точність запропонованого методу.

Аналіз публікацій показує, що прогнозування PV генерації залежить від точності обліку метеорологічних даних та застосування передових методів машинного навчання та глибокого навчання. Майбутні дослідження повинні зосередитись на розробці високоточних моделей прогнозування з урахуванням неконтрольованих факторів та інтеграції додаткових даних, таких як погодні умови, для покращення точності прогнозів. Можна зробити висновок про те, що прогноз генерації електроенергії з використанням нейронних мереж має високу точність, а подальші дослідження можуть зосередитися на зниженні вимог до обчислювальних ресурсів і часу навчання нейронних мереж. Так, наприклад, у [14] середня помилка при реальній виміряній інсоляції становить від -0,97% до 4,91%, а при розрахункових значеннях та прогнозі погоди - від -3,86% до 5,12%. Це пов'язано з неточностями у прогнозах погоди та розрахунках інсоляції. ШНМ при правильному налаштуванні потрібно лише 2000–3000 зразків даних, що знижує вимоги до обчислювальних ресурсів та прискорює навчання.

У зв'язку з переліченими факторами виникає необхідність точного прогнозування генерації електроенергії за допомогою сонячних панелей на підставі вибірки більш доступних для отримання даних.

Як вихідні дані з генерації електроенергії використовувався данні у реальному часі електростанції на сонячних елементах лабораторії відновлюваних джерел електроенергії Приазовського державного технічного університету, розташованого у місті Маріуполь. Обсяг даних – вибірка за 2020 рік, інтервал – 10 хвилин. З набору даних були використані дані за часом, виміряної сонячної радіації в місці встановлення сонячних панелей, а також відповідні значення генерованої активної потужності [14].

Для складання набору даних для тренування нейронної мережі використано дані архіву погоди для міста Маріуполь за аналогічний проміжок часу. Дані взяті з архіву сайту [95].

Всі дані були відфільтровані, приведені до дискретності 1 година, прибрані зайві та некоректні значення, а також нічні години, так як вони не несуть інформаційного навантаження, але при цьому вони роблять набір даних для тренування нейронної мережі надмірно великим, що збільшує час тренування мережі, збільшує вимоги до обчислювальних ресурсів.

У результаті набір даних для тренування та оцінки ефективності нейронної мережі містить 4269 значень для тренування нейронної мережі, що складається з восьми параметрів (матриця 4269×8):

- Час (у дробових значеннях від 1);
- Виміряне сонячне випромінювання у місці встановлення сонячних панелей, Вт/м²;
- Розраховане глобальне горизонтальне випромінювання по Clear Sky model для Direct and Diffuse Insolation on Horizontal Surfaces» R.E. Bird and R.L. Hulstrom, Вт/м²;
- Температура, °C;
- Загальна хмарність, %;

- Пряма видимість, км;
- Кут сонця над горизонтом, °;
- Середня потужність генерації електроенергії сонячними панелями за годину, кВт — цільові значення (вихід нейронної мережі).

Традиційно для оцінки продуктивності сонячних панелей сьогодні застосовуються методи, засновані на реальному виміряному значенні сонячного випромінювання в місці їх встановлення. Тому, як взірцеве значення було зроблено прогнозування генерації електроенергії сонячними панелями, засноване на даних виміряного реального сонячного випромінювання.

Модель даних для прогнозування представлена рис. 3.6.




Рис. 3.6. Структура даних для прогнозу, що базується на виміряному сонячному випромінюванні

Окрім цього, поставлено завдання пошуку даних із величинами сонячного випромінювання даної місцевості, які можна отримати розрахунковим шляхом. Складність полягає в тому, що наявні бази даних сонячного випромінювання (PVGIS) отримані з метеорологічних супутників, які оцінюють випромінювання, що доходить до землі за погодними параметрами, такими як хмарність, опади тощо. Отримання цих даних для приватних просьюмерів має труднощі, особливо прогнозні значення, оскільки дані системи надають інформацію за попередні

проміжки часу, без можливості прогнозування. Найзручнішими даними є звичайний метеорологічний прогноз погоди.

При цьому також слід враховувати те, що величина сонячного випромінювання, що доходить до поверхні землі залежить від часу доби, кута нахилу сонця над поверхнею горизонту, азимуту, пори року і т.д. Для вирішення завдання прогнозування генерації електроенергії сонячними панелями на основі непрямих вихідних даних було застосовано "Clear Sky model for Direct and Diffuse Insolation on Horizontal Surfaces" [96]. Принцип розрахунку сонячного випромінювання цієї моделлю заснований на використанні широти, довготи, часової зони, даних про шар озону над даною територією, атмосферного тиску, кількості вологи в повітрі, а також альбедо поверхні землі. Результатом розрахунку є матриця 4×8760 , де 8760 – кількість годин на рік, а 4 стовпці включають:

- Прямі промені, Вт/м^2 ;
- Пряме нормальне випромінювання, Вт/м^2 ;
- Глобальне горизонтальне опромінення, Вт/м^2 ;
- Розсіяне горизонтальне опромінення, Вт/м^2 .

Спрощена структура даних для роботи Clear Sky model представлена на рис. 3.7, а тренування нейронної мережі – на рис. 3.8.




Рис. 3.7. Структура даних для Clear Sky model для Direct and Diffuse Insolation on Horizontal Surfaces» by R.E. Bird




Рис. 3.8. Структура даних для прогнозу, що базується на розрахованому сонячному випромінюванні

На основі досвіду попередніх досліджень [14], [16], була обрана нейронна мережа прямого поширення (Feedforward Neural Network) зі зворотним поширенням помилки і наступними параметрами:

- Кількість шарів – 2;
- Кількість нейронів у прихованому шарі – 21;
- Кількість нейронів у вихідному шарі – 1;
- Функція активації прихованого шару: *Hyperbolic tangent*;
- Функція активації вихідного шару: *Linear*;
- Алгоритм навчання – *Levenberg-Marquart*.

Кількість нейронів N була визначена експериментальним шляхом, з урахуванням специфіки задачі та результатів попередніх тестувань, що дозволило досягти оптимального балансу між точністю моделі та її здатністю до узагальнення, $N = 21$;

Спрощена модель нейронної мережі, створена у програмі MATLAB з використанням пакета Neural Network Toolbox, представлена на рис. 3.9.

На рис. 3.10 наведено графіки, що ілюструють процес навчання, валідації та тестування нейронної мережі, виконані з використанням вбудованих засобів MATLAB.




Рис. 3.9. Спрощена структура нейронної мережі для прогнозування генерації електроенергії сонячними панелями

Аналіз представлених графіків свідчить, що коефіцієнт кореляції R , який оцінює лінійність зв'язку між виходами та цільовими значеннями нейронної мережі, наближається до 0,9. Це вказує на досягнення значного рівня лінійної залежності, що є задовільним результатом.




Рис. 3.10. Графіки з даними тренування, валідації та тестування нейронної мережі

Для оцінки точності роботи нейронних мереж з різними наборами даних, як зразок було зроблено прогнозування генерації електроенергії з використанням реальної вимірної інсоляції у місці встановлення сонячних панелей. В даному випадку на вхід нейронної мережі подаються дані без розрахованих значень прямої та глобальної горизонтальної інсоляції для моделі чистого неба. Приклад прогнозу та відповідних реальних значень наведено на рис. 3.11. Таблиця середніх похибок для п'яти прогнозів з використанням різної кількості вибірок даних представлена у таблиці 3.7.




Рис 3.11. Реальні та спрогнозовані значення потужності генерації електроенергії сонячними панелями на основі розрахованої інсоляції у місці встановлення сонячних панелей

Далі в наборі даних для тренування нейронної мережі обрано розраховані значення прямої та глобальної горизонтальної сонячної інсоляції. Приклад прогнозу представлений на рис. 3.12. Дані середніх похибок прогнозування даним методом також представлені у порівняльній таблиці 3.7.




Рис. 3.12. Реальні та спрогнозовані значення потужності генерації електроенергії сонячними панелями на основі вимірної інсоляції у місці встановлення сонячних панелей

Таблиця 3.7. Порівняння величин середніх похибок прогнозування на основі вимірної інсоляції, а також розрахованої за допомогою Clear Sky model.

Номер експерименту	1	2	3	4	5
Розмір вибірки даних з датасету	1...1500	1...2000	1...3500	1...4000	2500...3500
Виміряна середня похибка рівня інсоляції, %	-0,97	2,28	2,4	0,44	4,91
Розрахована середня похибка рівня інсоляції, %	-3,86	5,74	5,12	-0,81	2,25

Погодинне прогнозування генерації електроенергії сонячними панелями за допомогою нейронних мереж дозволяє отримати точний прогноз. Середня похибка прогнозування з використанням реально вимірної інсоляції у місці встановлення сонячних панелей (для п'яти дослідів у цій роботі) варіюється від -0,97% до 4,91%.

При використанні розрахованих значень сонячної інсоляції, а також прогнозу погоди похибка прогнозування зростає (діапазон у проведених дослідях становив від -3,86% до 5,12%). Це зумовлено насамперед неточностями в прогнозі погоди, а також похибками при розрахунках інсоляції з використанням Clear Sky model. Проте використання цього прогнозу має високу точність і може застосовуватися для оцінки генерації електроенергії при диспетчеризації енергосистем, укладанні договорів на постачання електроенергії більшими електростанціями в так званому ринку на добу вперед.

Крім цього відсутня необхідність використання громіздкого набору даних для роботи нейронної мережі. З порівняння похибок прогнозування обох методів, достатнім є набір з 2000...3000 вибірок даних щоб одержати точного прогнозу. Це своє чергу знижує вимоги до обчислювальних ресурсів і знижує загальний час тренування нейронних мереж.

Попередні дослідження, присвячені питанням прогнозування та оптимізації режимів роботи мереж з розподіленою генерацією, що включають СЕС, виявили суттєвий недолік – проблема вибору вихідних даних, необхідних для прогнозу [13],

[14], [16]. Сучасні засоби, що особливо широко використовуються сьогодні нейронні мережі, здатні давати досить точний прогноз навіть за наявності вхідних параметрів, що слабо впливають на цільові значення, а іноді і вносячи похибки. При цьому модель для прогнозування стає важкою для обробки та обчислення навіть на сучасному обладнанні [97].

Тому при цьому підході до прогнозування важливо правильно підбирати параметри, які є необхідними під час прогнозування та впливають на точність прогнозу. Одним із способів визначення даних, необхідних для прогнозування є визначення кореляційної залежності між вхідними параметрами (метеодані) і цільовими значеннями (рівень виробництва електроенергії).

Автокореляційна функція оцінює ступінь залежності значень часового ряду від його власних минулих значень. Вона ілюструє, як значення ряду корелюють між собою на різних часових зсувах. Автокореляційна функція дозволяє визначити ступінь і напрямок лінійного зв'язку між двома значеннями випадкового процесу в різні моменти часу: t_1 і t_2 . Для стаціонарних, ергодичних випадкових процесів автокореляційна функція не залежить від конкретних моментів часу t_1 і t_2 , а лише від часової затримки $\tau = t_2 - t_1$ між ординатами графіка активної потужності $P(t)$, і може бути визначена на основі єдиного процесу вимірювання за досить тривалий період T :

$$R(\tau) = E\left((P(t) - E_P)(P(t + \tau) - E_P)\right), \quad (3.7)$$

або

$$R(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T - \tau} \int_0^{T-\tau} (P(t) - E_P)(P(t + \tau) - E_P) dt. \quad (3.8)$$

де E_P — очікуване значення процесу $P(t)$.

Для дискретного випадкового процесу $P(t)$ рівняння (3.7) набуває вигляду рівняння (3.9), в якому значення крос-кореляційної послідовності $R_P(m)$ з лагом (зсувом) m задається через:

$$R_p(m) = \frac{1}{N-m} \sum_{n=1}^{N-m} (P_n - P_{av})(P_{n+m} - P_{av}). \quad (3.9)$$

де P_n – значення активної потужності в момент часу n , а P_{av} – середнє значення генерованої активної потужності $P_{(n)}$ за аналізований період часу.

На рис. 3.13 показано приклад реалізації випадкового процесу генерації потужності $P(t)$, а на рис. 3.14 – приклад автокореляційної функції для цього процесу.

Функція перехресної кореляції (крос-кореляції) визначає лінійний зв'язок між двома випадковими процесами на різних інтервалах. Вона показує, як значення одного ряду корелюють зі значеннями іншого ряду. Крос-кореляційна функція розширює можливості кореляційного аналізу, дозволяючи враховувати часові лаги між змінами метеорологічних умов і реакцією на них генерації сонячних панелей.

У контексті прогнозування генерації сонячних панелей крос-кореляційна функція використовується для аналізу впливу різних метеорологічних факторів, таких як сонячне випромінювання, температура, вологість і швидкість вітру, на продуктивність сонячних панелей.




Рис 3.13. Приклад реалізації випадкового процесу генерації електроенергії $P(t)$ сонячною електростанцією




Рис 3.14. Приклад автокореляційної функції випадкового процесу генерації електроенергії $P(t)$ сонячною електростанцією

Крос-кореляційна функція випадкових процесів генерації електроенергії сонячної електростанції $P(t)$ та обраного метеорологічного параметра $X(t)$ визначається як:

$$R_{PX}(m) = \frac{1}{N-m} \sum_{n=1}^{N-m} (P_n - E_P)(X_{n+m} - E_X) \quad (3.10)$$

На рис. 3.15 наведено приклад реалізації випадкового процесу генерації $P(t)$ та випадкового процесу зміни обраного метеорологічного параметра $X(t)$. При аналізі випадкових процесів часто використовують нормовану крос-кореляційну функцію виду:

$$r_{PX}(m) = \frac{R_{PX}(m)}{\sigma_P \sigma_X} = \frac{R_{PX}(m)}{\sqrt{D_P} \sqrt{D_X}} \quad (3.11)$$

де σ_P , σ_X – середньоквадратичні відхилення генерованої потужності P та значення метеорологічного параметра X відповідно, а D_P , D_X – дисперсії генерованої потужності P та значення метеорологічного параметра X .




Рис. 3.15. Приклад реалізації випадкового процесу генерації активної потужності $P(t)$ та випадкового процесу зміни обраного метеорологічного параметра $X(t)$

Для стаціонарних випадкових процесів функція крос-кореляції при $\tau = 0$ не залежить від моменту часу t і є коефіцієнтом крос-кореляції цих випадкових процесів [98]. Коефіцієнт крос-кореляції випадкового процесу генерації $P(t)$ і випадкового процесу зміни метеорологічного параметра $X(t)$ має вигляд:

$$r_{px} = \frac{N \sum_{n=1}^N (P_n X_n) - \sum_{n=1}^N (P_n) \sum_{n=1}^N (X_n)}{\sqrt{\left(N \sum_{n=1}^N P_n^2 - \left(\sum_{n=1}^N P_n \right)^2 \right) \left(N \sum_{n=1}^N X_n^2 - \left(\sum_{n=1}^N X_n \right)^2 \right)}} \quad (3.12)$$

де P_n – значення потужності, що генерується сонячною електростанцією, X_n – значення відповідного метеорологічного параметру, а N визначає кількість пар цих значень.

Дані, отримані з метеостанції, розташованої біля СЕС, подано з дискретністю 5 хвилин. Для відповідності даних з генерації метеоданим, останні були усереднені

та приведені до дискретності 1 год. Перелік метеорологічних параметрів, для яких оцінюється кореляційна залежність із даними про виробництво електроенергії:

- Температура повітря, ° C;
- Крапка роси, ° C;
- Вологість повітря, %;
- Відносний тиск повітря, ГПа;
- Швидкість вітру, м/с;
- Напрямок вітру, ° C;
- Середнє значення сонячної радіації, Вт/м²;
- Мінімальне значення сонячної радіації, Вт/м²;
- Максимальне значення сонячної радіації, Вт/м²;
- Середнє значення сонячної радіації, Вт/м²;
- Рівень забруднення сонячних панелей, %
- Температура панелей, ° C;
- Інтенсивність опадів, мм/год;
- Абсолютна кількість опадів, мм.

На першому етапі було визначено коефіцієнти кореляції між добовими векторами значень метеопараметрів та виробництва електроенергії. Результати розрахунків представлені у таблиці 3.8. Як видно, найбільшу кореляцію мають параметри, пов'язані із сонячною радіацією (близько 0,92), а також параметри часу та температури панелей (0,82). При цьому кореляція з опадами дорівнює нулю через їх низьку інтенсивність у вибраному періоді (жовтень 2021 року).

Однак дані показники можуть некоректно відображати реальну залежність саме метеопараметрів на виробництво електроенергії, оскільки очевидно, що кореляція інсоляції буде переважною, оскільки виміряна безпосередньо в місці встановлення сонячних панелей.

Таким чином, було прийнято рішення перейти від знаходження кореляції з виробництвом електроенергії до питомої виробленої енергії на одиницю потужності P^* (кВт/(Вт/м²)) як більш об'єктивну оцінку кореляційної залежності.

$$P^* = \frac{P}{G}, \quad (3.13)$$

де P – потужність генерації електроенергії, кВт;

G – відповідний рівень інсоляції, Вт/м².

Метеопараметри (насамперед зміна температури повітря протягом доби), а також значення часу доби мають прямий кореляційний зв'язок із генерацією електроенергії сонячними панелями і можуть бути застосовані як додаток до значень сонячної радіації для прогнозування разом із параметрами сонячної радіації. Але основний вплив на вироблення електроенергії, безумовно, мають різні види сонячної радіації, виміряні безпосередньо в місці установки панелей.

Таблиця 3.8. Середні (за місяць) коефіцієнти кореляції між метеопараметрами та виробництвом електроенергії

Параметр	Коефіцієнт (r)
Час	0,82
Температура повітря	0,54
Крапка роси	0,30
Вологість повітря	-0,48
Відносний тиск повітря	0,21
Швидкість вітру	0,56
Напрямок вітру	-0,11
Середнє значення сонячної радіації	0,92
Мінімальне значення сонячної радіації	0,92
Максимальне значення сонячної радіації	0,91
Рівень забруднення сонячних панелей	-0,12
Температура панелей	0,82
Інтенсивність опадів	0,00
Абсолютна кількість опадів	0,00

Перехід від використання значень виробленої електроенергії до питомої електроенергії на одиницю інсоляції P^* (кВт/(Вт/м²)), як більш об'єктивної оцінки кореляційної залежності, дозволив перейти від переважаючої кореляційної залежності з сонячною інсоляцією і сконцентруватися на значеннях погодних та

інших параметрів, які час), і побічно (температура повітря, температура панелі, вологість повітря) дозволяють оцінити рівень впливу виробництво електроенергії сонячними панелями.

Виходячи з результатів, наведених у таблиці 3.9 найбільш значущими параметрами є час, температура повітря, температура панелей і швидкість вітру. При цьому очевидно, що високі значення кореляції швидкості вітру для генерації сонячної електростанції є характерними. Але непрямий взаємозв'язок між цими параметрами полягає в тому, що при підвищенні температури повітря протягом дня посилюються рухи повітряних мас, а оскільки температура повітря і так корелює з виробництвом електроенергії, що призводить до такої картини «кореляції» генерації електроенергії та швидкості вітру. Очевидно, що для питань прогнозування цей параметр не може бути використаний.

Залежність питомої генерації $P^*(t)$ протягом доби не є константною, однак її варіації значно менші, ніж варіації генерації $P(t)$ (рис. 3.16). Це зумовлено тим, що на характер зміни питомої генерації $P^*(t)$ впливають практично всі метеорологічні параметри, за винятком сонячної радіації. Чим вища кореляційна залежність між метеопараметрами та генерацією електроенергії, тим значніші зміни спостерігаються у графіку питомої генерації.

Таблиця 3.9. Середні (за місяць) коефіцієнти кореляції між метеопараметрами та питомим виробництвом електроенергії на одиницю інсоляції

Параметр	Коефіцієнт (r)
Час	0,71
Температура повітря	0,35
Крапка роси	0,27
Вологість повітря	-0,28
Відносний тиск повітря	0,20
Швидкість вітру	0,42
Напрямок вітру,	-0,10
Рівень забруднення сонячних панелей	-0,14
Температура панелей	0,57
Інтенсивність опадів	0,00
Абсолютна кількість опадів	0,01

На рис. 3.16 представлений приклад рівня генерації електроенергії та питомої потужності на одиницю інсоляції




Рис. 3.16. Приклад рівня генерації електроенергії та питомої потужності на одиницю інсоляції

Для оцінки впливу коефіцієнтів кореляції на якість прогнозування генерації СЕС було створено штучну нейронну мережу, параметри якої наведені нижче:

Тип – Feedforward network;

Кількість нейронів у прихованому шарі – 30;

Функція активації у прихованому шарі – Hyperbolic tangent sigmoid;

Функція активації вихідного шару – Linear;

Алгоритм навчання – Levenberg-Marquardt;

Функція оцінки продуктивності – Mean Squared Error;

Максимальне число ітерацій навчання – 1000;

Мінімальний градієнт – $1e^{-5}$.

На сьогоднішній день, як правило, метод середньої абсолютної відсоткової помилки (*MAPE*) превалює в оцінюванні точності прогнозування виробництва та споживання електроенергії. Формула для *MAPE* (таблиця 1.1) передбачає

обчислення відносної похибки для кожного значення, яка визначається як відношення абсолютної похибки до фактичного значення.

Застосування метрики *MAPE* для оцінки точності прогнозування має суттєвий недолік у випадках, коли фактичні значення є близькими до нуля. У разі наближення значень до нуля, знаменник стає дуже малим, що призводить до різкого зростання відносної похибки. Це спричиняє спотворення загальної оцінки, оскільки навіть незначні абсолютні відхилення можуть призвести до дуже високих значень відносної похибки. Внаслідок цього метрика *MAPE* стає непридатною для аналізу даних, що містять низькі або нульові значення.

Для вирішення цієї проблеми запропоновано підхід, який використовує нормалізацію похибки шляхом ділення MAE (середньої абсолютної похибки) на середнє значення споживання електроенергії, що дозволяє уникнути зазначеного недоліку.

$$ERROR = \frac{MAE}{\frac{1}{n} \sum_{i=1}^{24} P_i} \cdot 100\% \quad (3.14)$$

Зазначений підхід забезпечує стабільність оцінки, оскільки нормалізація здійснюється відносно середнього рівня споживання енергії, а не до кожного окремого значення. Таким чином, велика похибка поблизу нульових значень фактичного споживання не домінує в загальній оцінці, що робить метрику більш стійкою та адекватною для використання у прогнозуванні споживання електроенергії.

