

Інститут електродинаміки  
Національна академія наук України

Інститут електродинаміки  
Національна академія наук України

Кваліфікаційна наукова  
праця на правах рукопису

**Шиманюк Павло Вячеславович**

УДК 621.313.8

## **ДИСЕРТАЦІЯ**

**Короткострокове прогнозування вузлових  
електричних навантажень в розподільних мережах**

141 - електроенергетика, електротехніка та електромеханіка

Подається на здобуття наукового ступеня доктора філософії

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

 П.В. Шиманюк

Науковий керівник Черненко Павло Олексійович, доктор технічних наук,  
професор

Блінов Ігор Вікторович, доктор технічних наук, с.н.с.

## АНОТАЦІЯ

*Шиманюк П.В.* Короткострокове прогнозування вузлових електричних навантажень в розподільчих мережах. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 141 «Електроенергетика, електротехніка та електромеханіка». – Інститут електродинаміки, НАН України, Київ, 2023.

В дисертаційній роботі розв’язано науково-технічну задачу короткострокового прогнозування погодинних значень вузлового електричного навантаження операторів систем розподілу з врахуванням додаткових факторів.

Прогнозування вузлового електричного навантаження є ключовим напрямком досліджень в електроенергетиці через свою значущість для оптимізації планування та оперативного керування режимами електроенергетичної системи. Точність прогнозів навантажень має велике значення для економічності завантаження генеруючого обладнання та вартості електроенергії для кінцевих споживачів. Прогноз вузлових навантажень необхідний для прийняття оперативних диспетчерських заявок, корегування поточних режимів та оптимізації майбутніх режимів, а також для подання заявок на купівлю та продаж електроенергії на різних сегментах ринку. Якщо прогнозування не дає задовільних результатів, може виникнути значний небаланс енергії, який потрібно докуповувати на балансуєчому ринку електроенергії, що збільшує витрати операторів системи розподілу (ОСР) та оператора системи передачі (ОСП).

Починаючи з 01.07.2019 в Україні почав функціонувати новий оптовий ринок електричної енергії. Згідно з правилами ринку ОС і ОСР, як учасникам ринку необхідно купувати електроенергію для покриття власних втрат. Для мінімізації середньозваженої ціни купівлі їм необхідно збільшувати частку на ринку двосторонніх договорів та на ринку «на добу наперед» (РДН) і зменшувати частки на внутрішньодобовому ринку (ВДР) та балансуєчому ринку (БР). Важливою науковою задачею для досягнення цих цілей є підвищення точності

короткострокового прогнозування втрат електричної енергії. Виходячи із затверджених Правил ринку «на добу наперед» та внутрішньодобового ринку заявки на РДН приймаються до 12 години доби що передується добі постачання і тому найбільш актуальним стає короткостроковий прогноз з горизонтом упередження від 12 до 36 годин.

Широке поширення та розвиток методів прогнозування стало можливим за рахунок розвитку обчислювальних засобів, що дозволило створювати багатofакторні моделі та проводити розрахунки з можливістю використання значних об'ємів даних без великих затрат в часі.

Аналіз літературних джерел та виконані дослідження в даному напрямку показав, що більшість досліджень спрямовані на вдосконалення методів прогнозування часових рядів, однією з концепцій вдосконалення є використання сучасних методів прогнозування, а також їх модифікація та комбінація з іншими методами для вирішення тих чи інших задач.

Виконані дослідження щодо ефективності використання класичних методів прогнозування, зокрема і методу експоненційного згладжування Холта-Вінтерса, результати прогнозування з використанням якого було порівняно з методами на основі ШНМ. При цьому важливою умовою під час прогнозування вузлових навантажень стало врахування зв'язків між вузлами. Показано, що застосування ШНМ глибинного навчання є найбільш ефективним методом прогнозування завдяки гнучкості та можливості моделювати багатомірні дані що повинно суттєво підвищити ефективність прогнозів.

Для оцінки точності результатів прогнозування часових рядів в науковій літературі можуть зустрічатись різні функції похибок. Одними з найпоширеніших методів являється функція MAPE - середня абсолютна похибка у відсотках (mean absolute percentage error), а також функція APE - абсолютна похибка у відсотках (absolute percentage error). Крім того, можуть використовуватись функції RMSE - середньоквадратичну похибку (root mean square deviation), MSE- середньоквадратична похибка (mean square error). Вибір конкретного параметру оцінки зумовлено складністю складністю прогнозів та

інтерпретацією їх результатів. Для оцінки прогнозу вузлового навантаження використовують функцію середньо абсолютної похибки у відсотках MARE.