У додатку А наведено приклади графіків прогнозів з різними наборами вхідних даних для 5 днів. У таблиці 3.10 представлено середні (за 14 днів) похибки прогнозування у відсотках згідно з методом, наведеним у формулі (3.14). Таблиця 3.11 містить похибки прогнозування для кожної.

Результати (таблиця 3.10) засвідчують, що врахування метеорологічних параметрів з високим коефіцієнтом кореляції ($\geq 0,3$), таких як температура панелей, швидкість вітру або вологість, призводить до зменшення похибки прогнозування генерації електроенергії. Причому додавання до будь-якого набору

метеопараметрів питомої генерації на одиницю інсоляції зумовлює додаткове зниження похибки. Це пояснюється тим, що питома генерація на одиницю інсоляції опосередковано враховує більшість цих параметрів, відображаючи інтегральний вплив умов навколишнього середовища. Особливо виражено це у випадку, коли питома генерація додається до невеликого набору метеоданих (таблиця III, рядки 1–6).

При додаванні питомої генерації до великого набору даних (таблиця III, рядки 7–8) похибка зменшується значно меншою мірою. Це пов'язано з тим, що питома генерація вже враховує вплив усіх цих метеопараметрів на генерацію електроенергії, а зниження похибки з 1,53% до 1,35% зумовлене тим, що питома генерація враховує також й інші метеопараметри, які не були враховані під час прогнозування.

Таблиця 3.10. Значення середніх похибок прогнозування генерації СЕС за 14 днів

Вхідні параметри набору даних для навчання ШНМ	Середня похибка, % за 14 днів	Підвищення точності прогнозу, %
1. Інсоляція	15,27	37,79
2. Інсоляція + питома генерація P^*	9,50	
3. Інсоляція + час	13,39	34,06
4. Інсоляція + час + питома генерація P^*	8,83	
5. Інсоляція + час + температура панелей	10,03	50,75
6. Інсоляція + час + температура панелей + питома генерація P^*	4,94	
7. Інсоляція + час + швидкість вітру	11,87	57,79
8. Інсоляція + час + швидкість вітру + питома генерація P^*	5,01	
9. Інсоляція + час + температура повітря	8,45	23,20
10. Інсоляція + час + температура повітря + питома генерація P^*	6,49	
11. Всі параметри без питомої генерації	1,42	16,03
12. Всі параметри з питомою генерацією	1,53	

Таблиця 3.11. Похибки, % прогнозування генерації СЕС для кожної доби

№	Набір даних, доба	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	1. Інсоляція	10,4	39,2	14,8	10,4	10,9	16,2	19,0	11,4	22,5	11,5	9,0	10,8	9,1	19,0
	2. Інсоляція + питома генерація P^*	7,4	11,0	8,7	7,4	3,9	9,7	20,1	5,8	14,2	6,5	3,4	7,9	6,9	20,1
2	3. Інсоляція + час	11,1	16,8	9,6	12,3	6,9	13,4	20,6	7,7	23,9	11,0	4,6	14,7	14,3	20,6
	4. Інсоляція + час + питома генерація P^*	4,5	13,2	4,4	4,7	3,5	15,5	19,1	3,9	10,7	4,6	3,8	9,3	7,4	19,1
3	5. Інсоляція + час + температура панелей	8,7	22,0	9,4	5,1	4,7	20,5	13,9	2,9	11,5	8,3	2,7	8,3	8,7	13,9
	6. Інсоляція + час + температура панелей + питома генерація P^*	2,1	10,4	2,7	3,7	3,0	6,1	10,3	2,0	5,0	4,8	1,0	6,0	3,2	9,0
4	7. Інсоляція + час + швидкість вітру	8,5	21,6	19,1	7,4	7,2	14,2	15,6	6,3	17,6	11,4	6,4	6,4	9,0	15,6
	8. Інсоляція + час + швидкість вітру + питома генерація P^*	6,1	15,4	4,0	3,7	2,9	5,6	5,1	1,9	7,8	4,5	2,1	3,1	3,1	5,1
5	9. Інсоляція + час + температура повітря	6,9	13,9	6,7	2,8	4,2	23,7	11,3	3,0	12,6	7,8	2,9	6,2	5,1	11,3
	10. Інсоляція + час + температура повітря + питома генерація P^*	3,5	14,8	6,0	1,6	3,4	21,9	9,2	3,0	7,8	5,8	1,5	4,4	2,7	5,3
6	11. Всі параметри без питомої генерації	0,8	4,2	2,1	0,5	1,0	4,5	1,7	0,6	1,5	0,6	1,0	1,3	1,0	1,0
	12. Всі параметри з питомою генерацією	1,0	2,3	2,2	0,7	2,1	5,4	1,5	0,5	1,2	0,3	0,2	0,3	0,4	0,3

Таким чином, для досягнення оптимального балансу між складністю моделі та точністю прогнозу рекомендується використовувати набір параметрів, що включає інсоляцію, час та питому генерацію на одиницю інсоляції. Врахування інших метеорологічних параметрів може бути виправданим лише за специфічних умов або для покращення прогнозування у короткострокових інтервалах.

3.2.2 Прогнозування генерації вітровими електростанціями

Прогнозування генерації ВЕС характеризується високим ступенем невизначеності, зумовленої стохастичною природою вітрових потоків та їх значною просторово-часовою варіативністю. Надійність прогнозів істотно залежить від точності метеорологічних даних, обраного горизонту прогнозування та застосованих математичних моделей, серед яких поширення набули статистичні, фізико-математичні та гібридні підходи [99]. Особливе значення має врахування локальних кліматичних умов, а також технічних характеристик вітрових турбін, що впливають на конверсію кінетичної енергії вітру в електричну. Удосконалення методів прогнозування генерації ВЕС є критично важливим для забезпечення балансу між попитом і виробництвом електроенергії в системах з високим рівнем інтеграції відновлюваних джерел енергії [13], [100].

Сьогодні найбільша увага приділяється питанням прогнозування виробництва електроенергії великими вітровими електростанціями, які мають метеорологічне обладнання та необхідні інформаційні ресурси для передачі плану з виробництва електроенергії оператору енергосистеми [101], [102]. Але при цьому обходиться стороною питання прогнозування виробництва електроенергії приватними невеликими вітровими турбінами у складі енергосистеми з розподіленою генерацією, які в сукупності також здатні істотно впливати на перетікання потужності та режим роботи енергосистеми [103].

Як джерело вихідних даних для тренування нейронної мережі використовувалися дані щодо генерації електроенергії, взяті з сайту енергетичного ринку Австралії [104]. Дані є часовим рядом по генерації електроенергії різними

вітровими електростанціями Австралії з дискретністю 5 хвилин за 2018 рік (близько 105 тис. значень). Для тренування ШНМ використовувались дані з рівнями генерації, отримані з вітрової електростанції в м. Портленд потужністю 195 МВт. Цей вибір зумовлений досить близьким (16 км) розташуванням в аеропорту м. Портленд метеостанції, дані з якої доступні для досліджень (рис. 3.17). Під час підготовки ці дані були приведені до дискретності 1 год.

Архів метеорологічних даних, отриманих з метеостанції, розташованої в аеропорту м. Портленд [104] включає дані по часу, температурі, тиску повітря, швидкості та напрямки вітру, тенденції зміни тиску (рис. 3.18). Дані часу для зручності використання в нейронній мережі представлені в частках від цілого значення доби (24 години ϵ 1). Дані напрямки вітру для тренування нейронної мережі представлені як 0,01 частина від кута рози вітрів (наприклад, північний вітер – 0, східний – 0,9, південний – 1,8). Інші дані прийняті без змін.



Рис. 3.17. Взаємне розташування вітрової електростанції та метеорологічної станції у м. Портленд (Австралія)




Рис. 3.18. Структурна схема вихідних даних для тренування нейронної мережі

Для прогнозування генерації електроенергії за допомогою метеорологічних даних була створена нейронна мережа прямого поширення (Feedforward Neural Network) з наступними параметрами:

- Кількість шарів – 2;
- Кількість нейронів у прихованому шарі – 18;
- Кількість нейронів у вихідному шарі – 1;
- Функція активації прихованого шару: *Hyperbolic tangent*;
- Функція активації вихідного шару: *Linear*;
- Алгоритм навчання – *Levenberg-Marquart*.

Кількість нейронів N була визначена експериментально (аналогічно розділу 3.2.1), з урахуванням особливостей вихідних даних для прогнозування та результатів попередніх тестувань, що дало змогу забезпечити оптимальний компроміс між точністю моделі та її здатністю до узагальнення.

Спрощена модель нейронної мережі, створена в програмі MATLAB за допомогою пакету Neural Network Toolbox [105], наведена на рис. 3.19.

Графік продуктивності (рис. 3.20) показує ітерацію, на якій продуктивність валідації досягла мінімуму. Навчання тривало ще 6 ітерацій, після чого навчання було зупинено.




Рис. 3.19. Спрощена структура нейронної мережі для прогнозування генерації електроенергії сонячними панелями

На наступному етапі валідації нейронної мережі здійснюється побудова регресійного графіка, який відображає взаємозв'язок між вихідними значеннями мережі та цільовими показниками.

На графіку (рис. 3.21) пунктирна лінія позначає ідеальний результат, при якому виходи мережі дорівнюють цільовим показникам, а суцільна лінія відображає найкращу лінійну регресію між отриманими та цільовими значеннями. Коефіцієнт кореляції R ілюструє ступінь зв'язку між виходами мережі та цільовими показниками. Значення $R = 1$ свідчить про повний лінійний зв'язок між виходами та цілями, тоді як R , близьке до нуля, вказує на відсутність лінійного зв'язку.




Рис. 3.20. Графік продуктивності нейронної мережі

У даному випадку, навчальні дані свідчать про добру відповідність моделі, зокрема значення R , близьке до 0,9, що також підтверджується результатами валідаційного та тестового наборів. Діаграма розсіювання допомагає виявити окремі точки даних, які демонструють низький рівень відповідності, що може бути корисним для подальшого аналізу.

На рис. 3.22 показаний графік із прикладом реальних (синій колір) та прогнозних значень, отриманих в результаті роботи нейронної мережі. Прогнозування проводилося під час тренування на різних обсягах наборів даних (1500–5500 значень). Прогнозування проводилося на 100 годин наперед, потім значення порівнювалися з реальними 100 значеннями, отриманими раніше від оператора енергосистеми Австралії.

У таблиці 3.12 відображені середні похибки прогнозування $MAPE, \%$ потужності генерації вітрової електростанції.




Рис. 3.21. Графіки навчання, валідації та тестування нейронної мережі




Рис. 3.22. Приклад прогнозу генерації електроенергії ВЕС у порівнянні з реальними значеннями

Таблиця 3.12 – Порівняння значень похибок $MAPE, \%$ прогнозу

Номер експерименту	1	2	3	4	5
Вибірка даних	1...1500	1...2500	1...3500	1...4500	1...4500
$MAPE, \%$	14,3	1,15	-2,46	1,34	4,91

Таким чином, для приватних невеликих вітрових електростанцій без метеорологічних станцій можливо отримувати точний прогноз при використанні в якості вихідних даних звичайного метеорологічного прогнозу погоди (дані про температуру, тиск повітря, і найголовніше – швидкість і напрям вітру).

При прогнозуванні за допомогою нейронних мереж необхідно враховувати їх вимогливість до якості вихідних даних та їх обсягу. Наприклад, при використанні вибірки даних у 1500 значень для тренування нейронної мережі була отримана середня похибка 14,3%, а при вибірці 2500 значень – 1,15%. У той же час при занадто великій вибірці (4500 значень) значення похибки збільшилося до 4,91%, що викликано надмірним узагальненням для тимчасового ряду, тому завдання пошуку компромісу для розміру вибірки для тренування мережі.

Цей прогноз також може бути використаний операторами енергосистем з розподіленою генерацією для оцінки впливу погодних умов на потужність виробництва електроенергії просьюмерами та більш точно балансувати перетоки електроенергії для досягнення найбільш економічного режиму роботи енергосистеми.

3.3 Висновки за третім розділом

1. Виконано прогнозування за допомогою ШНМ з подальшою оптимізацією режимів реактивної потужності за допомогою градієнтних методів послідовного наближення цільової функції до нульового значення. У результаті отримано оптимізовані рівні реактивної потужності у вузлах мережі, витрати на реактивну потужність та її перетоки зменшено до 10 разів, у порівнянні тільки з прогнозуванням за середнім значенням. Окрім цього, ефективне управління реактивною потужністю згідно з прогнозом сприяє покращенню якості електроенергії та надійності електропостачання в умовах змінного навантаження і генерації [70].

2. Досліджено прогнозування виробництва електроенергії сонячними електростанціями за допомогою нейронних мереж. При цьому використовувались як значення вимірної інсоляції у місці встановлення сонячних панелей, так і розрахованої згідно «Clear Sky Model». $MAPE, \%$ при використанні «Clear Sky Model», як джерела вихідних даних, змінюється у діапазоні від $-3,86$ до $5,74\%$, а при прогнозуванні з використанням вимірної інсоляції $MAPE$ знаходиться у діапазоні від $-0,97$ до $4,91\%$. Різниця може бути зумовлена похибками, що вносить «Clear Sky Model» у оцінку рівня інсоляції при певних погодних умовах. Також при експериментуванні за розміром навчальних вибірок встановлено, що для отримання досить точного прогнозу достатньо 2000...3000 вимірів у навчальній вибірці даних.

3. Отримані коефіцієнти кореляції між виробництвом електроенергії за допомогою СЕС та метеопараметрами з метою побудови загальної моделі мережі з

розподіленою генерацією. Найбільші коефіцієнти кореляції були отримані від наступних параметрів:

Час – 0,82;

Температура панелей – 0,82;

Середнє значення сонячної радіації – 0,92;

4. Оцінені коефіцієнти кореляції метеопараметрів до відносної потужності генерації на одиницю потужності як більш об'єктивного показника кореляційної залежності. Виходячи з результатів, найбільш значущими параметрами є час, температура повітря (0,35), температура панелей (0,57) і швидкість вітру (0,42).

5. Включення метеорологічних даних до моделі прогнозування генерації СЕС є обґрунтованим лише за наявності помірної або високої кореляції метеопараметрів з вихідною величиною, що підтверджується коефіцієнтами кореляції вище 0,3–0,4. Такий підхід дозволяє зменшити обсяг вхідних даних, уникаючи врахування факторів, які не мають істотного впливу на точність прогнозу. Це є особливо важливим для спрощення моделей та мінімізації обчислювальних витрат при навчанні нейронних мереж. Більш значущим параметром у прогнозуванні є питома генерація на одиницю інсоляції, яка інтегрує вплив множини факторів, таких як температура панелей, вологість та швидкість вітру. Використання цього комплексного показника у складі базового набору даних (інсоляція та час) демонструє максимальне зниження похибки прогнозування. Таким чином, врахування питомої генерації дозволяє підвищити точність моделей, що робить її ключовим параметром для побудови ефективних алгоритмів прогнозування.

6. Досліджено можливість прогнозування виробництва електроенергії вітровими електростанціями за допомогою нейронних мереж. Була створена нейронна мережа, вхідними параметрами якої були час, температура, швидкість вітру, напрямок вітру, атмосферний тиск. Середні значення *MAPE*,% склали від -2,46 до 4,91%. Також визначено, що середній розмір вибірки для тренування, необхідний для отримання якісного прогнозу має містити не менше 2000 значень.

4. РЕАЛІЗАЦІЯ МОДЕЛІ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ТА РЕЖИМІВ РОБОТИ ЕЛЕКТРИЧНИХ МЕРЕЖ З РОЗПОДІЛЕНОЮ ГЕНЕРАЦІЄЮ

4.1 Збір вихідних даних для моделювання

На основі вже розроблених у попередніх розділах ШНМ виконано прогнозування режимів роботи окремих елементів електричної мережі (споживачів, СЕС, ВЕС). Але у випадку з МРГ не завжди є можливість враховувати кожний елемент окремо, особливо коли в мережі багато невеликих просьюмерів.

Для забезпечення можливості зміни навантажень, структури та інших параметрів реалізовано імітаційне моделювання МРГ у пакеті MATLAB/Simulink.

Мережа складається з системи 110 кВ, від якої живляться два трансформатори ТДН-16000/110/10 кВ. Від першої та другої секцій шин 10 кВ живляться промислові споживачі *Industrial load 1 (IL1)* та *Industrial load 2 (IL2)*, навантаження яких взято з вузла навантаження промислового підприємства.. Передбачається, що промислові споживачі у своїй мережі мають генеруючі потужності ВДЕ, для *IL1* це вітрова електростанція потужністю 150 кВА, для *IL2* – СЕС потужністю 250 кВт.

Окрім промислових споживачів від обох секцій шин 10 кВ живляться кільце з КТП, що живлять побутових споживачів. *Load 1 – Load 4*, до яких підключені 2 СЕС потужністю 30 кВт та 2 ВЕС потужністю по 5 кВт кожна, для імітації впровадження ВДЕ у побутових споживачів. Параметри моделі наведено у таблиці 4.2.

Для моделювання роботи МРГ, найбільш наближених до реальних, дані щодо режимів роботи окремих елементів мережі отримані з реальних джерел, але потім деперсоніфіковано (таблиця 4.1). Далі ці елементи мережі з розподіленою генерацією були додані у модель Simulink (рис. 4.1). Параметри елементів моделі приведені у таблиці 4.2.

Таблиця 4.1. Особливості елементів електромережі з розподіленою генерацією

Елемент	Особливості та вплив роботи мережі	Залежність виробництва та споживання	Джерело даних
Побутові споживачі	Відображають реалістичну різноманітність та динаміку споживання електроенергії, зокрема в зв'язку зі сезонністю та добовою зміною. Їх згладжування та балансування важливо для підтримки стійкості мережі.	Залежні від побутових звичок, погодних умов, добових ритмів, соціальних подій тощо.	Міська розподільча підстанція 110/10 кВ
Промислові споживачі	Мають великі піки навантаження під час робочих годин, що може спричиняти високі навантаження на мережу та потребу у збалансованому режимі роботи.	Впливають від виробничої активності, виробничого циклу, виду та обсягів продукції.	ГПП Металургійного комбінату
Вітрові електростанції	Генерують електроенергію залежно від швидкості вітру, що може варіюватись у широких діапазонах. Вплив на мережу полягає у варіабельності виробництва та необхідності вирівнювання навантаження.	Залежить від атмосферних умов, топології локації станції, технічних характеристик та керування.	ВЕС потужністю 200 МВт
Сонячні електростанції	Генерують електроенергію від сонячної радіації. Їх виробництво залежить від денного світла та погодних умов. Вимагає дієвого керування для підтримки стабільності мережі.	Залежить від сонячної активності, кліматичних умов, технічних характеристик та керування.	СЕС потужністю 240 МВт

Згідно з дослідженнями [60], [106] збільшення частки встановленої потужності ВДЕ у мережі може негативно впливати на її режим роботи, приводити до ускладнення керування та диспетчеризації такої мережі. Тому важливо протестувати запропоноване рішення для прогнозування та оптимізації режиму роботи мережі при частках встановленої потужності ВДЕ. Потужності ВДЕ і відповідний їм частка представлені у таблиці 4.3.




Рис. 4.1. Мережа з розподіленою генерацією, що моделюється

Таблиця 4.2. Величини потужності елементів МРГ, що моделюється

Елемент мережі	Параметри
Система	$U=110$ кВ; $S_{кз}=100$ МВА;
Трансформатор Т1, Т2	ТДН 16000/110/10
Побутове навантаження 1	$S = 800$ кВА;
Побутове навантаження 2	$S = 400$ кВА;
Побутове навантаження 3	$S = 700$ кВА;
Побутове навантаження 4	$S = 600$ кВА;
Промислове навантаження 1	$S = 1000$ кВА;
Промислове навантаження 2	$S = 800$ кВА;
Сонячна електростанція для побутових споживачів	$P = 30$ кВт;
Вітрова електростанція для побутових споживачів	$P = 5$ кВт;
Сонячна електростанція для промисловості	$P=250$ кВт;
Вітрова електростанція для промисловості	$P=150$ кВт;

Таблиця 4.3. Варіанти частки встановленої потужності ВДЕ при моделюванні

Частка ВДЕ, %	Вітрова генерація, кВА	Сонячна генерація, кВА	Загальна потужність ВДЕ, кВА
5	65	150	215
10	150	280	430
20	300	560	860
30	550	750	1300
40	715	1000	1720
50	900	1250	2150

Здатність нейронної мережі адаптуватися до змін, пов'язаних з різними рівнями інтеграції ВДЕ, відіграє критичну роль у прогнозуванні виробництва та споживання електроенергії в сучасних енергетичних системах. Різна частка ВДЕ призводить до значних змін у виробництві електроенергії, що обумовлені змінами у погодних умовах та інших факторах [107]. Нейронні мережі виявляються ефективними у здатності адаптуватися до таких змін, адже вони можуть автоматично враховувати нові дані та змінювати свої ваги та параметри для відтворення нових залежностей.

Також врахування різних рівнів інтеграції ВДЕ допомагає нейронним мережам вчитися відтворювати складні залежності між виробництвом електроенергії та вхідними параметрами, такими як погодні умови. Це забезпечує гнучкість та надійність прогнозування навіть у випадку несподіваних змін у системі.

4.2 Вибір програмної платформи та реалізація моделі МРГ

Для загального моделювання та прогнозування режимів роботи мережі з розподіленою генерацією було обрано систему MATLAB/Simulink. Вибір цієї системи зумовлений тим, що це добре відома система для моделювання та симуляції електричних мереж з великою кількістю модулів та надбудов. Аспекти застосування цієї платформи наведені у таблиці 4.4:

Таблиця 4.4. Особливості системи MATLAB/Simulink для моделювання мережі з розподіленою генерацією

Особливість	Опис
Інтегроване середовище моделювання	Matlab/Simulink забезпечує єдине середовище для розробки, тестування та відлагодження алгоритмів, що усуває необхідність переходу між різними платформами та підвищує ефективність роботи.
Широкий спектр інструментів для аналізу	Matlab містить бібліотеки для статистичного аналізу, візуалізації, обробки сигналів та аналізу часових рядів, що спрощує процес підготовки даних і оцінки результатів прогнозування.
Гнучкість у побудові нейронних мереж	Matlab надає інструменти для створення, налаштування та навчання різних типів нейронних мереж, зокрема для задач прогнозування електричних навантажень.
Можливість симуляції систем у реальному часі	Simulink забезпечує моделювання динамічних систем у реальному часі, що є важливим для прогнозування режимів роботи мереж з розподіленою генерацією з урахуванням змінних параметрів.
Попередній досвід розробки	Обрання MATLAB враховує нашу попередню роботу в середовищі Simulink та необхідність взаємодії між різними моделями, сприяючи їх інтеграції та ефективному розв'язанню завдання.

На основі однолінійної схеми (рис. 4.1) та параметрів мережі (таблиця 4.2) у середовищі Simulink/MATLAB створено модель МРГ.

4.3 Опис складових елементів моделі МРГ

Всі представлені елементи моделі МРГ, що застосовуються, є стандартними блоками програмного комплексу Simulink/MATLAB, документація яких доступна у довідковій системі програми, або за посиланням [105].

Блоки, які моделюють змінне навантаження споживачів – *Three Phase Dynamic Load* (Трифазне динамічне навантаження). Особливість цього блоку у можливості задання графіку навантажень як вектора з необхідною дискретністю (у випадку даного дослідження 1 година) з робочого простору MATLAB. Задання графіку навантажень відбувається через вхід *PQ* (рис. 4.3), інші ж входи є «силовими» через яке відбувається споживання електроенергії при моделюванні. Вектор навантаження задається як добуток між вектором вихідних даних у відносних одиницях та встановленої потужності споживачів.




Рис. 4.2. Модель МРГ у Simulink

Моделювання роботи СЕС та ВЕС відбувалось у два етапи. На першому етапі відбувається моделювання генерації СЕС та ВЕС окремо від основної моделі. (рис. 4.4 та рис. 4.5.). Це дозволяє знизити необхідність у обчислювальних ресурсах та прискорити моделювання. Іншим аспектом є неможливість застосування деяких блоків MATLAB в режимі моделювання *Phasor*, який є оптимальним для дослідження саме режимів роботи мереж змінного струму, що не потребують дослідження складних перехідних процесів та високої частоти дискретизації. Вихідними даними для моделювання моделей з ВДЕ є дані щодо сонячної інсоляції та вітру відповідно. Результатом моделювання цих складових загальної моделі є вектори з даними генерації електроенергії, які були приведені до дискретності 1 година, що відповідає дискретності роботи основної моделі МРГ.




Рис. 4.3. Приклад блоку динамічного трифазного навантаження

Наприклад, на рис. 4.4 зображено структурну модель електричної мережі, яка інтегрована з ВЕС через лінію електропередачі. Це джерело живлення забезпечує передачу електроенергії від ВЕС до електромережі через ЛЕП.

Вимірювальний блок відповідає за зняття значень фазних напруг (V_{abc}) та струмів (I_{abc}) на лінії. Отримані дані передаються до блоку розрахунку потужності, де здійснюється обчислення активної ($P_{wind04kV}$) та реактивної ($Q_{wind04kV}$) потужності на виході ВЕС. Результати розрахунків відображаються у вигляді графіків генерації потужності, що дозволяє відслідковувати роботу ВЕС у реальному часі та зберігати результати до БД.

Блок моделювання вітру здійснює прийом швидкості вітру як вхідного параметра і відповідно до цього керує роботою ВЕС. Модель вітрогенератора підключена до мережі через трифазний інвертор, який відповідає за перетворення потужності.

На рис. 4.5 зображено модель сонячної електростанції (СЕС) з встановленою потужністю 30 кВт, яка інтегрована в електричну мережу з номінальною напругою 0,4 кВ.

Сонячні панелі в цій моделі представлені системою SunPower SPR-415E-WHT-D, яка складається з 7 послідовно з'єднаних модулів та 12 паралельних рядів. Вплив на генерацію електричної енергії здійснюють два ключові параметри: інсоляція та температура панелей.

Для забезпечення управління та контролю, напруга (V_{PI}) та струм (I_{PI}), що генеруються панелями, вимірюються і передаються на контролер інвертора. Контролер інвертора, у свою чергу, використовує ці дані для регулювання роботи інвертора, а також забезпечує оптимізацію роботи панелей через систему MPPT (Maximum Power Point Tracking).




Рис. 4.4. Модель ВЕС потужністю 5 кВт

Інвертор у цій системі виконує перетворення постійного струму (DC), що надходить від сонячних панелей, у змінний струм (AC), який далі передається до електричної мережі через лінію 0,4 кВ. Лінія 0,4 кВ служить для підключення інвертора до трифазної електричної мережі, забезпечуючи передачу енергії до мережі.

Вимірювальний блок здійснює моніторинг фазних напруг (V_{abc}) та струмів (I_{abc}) на виході інвертора, які потім використовуються для розрахунку активної (P_{30kW}) та реактивної (Q_{30kW}) потужності. Результати розрахунків генерованої потужності (P_{30kW} та Q_{30kW}) виводяться у вигляді графіків до БД, які далі використовуються для моделювання роботи МРГ.




Рис. 4.5. Модель СЕС потужністю 30 кВт

4.3 Створення та налагодження ШНМ для прогнозування режиму роботи МРГ

Базуючись на попередніх дослідженнях, приведених у попередніх розділах даної роботи, для прогнозування виробництва та споживання електроенергії у мережі, що моделюється, створена багатошарова нейронна мережа прямого розповсюдження (feedforward neural network), основні параметри якої наведені у таблиці 4.5. Питання та техніки вибору параметрів нейронної мережі описано у п. 2.6.4 дисертації.

Метод навчання ШНМ – метод Левенберга-Марквардта, є компромісом між двома наступними методами:

- метод Ньютона, який швидко сходиться поблизу локального або глобального мінімуму, але також може розійтися;
- метод градієнтного спуску, який гарантує збіжність за допомогою правильного вибору кроку, але сходиться повільно.

Кількість нейронів, яка дорівнює 30 обрано шляхом нарощування їх кількості та досягнення найкращої продуктивності на валідаційному наборі даних, але при цьому уникаючи узагальнення.

Таблиця 4.5. Параметри нейронної мережі

Параметр	Значення	Опис
numHiddenNeurons	30	Кількість нейронів у прихованому шарі
net.trainFcn	'trainlm'	Алгоритм навчання (Levenberg-Marquardt)
net.performFcn	'mse'	Функція оцінки продуктивності (Mean Squared Error)
Функція активації прихованого шару	'tansig'	Hyperbolic tangent
maxEpochs	1000	Максимальна кількість епох навчання
minGrad	1e-5	Мінімальний градієнт для зупинки навчання

Конкретніше, розглянемо оптимізацію функції другого порядку $F(w)$, де g – її градієнтний вектор, а H – її матриця Гессе. Згідно з методом Левенберга-Марквардта, оптимальне коригування, що застосовується до вектора параметрів w , визначається формулою:

$$\Delta w = [H + \lambda I]^{(-1)} g \quad (4.1)$$

де I - одинична матриця того ж розміру, що й H ,

λ - регуляризуючий або завантажувальний параметр, який гарантує, що сума матриць $(H + \lambda I)$ буде визначеною та стійкою протягом усіх обчислень.

Більш докладні відомості про метод тренування Левенберга-Маркварта приведено у [42].

Спираючись на попередні дослідження [13], [14] були обрані наступні вхідні дані для моделювання роботи мережі та прогнозування графіків виробництва/споживання електроенергії за допомогою нейронних мереж:

- Час доби, у годинах, оскільки параметри графіку розподілення вірогідностей та кореляційної функції графіків навантажень прив'язані до цих параметрів;
- Швидкість вітру, м/с, як основний параметр, що впливає на генерацію за допомогою ВЕС;

- Сонячна інсоляція, Вт/м^2 , як основний параметр, що впливає на генерацію за допомогою СЕС;

В якості вихідних даних для тренування нейронної мережі використовується загальний графік електричних навантажень, отриманий шляхом моделювання роботи електричної мережі у середовищі MATLAB/Simulink зі змінними вищенаведеними параметрами. Алгоритм навчання ШНМ і подальшого прогнозування режимів роботи представлений на рис. 4.6.

Алгоритм прогнозування електричного навантаження починається зі створення та налаштування нейронної мережі, яка буде використовуватися для прогнозування. Спочатку визначаються параметри тренування цієї мережі, такі як кількість шарів, кількість нейронів у кожному шарі, функції активації, а також алгоритми оптимізації (таблиця 4.5). Це забезпечує підготовку мережі до подальшого навчання та прогнозування.

Далі відбувається основний процес прогнозування, який виконується в циклі для кожного дня прогнозування протягом 31 дня. Для кожного дня система отримує вхідні дані, такі як інсоляція (*Irradiation*), швидкість вітру (*Wind*), час (*Time*) і потужність споживання від енергосистеми (*Psys*). Ці дані обираються з бази даних, що містить історичні дані за попередні 180 днів. Після отримання даних вони нормалізуються, тобто приводяться до діапазону від -1 до 1, щоб забезпечити оптимальну роботу нейронної мережі.

Після нормалізації дані розділяються на тренувальну та тестову вибірки (таблиця 4.6). На основі тренувальної вибірки нейронна мережа проходить процес навчання, під час якого вона вчиться розпізнавати залежності між вхідними даними та прогнозованим електричним навантаженням. Після навчання мережа використовується для прогнозування навантаження на основі поточних вхідних даних. Отримані результати зберігаються для подальшого аналізу.




Рис. 4.6. Алгоритм первинного створення та налагодження ШНМ

Заключним етапом є оцінка точності прогнозу, яка здійснюється шляхом порівняння прогнозованих значень з фактичними даними. Якщо необхідно, в

алгоритмі змінюється день прогнозування, після чого цикл продовжується до завершення 30-денної послідовності прогнозів. Після завершення циклу результати прогнозування візуалізуються у вигляді графіків та зберігаються для подальшого аналізу та використання. Алгоритм завершується після завершення всіх етапів прогнозування.

Таблиця 4.6. Вибірki даних для навчання та тестування мережі

Загальний набір даних	Данні для навчання	Данні для тестування
180 діб (4320 годин)	150 діб (3600 годин)	30 діб (720 годин)

Представлений на рис. 4.6 алгоритм є первинним, що забезпечує створення та попереднє навчання ШНМ. Для подальшої роботи ШНМ, в тому числі під час налагодження пропонується наступний алгоритм (рис. 4.7). Він забезпечувати «донавчання» нейронної мережі, тобто через одну добу набір даних для навчання та тренування нейронної мережі збільшується на 24 значення, що дозволяє враховувати фактори, які довше розподілені у часі (зміна сезонності, умов оплати за генерацію домашніми ВДЕ, зміни у зовнішній мережі), які не подаються на входи нейронної мережі, але за рахунок зміни тренду графіків електричних навантажень та збільшення похибок ці зміни мають бути враховані у прогнозах.

Алгоритм, зображений на рис. 4.7 починається з завантаження вже налаштованої нейронної мережі, яка раніше була навчена (з алгоритму на рис 4.6). На відміну від першого алгоритму, де нейронна мережа створюється і навчається, ШНМ вже існує і готова до використання для прогнозування.

Після завантаження нейронної мережі починається цикл прогнозування. Спочатку вводяться реальні значення потужності за попередню добу, які використовуються для коригування і перевірки прогнозу. Введення реальних даних додає додатковий рівень точності, оскільки мережа може адаптувати свої прогнози на основі актуальних даних. Також вводяться метеодані (інсоляція, вітер, час,

потужність) з бази даних прогнозу метеопараметрів, які потім нормалізуються (приводяться до діапазону від -1 до 1), аналогічно попередньому алгоритму.




Рис. 4.7. Робочий алгоритм прогнозування режимів роботи мережі з розподіленою генерацією

Результат прогнозування (*output*) потім використовується для формування графіку навантаження. Паралельно, реальні значення графіку використовуються для оцінки точності прогнозу. На основі цієї оцінки похибки, результати коригуються, а дані про похибку зберігаються у відповідній базі даних. Цикл прогнозування завершується після виконання всіх необхідних розрахунків і коригувань, а результати візуалізуються та зберігаються. Графічна інтерпретація донавчання ШНМ представлена на рис. 4.8.




Рис. 4.8. Графічна інтерпретація донавчання ШНМ

4.4 Результати тренування нейронної мережі

В MATLAB для візуалізації та аналізу результатів тренування нейронних мереж використовувались декілька основних функцій параметрів контролю та моніторингу, які перераховані в таблиці 4.7.

Гістограма помилок (error histogram) в MATLAB - це інструмент для візуалізації та аналізу помилок під час тренування нейронної мережі. Під час тренування мережі нейронів, модель намагається підлаштувати свої внутрішні параметри (ваги) для мінімізації функції втрат, яка визначає рівень помилок між прогнозованими та очікуваними виходами.

Таблиця 4.7. Перелік метрик параметрів тренування нейронної мережі

Функція MATLAB	Назва	Опис
plotperform	Графік продуктивності	Відображає графік функції продуктивності, яка показує, як змінюється продуктивність мережі з кожною ітерацією тренування.
plottrainstate	Графік стану тренування	Відображає графік стану тренування, який показує зміну параметрів тренування (наприклад, кількість ітерацій, швидкість навчання тощо) з часом.
plotregression	Графік регресії	Відображає графік регресії, який показує порівняння прогнозованих значень мережі з фактичними значеннями. Це дозволяє оцінити точність регресії.
errorhistogram	Гістограма помилок	Відображає гістограму помилок, що виникають під час тренування мережі. Це допомагає аналізувати розподіл помилок та їх величину.

Гістограма помилок надає графічну інформацію про розподіл цих помилок. Вона відображається як гістограма, де на осі X відображаються значення помилок, а на осі Y – кількість випадків, коли помилка мала певне значення. Ця гістограма дозволяє наочно оцінити, як різні значення помилок розподілені під час тренування мережі. Гістограма помилок для пропонованої ШНМ представлена на рис. 4.9.

У загальному випадку функція представлена у наступній формулі:

$$g(x) = f(x) \text{ для } -\infty \leq x \leq \infty \quad (4.2)$$

де $f(x)$ – щільність ймовірності помилок.

Функція гістограми помилок:

$$g(x) = \frac{n_i}{N} \text{ для } x_i - \frac{w}{2} \leq x \leq x_i + \frac{w}{2} \quad (4.3)$$

де $g(x)$ – частота виникнення значення помилки x ;

n_i – число помилок, що потрапляють у i -й стовпчик гістограми;

N – загальна кількість помилок;

x_i – центр i -го стовпчика гістограми;

w – ширина стовпчика гістограми.




Рис. 4.9. Гістограма помилок для ШНМ, що досліджується

Графік продуктивності (*plotperform*) в MATLAB – це інструмент для візуалізації динаміки функції втрат та інших метрик ефективності під час тренування нейронної мережі. Основним компонентом *plotperform* є графік, який відображає зміну значення функції втрат з часом або кількістю ітерацій тренування. Функція втрат визначає, наскільки добре мережа прогнозує виходи для набору даних навчання. Якщо функція втрат зменшується з кожною ітерацією тренування, то це означає, що мережа навчається. На рис. 4.10 представлений графік продуктивності для представленої ШНМ.

Функція похибки на навчальному наборі:

$$E_{\text{train}}(n) = f(n, w_n, x_{\text{train}}, y_{\text{train}}), \quad (4.4)$$

де $x_{\text{train}}, y_{\text{train}}$ – тренувальний набір даних;

$E(n)$ – помилка мережі на n -й епосі;

n – номер епохи;

w_n – ваги нейронної мережі на n -й епосі;

x_n – вхідні дані на n -й епосі;

y_n – бажані вихідні дані на n -й епосі.

Валідаційна похибка:

$$E_{\text{val}}(n) = f(n, w_n, x_{\text{val}}, y_{\text{val}}), \quad (4.5)$$

де $x_{\text{val}}, y_{\text{val}}$ – валідаційний набір даних.

Тестова похибка:

$$E_{\text{test}}(n) = f(n, w_n, x_{\text{test}}, y_{\text{test}}), \quad (4.6)$$

де $x_{\text{test}}, y_{\text{test}}$ – тестовий набір даних.

Графік стану тренування (*plottrainstate*) - це інструмент в MATLAB, який дозволяє візуалізувати динаміку тренування нейронної мережі під час процесу навчання. Використовуючи цей інструмент, є можливість аналізувати різні аспекти процесу тренування, такі як зміна функції втрат, швидкість навчання, кількість ітерацій та інші параметри (рис 4.11).




Рис. 4.10. Графік продуктивності для ШНМ, що досліджується

Градiєнт:

$$\nabla_w E(n) = \frac{\partial E(n)}{\partial w_n}, \quad (4.7)$$

де $\nabla_w E(n)$ – градiєнт помилки $E(n)$ по вiдношенню до ваг w_n ;

$E(n)$ – помилка мережi на n -й епосi;

w_n – ваги нейронної мережi на n -й епосi.

Формула моменту в градiєнтному спуску:

$$m_k(n) = \eta \cdot \nabla_w E(n) + \beta m_k(n-1), \quad (4.8)$$

де $\eta \cdot \nabla_w E(n)$ – поточний градiєнт з вагою η , що визначає швидкiсть навчання;

$\beta m_k(n-1)$ – попереднє значення моменту з коефiцієнтом iнерцiї β , яке зменшує коливання та сприяє згладженню градiєнта.

$m_k(n)$ – поточний моментний вектор на n -й iтерацiї для вагiв w_k .

β – коефiцієнт моменту (згладжування).

Стан вагiв:

$$w_k(n) = w_k(n-1) - m_k(n), \quad (4.9)$$

де $w_k(n)$ – значення k -го параметра на n -й iтерацiї навчання.

Графiк регресiї (*plotregression*) в MATLAB - це iнструмент для вiзуалiзацiї якостi прогнозування моделi пiд час тренування нейронної мережi для задач регресiї. Цей iнструмент дозволяє аналізувати, наскiльки добре модель передбачає значення цiльової змiнної на основi вхiдних даних. Основна функцiя *plotregression* полягає в тому, щоб вiдобразити графiк, на якому вiдображаються фактичнi значення цiльової змiнної проти передбачених значень моделi. Кожна точка на графiку представляє один приклад з навчального набору даних. Чим ближче точки до дiагональної лiнii, тим краще модель передбачає значення цiльової змiнної.




Рис. 4.11. Графік стану тренування для ШНМ, що досліджується

Графіки на рис. 4.12, отримані після тренування штучної нейронної мережі, демонструють загалом високу точність моделі для прогнозування режиму роботи мережі з розподіленою генерацією. Значення коефіцієнтів кореляції (R) для навчального ($R_n = 0,85$), валідаційного ($R_g = 0,82$) і тестового ($R_m = 0,77$) наборів даних свідчать про достатню узгодженість між прогнозованими та фактичними значеннями, що вказує на здатність моделі ефективно навчатися та виконувати прогнозування на невідомих даних. Сумарний коефіцієнт кореляції ($R = 0,83$) підтверджує загальний високий рівень відповідності моделі. Лінії регресії для кожного з наборів даних розташовані близько до ідеальної лінії ($y = x$), що вказує на хорошу узгодженість між цільовими та прогнозованими значеннями. Модель демонструє стабільну продуктивність, що свідчить про її потенціал для практичного використання у завданнях прогнозування режиму роботи мережі, враховуючи розподілену генерацію.




Рис. 4.12. Графік регресії для нейронної мережі, що досліджується

4.5 Оцінка результатів, визначення похибок

В результаті моделювання роботи представленої мережі з розподіленою генерацією та подальшим прогнозуванням графіка електричних навантажень підстанції була отримані результати, які приведені у таблиці 4.8, що включає дані по *MAPE*, % за 30 днів для різних рівнів частки встановленої потужності ВДЕ *CP*, % у мережі. У таблиці 4.9 приведені середні абсолютні похибки *MAPE*, % за кожну добу.

Згідно отриманих похибок прогнозування (рис. 4.13), середнє значення *MAPE*, % за місяць змінюється від 7,67% при *CP* = 5%, до 10,51% при *CP* = 40%. Незначне зменшення похибки до 10,2 % при *CP* = 50% можна пояснити мінливістю графіків навантажень при даній величині інтеграції ВДЕ до енергосистеми, а також намаганням ШНМ усереднювати прогноз при значних коливання графіка навантажень.




Рис. 4.13. Залежність середнього місячного значення $MAPE$, % від частки встановленої потужності ВДЕ (CP , %)

Таблиця 4.8. Середні абсолютні похибки у відсотках ($MAPE$, %) за місяць

Ступінь інтеграції ВДЕ	Середнє $MAPE$ за 30 днів, %
5%	7,67
10%	8,24
20%	8,82
30%	7,20
40%	10,51
50%	10,20

Мінливість похибки прогнозування може бути викликано різноманітністю факторів, що впливають на генерацію електроенергії від ВДЕ. Наприклад, зміни в погодних умовах, такі як несподівані вітрові пориви або низька сонячна активність, можуть значно впливати на точність прогнозування. Також можуть бути інші фактори, такі як технічні проблеми з обладнанням ВДЕ або зміни в споживачах електроенергії.

Таблиця 4.9. Середні абсолютні похибки у відсотках (*MAPE*, %) по добам

Доба															
Частка ВДЕ	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
5%	11,6	18,4	7,4	10,3	6,2	6,0	10,0	7,5	11,4	10,5	8,5	5,5	7,5	5,0	8,7
10%	11,9	17,0	9,1	10,8	7,4	7,2	12,3	7,7	13,1	9,5	7,5	6,6	8,4	6,1	9,1
20%	12,3	19,4	9,5	12,3	7,6	7,3	15,5	7,8	13,0	11,1	8,0	6,8	7,9	6,4	9,2
30%	10,6	14,5	8,2	11,1	6,3	7,4	9,6	7,0	10,9	8,7	6,9	6,2	8,1	5,0	6,9
40%	14,1	24,2	11,4	14,1	8,9	11,2	17,8	8,9	18,4	12,8	8,8	8,7	11,4	6,3	12,3
50%	15,1	25,2	11,6	13,3	8,9	11,3	15,5	10,1	18,0	11,7	8,3	7,9	10,0	5,7	11,0
Частка ВДЕ	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
5%	5,7	7,7	7,4	7,6	4,1	6,6	7,2	4,9	7,1	6,8	4,8	7,4	6,5	5,3	6,5
10%	6,2	8,0	7,0	8,3	4,6	7,5	7,6	4,9	8,7	7,7	5,6	7,5	7,4	5,6	6,9
20%	6,8	8,8	7,7	8,3	4,6	8,4	7,7	5,3	9,4	8,2	5,9	8,5	7,3	6,4	7,1
30%	5,7	8,1	6,6	6,7	3,5	6,3	5,9	4,7	7,6	6,6	4,4	7,0	5,8	4,5	5,5
40%	9,0	10,4	8,9	9,3	5,5	8,6	8,6	6,9	9,8	9,4	7,2	9,2	8,5	6,9	7,8
50%	8,2	10,1	9,7	9,4	5,5	8,7	8,3	6,7	9,8	8,8	6,9	7,6	8,0	7,2	7,6

4.6 Висновки за четвертим розділом

1. У рамках даного дослідження було розроблено методику прогнозування режимів роботи МРГ з використанням ШНМ. Було проведено аналіз точності прогнозів при різних частках встановленої потужності ВДЕ (CP , %) в електричній мережі. За результатами 30-денного прогнозу були обчислені середні абсолютні похибки ($MAPE$, %), які для запропонованої моделі варіюються від 7,67% (при частці ВДЕ = 5%) до 10,51% (при частці ВДЕ = 50%).