Визначено, що на точність результатів прогнозування значною мірою впливають і самі вхідні дані. У більшості випадків дані, які використовуються для досліджень, можуть містити певні спотворення, що викликані різними причинами: пошкодження ліній передачі даних, несправність обладнання, хакерські дії, вивід обладнання в ремонт чи інші. Показано, що для виявлення спотворень, пропусків чи аномальних значень даних необхідно проводити відповідний аналіз, що дозволяє чітко виявляти аномальні значення та проводити заміну даних для покращення результатів прогнозування вузлового навантаження та втрат електричної енергії.

Для виявлення аномальних значень використовують ряд методів аналізу даних, кожен з яких має свої особливості та переваги. В дослідженнях для аналізу часових рядів досить часто використовують методи кластеризації за рахунок своєї простоти та ефективності. Найбільш поширеними методами виявлення аномальних даних є Density-Based Spatial Clustering of Applications with Noise (DBSCAN), Isolation forest (IF), Elliptic envelope (EE), Local outlier factor (LOF). В більшості випадків методи аналізу даних побудовані на методах кластеризації даних. Виконавши аналіз та провівши порівняння даних методів було визначено, що усі представлені методи мають різну кількість хибних спрацювань.

В роботі було розроблено метод двоетапного аналізу даних для виявлення та заміни аномальних значень, для якого запропоновано використовувати метод DBSCAN та декомпозицію графіків вузлового навантаження для виявлення аномальних значень, та відновленням даних за допомогою методу лінійної інтерполяції в часових спектрах (зрізах), що дозволяє значно ефективніше виявляти аномальні значення та формувати коректніші набори ретроспективних даних.

Сьогодні, для прогнозування широко використовуються різні методи, включаючи методи часових рядів [1], авторегресійні моделі [2], методи

експоненційного згладжування [3], класичні штучні нейронні мережі (ШНМ) [4] та методи опорних векторів [5]. За останні 10 років в галузях комп'ютерного зору, автоматичного керування, обробки тексту та звуків вдалось досягти значних результатів, які в окремих задачах досягають та перевершують можливості людини. Основою для відновлення популярності стало значне зростання обчислювальних можливостей, за рахунок сучасних графічних процесорів (GPU), збільшення кількості доступних даних, використання ШНМ більш складної архітектури та вдосконалення методів їх навчання. Сучасні методи дозволяють моделювати складні мультифакторні процеси, що сприяє ефективному прогнозуванню навантаження на вузли. При цьому, розробка і вдосконалення методів прогнозування є актуальною темою для досліджень, оскільки це дає можливість забезпечувати точність і надійність прогнозів та ефективність рішень в галузі енергетики.

Показано, що використання ШНМ для прогнозування вузлових електричних навантажень в умовах нового ринку електроенергії України підвищить економічну ефективність роботи оператора системи розподілу та розподільчих мереж загалом.

В роботі було розглянуто різні методи прогнозування як класичні методи типу авторегресії чи експоненційного згладжування Холта-Вінтерса так і різних методів на основі штучних нейронних мереж.

В роботі запропоновано використання ШНМ глибинного навчання в якості методу прогнозування вузлового електричного навантаження з можливістю врахуванням додаткових факторів, зокрема температури повітря. В якості архітектур ШНМ використовуються рекурентні нейронні мережі та згорткові ШНМ. Було розроблено декілька архітектур ШНМ для короткострокового прогнозування вузлового електричного навантаження мереж з можливістю обробки та врахування впливу зовнішніх факторів.

В роботі було виконано аналіз впливу температури повітря на величину вузлового навантаження та розглянуто ефективність прогнозування вузлових навантажень з врахуванням додаткових факторів. Та розглянуто варіанти

застосування додаткових факторів у вхідних даних ШНМ.