2. На відміну від попередніх досліджень, ця методика дозволяє прогнозувати режими роботи не лише окремих елементів електричної мережі (споживачів, сонячних і вітрових електростанцій тощо), але й враховувати функціонування всієї мережі. Вхідні параметри для моделювання та прогнозування режимів роботи включають як графіки навантажень за попередні періоди для різних груп споживачів, так і зовнішні метеопараметри, такі як швидкість вітру та інсоляція.

3. Запропоновані методики можуть бути використані для оптимізації режимів роботи мереж з розподіленою генерацією, дозволяючи прогнозувати їхні робочі режими на основі доступних метеопараметрів. Ці методи можуть бути особливо корисними для невеликих мереж та їхніх операторів, а також мають потенціал для масштабування на регіональний або національний рівень.

4. Рішення, які були отримані в результаті досліджень мають потенціал до подальшого розвитку у питаннях прогнозування режимів роботи мереж з розподіленою генерацією, особливо враховуючи підвищений інтерес до цієї теми сьогодні.

ВИСНОВКИ

1. У роботі поставлено та вирішено завдання розробки методів прогнозування режимів електричних мереж з розподіленою генерацією.

2. Проведений аналіз існуючих методик прогнозування режимів роботи електричних мереж та графіків генерації СЕС і ВЕС виявив, що більшість з цих методик не враховують інтегровані мережеві характеристики та метеопараметри у розрізі єдиної мережі з розподіленою генерацією, а не окремих її елементів.

3. Аналізуючи дослідження щодо особливостей МРГ виявлено, що окрім очікуваних позитивних змін розвитку зеленої генерації їх впровадження зумовлює деякі складнощі. При збільшенні частки ВДЕ зростає рівень коливання навантаження мережі, наприклад при частці ВДЕ у 60 % рівень коливань може досягати 29,4%. Також зростають вимоги до методів прогнозування режимів роботи у таких мережах. Методи, засновані тільки на оцінці ймовірнісних характеристик графіків навантажень вже не можуть конкурувати з методами, що здатні оцінювати і зовнішні дані, які прямо не впливають на зміни у графіку (наприклад, нейронними мережами). У більшості досліджень сьогодні для прогнозування виробництва або споживання електроенергії використовують статистичні методи, штучні нейронні мережі або їх комбінацію (гібридні методи навчання). Середня абсолютна похибка ($MAPE$) у статистичних методів складає $MAPE_{stat} > 10\%$; у ШНМ $MAPE_{ШНМ} \approx 2-10\%$, але при цьому ШНМ, як правило, більш складні у розробці і налаштуванні.

4. Досліджено прогнозування графіків виробництва електроенергії за допомогою СЕС, використовуючи повні вихідні дані, що включають інсоляцію, та неповні, що включають дані загальних метеопараметрів та «Clear Sky Model». При використанні вимірів інсоляції у місці встановлення СЕС похибка $MAPE = -0,97-4,91\%$, а при використанні Clear Sky Model похибка $MAPE = -3,86$ до $5,74\%$. Для отримання прогнозу достатньо вибірки у 2000...3000 значень тренувальних даних для ШНМ.

5. Отримано коефіцієнти кореляції між виробництвом електроенергії за допомогою СЕС та метеопараметрами. Очікувано, найбільший коефіцієнт кореляції для СЕС був отриманий між виробництвом електроенергії та часом (0,82), температурою панелей (0,82), та рівнем сонячної інсоляції (0,92), але ці показники можуть недостатньо точно відтворювати реальні взаємозв'язки між метеопараметрами та виробництвом електроенергії, оскільки існує очевидна перевага їх кореляції з інсоляцією, яка вимірюється безпосередньо на місці розташування сонячних панелей. У зв'язку з цим, були оцінені коефіцієнти кореляції метеопараметрів до відносної потужності генерації на одиницю інсоляції P^* , $\text{кВт}/(\text{Вт}/\text{м}^2)$, як більш об'єктивного показника кореляційної залежності. Виходячи з результатів, найбільш значущими параметрами є час, температура повітря (0,35), температура панелей (0,57) і швидкість вітру (0,42). Включення відносної потужності генерації на одиницю інсоляції збільшує точність прогнозування в середньому на 30%.

6. Включення метеорологічних даних до моделей прогнозування генерації СЕС доцільне лише за умови наявності помірного або високого рівня кореляції між метеопараметрами та цільовою змінною, що підтверджується значеннями коефіцієнтів кореляції понад 0,3-0,4. Такий підхід сприяє зменшенню обсягу вхідних даних, дозволяючи уникнути врахування малозначущих факторів, які не мають істотного впливу на точність прогнозу, що є важливим для спрощення моделей та зниження обчислювальних витрат при навчанні нейронних мереж. У цьому контексті більш інформативним параметром є питома генерація на одиницю інсоляції, яка інтегрує сукупний вплив таких факторів, як температура панелей, вологість повітря та швидкість вітру. Використання цього узагальненого показника у базовому наборі даних (інсоляція та час) забезпечує мінімальну похибку прогнозування, що підтверджує його доцільність як ключового параметра в побудові високоточних моделей прогнозування.

7. Виконано прогнозування виробництва електроенергії ВЕС за допомогою нейронних мереж. З метеофакторів враховувались температура, швидкість вітру,

напрямок вітру, атмосферний тиск. $MAPE$ в даному випадку складає $-2,46...4,91\%$, необхідний розмір вибірки даних для навчання ≈ 2000 значень.

8. Вперше для МРГ як єдиної складової розроблено методи прогнозування режимів роботи мережі з розподіленою генерацією, що враховують не лише імовірнісні параметри графіків електричних навантажень, а й метеодані. Досліджено частки встановленої потужності ВДЕ, (CP , %) на похибку прогнозування режимів роботи мережі. У Simulink / MATLAB змодельовано роботу мережі з розподіленою генерацією протягом 180 діб (4320 годин), яка включає в себе побутових, промислових споживачів, ВЕС, а також СЕС. Була змодельована робота мережі з різним коефіцієнтом $CP = 5...50\%$. В результаті отриманого прогнозу на 30 діб були розраховані середні абсолютні похибки $MAPE$, % які для представленої моделі склали від $7,67\%$ (для $CP = 5\%$) до $10,51\%$ (для $CP = 50\%$). Це вказує на суттєве збільшення $MAPE$ з ростом коефіцієнту інтеграції ВДЕ до енергосистеми, що пов'язано зі збільшенням нерівномірності графіку електричних навантажень через мінливі зовнішні фактори.

9. Розроблені методи прогнозування режимів роботи МРГ впроваджені в промислову експлуатацію в АТ «Нікопольський завод феросплавів» та ТОВ «ДТЕК Покровська СЕС», що отримало позитивний відгук від представників компаній та дозволило спростити прогнозування та диспетчеризацію мереж з ВДЕ, що у перспективі дозволить знизити переоплату за небаланси на енергоринку. Також матеріали досліджень використовуються в навчальному процесі кафедри електроенергетики НТУ «Дніпровська політехніка», а також кафедри автоматизації систем електропостачання та електроприводу ДВНЗ «Приазовський державний технічний університет».

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. International Energy Agency, *Electricity Mid-Year Update - July 2024*. Paris: IEA, 2024. [Online]. Available: <https://www.iea.org/reports/electricity-mid-year-update-july-2024>
2. Н. Майстренко, “Прогнозування споживання електроенергії в Україні у воєнний та післявоєнний період,” *System Research in Energy*, № 2а (78), с. 21–22, 2024.
3. R. Zvarych and O. Masna, “Ukraine’s national policy on RES: analysis of international obligations and integration into European energy markets,” *Visnyk of TNEU*, no. 4, pp. 122–136, Jan. 2025, doi: 10.35774/visnyk2024.04.122.
4. Закон України “Про ринок електричної енергії,” 2017. [Електронний ресурс]. Доступно: <https://zakon.rada.gov.ua/laws/show/2019-19#Text>
5. Д. Олефір, В. Бабич та І. Блінов, “Актуальні проблеми забезпечення ресурсів регулювання частоти та потужності в ОЕС України,” *Енергетика: економіка, технології, екологія*, № 3, січ. 2022, doi: 10.20535/1813-5420.3.2021.251196.
6. І. В. Блінов, В. О. Мірошник та С. С. Лоскутов, “Зменшення вартості небалансів балансуючої групи виробників з відновлюваних джерел енергії,” *Технічна електродинаміка*, № 1, с. 62–66, січ. 2023, doi: 10.15407/technd2023.01.062.
7. НКРЕКП, “Про затвердження нормативно-правових актів, що регулюють діяльність гарантованого покупця та купівлі електричної енергії за ‘зеленим’ тарифом,” 2019. [Електронний ресурс]. Доступно: <https://www.nerc.gov.ua/acts/pro-zatverdzhennya-normativno-pravovikh-aktiv-shcho-regulyuyut-diyalnist-garantovanogo-pokuptsya-ta-kupivli-elektrichnoi-energii-za-zelenim-tarifom>
8. Г. І. Сторожилова та Я. М. Демчик, “Вплив параметрів моделі на точність прогнозування електроспоживання на об’єктах енергоринку,” *НТУ “КПІ ім. Сікорського”*, № 3, 2016.

9. S. K. Aggarwal and M. Gupta, “Wind power forecasting: A review of statistical models,” *International Journal of Energy Science*, vol. 3, no. 1, 2013.
10. О. А. Ковальчук, П. Д. Лежнюк, В. О. Комар та С. В. Кравчук, “Прогнозування графіка генерування фотоелектричних станцій на наступну добу,” матеріали XX Міжнародної науково-практичної конференції “Відновлювана енергетика та енергоефективність у XXI столітті”, Київ, трав. 2019, с. 320–324.
11. U. K. Das et al., “Forecasting of photovoltaic power generation and model optimization: A review,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 912–928, Jan. 2018, doi: 10.1016/j.rser.2017.08.017.
12. M. Osińska, M. Kyzym, V. Khaustova, O. Ilyash, and T. Salashenko, “Does the Ukrainian electricity market correspond to the European model?,” *Utilities Policy*, vol. 79, p. 101436, Dec. 2022, doi: 10.1016/j.jup.2022.101436.
13. Y. Sayenko, “Wind power forecasting based on meteorological data using neural networks,” *Electrotechnical Review*, vol. 1, no. 11, pp. 209–212, Nov. 2021, doi: 10.15199/48.2021.11.39.
14. Y. Sayenko, T. Baranenko, and V. Liubartsev, “Forecasting of electricity generation by solar panels using neural networks with incomplete initial data,” in *Proc. 2020 IEEE 4th Int. Conf. Intelligent Energy and Power Systems (IEPS)*, Istanbul, Turkey: IEEE, Sep. 2020, pp. 140–143, doi: 10.1109/IEPS51250.2020.9263085.
15. P. Lezhnyuk, V. Komar, S. Kravchuk, V. Lesko, and V. Netrebnyi, “Meteorological parameters analysis for hourly forecast of electricity generation by photovoltaic power station on the day ahead,” in *Proc. 2018 IEEE 3rd Int. Conf. Intelligent Energy and Power Systems (IEPS)*, Kharkiv: IEEE, Sep. 2018, pp. 235–238, doi: 10.1109/IEPS.2018.8559598.
16. Y. Sayenko, V. Sychenko, and V. Liubartsev, “Development of methods for optimizing reactive power modes based on neural network technologies,” in *Proc. 2019 IEEE 6th Int. Conf. Energy Smart Systems (ESS)*, Kyiv, Ukraine: IEEE, Apr. 2019, pp. 98–103, doi: 10.1109/ESS.2019.8764220.
17. Л. Третьякова, В. Побігайло та Е. Усатий, “Зміни у світовому енергетичному секторі, спричинені війною Росії проти України,” *Енергетика:*

економіка, технології, екологія, № 4, груд. 2024, doi: 10.20535/1813-5420.4.2024.315592.

18. A. Szeberényi and F. Bakó, “Electricity market dynamics and regional interdependence in the face of pandemic restrictions and the Russian–Ukrainian conflict,” *Energies*, vol. 16, no. 18, p. 6515, Sep. 2023, doi: 10.3390/en16186515.

19. Д. О. Мельник та В. П. Калінчик, “Аналіз статистичних методів прогнозування для планування електроспоживання промисловими підприємствами,” у *Енергетика. Екологія. Людина*, Київ: КПІ ім. Ігоря Сікорського, трав. 2021, с. 19–24.

20. M. A. Hammad, B. Jereb, B. Rosi, and D. Dragan, “Methods and models for electric load forecasting: A comprehensive review,” *Logistics & Sustainable Transport*, vol. 11, no. 1, pp. 51–76, Feb. 2020, doi: 10.2478/jlst-2020-0004.

21. R. Wang, J. Wang, and Y. Xu, “A novel combined model based on hybrid optimization algorithm for electrical load forecasting,” *Appl. Soft Comput.*, vol. 82, p. 105548, Sep. 2019, doi: 10.1016/j.asoc.2019.105548.

22. N. Ahmad, Y. Ghadi, M. Adnan, and M. Ali, “Load Forecasting Techniques for Power System: Research Challenges and Survey,” *IEEE Access*, vol. 10, pp. 71054–71090, 2022, doi: 10.1109/ACCESS.2022.3187839.

23. W. Xu *et al.*, “Long term intelligent load forecasting method considering the expectation of power market transaction,” in *Proc. 29th Chinese Control Decis. Conf. (CCDC)*, Chongqing, China, May 2017, pp. 2310–2315, doi: 10.1109/CCDC.2017.7978900.

24. T. Hong, J. Wilson, and J. Xie, “Long Term Probabilistic Load Forecasting and Normalization With Hourly Information,” *IEEE Trans. Smart Grid*, vol. 5, no. 1, pp. 456–462, Jan. 2014, doi: 10.1109/TSG.2013.2274373.

25. Md. R. Haq and Z. Ni, “A New Hybrid Model for Short-Term Electricity Load Forecasting,” *IEEE Access*, vol. 7, pp. 125413–125423, 2019, doi: 10.1109/ACCESS.2019.2937222.

26. R. Weron, *Loads and Prices: A Statistical Approach*. Wiley, 2006.

27. H. K. Alfares and M. Nazeeruddin, "Electric load forecasting: Literature survey and classification of methods," *Int. J. Syst. Sci.*, vol. 33, no. 1, pp. 23–34, Jan. 2002, doi: 10.1080/00207720110067421.
28. H. Matsila and P. Bokoro, "Load Forecasting Using Statistical Time Series Model in a Medium Voltage Distribution Network," in *Proc. IECON 2018 - 44th Annu. Conf. IEEE Ind. Electron. Soc.*, Washington, DC, USA, Oct. 2018, pp. 4974–4979, doi: 10.1109/IECON.2018.8592891.
29. Shilpa G. N. and G. S. Sheshadri, "Electrical Load Forecasting Using Time Series Analysis," in *Proc. 2020 IEEE Bangalore Humanitarian Technol. Conf. (B-HTC)*, Vijayapur, India, Oct. 2020, pp. 1–6, doi: 10.1109/B-HTC50970.2020.9297986.
30. P. Zinkevych, S. Baluta, and Iu. Kuievda, "Comparative analysis of methods of short-term electric load forecasting one step forward," *Sci. Bull. NWUFT*, vol. 27, no. 3, pp. 62–76, Jun. 2021, doi: 10.24263/2225-2924-2021-27-3-9.
31. A. A. Mamun *et al.*, "A Comprehensive Review of the Load Forecasting Techniques Using Single and Hybrid Predictive Models," *IEEE Access*, vol. 8, pp. 134911–134939, 2020, doi: 10.1109/ACCESS.2020.3010702.
32. M. Madhukumar *et al.*, "Regression Model-Based Short-Term Load Forecasting for University Campus Load," *IEEE Access*, vol. 10, pp. 8891–8905, 2022, doi: 10.1109/ACCESS.2022.3144206.
33. B. Yildiz, J. I. Bilbao, and A. B. Sproul, "A review and analysis of regression and machine learning models on commercial building electricity load forecasting," *Renew. Sustain. Energy Rev.*, vol. 73, pp. 1104–1122, Jun. 2017, doi: 10.1016/j.rser.2017.02.023.
34. J. Wu *et al.*, "Short term load forecasting technique based on the seasonal exponential adjustment method and the regression model," *Energy Convers. Manage.*, vol. 70, pp. 1–9, Jun. 2013, doi: 10.1016/j.enconman.2013.02.010.
35. S. Muzaffar and A. Afshari, "Short-Term Load Forecasts Using LSTM Networks," *Energy Procedia*, vol. 158, pp. 2922–2927, Feb. 2019, doi: 10.1016/j.egypro.2019.01.952.

36. H. Nguyen and C. K. Hansen, "Short-term electricity load forecasting with Time Series Analysis," in *Proc. 2017 IEEE Int. Conf. Prognostics Health Manage. (ICPHM)*, Dallas, TX, USA, Jun. 2017, pp. 214–221, doi: 10.1109/ICPHM.2017.7998331.
37. U. Javed *et al.*, "Exploratory Data Analysis Based Short-Term Electrical Load Forecasting: A Comprehensive Analysis," *Energies*, vol. 14, no. 17, p. 5510, Sep. 2021, doi: 10.3390/en14175510.
38. E. Chodakowska, J. Nazarko, and Ł. Nazarko, "ARIMA Models in Electrical Load Forecasting and Their Robustness to Noise," *Energies*, vol. 14, no. 23, p. 7952, Nov. 2021, doi: 10.3390/en14237952.
39. G. Dudek, P. Pelka, and S. Smyl, "A Hybrid Residual Dilated LSTM and Exponential Smoothing Model for Midterm Electric Load Forecasting," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 7, pp. 2879–2891, Jul. 2022, doi: 10.1109/TNNLS.2020.3046629.
40. R. Bindiu, M. Chindri, and G. V. Pop, "Day Ahead Load Forecasting Using Exponential Smoothing," *Sci. Bull. Petru Maior Univ. Tirgu Mures*, no. 6 (XXIII), 2009.
41. N. A. Jalil, M. Ahmad, and N. Mohamed, "Electricity load demand forecasting using exponential smoothing methods," *World Applied Sciences Journal*, vol. 22, pp. 1540–1543, Jan. 2013, doi: 10.5829/idosi.wasj.2013.22.11.2891.
42. S. S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. New York, NY, USA: Prentice Hall, 2009.
43. G. M. U. Din and A. K. Marnerides, "Short term power load forecasting using Deep Neural Networks," in *Proc. 2017 Int. Conf. Comput., Netw. Commun. (ICNC)*, Silicon Valley, CA, USA, Jan. 2017, pp. 594–598, doi: 10.1109/ICCNC.2017.7876196.
44. M. Mansoor, F. Grimaccia, S. Leva, and M. Mussetta, "Comparison of echo state network and feed-forward neural networks in electrical load forecasting for demand response programs," *Math. Comput. Simul.*, vol. 184, pp. 282–293, Jun. 2021, doi: 10.1016/j.matcom.2020.07.011.

45. S. Singh, S. Hussain, and M. A. Bazaz, "Short term load forecasting using artificial neural network," in *Proc. 2017 4th Int. Conf. Image Inf. Process. (ICIIP)*, Shimla, India, Dec. 2017, pp. 1–5, doi: 10.1109/ICIIP.2017.8313703.
46. M. A. Majeed *et al.*, "Artificial Neural Network Modelling for Short Term Load Forecasting," in *Proc. 2021 Int. Conf. Technol. Policy Energy Elect. Power (ICT-PEP)*, Sep. 2021, pp. 302–306, doi: 10.1109/ICT-PEP53949.2021.9601105.
47. N. Shirzadi *et al.*, "Medium-Term Regional Electricity Load Forecasting through Machine Learning and Deep Learning," *Designs*, vol. 5, no. 2, p. 27, Apr. 2021, doi: 10.3390/designs5020027.
48. F. Abbas *et al.*, "Short Term Residential Load Forecasting: An Improved Optimal Nonlinear Auto Regressive (NARX) Method with Exponential Weight Decay Function," *Electronics*, vol. 7, no. 12, p. 432, Dec. 2018, doi: 10.3390/electronics7120432.
49. M. A. Yahya, S. P. Hadi, and L. M. Putranto, "Short-Term Electric Load Forecasting Using Recurrent Neural Network," in *Proc. 2018 4th Int. Conf. Sci. Technol. (ICST)*, Yogyakarta, Indonesia, Aug. 2018, pp. 1–6, doi: 10.1109/ICSTC.2018.8528651.
50. L. Sehovac and K. Grolinger, "Deep Learning for Load Forecasting: Sequence to Sequence Recurrent Neural Networks With Attention," *IEEE Access*, vol. 8, pp. 36411–36426, 2020, doi: 10.1109/ACCESS.2020.2975738.
51. Y. Liu, D. Li, H. Pei, K. Liu, Y. Li, and L. Yang, "Short-term load prediction method for power distributing method based on back-propagation neural network," in *Proc. 2017 12th IEEE Conf. Ind. Electron. Appl. (ICIEA)*, Siem Reap, Jun. 2017, pp. 881–886. doi: 10.1109/ICIEA.2017.8282964.
52. D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, and M. J. Damborg, "Electric load forecasting using an artificial neural network," *IEEE Trans. Power Syst.*, vol. 6, no. 2, pp. 442–449, May 1991, doi: 10.1109/59.76685.
53. L. Govindarajan, M. F. Mohideen Batcha, M. K. Abdullah, S. Md Seri, and J. Taweekun, "Analysing the performance of large-scale rooftop solar PV system using Helioscope, PVsyst and PV*SOL photovoltaic simulation software: As a renewable

energy strategy,” *J. Adv. Res. Appl. Sci. Eng. Technol.*, vol. 52, no. 1, pp. 192–208, Oct. 2024, doi: 10.37934/araset.52.1.192208.