Враховуючи можливості застосування штучного інтелекту для різних задач прогнозування в роботі також використано моделі на основі ШНМ для прогнозування втрат електричної енергії електричної мережі. Також для цієї задачі було розроблено тестову електричну мережу за допомогою якої можливо проводити розрахунок втрат електричної енергії використовуючи дані вузлового навантаження. Застосування до даної мережі методів прогнозування дозволило суттєво знизити похибку прогнозування та величину втрат електричної енергії у порівнянні з розрахунком втрат за коефіцієнтами втрат, що сьогодні традиційно використовуються ОСР для розв'язання цієї задачі.

В роботі було запропоновано використання ШНМ глибинного навчання для визначення очікуваного значення втрат під час формування їх погодинного графіка закупівлі операторами систем розподілу на ринку електричної енергії України за рахунок використання прогнозів вузових навантажень і подальшого їх застосування.

В роботі розв'язано комплекс задач щодо вибору методу прогнозування, розробки нових моделей ШНМ, розвинуто методи аналізу даних для виявлення та заміни аномальних значень та пропусків, запропоновано розв'язання задачі прогнозування втрат електричної енергії за допомогою методів на основі ШНМ, що у сукупності дозволило підвищити точність та стабільність результатів прогнозування вузлового навантаження та втрат в електричних мережах.

*Ключові слова:* короткострокове прогнозування, вузлове електричне навантаження, втрати, ринок електроенергії, штучні нейронні мережі, методи аналізу даних.

*Список публікацій здобувача*

1. Miroshnyk V., Shymaniuk P., Sychova V. Short term renewable energy forecasting with deep learning neural networks. *Power Systems Research and Operation: Selected problems*. editors: Kyrylenko O., Zharkin A. and other. Springer, 2021. pp. 121–142. DOI: [https://doi.org/10.1007/978-3-030-82926-1\\_6](https://doi.org/10.1007/978-3-030-82926-1_6). (Scopus). (Особистий внесок – розробка нейронної мережі для прогнозу вузлового навантаження з врахування температури повітря).
2. Miroshnyk V., Shymaniuk P., Sychova V., Loskutov S. Short-term load forecasting in electrical networks and systems with artificial neural networks and taking into account additional factors. *Power Systems Research and Operation: Selected problems II*. editors: Kyrylenko O., Denysiuk S. and other. 2022. pp. 87-105. DOI: [https://doi.org/10.1007/978-3-031-17554-1\\_5](https://doi.org/10.1007/978-3-031-17554-1_5). (Scopus). (Особистий внесок – розробка моделей нейронних мереж та проведення, порівняння та оцінка результатів прогнозування).
3. Блінов І.В., Мірошник В.О., Шиманюк П.В. Короткостроковий інтервальний прогноз сумарного відпуску електроенергії виробниками з відновлюваних джерел енергії. *Праці ІЕД НАН України*. 2019. №54. С. 5-12. DOI:<https://doi.org/10.15407/publishing2019.54.005> (Особистий внесок – адаптація нейронної мережі для прогнозування відпуску електричної енергії).
4. Черненко П.О., Мірошник В.О., Шиманюк П.В. Однофакторне короткострокове прогнозування вузлових електричних навантажень енергосистеми. *Технічна електродинаміка*. 2020. №2. С. 67-73. DOI:<https://doi.org/10.15407/techned2020.02.067>. (Категорія «А», Scopus). (Особистий внесок – аналіз та підготовка даних, розробка рекурентної нейронної мережі).
5. Блінов І.В., Мірошник В.О., Шиманюк П.В. Оцінка вартості похибки прогнозу «на добу наперед» технологічних втрат в електричних мережах України. *Технічна електродинаміка*. 2020. №5. С. 70-73. DOI: <https://doi.org/10.15407/techned2020.05.070> (Категорія «А», Scopus).

(Особистий внесок – аналіз та підготовка матеріалів про новий ринок електричної енергії).

6. Лоскутов С.С., Шиманюк П.В. Прогнозування сумарного електричного навантаження на кожному з ієрархічних рівнів ОЕС України за допомогою нейронних мереж. *Праці ІЕД НАН України*. 2021. №59. С 81-85. DOI: <https://doi.org/10.15407/publishing2021.59.081> (Особистий внесок – підготовка матеріалів для розрахунку ієрархічних прогнозів).
7. Блінов І.В., Парус Є.В., Мірошник В.О., Шиманюк П.В., Сичова В.В. Модель оцінки доцільності переходу промислових споживачів до погодинного обліку електричної енергії на роздрібному ринку. *Енергетика: економіка, технології, екологія*. 2021. №1. С. 88-97. DOI: <https://doi.org/10.20535/1813-5420.1.2021.242186>. (Особистий внесок – підготовка та аналіз матеріалів про ринок електроенергії).
8. Шиманюк П.В., Мірошник В.О., Блінов І.В., Черненко П.О. Аспекти врахування температури повітря для підвищення точності короткострокового прогнозування вузлових навантажень. *Енергетика: економіка, технології, екологія*. 2021. №2 С.50-58. DOI: <https://doi.org/10.20535/1813-5420.2.2021.247368> (Особистий внесок – підготовка та розрахунок прогнозних значень вузлового навантаження з врахування температури повітря).
9. Шиманюк П.В., Мірошник В.О., Блінов І.В. Визначення втрат електричної енергії на основі прогнозів вузлового електричного навантаження. *Енергетика: економіка, технології, екологія*. 2022. №3. С.38-43. DOI: <https://doi.org/10.20535/1813-5420.3.2022.271484> (Особистий внесок – розробка архітектури нейронної мережі та розрахунок втрат електричної енергії).
10. Мірошник В.О., Шиманюк П.В. Аналіз методів достовіризації даних для задач короткострокового прогнозування вузлових електричних навантажень. *Праці інституту електродинаміки НАН України*. 2021. №60. С. 51-57. DOI: <https://doi.org/10.15407/publishing2021.60.051>

- (Особистий внесок – виконання експериментальних досліджень, розробка алгоритму виявлення та заміни аномальних даних).
11. Кучанський В.В., Шиманюк П.В., Шкарупило В.В. Розроблення штучної нейронної мережі для прогнозу характеристик перенапруг в електричних мережах. *I International Scientific and Practical Conference «Problemas y perspectivas de la aplicación de la investigación científica innovadora»*. 2021. Рр. 105-109. DOI: <https://doi.org/10.36074/logos-11.06.2021.v1.30>. (Особистий внесок – опис штучних нейронних мереж).
  12. Blinov I., Miroshnyk V., Shymaniuk P. Short-term nodal electrical load forecasting with artificial neural networks. *2022 IEEE 8th International Conference on Energy Smart Systems (ESS)*. Рр.12-14. DOI: 10.1109/ESS57819.2022.9969245. (Scopus). (Особистий внесок - розробка архітектур штучних нейронних мереж).
  13. Shymaniuk P., Miroshnyk V., Blinov I., Estimation of electrical losses in the distribution network based on nodal electrical load forecasts. *2022 IEEE KhPI Week on Advanced Technology (KhPIWeek)*. 2022 рр. 1-4. DOI: 10.1109/KhPIWeek57572.2022.9916407. (Scopus). (Особистий внесок - розробка архітектури нейронної мережі та розрахунок втрат електричної енергії).
  14. А.с. на комп'ютерну програму «Модель розрахунку цін та тарифів на електричну енергію» № 115250 України: заявл. 27.09.22; опубл. 13.10.22.
  15. Шиманюк П.В. Аналіз та визначення типу штучних нейронних мереж для розв'язання задачі прогнозування вузлового навантаження. XXXVIII Науково-технічна конференція молодих вчених та спеціалістів інституту проблем моделювання в Енергетиці ім. Г.Є. Пухова НАН України. м. Київ. С-16-18. 2020.
  16. Черненко П.О., Мірошник В.О., Шиманюк П.В. Короткострокове прогнозування вузових електричних навантажень енергосистеми з врахування температури повітря. XV міжнародна конференція "Контроль і управління в складних системах (КУСС-2020)" м. Вінниця. С.1. 2020.

17. Сичова В.В., Шиманюк П.В. Застосування декомпозиції графіків сумарного електричного навантаження для задач їх короткострокового прогнозування. XXXIX Науково-технічна конференція молодих вчених та спеціалістів Інституту проблем моделювання в енергетиці ім. Г.Є. Пухова НАН України. м. Київ. С. 101-103. 2021.
18. Шиманюк П.В. Достовіризація даних та аналіз методів для задач прогнозування вузлових електричних навантажень в ринкових умовах. VIII Всеукраїнської науково-практичної конференції молодих вчених «Наукова молодь-2020». м. Київ. С.151-156. 2020.