54. L. Jonathan, K. Christian, R. G. Lina, and S. Stijn, “Benchmark of eight commercial solutions for deterministic intra-day solar forecast,” unpublished.

55. “Solar Live & Forecast Accuracy | SolcastTM — solcast.com.” [Online]. Available: <https://solcast.com/forecast-accuracy>

56. M. Fields *et al.*, “Wind Plant Performance Prediction Benchmark Phase 1 (Technical Report),” NREL/TP-5000-78715, MainId:32632, Oct. 2021. doi: 10.2172/1826665.

57. M. Bollen and F. Hassan, *Integration of Distributed Generation in the Power System: Bollen/Integration of Distributed Generation*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2011. doi: 10.1002/9781118029039.

58. M. S. Mahmoud and F. M. AL-Sunni, *Control and Optimization of Distributed Generation Systems*, in *Power Systems*. Cham: Springer Int. Publ., 2015. doi: 10.1007/978-3-319-16910-1.

59. R. Bansal, Ed., *Handbook of Distributed Generation*. Cham: Springer Int. Publ., 2017. doi: 10.1007/978-3-319-51343-0.

60. B. Zhao, C. Wang, and X. Zhang, *Grid-Integrated and Standalone Photovoltaic Distributed Generation Systems: Analysis, Design, and Control*, 1st ed. Wiley, 2017. doi: 10.1002/9781119187349.

61. T. Lehtola and A. Zahedi, “Solar energy and wind power supply supported by storage technology: A review,” *Sustain. Energy Technol. Assess.*, vol. 35, pp. 25–31, Oct. 2019, doi: 10.1016/j.seta.2019.05.013.

62. IEA PVPS, *Task 14: Transition from Uni-Directional to Bi-Directional Distribution Grids*. Sep. 2014.

63. J. Wang, X. Wang, X. Zhang, and Z. Hu, “Bidding model of reserve capacity in electricity market,” *Autom. Electr. Power Syst.*, vol. 27, no. 02, pp. 7–11, 2003.

64. І. В. Жежеленко, Ю. Л. Саєнко та В. П. Степанов, *Методи ймовірнісного моделювання в розрахунках характеристик електричних навантажень споживачів*. М.: Енергоатоміздат, 1990.

65. B. Nepal, M. Yamaha, A. Yokoe, and T. Yamaji, "Electricity load forecasting using clustering and ARIMA model for energy management in buildings," *Jpn. Archit. Rev.*, vol. 3, no. 1, pp. 62–76, Jan. 2020, doi: 10.1002/2475-8876.12135.
66. R. H. Shumway and D. S. Stoffer, "Time Series Regression and ARIMA Models," in *Time Series Analysis and Its Applications*, New York, NY: Springer, 2000, pp. 89–212. doi: 10.1007/978-1-4757-3261-0_2.
67. F. M. Bianchi, E. Maiorino, M. C. Kampffmeyer, A. Rizzi, and R. Jenssen, *An Overview and Comparative Analysis of Recurrent Neural Networks for Short Term Load Forecasting*, 2017. doi: 10.1007/978-3-319-70338-1.
68. Y. Sayenko, R. Pawelek, and T. Baranenko, "Analysis of reactive power in electrical networks supplying nonlinear fast-varying loads," *Energies*, vol. 16, no. 24, p. 8011, Dec. 2023, doi: 10.3390/en16248011.
69. B. Xu *et al.*, "Reactive power optimization of a distribution network with high-penetration of wind and solar renewable energy and electric vehicles," *Prot. Control Mod. Power Syst.*, vol. 7, no. 1, p. 51, Dec. 2022, doi: 10.1186/s41601-022-00271-w.
70. X. Li, H. Li, S. Li, Z. Jiang, and X. Ma, "Review on reactive power and voltage optimization of active distribution network with renewable distributed generation and time-varying loads," *Math. Probl. Eng.*, vol. 2021, pp. 1–18, Nov. 2021, doi: 10.1155/2021/1196369.
71. Р. Грушевий та Д. Лавренова, "Керування електромережею із розподіленою генерацією," *Міжнародний науково-технічний журнал «Сучасні проблеми електроенергетики та автоматики»*, с. 29–33, 2024.
72. V. G. Yagup, K. V. Yagup, and National Technical University "Kharkiv Polytechnic Institute", "Research optimization of the mode of full reactive power compensation in the electrical network," *Teh. Elektrodin.*, vol. 2023, no. 5, pp. 55–63, Sep. 2023, doi: 10.15407/techned2023.05.055.
73. "Про затвердження Методики обчислення плати за перетікання реактивної електроенергії," *Офіційний вебпортал парламенту України*. [Електронний ресурс]. Доступно: <https://zakon.rada.gov.ua/laws/show/z0392-18#Text> (дата звернення: 23.06.2024).

74. S. Theocharides *et al.*, “Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing,” *Appl. Energy*, vol. 268, p. 115023, Jun. 2020, doi: 10.1016/j.apenergy.2020.115023.
75. R. Tawn and J. Browell, “A review of very short-term wind and solar power forecasting,” *Renew. Sustain. Energy Rev.*, vol. 153, p. 111758, Jan. 2022, doi: 10.1016/j.rser.2021.111758.
76. M. O. Moreira *et al.*, “Design of experiments using artificial neural network ensemble for photovoltaic generation forecasting,” *Renew. Sustain. Energy Rev.*, vol. 135, p. 110450, Jan. 2021, doi: 10.1016/j.rser.2020.110450.
77. A. Mellit *et al.*, “Advanced methods for photovoltaic output power forecasting: A review,” *Appl. Sci.*, vol. 10, no. 2, p. 487, Jan. 2020, doi: 10.3390/app10020487.
78. K. J. Iheanetu, “Solar photovoltaic power forecasting: A review,” *Sustainability*, vol. 14, no. 24, p. 17005, Dec. 2022, doi: 10.3390/su142417005.
79. Li, Wang, Zhang, Xin, and Liu, “Recurrent neural networks based photovoltaic power forecasting approach,” *Energies*, vol. 12, no. 13, p. 2538, Jul. 2019, doi: 10.3390/en12132538.
80. S. Sobri, S. Koohi-Kamali, and N. Abd. Rahim, “Solar photovoltaic generation forecasting methods: A review,” *Energy Convers. Manag.*, vol. 156, pp. 459–497, Jan. 2018, doi: 10.1016/j.enconman.2017.11.019.
81. R. Zafar, B. H. Vu, M. Husein, and I.-Y. Chung, “Day-Ahead Solar Irradiance Forecasting Using Hybrid Recurrent Neural Network with Weather Classification for Power System Scheduling,” *Applied Sciences*, vol. 11, no. 15, p. 6738, Jul. 2021, doi: 10.3390/app11156738.
82. I. Blinov, V. Miroshnyk, and V. Sychova, “Short-term forecasting of electricity imbalances using artificial neural networks,” *IOP Conf. Ser.: Earth Environ. Sci.*, vol. 1254, no. 1, p. 012029, Oct. 2023, doi: 10.1088/1755-1315/1254/1/012029.
83. V. Miroshnyk, P. Shymaniuk, and V. Sychova, “Short term renewable energy forecasting with deep learning neural networks,” in *Power Systems Research and Operation: Selected Problems*, Springer, 2021, pp. 121–142.

84. A. Ziane et al., “Photovoltaic output power performance assessment and forecasting: Impact of meteorological variables,” *Solar Energy*, vol. 220, pp. 745–757, May 2021, doi: 10.1016/j.solener.2021.04.004.
85. Z. Si, M. Yang, Y. Yu, and T. Ding, “Photovoltaic power forecast based on satellite images considering effects of solar position,” *Applied Energy*, vol. 302, p. 117514, Nov. 2021, doi: 10.1016/j.apenergy.2021.117514.
86. M. A. Munir, A. Khattak, K. Imran, A. Ulasyar, and A. Khan, “Solar PV Generation Forecast Model Based on the Most Effective Weather Parameters,” in *Proc. 2019 Int. Conf. Electr., Commun., Comput. Eng. (ICECCE)*, Swat, Pakistan: IEEE, Jul. 2019, pp. 1–5. doi: 10.1109/ICECCE47252.2019.8940664.
87. M. Koivisto, N. Cutululis, and J. Ekstrom, “Minimizing Variance in Variable Renewable Energy Generation in Northern Europe,” in *Proc. 2018 IEEE Int. Conf. Probabilistic Methods Appl. Power Syst. (PMAPS)*, Boise, ID: IEEE, Jun. 2018, pp. 1–6. doi: 10.1109/PMAPS.2018.8440369.
88. P. Lezhniuk et al., “Natural-simulation model of photovoltaic station generation in process of electricity balancing in electrical power system.”
89. H. Zsiborács, A. Vincze, G. Pintér, and N. H. Baranyai, “The Accuracy of PV Power Plant Scheduling in Europe: An Overview of ENTSO-E Countries,” *IEEE Access*, vol. 11, pp. 74953–74979, 2023, doi: 10.1109/ACCESS.2023.3297494.
90. K. Maciejowska, “Enhancing load, wind and solar generation for day-ahead forecasting of electricity prices,” *Energy Economics*, 2021.
91. M. Jasiński, Z. Leonowicz, J. Jasiński, L. Martirano, and R. Gono, “PV Advancements & Challenges: Forecasting Techniques, Real Applications, and Grid Integration for a Sustainable Energy Future,” in *Proc. 2023 IEEE Int. Conf. Environment and Electrical Engineering and 2023 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Madrid, Spain: IEEE, Jun. 2023, pp. 1–5. doi: 10.1109/EEEIC/ICPSEurope57605.2023.10194796.
92. G. Luis, J. Esteves, and N. P. Da Silva, “Energy Forecasting Using an Ensemble of Machine Learning Methods Trained Only with Electricity Data,” in *Proc. 2020 IEEE PES Innov. Smart Grid Technol. Eur. (ISGT-Europe)*, The Hague,

Netherlands: IEEE, Oct. 2020, pp. 449–453. doi: 10.1109/ISGT-Europe47291.2020.9248865.

93. Y. Gao, S. Qi, and J. Ponoćko, “Assessing Critical Data Types for Deep Learning-Based PV Generation Forecasting,” in *Proc. 2023 IEEE Belgrade PowerTech*, Belgrade, Serbia: IEEE, Jun. 2023, pp. 1–6. doi: 10.1109/PowerTech55446.2023.10202973.

94. U. Yildiz and M. Gol, “Solar Power Generation Prediction for Distribution Systems with High PV Penetration,” in *Proc. 2020 IEEE PES Innov. Smart Grid Technol. Eur. (ISGT-Europe)*, The Hague, Netherlands: IEEE, Oct. 2020, pp. 389–393. doi: 10.1109/ISGT-Europe47291.2020.9248919.

95. “2020 Past Weather at Mariupol International Airport, Ukraine - Weather Spark — weatherspark.com.” [Online]. Available: <https://weatherspark.com/h/y/149634/2020/Historical-Weather-during-2020-at-Mariupol-International-Airport-Ukraine#Figures-Temperature>

96. R. E. Bird and R. L. Hulstrom, “Simplified clear sky model for direct and diffuse insolation on horizontal surfaces,” *Solar Energy Research Inst. (SERI)*, Golden, CO (United States), 1981.

97. Y. Sayenko, R. Pawelek, T. Baranenko, and V. Liubartsev, “The Impact of Meteorological Data on the Accuracy of Solar Electricity Generation Forecasting Using Neural Networks,” *Energies*, vol. 18, no. 9, p. 2309, Apr. 2025, doi: 10.3390/en18092309.

98. G. Puccetti, “Measuring linear correlation between random vectors,” *Information Sciences*, vol. 607, pp. 1328–1347, Aug. 2022, doi: 10.1016/j.ins.2022.06.016.

99. H. Acaroğlu and F. P. García Márquez, “Comprehensive Review on Electricity Market Price and Load Forecasting Based on Wind Energy,” *Energies*, vol. 14, no. 22, p. 7473, Nov. 2021, doi: 10.3390/en14227473.

100. W.C. Tsai, C.-M. Hong, C.-S. Tu, W.-M. Lin, and C.-H. Chen, “A Review of Modern Wind Power Generation Forecasting Technologies,” *Sustainability*, vol. 15, no. 14, p. 10757, Jul. 2023, doi: 10.3390/su151410757.

101. Y. Chen and J. Xu, “Solar and wind power data from the Chinese State Grid Renewable Energy Generation Forecasting Competition,” *Sci Data*, vol. 9, no. 1, p. 577, Sep. 2022, doi: 10.1038/s41597-022-01696-6.
102. I. K. Bazionis and P. S. Georgilakis, “Review of Deterministic and Probabilistic Wind Power Forecasting: Models, Methods, and Future Research,” *Electricity*, vol. 2, no. 1, pp. 13–47, Jan. 2021, doi: 10.3390/electricity2010002.
103. J. Maldonado-Correa, J. Solano, and M. Rojas-Moncayo, “Wind power forecasting: A systematic literature review,” *Wind Engineering*, vol. 45, no. 2, pp. 413–426, Apr. 2021, doi: 10.1177/0309524X19891672.
104. “Weather Archive Portland - meteoblue — meteoblue.com.” [Online]. Available: https://www.meteoblue.com/en/weather/historyclimate/weatherarchive/portland_australia_2152667
105. “MATLAB Documentation — mathworks.com.” [Online]. Available: <https://www.mathworks.com/help/matlab/>
106. Erdiwansyah, Mahidin, H. Husin, Nasaruddin, M. Zaki, and Muhibbuddin, “A critical review of the integration of renewable energy sources with various technologies,” *Prot Control Mod Power Syst*, vol. 6, no. 1, p. 3, Dec. 2021, doi: 10.1186/s41601-021-00181-3.
107. В. Степаненко, А. Замулько, Ю. Веремійчук, і В. Находов, “Оцінювання ризику інтеграції відновлюваних джерел енергії в систему електропостачання,” *Енергетика: економіка, технології, екологія*, № 2, лип. 2022, doi: 10.20535/1813-5420.2.2022.261372.

ДОДАТОК А

Приклади графіків прогнозів генерації СЕС з різними наборами вхідних даних




Рис. А.1. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі інсоляції




Рис. А.2. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі інсоляції, часу та температури панелі.




Рис. А.3. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі інсоляції та часу




Рис. А.4. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі інсоляції, часу та питомої генерації на одиницю інсоляції




Рис. А.5. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі інсоляції, часу та температури панелі




Рис. А.6. Порівняння фактичних і прогнозованих графіків генерації СЕС на основі інсоляції, часу, питомої генерації на одиницю інсоляції та температури панелі




Рис. А.7. Порівняння фактичних і прогнозованих графіків генерації СЕС на основі інсоляції, часу, питомої генерації на одиницю інсоляції та швидкості вітру




Рис. А.8. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі інсоляції, часу, питомої генерації на одиницю інсоляції та вологості




Рис. А.9. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі всіх даних, крім питомої генерації на одиницю інсоляції




Рис. А.10. Порівняння фактичного та прогнозованого графіків генерації СЕС на основі всіх даних, включаючи питому генерацію на одиницю інсоляції

ДОДАТОК Б

Результати прогнозування активної потужності, що споживається МРГ, при різних частках встановленої потужності ВДЕ (CP, %)

Таблиця Б.1 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 5\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	Реал.	2207	2266	2207	2221	2316	2633	3407	3291	3699	2821	2536	2863	2994	2989	3665	2959	4082	3867	4104	4201	4304	3848	4089	2512
	Прог.	2551	2465	2440	2450	2441	2711	4050	3766	3711	3060	3401	3268	3366	3642	3228	3142	4557	4521	4540	4105	4154	4220	4344	3029
2	Реал.	2035	2291	2251	2166	2250	2312	3163	3277	3092	2477	2745	2580	2824	2712	2675	2918	3958	4016	4447	3980	4459	3638	4282	2870
	Прог.	2419	2549	2528	2475	2486	2627	5545	4290	3533	3129	3518	3216	3456	3526	3366	3436	4354	4667	4620	4359	4509	4215	4418	3008
3	Реал.	2310	2266	2513	2441	2402	2623	3508	2979	3192	3515	3715	3745	3876	3372	4313	4044	3891	4355	4530	4024	3832	4249	3632	2787
	Прог.	2458	2453	2511	2555	2504	2739	3747	3599	3299	3460	3654	3379	3475	3553	3695	3827	4400	4713	4620	4277	4308	4328	4247	3064
4	Реал.	2240	2167	2187	3178	2314	2242	3696	3012	3697	3373	4080	3572	4083	3963	3487	3535	4169	4210	4040	4073	4356	3929	4007	2635
	Прог.	2440	2436	2495	2653	2443	2603	3594	3404	3925	3725	3553	3307	3353	3312	3535	3353	4628	4698	4619	4494	4370	4333	4293	3031
5	Реал.	2431	2614	2356	2546	2881	2622	3749	3565	3581	3033	2975	3046	3286	2879	3167	3044	4508	4544	4494	4493	4232	4124	4293	2648
	Прог.	2484	2513	2489	2575	2606	2755	3590	3698	3611	3320	3251	3244	3567	3779	3370	3562	4489	4501	4607	4541	4189	4200	4354	3043
6	Реал.	2347	2469	2625	2499	2522	2566	4000	3232	3457	2988	2922	2966	2867	3360	4128	3488	4679	4080	4760	4548	4476	4218	4241	2846
	Прог.	2458	2492	2536	2508	2521	2593	3782	4132	3257	3090	3466	3247	3065	3348	3254	3682	4503	4558	4737	4616	4322	4329	4344	2962
7	Реал.	2105	2334	2308	2435	2369	2293	3660	3064	3554	3020	2976	2724	2844	2915	2999	2926	4915	5039	4138	3952	4400	3750	4488	2752
	Прог.	2420	2481	2476	2545	2510	2629	3582	3699	3780	3475	3285	3229	3489	3112	3413	3365	4667	4796	4539	4405	4248	4166	4448	3010
8	Реал.	2412	2396	2711	2414	3291	2610	3678	3637	3990	3299	3131	3098	2977	3089	2994	3209	4538	4115	4767	4252	4630	3954	3846	3450
	Прог.	2545	2453	2545	2537	2630	2685	3497	3751	3805	3573	3510	3573	3179	3336	3403	3349	4261	4566	4647	4344	4257	4244	4159	3073
9	Реал.	2725	2121	2296	2218	2215	2314	3356	3695	3235	2594	2867	2596	2684	2804	2909	2580	4513	4539	4506	3962	4074	3960	4164	2769
	Прог.	2619	2494	2469	2514	2477	2610	3520	3711	3556	3277	3537	3225	3573	3109	3594	3058	4166	4570	4596	4133	4038	4106	4413	2953
10	Реал.	2388	2127	2179	2128	2115	2119	3526	3525	3316	4098	3664	3865	3757	3686	3827	2989	4279	4345	4348	3985	4988	4384	3911	2708
	Прог.	2548	2486	2463	2489	2414	2592	3580	3462	3260	3485	3457	3416	3205	3202	2920	3471	4377	4605	4596	4436	4539	4243	4173	3028
11	Реал.	2248	2196	2298	2411	2376	2411	3009	3507	3220	3890	3445	3430	3922	4009	3368	4047	4495	4358	4586	4240	4264	4275	3825	2602
	Прог.	2558	2521	2477	2541	2507	2736	3922	3726	3662	3488	3480	3525	3630	3562	3595	3803	4398	4719	4698	4302	4117	4348	4251	3007
12	Реал.	3364	2646	2674	2522	2406	2515	3477	3501	3750	3206	2987	3152	3158	3221	3303	3225	4941	4349	4782	4573	5226	4247	4162	2704
	Прог.	2661	2495	2531	2538	2491	2744	3754	3573	3482	3151	3278	3133	3267	3093	3302	3403	4519	4412	4654	4583	4256	4224	4189	3017