## ANNOTATION

*Shimanyuk P.V.* Short-term forecasting of nodal electrical loads in distribution network. - Qualifying scientific work on manuscript rights.

Dissertation for obtaining the scientific degree of Doctor of Philosophy in specialty 141 "Electroenergetics, electrical engineering, and electromechanics". – Institute of Electrodynamics, National Academy of Sciences of Ukraine, Kyiv, 2022.

In the dissertation work, the scientific and technical problem of short-term forecasting of hourly values of nodal electric load of operators of distribution systems is solved, taking into account additional factors.

Forecasting the nodal electric load is a key area of research in electric power due to its significance for the optimization of planning and operational control of electric power system modes. The accuracy of load forecasts is of great importance for the cost-effectiveness of loading generating equipment and the cost of electricity for end users. The forecast of nodal loads is necessary for accepting operational dispatch requests, correcting current modes and optimizing future modes, as well as for submitting applications for the purchase and sale of electricity in various market segments. If forecasting does not provide satisfactory results, there may be a significant energy imbalance that needs to be purchased in the balancing electricity market, increasing the costs of distribution system operators (DSOs) and transmission system operators (TSOs).

Starting from July 1, 2019, a new wholesale electricity market began to function in Ukraine. According to the rules of the OS and OSR market, as market participants, it is necessary to purchase electricity to cover own losses. To minimize the weighted average purchase price, they need to increase their share in the market of bilateral contracts and the day-ahead market and reduce their shares in the intraday market (IDR) and the balancing market (BR). An important scientific task for achieving these goals is to increase the accuracy of short-term forecasting of electrical energy losses. Based on the approved "day-ahead" market rules and the intraday market, applications for RDN are accepted until 12:00 a.m. of the day preceding the day of delivery, and therefore a short-term forecast with a bias horizon of 12 to 36 hours becomes the most relevant.

The wide distribution and development of forecasting methods became possible

due to the development of computing tools, which made it possible to create multifactorial models and carry out calculations with the possibility of using significant volumes of data without spending a lot of time.

Analysis of literary sources and conducted research in this direction showed that most research is aimed at improving time series forecasting methods, one of the concepts of improvement is the use of modern forecasting methods, as well as their modification and combination with other methods to solve certain problems.

Studies have been carried out on the effectiveness of using classical forecasting methods, in particular the Holt-Winters exponential smoothing method, the forecasting results of which were compared with ANN-based methods. At the same time, taking into account the connections between nodes became an important condition when forecasting nodal loads. It is shown that the application of deep learning ANNs is the most effective forecasting method due to flexibility and the ability to model multidimensional data, which should significantly increase the effectiveness of forecasts.

Various error functions can be found in the scientific literature to assess the accuracy of time series forecasting results. One of the most common methods is the MAPE function - mean absolute percentage error (mean absolute percentage error), as well as the APE function - absolute percentage error. In addition, the functions RMSE - root mean square deviation, MSE - mean square error can be used. The choice of a specific evaluation parameter is determined by the complexity of forecasts and the interpretation of their results. To estimate the nodal load forecast, the mean absolute error function in MAPE percentage is used.

It was determined that the accuracy of forecasting results is largely influenced by the input data itself. In most cases, the data used for research may contain certain distortions caused by various reasons: damage to data transmission lines, equipment malfunction, hacker actions, removal of equipment for repair, or others. It is shown that in order to detect distortions, omissions or anomalous data values, it is necessary to carry out an appropriate analysis, which allows you to clearly identify anomalous values and carry out data replacement to improve the results of forecasting nodal load and electrical energy losses.

A number of data analysis methods are used to detect abnormal values, each of which has its own characteristics and advantages. Clustering methods are often used in

research to analyze time series due to their simplicity and effectiveness. The most common methods of detecting anomalous data are Density-Based Spatial Clustering of Applications with Noise (DBSCAN), Isolation forest (IF), Elliptic envelope (EE), Local outlier factor (LOF). In most cases, data analysis methods are based on data clustering methods. After analyzing and comparing these methods, it was determined that all presented methods have a different number of false positives.

The paper developed a two-stage data analysis method for detecting and replacing anomalous values, for which it is proposed to use the DBSCAN method and the decomposition of nodal load graphs to detect anomalous values, and restore data using the method of linear interpolation in time spectra (slices), which allows for a much more efficient detect anomalous values and form more correct sets of retrospective data.