Таблиця Б.1 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 5\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
13	Реал.	2438	2240	2308	2471	2599	3871	3380	3888	3609	2727	3722	3016	3036	2943	3469	3116	4509	4211	4153	4746	4062	4403	4792	3043
	Прог.	2518	2473	2497	2555	2554	2947	3553	3791	3741	3519	3344	3179	3478	3410	3500	3377	4419	4542	4497	4560	4188	4426	4453	3068
14	Реал.	2496	2665	2733	2472	2522	2911	3434	5294	3896	3150	3354	3285	3305	3172	3242	3086	4904	4891	4336	4369	4736	4607	4088	3337
	Прог.	2492	2537	2560	2553	2508	2743	3789	4146	3712	3293	3373	3365	3229	3227	3202	3241	4371	4656	4500	4499	4545	4378	4346	3135
15	Реал.	2569	2295	2776	2130	2377	2345	3663	3533	3311	2848	2621	2899	3384	4527	3113	3053	4412	4890	4571	4262	4292	4320	4547	2732
	Прог.	2513	2454	2555	2468	2496	2606	3592	3707	3653	3401	3248	3239	3362	3470	3582	3516	4420	4501	4396	4384	4374	4403	4303	2952
16	Реал.	2643	2568	2240	2708	2314	2741	3770	3861	3502	3011	3065	2847	3054	3122	2961	3379	4372	4523	4255	4454	4698	4674	4701	2900
	Прог.	2568	2526	2463	2549	2484	2715	3558	3766	3539	3360	3328	3310	3439	2946	3077	3333	4593	4604	4479	4349	4172	4420	4416	2987
17	Реал.	2343	2291	2339	2307	2166	2534	3148	3599	3352	3882	3530	3663	3988	4197	4073	3763	4306	4254	5097	4637	4243	4532	4605	2567
	Прог.	2491	2458	2495	2485	2451	2636	3476	3808	3583	3559	3529	3393	3299	3559	3654	3538	4395	4562	4499	4450	4086	4270	4473	2948
18	Реал.	2101	2398	2191	2630	2193	2399	3546	3477	3657	3311	4052	4106	3444	3200	3835	3851	4461	4420	4649	5073	4270	4601	4109	2838
	Прог.	2439	2470	2458	2560	2461	2657	3517	4014	3360	3422	3548	3626	3171	3607	3467	3564	4448	4585	4583	4640	4296	4311	4387	2956
19	Реал.	2226	2421	2419	2378	2331	2944	3819	3598	3644	2854	3396	3159	2955	3082	3191	2992	4043	4474	4016	3907	4360	3925	4058	2598
	Прог.	2466	2475	2507	2507	2489	2732	3524	3672	3626	3401	3402	3434	3238	3292	3446	3302	4416	4601	4543	4448	4427	4301	4357	2986
20	Реал.	2684	2638	2525	2704	2582	2646	3714	3759	3999	3542	3400	3011	3524	3480	3580	3110	4340	4705	4672	4692	5152	4578	4697	3072
	Прог.	2580	2508	2504	2553	2519	2653	3562	3570	3658	3476	3346	3117	3358	3273	3509	3574	4542	4630	4608	4655	4602	4453	4425	3083
21	Реал.	2421	2475	2432	2152	2504	2334	3268	3333	3082	2799	3132	3018	3231	2929	3309	3477	4755	4120	4466	4120	4552	4246	4041	2994
	Прог.	2519	2469	2489	2477	2514	2650	3556	3797	3445	3183	3390	3229	3469	3184	3510	3419	4446	4190	4535	4334	4300	4455	4375	2972
22	Реал.	2799	2712	2457	2714	2834	2719	4241	3611	4279	3294	3112	3771	3024	3307	3169	3374	4342	5033	5243	4822	5112	4602	4122	3374
	Прог.	2585	2532	2493	2558	2576	2677	3646	3689	3658	3429	3363	3374	3362	3413	3392	3628	4503	4760	4683	4580	4324	4397	4394	3126
23	Реал.	2589	2394	2449	2527	2657	2800	3929	3962	3315	3519	2995	3487	3131	3382	3051	3340	4420	4898	4557	4477	4990	4702	4128	3581
	Прог.	2549	2468	2497	2533	2544	2721	3611	3734	3607	3396	3180	3344	3148	3413	3520	3500	4537	4753	4686	4575	4522	4427	4390	3066
24	Реал.	2366	2531	2422	2430	2655	2602	3369	3277	3869	3803	4653	3967	3604	4302	4324	3984	5066	4950	4696	4538	4568	5040	4696	2800
	Прог.	2493	2513	2486	2528	2499	2656	3539	3422	3504	3571	3590	3323	3602	3680	3524	3684	4562	4789	4676	4459	4308	4425	4490	3023
25	Реал.	2333	3634	2445	2182	2281	3727	3409	3524	3333	3703	3807	3857	3531	3976	3556	3727	4417	4311	4277	4309	4527	4542	4331	2926
	Прог.	2512	2708	2492	2485	2480	2826	3485	3710	3596	3559	3474	3412	3436	3559	3505	3686	4425	4705	4608	4442	4486	4383	4404	2953
26	Реал.	2285	2231	2537	2745	2520	2365	3747	3537	3770	3306	3327	2954	3280	3210	3229	3387	4648	4475	4214	4536	4822	4108	4595	3017
	Прог.	2462	2430	2500	2537	2491	2587	3841	3671	3740	3461	3413	3384	3321	3386	3389	3608	4586	4677	4648	4480	4493	4272	4464	2986

Таблиця Б.1 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 5\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
27	Реал.	2241	2314	2199	2363	2275	2582	3933	3809	3954	3175	3170	3093	3326	3039	3183	4660	4337	4528	4950	4659	4524	4583	4774	3236
	Прог.	2494	2465	2464	2487	2475	2691	3623	3782	3719	3462	3372	3349	3510	3290	3542	3560	4430	4604	4742	4575	4035	4286	4381	3012
28	Реал.	2546	2095	2546	2125	2343	2629	3483	3194	3319	3175	3146	3152	3072	3236	3029	2911	4232	4907	4217	4316	4445	5189	4239	3003
	Прог.	2527	2404	2503	2436	2443	2629	3497	3608	3597	3436	3363	3513	3436	3449	3248	3206	4403	4667	4417	4525	4466	4497	4359	3023
29	Реал.	2539	2676	2458	2561	2565	2605	4056	3777	3644	3148	3515	3143	2963	3539	3067	3282	5166	5061	4489	4369	5351	4581	4373	2957
	Прог.	2502	2527	2516	2535	2515	2691	3804	3318	3468	3404	3458	3287	3333	3477	3207	3592	4608	4690	4653	4512	4636	4384	4354	3029
30	Реал.	2771	2606	2858	2797	2519	2900	3821	3721	3845	3702	3373	3157	3293	3150	3768	3039	4308	5864	5759	4765	4345	4566	4709	3458
	Прог.	2594	2509	2575	2590	2485	2732	3578	3712	3671	3473	3470	3229	3496	3529	3329	3237	4550	4799	4791	4567	4440	4482	4496	3143

Таблиця Б.2 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 10\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	Реал.	2197	2254	2194	2208	2302	2618	3354	3254	3668	2765	2465	2785	2908	2861	3553	2876	4020	3840	4082	4183	4289	3835	4077	2501
	Прог.	2348	2426	2526	2502	2449	2697	4254	3678	3422	3254	3172	3163	3192	3520	3375	3189	4422	4434	4589	4270	4291	4363	4337	2967
2	Реал.	2025	2281	2242	2155	2238	2284	3096	3186	2979	2353	2641	2475	2705	2591	2582	2862	3906	3989	4423	3959	4441	3622	4269	2859
	Прог.	2412	2453	2513	2466	2479	2776	3879	3496	3557	3173	3465	3141	3306	3403	3175	3584	4455	4582	4628	4428	4572	4343	4380	2926
3	Реал.	2300	2256	2502	2430	2390	2609	3492	2949	3135	3446	3639	3663	3791	3282	4219	3963	3832	4330	4507	4003	3815	4235	3620	2777
	Прог.	2460	2431	2499	2559	2477	2711	3593	3642	3514	3332	3245	3257	3275	3213	3382	3634	4506	4581	4634	4365	4394	4406	4361	2974
4	Реал.	2229	2157	2176	3166	2301	2204	3661	2946	3604	3268	3978	3457	3957	3821	3361	3460	4109	4181	4013	4050	4337	3914	3995	2625
	Прог.	2473	2421	2484	2571	2445	2795	3618	3820	3563	3495	3445	3729	3577	3368	3350	3586	4555	4579	4585	4624	4419	4408	4310	2953
5	Реал.	2421	2605	2347	2535	2869	2607	3718	3539	3554	2978	2893	2958	3189	2760	3051	2966	4456	4521	4473	4475	4216	4110	4281	2637
	Прог.	2460	2466	2482	2585	2574	2722	3611	3696	3441	3415	3194	3195	3185	3483	3703	3572	4342	4412	4628	4607	4305	4408	4428	2964
6	Реал.	2337	2458	2614	2487	2508	2547	3947	3132	3329	2864	2810	2869	2778	3289	4076	3459	4651	4053	4735	4527	4458	4204	4229	2835
	Прог.	2517	2449	2509	2514	2484	2707	3969	3863	3099	2926	3654	3259	3239	3301	3261	3658	4299	4442	4661	4706	4379	4406	4339	2869
7	Реал.	2095	2323	2297	2423	2356	2279	3642	3015	3454	2886	2861	2626	2749	2836	2929	2890	4886	5011	4113	3932	4384	3737	4477	2742
	Прог.	2448	2432	2478	2536	2498	2657	3524	3957	3901	3429	3540	3186	3129	3339	3197	3480	4565	4622	4586	4479	4337	4364	4437	2932
8	Реал.	2401	2385	2700	2403	3278	2596	3649	3582	3956	3227	3052	2983	2892	3016	2943	3165	4489	4091	4747	4235	4616	3942	3836	3440
	Прог.	2387	2525	2519	2525	2541	2689	3608	3720	3444	3231	3183	3183	3223	3208	3378	3444	4207	4474	4642	4407	4344	4372	4389	2889
9	Реал.	2715	2112	2286	2207	2202	2299	3339	3675	3208	2516	2793	2499	2560	2670	2786	2502	4441	4516	4486	3946	4060	3948	4154	2760
	Прог.	2461	2471	2506	2576	2503	2655	3508	3886	3507	3214	3148	3133	3259	3464	3437	3295	4350	4378	4513	4230	4222	4392	4380	2812
10	Реал.	2378	2117	2168	2116	2102	2104	3492	3460	3238	4048	3638	3839	3731	3662	3803	2963	4252	4318	4324	3964	4970	4370	3899	2698
	Прог.	2429	2467	2509	2548	2440	2639	3533	3732	3372	3436	3404	3833	3949	3699	3034	3582	4201	4482	4575	4460	4518	4429	4383	2740
11	Реал.	2239	2187	2288	2400	2365	2399	2980	3469	3188	3842	3388	3366	3879	3972	3331	4013	4442	4331	4563	4220	4247	4261	3813	2591
	Прог.	2419	2489	2515	2583	2524	2697	3405	3604	3398	3356	3412	3374	3461	3487	3259	3561	4290	4630	4627	4325	4257	4419	4291	2995
12	Реал.	3352	2633	2661	2509	2394	2501	3442	3423	3682	3138	2941	3114	3117	3189	3274	3199	4917	4327	4761	4554	5209	4233	4151	2695
	Прог.	2549	2529	2545	2547	2495	2709	3561	3503	3456	3263	3287	3184	3242	3656	3329	3497	4285	4308	4603	4617	4343	4415	4408	2920
13	Реал.	2429	2231	2298	2460	2587	3857	3364	3870	3573	2634	3656	2936	2936	2813	3343	3031	4459	4185	4132	4728	4046	4388	4779	3032
	Прог.	2450	2529	2579	2523	2518	2844	3510	3815	3420	3454	3275	3261	3141	3447	3440	3362	4292	4462	4466	4550	4265	4437	4379	3031
14	Реал.	2486	2656	2723	2461	2509	2895	3413	5270	3861	3089	3288	3221	3244	3104	3162	3014	4866	4865	4313	4349	4719	4593	4076	3327
	Прог.	2497	2530	2583	2556	2478	2725	3661	4020	3585	3314	3305	3266	3197	3223	3359	3450	4114	4484	4446	4524	4552	4443	4318	3035

Таблиця Б.2 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 10\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
15	Реал.	2559	2285	2765	2118	2364	2330	3646	3514	3278	2803	2572	2857	3334	4471	3053	2993	4387	4867	4550	4243	4276	4306	4536	2722
	Прог.	2508	2478	2628	2482	2523	2663	3570	3922	3402	3259	3245	3195	3221	2969	2670	3366	4328	4372	4358	4366	4363	4418	4446	2880
16	Реал.	2634	2558	2230	2697	2301	2726	3751	3831	3477	2983	3021	2799	2992	3039	2878	3309	4316	4500	4235	4437	4682	4660	4689	2889
	Прог.	2459	2539	2586	2624	2493	2725	3554	3795	3516	3278	3256	3225	3056	3361	3398	3433	4666	4499	4435	4328	4264	4446	4369	3038
17	Реал.	2333	2281	2329	2296	2154	2519	3124	3551	3319	3840	3465	3594	3905	4095	3979	3693	4278	4229	5076	4619	4229	4520	4594	2556
	Прог.	2511	2482	2510	2566	2519	2680	3417	3577	3537	3517	3431	3356	3371	3243	3347	3457	4286	4490	4419	4405	4217	4448	4420	2882
18	Реал.	2091	2387	2178	2617	2180	2384	3513	3395	3594	3257	3980	4041	3363	3083	3734	3784	4431	4392	4625	5053	4253	4588	4098	2827
	Прог.	2473	2491	2510	2554	2474	2692	3528	3243	3528	3371	3310	3335	3311	3413	3346	3472	4419	4485	4521	4644	4307	4452	4389	2879
19	Реал.	2216	2410	2407	2365	2317	2929	3790	3578	3614	2813	3347	3106	2908	3038	3141	2917	4011	4445	3991	3886	4342	3909	4044	2585
	Прог.	2416	2491	2526	2548	2505	2734	3529	3797	3477	3305	3340	3294	3180	3294	3407	3317	4447	4512	4558	4550	4413	4371	4346	2981
20	Реал.	2672	2627	2514	2692	2567	2628	3674	3682	3938	3488	3349	2965	3489	3437	3530	3043	4308	4678	4648	4670	5132	4561	4683	3059
	Прог.	2570	2511	2559	2540	2497	2733	3504	3642	3490	3290	3165	3097	3353	3322	3439	3402	4569	4495	4587	4679	4553	4446	4357	2980
21	Реал.	2409	2464	2421	2140	2491	2320	3235	3238	2992	2716	3053	2936	3143	2857	3225	3412	4734	4100	4446	4101	4535	4231	4027	2982
	Прог.	2533	2485	2534	2507	2504	2691	3487	3745	3361	3252	3218	3261	3235	3304	3350	3437	4282	4219	4478	4329	4311	4465	4363	3062
22	Реал.	2788	2702	2447	2703	2820	2703	4223	3590	4257	3271	3087	3745	2978	3247	3113	3309	4312	5007	5220	4802	5096	4588	4109	3362
	Прог.	2572	2531	2564	2601	2564	2703	3596	3896	3605	3542	3527	3475	3243	3198	3254	3432	4517	4650	4576	4564	4335	4439	4382	2997
23	Реал.	2577	2382	2436	2514	2644	2786	3913	3944	3282	3409	2920	3408	3040	3301	2956	3267	4387	4868	4531	4454	4972	4687	4115	3569
	Прог.	2551	2490	2539	2564	2550	2729	3587	3898	3474	3206	3122	3271	3241	3280	3243	3381	4575	4806	4663	4637	4459	4448	4372	3125
24	Реал.	2354	2520	2411	2418	2640	2584	3329	3190	3806	3765	4624	3877	3486	4204	4233	3911	5032	4921	4672	4519	4552	5026	4684	2789
	Прог.	2511	2534	2555	2524	2489	2690	3529	3616	3471	3333	3395	3340	3353	3277	3389	3461	4500	4791	4632	4421	4315	4490	4431	3000
25	Реал.	2323	3625	2435	2171	2268	3712	3381	3482	3299	3662	3763	3815	3494	3940	3506	3663	4387	4284	4252	4287	4509	4526	4317	2914
	Прог.	2425	2639	2566	2499	2495	2796	3444	3595	3538	3338	3375	3289	3392	3473	3419	3474	4354	4679	4592	4425	4475	4433	4373	3059
26	Реал.	2274	2219	2525	2730	2504	2347	3691	3479	3727	3247	3261	2902	3240	3171	3191	3317	4612	4442	4186	4514	4805	4093	4582	3004
	Прог.	2475	2462	2554	2563	2478	2679	3796	3765	3477	3450	3329	3257	3357	3412	3283	3439	4578	4607	4609	4446	4443	4396	4411	3059
27	Реал.	2229	2301	2186	2350	2261	2567	3904	3752	3916	3133	3124	3051	3292	3003	3148	4610	4306	4500	4927	4641	4509	4571	4763	3226
	Прог.	2521	2494	2495	2509	2482	2713	3478	3739	3588	3329	3327	3277	3522	3458	3241	3536	4415	4496	4665	4619	4215	4452	4470	2909
28	Реал.	2535	2083	2534	2110	2327	2611	3457	3172	3291	3127	3116	3053	3021	3161	2947	2837	4206	4883	4195	4297	4428	5175	4226	2991
	Прог.	2445	2447	2554	2490	2459	2693	3545	3746	3578	3384	3297	3217	3235	3257	3251	3361	4381	4522	4381	4600	4457	4498	4342	3040

Таблиця Б.2 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 10\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
29	Реал.	2527	2666	2447	2550	2553	2590	4012	3665	3540	3064	3429	3069	2909	3506	3033	3248	5134	5033	4465	4349	5334	4566	4359	2943
	Прог.	2482	2528	2522	2577	2495	2712	3620	3685	3404	3301	3256	3235	3210	3437	3289	3657	4555	4522	4616	4551	4573	4438	4331	3028
30	Реал.	2757	2592	2845	2785	2505	2886	3804	3701	3796	3635	3293	3076	3190	3050	3655	2948	4248	5838	5737	4745	4327	4551	4695	3446
	Прог.	2579	2514	2562	2553	2475	2734	3554	3912	3455	3306	3250	3270	3141	3184	3442	3324	4394	4549	4680	4551	4434	4470	4438	3060

Таблиця Б.3 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 20\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	Реал.	2179	2235	2173	2185	2277	2591	3246	3180	3609	2656	2322	2627	2734	2598	3326	2710	3899	3792	4042	4150	4261	3810	4056	2483
	Прог.	2398	2452	2418	2399	2484	2741	4081	3775	3762	3232	3073	2976	2894	3082	3096	3188	4048	4353	4510	4301	4421	4413	4094	2998
2	Реал.	2009	2265	2225	2137	2217	2227	2959	2999	2743	2094	2429	2260	2459	2345	2395	2754	3807	3942	4381	3922	4409	3594	4246	2839
	Прог.	2384	2491	2513	2498	2588	3011	3912	3414	3180	3175	3007	3065	2955	3019	2970	3658	4181	4472	4560	4388	4565	4454	4060	3025
3	Реал.	2283	2239	2484	2410	2368	2584	3464	2892	3020	3304	3487	3500	3620	3100	4029	3799	3715	4284	4466	3968	3785	4210	3598	2758
	Прог.	2411	2448	2488	2528	2600	2761	3091	3514	3361	3248	3148	3055	2970	2944	3175	3398	4056	4469	4550	4352	4482	4507	3909	3014
4	Реал.	2211	2139	2157	3144	2277	2127	3592	2811	3413	3051	3768	3218	3695	3527	3100	3309	3990	4130	3965	4008	4303	3887	3973	2606
	Прог.	2414	2441	2493	2577	2497	3598	3587	3454	3179	2946	3120	3142	3198	3347	3163	3551	3945	4467	4632	4528	4508	4506	4124	3003
5	Реал.	2404	2588	2329	2516	2848	2582	3658	3491	3506	2870	2729	2779	2992	2515	2814	2810	4355	4480	4437	4444	4188	4086	4259	2618
	Прог.	2416	2474	2482	2536	2611	2767	3461	3579	3687	3241	3169	2992	3026	3083	3100	3504	4098	4311	4538	4510	4436	4324	3956	3005
6	Реал.	2318	2439	2594	2464	2483	2512	3840	2926	3061	2608	2578	2671	2597	3148	3974	3408	4601	4005	4691	4489	4427	4179	4209	2817
	Прог.	2444	2464	2501	2454	2606	2702	3963	3458	3248	2829	3025	3103	3039	3161	3495	3866	4210	4355	4635	4605	4490	4511	4131	3036
7	Реал.	2077	2305	2278	2403	2334	2254	3610	2918	3246	2604	2624	2425	2555	2678	2791	2826	4833	4962	4070	3895	4354	3713	4457	2723
	Прог.	2399	2459	2473	2527	2593	2697	3125	3943	3291	3826	3091	3082	3010	3037	3128	3817	4271	4498	4492	4420	4460	4334	3998	3013
8	Реал.	2382	2366	2681	2383	3256	2570	3592	3472	3893	3081	2891	2746	2721	2872	2845	3084	4393	4049	4712	4205	4590	3920	3817	3424
	Прог.	2408	2458	2502	2525	2622	2721	3399	3545	3818	3186	3105	3042	2942	3037	3516	3857	4079	4386	4524	4380	4465	4435	3900	3093
9	Реал.	2699	2095	2267	2187	2180	2273	3308	3640	3156	2356	2643	2302	2305	2393	2532	2347	4299	4473	4451	3916	4035	3928	4137	2743
	Прог.	2441	2393	2473	2440	2474	2629	3340	3812	3548	2952	3084	3067	2978	2997	3146	3095	4064	4335	4470	4279	4001	4104	4294	2951
10	Реал.	2361	2100	2150	2096	2079	2078	3426	3327	3078	3950	3591	3791	3685	3618	3760	2918	4205	4271	4281	3927	4939	4345	3880	2682
	Прог.	2410	2393	2446	2438	2382	2629	3549	3463	3048	3329	3209	3155	3100	3158	3464	3756	4111	4412	4559	4467	4512	4145	4384	2935
11	Реал.	2224	2171	2270	2382	2345	2379	2922	3394	3128	3751	3277	3243	3800	3907	3268	3953	4342	4284	4521	4185	4218	4237	3792	2571
	Прог.	2444	2403	2461	2458	2490	2762	3393	3622	3522	3197	3312	3296	3369	3313	3478	3865	4217	4584	4647	4370	4072	4374	4231	2945
12	Реал.	3331	2612	2639	2487	2371	2476	3374	3263	3546	2999	2852	3043	3040	3133	3222	3153	4876	4289	4725	4521	5179	4209	4132	2679
	Прог.	2488	2500	2504	2473	2458	2750	3477	3441	3296	3012	3192	3050	3043	3119	3421	3709	4165	4324	4559	4581	4108	4137	4412	2961
13	Реал.	2414	2215	2281	2441	2566	3832	3336	3838	3502	2443	3523	2776	2733	2547	3084	2861	4363	4140	4094	4696	4017	4362	4756	3013
	Прог.	2561	2498	2457	2474	2485	2907	3387	3806	3459	3415	3331	3072	3014	2937	2888	3123	4345	4370	4372	4570	4269	4365	4301	2972
14	Реал.	2469	2640	2707	2443	2486	2865	3375	5227	3796	2968	3156	3093	3123	2971	3004	2872	4796	4819	4273	4314	4690	4568	4055	3309
	Прог.	2470	2470	2488	2474	2425	2722	3547	3947	3516	3332	3294	3248	3042	3012	3000	3238	4216	4338	4377	4544	4560	4197	4246	2992

Таблиця Б.3 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 20\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
15	Реал.	2542	2267	2746	2097	2342	2305	3617	3480	3213	2716	2476	2776	3236	4360	2934	2875	4343	4826	4513	4210	4247	4283	4517	2705
	Прог.	2478	2433	2492	2440	2485	2654	3436	3754	3379	3145	3122	3171	3103	2900	2845	3148	4244	4254	4387	4502	4419	4316	4304	2889
16	Реал.	2617	2541	2212	2677	2278	2698	3719	3774	3434	2934	2940	2706	2869	2872	2711	3171	4205	4460	4200	4406	4654	4635	4667	2870
	Прог.	2522	2485	2459	2480	2467	2787	3404	3684	3639	3377	3197	3163	3103	2939	3028	3367	4357	4405	4372	4489	4128	4252	4294	2959
17	Реал.	2315	2263	2310	2276	2131	2493	3081	3456	3258	3761	3338	3460	3740	3886	3790	3555	4227	4184	5038	4589	4204	4498	4574	2537
	Прог.	2491	2435	2491	2454	2471	2662	3482	3614	3526	3297	3342	3261	3141	3244	3046	3215	4189	4420	4427	4530	4086	4119	4313	2892
18	Реал.	2072	2367	2157	2595	2155	2359	3450	3227	3466	3149	3836	3909	3200	2841	3528	3652	4379	4345	4583	5018	4224	4564	4077	2808
	Прог.	2457	2487	2466	2489	2451	2767	3496	3508	3354	3347	3284	3363	3066	3030	3242	3222	4363	4389	4410	4607	4329	4141	4291	2886
19	Реал.	2197	2390	2386	2342	2292	2901	3736	3544	3557	2732	3250	3005	2819	2957	3046	2766	3956	4395	3947	3847	4309	3881	4020	2562
	Прог.	2420	2442	2490	2466	2475	2746	3500	3776	3458	3182	3212	3237	3180	3227	3332	3130	4405	4437	4513	4530	4472	4217	4257	2939
20	Реал.	2651	2606	2493	2669	2541	2597	3595	3523	3817	3382	3249	2878	3427	3358	3436	2912	4254	4630	4605	4632	5098	4531	4657	3037
	Прог.	2551	2500	2473	2473	2460	2661	3540	3339	3428	3340	3125	3000	3313	3161	3376	3302	4481	4375	4470	4627	4573	4346	4341	2962
21	Реал.	2389	2443	2400	2119	2469	2294	3170	3042	2809	2547	2894	2772	2965	2712	3052	3281	4698	4064	4410	4067	4504	4203	4003	2960
	Прог.	2514	2463	2477	2454	2473	2800	3520	3769	3454	2968	3090	3067	3022	3042	3001	3430	4146	4188	4390	4482	4297	4431	4271	2966
22	Реал.	2768	2684	2428	2683	2796	2674	4190	3553	4218	3230	3044	3698	2892	3132	3006	3182	4260	4960	5180	4768	5066	4563	4087	3341
	Прог.	2544	2517	2464	2485	2517	2693	3451	3748	3705	3428	3301	3279	3217	3159	3169	3300	4458	4626	4452	4577	4252	4230	4286	2976
23	Реал.	2556	2360	2414	2491	2620	2760	3885	3913	3219	3180	2767	3249	2857	3139	2766	3121	4328	4814	4484	4415	4939	4660	4092	3547
	Прог.	2528	2485	2481	2477	2505	2777	3430	3776	3367	2918	3070	3116	2979	3008	2958	3222	4474	4745	4679	4590	4502	4257	4277	3012
24	Реал.	2333	2500	2391	2396	2615	2552	3250	3012	3682	3695	4573	3697	3244	4007	4052	3767	4972	4868	4629	4484	4524	5002	4662	2770
	Прог.	2489	2510	2463	2473	2405	2682	3582	3323	3340	3329	3365	3070	3015	3089	3059	3307	4430	4751	4581	4532	4304	4204	4321	2955
25	Реал.	2305	3608	2417	2151	2245	3685	3328	3401	3235	3586	3679	3737	3428	3874	3412	3537	4334	4236	4210	4250	4477	4498	4292	2893
	Прог.	2483	2555	2463	2455	2469	2722	3512	3603	3472	3236	3250	3280	3390	3457	3344	3314	4281	4685	4556	4522	4519	4220	4277	2963
26	Реал.	2255	2200	2503	2705	2475	2315	3579	3362	3645	3132	3132	2802	3170	3103	3123	3183	4548	4385	4138	4476	4774	4068	4560	2982
	Прог.	2453	2431	2482	2463	2426	2620	3678	3544	3401	3350	3310	3199	3313	3382	3392	3225	4498	4604	4620	4538	4490	4142	4305	2967
27	Реал.	2207	2279	2164	2328	2237	2540	3848	3638	3845	3052	3038	2971	3230	2941	3087	4516	4251	4450	4885	4607	4483	4549	4745	3208
	Прог.	2508	2489	2478	2443	2458	2796	3602	3582	3467	3202	3204	3202	3508	3311	3415	3350	4364	4397	4625	4583	3995	4127	4330	2906
28	Реал.	2517	2062	2511	2085	2300	2581	3408	3134	3240	3035	3062	2853	2926	3013	2782	2690	4158	4840	4156	4263	4399	5150	4204	2970
	Прог.	2449	2435	2483	2421	2378	2634	3405	3753	3557	3277	3314	3042	3258	3015	2941	3128	4328	4402	4365	4565	4507	4270	4258	2967

Таблиця Б.3 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 20\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
29	Реал.	2507	2646	2428	2530	2531	2564	3926	3432	3324	2893	3255	2921	2806	3447	2973	3188	5077	4983	4423	4313	5304	4539	4335	2920
	Прог.	2455	2515	2499	2477	2458	2776	3624	3233	3220	3028	3070	3192	3165	3428	3219	3742	4484	4385	4581	4550	4588	4214	4277	2965
30	Реал.	2733	2568	2821	2762	2482	2860	3773	3664	3699	3499	3133	2911	2980	2851	3426	2767	4130	5792	5696	4709	4296	4524	4671	3424
	Прог.	2556	2504	2524	2495	2415	2763	3427	3757	3469	3222	3071	3064	3057	2969	3176	3024	4305	4369	4527	4571	4490	4415	4327	3003

Таблиця Б.4 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 30\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	Реал.	2149	2202	2137	2146	2236	2547	3145	3097	3533	2540	2179	2468	2561	2359	3111	2537	3762	3711	3976	4096	4215	3770	4021	2452
	Прог.	2439	2342	2344	2387	2350	2612	3591	3524	3351	2901	2724	2748	2836	2950	2944	2798	4159	4206	4301	4000	4089	4114	4270	2910
2	Реал.	1980	2238	2197	2106	2182	2165	2838	2841	2547	1876	2236	2061	2236	2122	2211	2627	3688	3863	4311	3861	4356	3548	4207	2806
	Прог.	2318	2376	2344	2397	2385	2432	3337	3433	2822	2608	2842	2603	2624	2679	2588	3041	4152	4394	4394	4198	4453	4129	4354	2941
3	Реал.	2253	2210	2454	2377	2331	2541	3417	2823	2907	3168	3335	3336	3448	2923	3848	3638	3587	4209	4398	3909	3735	4168	3563	2726
	Прог.	2390	2344	2428	2448	2425	2641	3592	3349	3080	2949	3005	2983	3067	2893	3167	3216	4131	4424	4416	4120	4225	4311	4356	2986
4	Реал.	2181	2108	2125	3109	2237	2048	3516	2687	3247	2864	3583	3010	3467	3276	2872	3154	3857	4045	3886	3939	4246	3842	3936	2575
	Прог.	2369	2316	2327	2670	2357	2829	3441	3231	3371	2939	3095	2814	2640	2953	3340	3055	4289	4404	4383	4324	4332	4280	4226	2942
5	Реал.	2376	2561	2301	2485	2812	2541	3588	3426	3436	2753	2569	2603	2804	2297	2604	2659	4243	4411	4376	4391	4142	4045	4224	2586
	Прог.	2425	2440	2383	2472	2552	2658	3373	3620	3538	3079	2763	2780	2855	2956	2946	2973	4262	4300	4410	4445	4118	4117	4545	2949
6	Реал.	2287	2408	2560	2427	2441	2462	3736	2751	2840	2390	2374	2490	2427	3002	3855	3323	4518	3926	4618	4425	4376	4138	4175	2786
	Прог.	2398	2398	2454	2474	2453	2510	3576	3697	3745	2498	2697	2777	2800	3049	3103	3371	4336	4268	4522	4456	4285	4315	4297	2786
7	Реал.	2048	2275	2246	2368	2296	2212	3560	2821	3071	2377	2423	2244	2374	2519	2643	2728	4746	4881	3999	3835	4305	3674	4423	2692
	Прог.	2333	2362	2371	2454	2416	2495	3540	3692	3574	2049	2447	2667	2719	2863	2923	3036	4533	4559	4311	4248	4195	4031	4522	2941
8	Реал.	2351	2335	2649	2349	3220	2528	3524	3363	3811	2938	2733	2532	2547	2714	2718	2973	4280	3980	4653	4155	4548	3884	3786	3396
	Прог.	2443	2386	2481	2452	2649	2582	3375	3518	3365	2914	2816	2802	2803	2955	2926	2983	4093	4274	4493	4214	4228	4160	4540	2801
9	Реал.	2673	2067	2237	2154	2142	2230	3257	3581	3082	2207	2498	2121	2080	2149	2303	2186	4153	4403	4393	3866	3994	3894	4107	2716
	Прог.	2546	2314	2371	2389	2374	2473	3474	3616	3433	2682	2771	2648	2574	2651	3014	2760	3889	4345	4415	3990	3958	4069	4363	2628
10	Реал.	2333	2070	2118	2062	2041	2035	3352	3205	2934	3843	3515	3713	3609	3546	3689	2843	4126	4193	4209	3864	4887	4303	3847	2655
	Прог.	2443	2312	2332	2372	2311	2438	3390	3283	3028	3308	3359	3383	3348	3321	3159	3150	4215	4334	4364	4284	4571	4187	4555	2288
11	Реал.	2198	2144	2241	2351	2313	2344	2859	3313	3050	3643	3146	3097	3683	3798	3162	3853	4221	4204	4452	4126	4169	4196	3757	2538
	Прог.	2448	2340	2367	2449	2421	2631	3427	3627	3176	3123	3143	3101	3371	3458	3273	3513	4117	4434	4466	4167	4047	4343	4171	2890
12	Реал.	3297	2575	2602	2450	2333	2434	3300	3122	3417	2863	2744	2941	2931	3039	3136	3076	4807	4225	4665	4465	5130	4168	4101	2653
	Прог.	2682	2451	2474	2490	2418	2638	3547	3248	3127	2769	2895	3100	3154	3180	3081	3250	4412	4212	4491	4468	4285	4152	4651	2946
13	Реал.	2389	2189	2252	2410	2531	3790	3288	3786	3421	2277	3391	2618	2540	2306	2848	2688	4247	4064	4030	4642	3969	4319	4718	2980
	Прог.	2537	2374	2358	2479	2474	3009	3484	3725	3275	2959	2979	2849	2728	2962	3212	2893	4118	4300	4309	4505	4059	4388	4421	3024
14	Реал.	2440	2613	2679	2413	2448	2816	3313	5156	3706	2840	3020	2956	2987	2826	2840	2721	4699	4744	4206	4256	4640	4526	4020	3278
	Прог.	2452	2471	2499	2494	2411	2696	3591	4056	3548	3000	2986	3024	3084	2940	2895	2856	4132	4482	4306	4390	4524	4263	4212	3087

Таблиця Б.4 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 30\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
15	Реал.	2513	2238	2714	2063	2304	2263	3569	3424	3132	2614	2366	2675	3121	4238	2806	2748	4270	4759	4451	4154	4200	4244	4485	2676
	Прог.	2472	2367	2493	2393	2427	2531	3532	3494	3256	2972	2863	2948	3061	3512	3116	2936	4249	4381	4238	4222	4261	4320	4530	2889
16	Реал.	2589	2513	2183	2645	2240	2652	3664	3699	3361	2851	2833	2592	2737	2710	2549	3029	4084	4394	4142	4354	4607	4593	4630	2837
	Прог.	2540	2445	2343	2537	2400	2684	3559	3702	3453	3214	3038	2890	3023	2988	2941	2955	4304	4391	4285	4203	4109	4333	4377	2927
17	Реал.	2285	2234	2279	2242	2093	2451	3021	3353	3170	3655	3196	3312	3572	3688	3605	3407	4143	4110	4976	4538	4161	4461	4541	2506
	Прог.	2410	2366	2407	2437	2367	2579	3280	3625	3442	3392	3074	3041	3024	3121	3091	3125	4216	4315	4392	4328	3982	4174	4379	2859
18	Реал.	2040	2333	2122	2557	2115	2316	3379	3081	3343	3034	3693	3772	3041	2628	3336	3509	4293	4265	4512	4958	4175	4524	4043	2777
	Прог.	2342	2401	2360	2537	2361	2594	3378	3215	3188	3109	3118	3217	2880	2865	3063	3110	4264	4355	4428	4600	4161	4207	4273	2905
19	Реал.	2166	2358	2351	2304	2250	2856	3669	3487	3480	2634	3137	2882	2699	2839	2919	2605	3863	4311	3873	3783	4254	3834	3979	2525
	Прог.	2391	2400	2426	2464	2408	2718	3412	3579	3469	2959	3059	2943	2997	3055	3153	2867	4192	4370	4298	4281	4339	4144	4211	2869
20	Реал.	2616	2572	2459	2631	2497	2546	3507	3378	3693	3267	3136	2770	3330	3244	3310	2763	4163	4551	4535	4569	5041	4481	4615	3000
	Прог.	2506	2466	2439	2538	2451	2598	3466	3222	3302	3220	3127	2915	3240	3200	3281	3056	4414	4433	4456	4519	4614	4395	4361	3015
21	Реал.	2355	2409	2366	2084	2431	2252	3096	2875	2645	2389	2736	2606	2791	2563	2891	3152	4637	4004	4351	4010	4452	4158	3962	2924
	Прог.	2431	2417	2421	2407	2447	2588	3306	3401	3014	2750	2838	2809	2866	2791	2982	3011	4350	4057	4364	4153	4191	4380	4220	2933
22	Реал.	2736	2654	2398	2649	2756	2627	4135	3492	4152	3162	2972	3620	2782	2998	2874	3038	4172	4883	5113	4711	5017	4520	4049	3307
	Прог.	2536	2491	2419	2551	2550	2637	3705	3519	3685	3336	3217	3319	2947	3050	2990	3133	4324	4573	4590	4512	4281	4296	4258	3097
23	Реал.	2521	2325	2377	2453	2580	2717	3838	3861	3142	2985	2619	3091	2677	2970	2576	2962	4229	4724	4405	4349	4886	4615	4052	3511
	Прог.	2477	2399	2429	2504	2502	2697	3601	3633	3285	2697	2801	2898	2818	2940	2805	2995	4435	4631	4557	4442	4489	4342	4245	3089
24	Реал.	2299	2467	2358	2360	2572	2498	3158	2847	3549	3597	4488	3523	3026	3814	3868	3607	4871	4781	4558	4427	4476	4961	4626	2737
	Прог.	2414	2442	2410	2483	2413	2601	3330	3098	3297	3397	3566	3039	2931	3114	3087	3204	4432	4672	4496	4329	4202	4356	4405	2928
25	Реал.	2276	3579	2387	2118	2207	3640	3261	3309	3150	3487	3570	3628	3325	3770	3290	3394	4246	4156	4138	4188	4423	4450	4252	2859
	Прог.	2448	2737	2415	2416	2394	2886	3284	3529	3387	3259	3242	3310	3202	3388	3235	3230	4241	4491	4385	4295	4433	4271	4285	2910
26	Реал.	2224	2167	2467	2663	2427	2263	3468	3244	3547	3007	2991	2674	3057	2989	3010	3026	4441	4289	4058	4412	4724	4026	4522	2946
	Прог.	2392	2348	2450	2511	2407	2505	3380	3504	3367	3099	3022	2906	3163	3215	3147	3080	4449	4425	4429	4355	4445	4108	4366	2946
27	Реал.	2170	2242	2127	2290	2197	2495	3780	3525	3755	2950	2927	2860	3127	2837	2985	4395	4159	4368	4816	4552	4439	4513	4713	3178
	Прог.	2382	2378	2364	2438	2385	2648	3408	3547	3451	3062	3054	3082	3334	3144	3297	3316	4231	4384	4585	4491	3994	4192	4562	3003
28	Реал.	2485	2028	2474	2044	2254	2529	3342	3070	3163	2925	2972	2660	2800	2851	2613	2539	4080	4768	4092	4206	4351	5108	4166	2935
	Прог.	2482	2312	2452	2360	2322	2575	3481	3476	3413	3035	3065	2807	2990	2962	2847	2851	4201	4493	4214	4398	4404	4453	4254	2964

Таблиця Б.4 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 30\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
29	Реал.	2474	2615	2396	2496	2493	2521	3837	3238	3135	2727	3083	2765	2679	3349	2873	3088	4983	4900	4352	4253	5254	4496	4295	2880
	Прог.	2462	2480	2439	2513	2450	2648	3671	2920	3038	2832	2889	2827	2881	3340	3044	3290	4495	4528	4450	4401	4672	4275	4282	2955
30	Реал.	2693	2528	2781	2724	2444	2817	3722	3603	3593	3365	2977	2748	2778	2649	3203	2582	3998	5716	5629	4650	4245	4478	4631	3387
	Прог.	2527	2455	2542	2579	2400	2715	3599	3547	3413	3048	2882	2831	2817	2848	3008	2764	4119	4734	4754	4491	4362	4446	4414	3110

Таблиця Б.5 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 40\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	Реал.	2126	2176	2108	2114	2203	2512	3036	3017	3464	2424	2031	2304	2381	2098	2882	2363	3629	3647	3924	4053	4178	3738	3993	2427
	Прог.	2361	2349	2349	2327	2411	2690	3403	3640	3512	3279	2783	2647	2629	2721	2267	2778	3826	4198	4385	4161	4323	4406	4124	2938
2	Реал.	1958	2216	2174	2081	2154	2104	2703	2660	2321	1626	2025	1845	1991	1877	2019	2507	3577	3800	4255	3812	4313	3512	4176	2780
	Прог.	2386	2419	2463	2398	2523	2654	2802	4384	2757	2665	3033	2784	2823	2839	2500	3236	3943	4505	4421	4287	4463	4393	4147	2940
3	Реал.	2229	2186	2430	2350	2301	2508	3379	2759	2789	3023	3178	3166	3270	2737	3655	3470	3461	4148	4343	3862	3695	4134	3534	2701
	Прог.	2404	2349	2363	2524	2503	2697	3090	3456	3230	3008	2802	2675	2621	2609	2546	2920	3865	4446	4402	4238	4396	4399	4228	2938
4	Реал.	2157	2084	2099	3081	2205	1967	3441	2552	3060	2653	3376	2776	3211	2990	2616	2996	3728	3977	3822	3884	4200	3806	3907	2550
	Прог.	2420	2348	2418	2420	2421	2975	3336	3323	4248	2786	2870	2689	2528	2784	2618	3122	3680	4467	4543	4442	4387	4401	4110	2936
5	Реал.	2353	2539	2278	2460	2784	2507	3521	3368	3376	2637	2401	2419	2604	2055	2370	2499	4133	4356	4327	4349	4106	4013	4195	2560
	Прог.	2396	2352	2369	2546	2563	2699	3300	3496	3472	2933	3075	2682	2636	2758	2680	3069	4005	3953	4388	4393	4331	4454	4238	2937
6	Реал.	2263	2383	2533	2397	2408	2419	3627	2551	2584	2142	2147	2292	2244	2853	3742	3254	4452	3863	4559	4374	4334	4106	4148	2762
	Прог.	2452	2351	2372	2350	2497	2725	3381	3880	2846	2394	2798	2755	2675	2741	2948	3895	3943	4159	4492	4487	4359	4398	4116	2948
7	Реал.	2024	2251	2221	2340	2266	2178	3519	2720	2871	2110	2193	2044	2178	2355	2496	2646	4676	4816	3941	3786	4266	3643	4397	2667
	Прог.	2409	2351	2361	2489	2532	2680	3149	3777	3610	3569	2570	2766	2629	2655	2713	3656	4311	4397	4359	4328	4340	4431	4204	2938
8	Реал.	2326	2309	2624	2323	3190	2494	3461	3250	3737	2789	2568	2297	2368	2558	2604	2875	4173	3924	4606	4116	4514	3855	3761	3374
	Прог.	2352	2393	2364	2474	2465	2683	3323	3205	3563	2917	2800	2859	2609	2628	3021	3547	4134	4247	4345	4253	4335	4403	4295	2961
9	Реал.	2651	2045	2212	2127	2113	2195	3216	3533	3019	2046	2344	1923	1829	1877	2051	2022	4004	4347	4346	3827	3961	3867	4084	2694
	Прог.	2353	2374	2355	2513	2513	2672	3139	3510	3447	3029	2821	2724	2658	2529	2655	2835	3376	4008	4275	4182	4311	4486	4166	2954
10	Реал.	2311	2047	2093	2034	2010	2000	3280	3072	2775	3737	3454	3650	3547	3488	3631	2783	4063	4131	4151	3814	4846	4270	3820	2633
	Прог.	2350	2367	2374	2475	2431	2676	3329	3215	3053	2954	3230	3109	3022	3097	3152	3774	3795	4237	4411	4358	4426	4457	4294	2967
11	Реал.	2178	2122	2218	2326	2287	2316	2796	3233	2980	3541	3023	2959	3584	3711	3077	3773	4107	4140	4397	4078	4129	4164	3729	2511
	Прог.	2360	2390	2366	2490	2521	2692	2993	3433	3583	3058	2955	2982	2956	3073	3388	3787	4004	4456	4479	4234	4318	4399	4104	2950
12	Реал.	3269	2546	2573	2421	2303	2401	3226	2964	3279	2720	2643	2853	2837	2963	3067	3015	4751	4173	4617	4420	5091	4136	4075	2632
	Прог.	2386	2389	2356	2409	2477	2698	3268	3047	3076	3223	2959	2925	2829	3090	3419	3539	3845	3918	4382	4450	4324	4453	4312	2937
13	Реал.	2369	2168	2228	2384	2502	3757	3250	3744	3343	2090	3254	2452	2334	2042	2590	2511	4138	4004	3980	4599	3931	4284	4687	2954
	Прог.	2386	2448	2470	2378	2484	2711	3142	3503	3608	3691	3038	2889	2622	2686	2669	2750	4021	4224	4255	4377	4327	4401	4105	2951
14	Реал.	2417	2591	2658	2388	2418	2777	3264	5099	3628	2711	2881	2820	2856	2683	2674	2570	4614	4683	4152	4209	4600	4492	3991	3254
	Прог.	2420	2385	2407	2431	2426	2690	3338	3585	3384	2908	2778	2712	2656	2649	2687	3130	4096	4147	4207	4382	4457	4426	4107	2947

Таблиця Б.5 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 40\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
15	Реал.	2490	2214	2689	2036	2274	2229	3530	3380	3058	2518	2260	2582	3012	4118	2679	2622	4211	4705	4402	4109	4161	4213	4459	2653
	Прог.	2425	2361	2477	2355	2519	2679	3112	3523	3500	3033	2850	2821	2683	3018	3454	3217	4022	3940	4087	4263	4370	4399	4322	2941
16	Реал.	2567	2490	2159	2618	2209	2615	3621	3632	3303	2785	2738	2487	2605	2539	2378	2884	3965	4341	4096	4313	4570	4560	4601	2811
	Прог.	2365	2413	2493	2515	2486	2698	3132	3479	3542	3406	2996	2826	2892	2983	3000	3254	3971	4238	4203	4222	4315	4410	4104	2959
17	Реал.	2260	2210	2255	2215	2063	2416	2968	3252	3095	3561	3057	3166	3400	3477	3411	3260	4075	4051	4927	4497	4127	4432	4515	2480
	Прог.	2419	2391	2442	2396	2444	2567	3499	3496	3406	3174	2918	2739	2713	2861	2676	2898	4112	4316	4272	4321	4051	4071	4285	2923
18	Реал.	2014	2307	2093	2526	2083	2282	3310	2917	3213	2919	3544	3633	2873	2390	3129	3368	4224	4201	4456	4911	4137	4492	4016	2752
	Прог.	2411	2427	2444	2418	2407	2672	3475	3116	3215	2856	3020	2713	2744	2778	2877	2885	4276	4287	4318	4437	4179	4086	4291	2904
19	Реал.	2142	2332	2322	2273	2217	2819	3607	3441	3412	2542	3029	2768	2593	2739	2807	2444	3788	4244	3814	3732	4210	3796	3946	2495
	Прог.	2413	2394	2449	2404	2420	2617	3472	3615	3311	3053	2918	2970	3002	3090	2941	2842	4338	4320	4399	4438	4299	4179	4269	2934
20	Реал.	2588	2545	2432	2601	2461	2504	3421	3219	3567	3153	3026	2670	3250	3147	3198	2620	4090	4487	4479	4518	4995	4441	4581	2970
	Прог.	2434	2427	2392	2429	2400	2557	3402	3057	3139	2986	2803	2825	3182	3080	2931	3111	4397	4264	4356	4478	4364	4254	4292	2946
21	Реал.	2327	2382	2339	2056	2400	2218	3025	2685	2464	2219	2572	2435	2608	2411	2717	3018	4589	3956	4303	3965	4411	4121	3930	2895
	Прог.	2426	2410	2406	2413	2410	2720	3619	3209	3000	2575	2863	2699	2632	2633	2777	3026	4030	4124	4306	4301	4148	4346	4279	2928
22	Реал.	2710	2630	2374	2622	2724	2589	4091	3444	4100	3107	2915	3558	2682	2870	2751	2899	4102	4822	5060	4665	4978	4487	4020	3279
	Прог.	2431	2435	2385	2401	2431	2582	3384	3627	3445	3313	3291	3292	2979	2925	2961	3112	4369	4437	4322	4405	4106	4155	4287	2947
23	Реал.	2494	2296	2347	2422	2547	2683	3800	3819	3070	2763	2463	2926	2489	2800	2379	2805	4151	4653	4343	4297	4842	4579	4021	3482
	Прог.	2428	2426	2444	2406	2431	2656	3420	3617	3270	2318	2802	2727	2776	2753	2648	2939	4397	4519	4483	4460	4286	4173	4280	2935
24	Реал.	2272	2441	2331	2331	2538	2456	3070	2669	3416	3511	4420	3339	2786	3612	3679	3451	4791	4711	4501	4381	4438	4928	4597	2712
	Прог.	2418	2441	2387	2423	2373	2580	3391	2839	2986	3142	3230	2739	2699	2716	2583	3007	4303	4527	4417	4336	4152	4114	4287	2936
25	Реал.	2253	3556	2363	2091	2177	3604	3199	3220	3075	3397	3471	3533	3239	3684	3179	3256	4175	4092	4081	4138	4380	4413	4219	2831
	Прог.	2445	2403	2383	2421	2416	2558	3504	3465	3388	3065	3056	3044	3098	3158	2951	3123	4200	4514	4416	4350	4344	4151	4272	2928
26	Реал.	2198	2141	2437	2629	2389	2220	3352	3123	3455	2884	2852	2558	2965	2898	2919	2876	4356	4212	3994	4362	4684	3993	4492	2917
	Прог.	2408	2399	2438	2394	2385	2547	3483	3521	3218	2954	2650	2989	3209	3285	3239	3135	4390	4447	4463	4352	4286	4111	4280	2927
27	Реал.	2141	2212	2098	2260	2165	2459	3717	3407	3673	2857	2826	2764	3045	2754	2903	4286	4086	4302	4760	4507	4404	4484	4689	3154
	Прог.	2427	2433	2432	2421	2409	2693	3562	3523	3368	3063	3055	3013	3138	3328	3196	2949	4284	4288	4436	4442	4007	4075	4270	2898
28	Реал.	2460	2001	2444	2010	2217	2489	3283	3019	3099	2822	2900	2455	2688	2692	2440	2385	4017	4711	4040	4161	4312	5074	4136	2907
	Прог.	2421	2407	2439	2409	2368	2545	3407	3615	3432	3093	3144	2604	2975	2849	2672	2835	4257	4275	4279	4447	4335	4159	4267	2931

Таблиця Б.5 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 40\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
29	Реал.	2448	2589	2371	2469	2464	2487	3746	3014	2923	2552	2904	2608	2561	3270	2792	3008	4908	4833	4295	4205	5214	4461	4262	2849
	Прог.	2408	2436	2445	2402	2399	2668	3565	2428	2870	2763	2750	2619	2907	3265	3206	3481	4346	4256	4424	4419	4366	4144	4279	2933
30	Реал.	2661	2495	2750	2693	2413	2782	3681	3554	3489	3225	2813	2578	2565	2441	2968	2393	3869	5655	5575	4603	4203	4441	4598	3358
	Прог.	2435	2431	2433	2432	2380	2635	3381	3631	3153	2818	2784	2723	2688	2714	2771	2462	4146	4208	4354	4401	4321	4314	4291	2945

Таблиця Б.6 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 50\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
1	Реал.	2108	2156	2086	2091	2178	2486	2937	2947	3408	2322	1899	2158	2221	1856	2672	2208	3515	3599	3884	4020	4150	3714	3971	2408
	Прог.	2430	2410	2364	2329	2324	2602	3459	3369	3104	3079	2682	2534	2324	2531	2256	2439	4234	4270	4317	4094	4157	4304	4287	2975
2	Реал.	1941	2200	2157	2062	2133	2051	2577	2489	2107	1390	1830	1647	1766	1651	1845	2405	3482	3753	4213	3775	4281	3484	4153	2760
	Прог.	2373	2448	2424	2360	2375	2332	4010	3520	2426	2435	2534	2515	2541	2653	2276	3055	3983	4449	4348	4246	4382	4316	4356	2913
3	Реал.	2211	2169	2412	2330	2279	2482	3351	2705	2682	2893	3037	3014	3112	2569	3480	3318	3351	4103	4302	3826	3665	4109	3513	2682
	Прог.	2381	2407	2408	2399	2375	2615	3320	3407	3119	2806	2737	2575	2380	2386	2544	2909	4218	4429	4341	4201	4309	4351	4450	2981
4	Реал.	2139	2066	2080	3060	2182	1896	3376	2429	2885	2454	3184	2559	2972	2723	2378	2856	3617	3926	3775	3842	4166	3779	3885	2531
	Прог.	2374	2402	2409	2410	2329	2410	3236	2990	3028	2378	2526	2281	2426	2186	2317	2664	4233	4436	4439	4315	4312	4387	4243	2970
5	Реал.	2336	2522	2260	2441	2762	2482	3463	3322	3329	2536	2249	2253	2422	1830	2153	2355	4038	4315	4291	4317	4078	3989	4174	2540
	Прог.	2389	2423	2404	2410	2409	2621	3272	3492	3386	2901	2519	2467	2519	2615	2542	2875	4266	4212	4335	4323	4189	4345	4481	2977
6	Реал.	2244	2365	2513	2374	2383	2385	3528	2362	2340	1908	1935	2110	2078	2721	3646	3203	4402	3815	4515	4336	4303	4081	4127	2743
	Прог.	2372	2417	2416	2348	2377	2514	3497	3259	2860	2554	2259	2652	2732	2514	2570	3574	4073	4266	4413	4349	4267	4357	4264	2798
7	Реал.	2006	2233	2201	2320	2243	2153	3488	2629	2681	1854	1977	1859	2000	2209	2366	2583	4624	4768	3898	3750	4237	3619	4377	2648
	Прог.	2370	2414	2398	2391	2381	2574	3280	3280	2797	3281	2217	2558	2486	2480	2541	3375	4234	4421	4308	4272	4218	4314	4470	2936
8	Реал.	2307	2290	2604	2303	3168	2468	3407	3148	3676	2654	2419	2080	2209	2424	2510	2797	4082	3882	4571	4086	4489	3834	3743	3357
	Прог.	2408	2389	2416	2388	2393	2589	3287	3353	3090	2765	2694	2588	2436	2580	2920	3272	3966	4301	4332	4227	4206	4311	4438	2727
9	Реал.	2635	2028	2194	2107	2090	2169	3186	3498	2968	1900	2206	1742	1596	1623	1818	1877	3871	4305	4311	3797	3936	3846	4066	2677
	Прог.	2432	2420	2392	2387	2370	2559	3241	3583	3449	2656	2709	2596	2504	2226	2477	2554	3242	4236	4302	4125	4096	4359	4401	2704
10	Реал.	2294	2029	2075	2014	1987	1974	3218	2950	2628	3645	3407	3602	3501	3445	3589	2737	4015	4084	4108	3777	4815	4245	3800	2616
	Прог.	2410	2417	2398	2375	2327	2561	3234	2898	2599	3021	3141	2997	2985	3050	2891	3527	4005	4305	4338	4288	4380	4358	4442	2511
11	Реал.	2162	2106	2200	2307	2268	2295	2742	3162	2922	3454	2918	2842	3507	3646	3013	3714	4012	4092	4356	4043	4100	4139	3708	2491
	Прог.	2430	2431	2401	2391	2380	2611	3446	3367	3042	3102	2914	2932	3080	3017	3053	3449	3974	4435	4396	4204	4134	4368	4226	2940
12	Реал.	3248	2525	2551	2399	2280	2376	3162	2817	3153	2591	2559	2784	2762	2907	3016	2969	4710	4135	4581	4387	5061	4111	4056	2616
	Прог.	2435	2402	2396	2378	2365	2617	3319	2799	2826	2831	2868	2953	2870	3013	3155	3428	4052	4185	4344	4340	4159	4350	4439	2952
13	Реал.	2354	2152	2211	2365	2481	3732	3222	3712	3276	1915	3132	2304	2147	1798	2352	2353	4047	3958	3942	4566	3902	4258	4664	2934
	Прог.	2459	2458	2428	2363	2376	2678	3242	3577	3157	2584	2838	2557	2469	2450	2473	2667	3936	4295	4280	4328	4173	4383	4254	2974
14	Реал.	2400	2575	2641	2370	2395	2747	3227	5056	3565	2598	2759	2701	2742	2558	2526	2437	4547	4638	4112	4174	4570	4467	3970	3236
	Прог.	2387	2448	2431	2383	2340	2608	3309	3681	3426	2891	2716	2645	2488	2594	2502	2626	3950	4297	4270	4313	4392	4343	4238	3011

Таблиця Б.6 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 50\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
15	Реал.	2472	2197	2670	2016	2252	2204	3501	3346	2996	2435	2170	2505	2919	4014	2568	2512	4167	4665	4365	4076	4133	4189	4439	2636
	Прог.	2389	2420	2450	2337	2379	2574	3289	3621	3088	3050	2855	2845	2675	2422	2805	3074	4094	4219	4208	4236	4283	4358	4451	2879
16	Реал.	2550	2473	2141	2599	2186	2588	3588	3578	3259	2735	2659	2399	2490	2384	2224	2755	3861	4301	4062	4282	4542	4535	4579	2791
	Прог.	2449	2456	2432	2408	2365	2622	3261	3564	3461	3261	2938	2821	2606	2723	2830	2632	4383	4314	4266	4198	4086	4343	4250	2923
17	Реал.	2242	2192	2236	2195	2041	2391	2926	3162	3036	3485	2938	3040	3246	3285	3235	3131	4025	4006	4889	4467	4102	4410	4495	2461
	Прог.	2371	2423	2386	2384	2375	2579	3304	3436	3456	3162	2879	2655	2539	2492	2462	2831	4067	4314	4238	4255	4062	4381	4403	2907
18	Реал.	1995	2286	2072	2504	2059	2256	3251	2763	3095	2819	3410	3510	2723	2169	2940	3244	4172	4153	4414	4875	4107	4468	3995	2733
	Прог.	2364	2398	2361	2381	2355	2608	3240	3302	2978	2939	2771	2745	2551	2623	2441	2890	4153	4305	4304	4357	4214	4372	4446	2859
19	Реал.	2123	2312	2301	2250	2191	2792	3555	3407	3357	2466	2938	2671	2507	2660	2716	2304	3732	4193	3770	3694	4176	3768	3921	2472
	Прог.	2397	2426	2378	2378	2371	2617	3299	3560	3240	3008	2886	2896	2826	2852	2981	2578	4179	4323	4345	4309	4325	4312	4316	2961
20	Реал.	2567	2525	2411	2578	2435	2473	3347	3074	3454	3054	2931	2587	3189	3070	3107	2497	4035	4439	4436	4480	4961	4411	4556	2948
	Прог.	2365	2411	2419	2354	2360	2548	3243	2941	3048	3143	2973	2834	2964	2880	3000	3102	4174	4306	4335	4369	4395	4374	4254	2992
21	Реал.	2307	2362	2318	2034	2378	2193	2964	2506	2296	2063	2425	2282	2443	2276	2558	2896	4552	3920	4267	3931	4380	4094	3906	2874
	Прог.	2367	2413	2409	2360	2368	2609	3296	2931	2699	2555	2618	2561	2417	2466	2791	2656	4057	4101	4286	4212	4190	4422	4377	2891
22	Реал.	2690	2612	2356	2602	2700	2560	4058	3407	4061	3067	2872	3511	2599	2761	2649	2779	4049	4776	5020	4630	4949	4461	3997	3258
	Прог.	2383	2409	2421	2400	2398	2594	3280	3591	3454	2985	2991	3148	2821	2672	2792	3149	4210	4422	4330	4332	4159	4338	4418	2993
23	Реал.	2473	2275	2325	2400	2523	2658	3772	3787	3010	2554	2322	2779	2319	2649	2203	2669	4092	4599	4296	4258	4810	4552	3997	3460
	Прог.	2374	2399	2371	2385	2391	2622	3287	3588	3238	2330	2486	2614	2713	2285	2404	2758	4116	4424	4500	4344	4339	4344	4381	2908
24	Реал.	2251	2421	2311	2309	2512	2424	2996	2505	3300	3443	4369	3172	2564	3429	3510	3316	4731	4659	4458	4346	4409	4904	4576	2692
	Прог.	2372	2388	2417	2365	2325	2587	3217	2849	2942	3169	3247	2759	2769	2442	2416	2920	4192	4473	4387	4267	4195	4373	4416	2972
25	Реал.	2235	3539	2346	2071	2154	3577	3148	3143	3014	3324	3391	3457	3174	3619	3089	3137	4122	4044	4038	4101	4347	4384	4195	2810
	Прог.	2429	2500	2422	2355	2367	2617	3303	3339	3401	3092	2916	2923	2945	2962	2993	3183	4109	4466	4372	4272	4361	4335	4328	2880
26	Реал.	2179	2122	2416	2604	2361	2189	3248	3014	3378	2776	2731	2462	2895	2830	2852	2749	4292	4155	3946	4324	4654	3968	4469	2895
	Прог.	2377	2409	2372	2347	2340	2539	3480	3283	3223	2896	2727	2861	2977	2987	3120	3159	4219	4407	4430	4281	4333	4327	4376	2904
27	Реал.	2119	2190	2075	2238	2142	2432	3664	3301	3605	2779	2744	2686	2984	2691	2842	4196	4032	4253	4718	4474	4378	4463	4670	3136
	Прог.	2354	2388	2386	2335	2359	2618	3338	3323	3306	3046	2882	2871	3101	3025	3045	3146	4153	4310	4417	4343	4021	4381	4484	2854
28	Реал.	2441	1980	2421	1985	2189	2458	3236	2981	3049	2734	2846	2271	2597	2554	2287	2248	3970	4668	4002	4127	4283	5049	4114	2886
	Прог.	2375	2389	2384	2317	2298	2585	3360	3586	3495	2892	3108	2497	2858	2522	2412	2625	4045	4281	4257	4334	4363	4319	4195	2950

Таблиця Б.6 – Реальні та спрогнозовані значення активної потужності (кВт), що споживається МРГ, при $CP = 50\%$

Доба/ година		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
29	Реал.	2428	2570	2352	2449	2442	2461	3665	2802	2726	2394	2743	2470	2463	3211	2732	2948	4852	4783	4252	4170	5184	4434	4238	2825
	Прог.	2380	2419	2409	2397	2380	2659	3311	2793	2396	2726	2693	2660	2755	3078	3095	3545	4154	4280	4360	4334	4416	4291	4175	2962
30	Реал.	2637	2471	2726	2670	2389	2756	3650	3518	3398	3099	2665	2425	2371	2255	2757	2224	3759	5609	5535	4567	4172	4414	4574	3336
	Прог.	2385	2416	2430	2394	2338	2662	3331	3662	3175	2764	2716	2613	2393	2452	2275	2287	4007	4298	4370	4346	4350	4392	4373	3018

ДОДАТОК В

Документи, що підтверджують практичне значення отриманих результатів роботи



10.04.2025 № 71/6-86/2025
На № _____ від _____

ТОВ «ДТЕК ПОКРОВСЬКА СЕС»
04119, Україна, м. Київ,
вул. Джонса Гарета, буд. 8, літера 20Д
+38 044 594 46 52

АТ «ПУМБ», м. Київ
МФО 334851
код ЄДРПОУ 41442374
IBAN UA293348510000000002600736540

АКТ
про впровадження результатів дисертаційної роботи
Любарцева Вадима Володимировича на тему:
«Прогнозування та оптимізація режимів роботи систем електропостачання з розподіленою генерацією»

Теоретичні, науково-методичні та прикладні результати дисертаційної роботи були впроваджені у практичну діяльність в ТОВ «ДТЕК ПОКРОВСЬКА СЕС»:

- У рамках роботи було обґрунтовано та реалізовано підходи до прогнозування графіків генерації електроенергії СЕС на основі даних про інсоляцію, температуру повітря та інші метеопараметри. Зокрема, впроваджено моделі прогнозування, що базуються на штучних нейронних мережах, які враховують не лише класичні параметри навантажень, а й зовнішні впливи, зокрема погодні умов;
- Запропоновано використання показника питомої генерації на одиницю інсоляції P^* ($\text{кВт(Вт/м}^2\text{)}$), як ключового аналітичного параметра, що дозволив удосконалити кореляційний аналіз і забезпечити підвищену точність прогнозів генерації;
- У виробничій діяльності використано метод донавчання нейромереж при прогнозуванні генерації, що дозволяє оперативно адаптувати прогнозні моделі до змінних умов роботи станції, зокрема при появі нових трендів у метеоданих.

Застосування результатів дослідження дозволило підвищити надійність планування генерації СЕС, забезпечити її адаптивність до змін зовнішніх умов, зменшити втрати електроенергії та оптимізувати участь об'єкта у балансуванні навантаження в мережі.

Директор ТОВ «ДТЕК ПОКРОВСЬКА СЕС»



Литвинович А.С.





**АКЦІОНЕРНЕ ТОВАРИСТВО
«НІКОПОЛЬСЬКИЙ ЗАВОД ФЕРОСПЛАВІВ»**

вул. Електрометалургів, 310, м. Нікополь, Дніпропетровська область, Україна, 53200

тел.: (0566) 654-236, (0566) 696-123, (0566) 630-802(803)

e-mail: 01@nzf.com.ua, www.nzf.com.ua, код згідно з ЄДРПОУ 00186520

Від 09.04.25 № 4005/127

На № _____ від _____

«ЗАТВЕРДЖУЮ»
В.о. головного енергетика
Матинюк Максим Михайлович
2025р.

АКТ

про впровадження результатів дисертаційної роботи

Любарцева Вадима Володимировича

на тему: **«Прогнозування та оптимізація режимів роботи систем електропостачання з розподіленою генерацією»**

Наукові та практичні результати дисертаційної роботи Любарцева В.В. були впроваджені у виробничу діяльність АТ «Нікопольський завод феросплавів», зокрема у процеси, пов'язані з плануванням споживання та організацією електроживлення технологічних навантажень:

- У роботі розкрито напрямки прогнозування режимів роботи електричних мереж із розподіленою генерацією, що дозволило обґрунтовано враховувати динаміку споживання електроенергії з урахуванням змін погодних умов, виробничого графіка та загального навантаження в мережі. Це дозволило оптимізувати внутрішні алгоритми енергопланування на АТ «Нікопольський завод феросплавів»;
- Застосування нейромережних моделей прогнозування, що враховують метеопараметри та виробничі фактори, забезпечило можливість оперативного формування коротко- та середньострокових прогнозів енергоспоживання. У процесі практичного використання це дозволило точніше планувати закупівлю електроенергії та зменшити небаланси;
- У межах експлуатації внутрішньоцехових енергетичних систем впроваджено підхід до часткового згладжування навантажень за рахунок перенесення споживання на прогнозовано більш сприятливі періоди. Це дозволило зменшити вартість споживання електроенергії за рахунок зниження навантаження у годинні зони високого тарифу.

Впровадження результатів дисертаційної роботи Любарцева В.В. надало можливість суттєво підвищити ефективність внутрішньої енергетичної логістики, зменшити фінансові втрати від небалансів, а також покращити загальну надійність роботи електрообладнання підприємства в умовах нестабільних графіків навантаження.

Від НТУ ДП :

Професор, завідувач кафедри електроенергетики:

_____ Папайка Юрій Анатолійович

Аспірант кафедри електроенергетики:

_____ Любарцев В.В.

026454