Today, various methods are widely used for forecasting, including time series methods [1], autoregressive models [2], exponential smoothing methods [3], classical artificial neural networks (ANNs) [4], and support vector methods [5]. Over the past 10 years, significant results have been achieved in the fields of computer vision, automatic control, text and sound processing, which in some tasks reach and exceed human capabilities. The basis for the restoration of popularity was a significant increase in computing capabilities due to modern graphics processors (GPUs), an increase in the amount of available data, the use of ANNs with a more complex architecture, and the improvement of their training methods. Modern methods make it possible to model complex multifactorial processes, which contributes to effective forecasting of the load on nodes. At the same time, the development and improvement of forecasting methods is a relevant topic for research, as it makes it possible to ensure the accuracy and reliability of forecasts and the effectiveness of decisions in the field of energy.

It is shown that the use of ANNs for forecasting nodal electrical loads in the conditions of the new electricity market of Ukraine will increase the economic efficiency of the distribution system operator and distribution networks in general.

The paper considered various methods of forecasting, both classical methods of autoregression or Holt-Winters exponential smoothing, as well as various methods based on artificial neural networks.

The paper proposes the use of deep learning ANN as a method of forecasting the

nodal electrical load with the possibility of taking into account additional factors, in particular air temperature. Recurrent neural networks and convolutional ANNs are used as ANN architectures. Several ANN architectures were developed for short-term forecasting of nodal electrical load of networks with the possibility of processing and taking into account the influence of external factors.

The work analyzed the effect of air temperature on the value of nodal load and considered the effectiveness of forecasting nodal loads taking into account additional factors. Options for using additional factors in the input data of the ANN are considered.

Taking into account the possibilities of applying artificial intelligence for various forecasting tasks, models based on ANNs were also used in the work to forecast electrical energy losses of the electrical network. Also, for this task, a test electric network was developed, with the help of which it is possible to calculate the losses of electric energy using the nodal load data. The application of forecasting methods to this network made it possible to significantly reduce the forecasting error and the amount of electrical energy losses in comparison with the calculation of losses based on the loss coefficients, which are traditionally used by OSR today to solve this problem.

In the work, the use of deep-source ANN was proposed to determine the expected value of losses during the formation of their hourly purchase schedule by operators of distribution systems on the electricity market of Ukraine due to the use of nodal load forecasts and their further application.

The work solved a set of problems regarding the choice of forecasting method, development of new ANN models, data analysis methods were developed to identify and replace anomalous values and omissions, proposed a solution to the problem of forecasting electrical energy losses using ANN-based methods, which in total allowed increase the accuracy and stability of the results of forecasting the nodal load and losses in electric networks.

Keywords: short-term forecasting, nodal electric load, losses, electricity market, artificial neural networks, data analysis methods.

## ЗМІСТ

|                                                                                                                                           |    |
|-------------------------------------------------------------------------------------------------------------------------------------------|----|
| ПЕРЕЛІК СКОРОЧЕНЬ.....                                                                                                                    | 16 |
| ВСТУП.....                                                                                                                                | 18 |
| РОЗДІЛ 1 КОРОТКОСТРОКОВЕ ПРОГНОЗУВАННЯ ВУЗЛОВОГО ЕЛЕКТРИЧНОГО НАВАНТАЖЕННЯ В УМОВАХ ФУНКЦІОНУВАННЯ РИНКУ ЕЛЕКТРИЧНОЇ ЕНЕРГІЇ УКРАЇНИ..... | 27 |
| 1.1 Задачі прогнозування в новій моделі ринку електричної енергії України                                                                 | 27 |
| 1.2 Короткострокове прогнозування вузлового навантаження.....                                                                             | 35 |
| 1.3 Аналіз класичних методів для вибору методу для вузлового навантаження .....                                                           | 40 |
| 1.3.1 Метод експоненційного згладження .....                                                                                              | 40 |
| 1.3.2 Метод векторної авторегресії.....                                                                                                   | 42 |
| 1.3.3 Штучні нейронні мережі для прогнозування часових рядів (Багатошаровий перцептрон) .....                                             | 44 |
| 1.3.4 Рекурентна нейронна мережа.....                                                                                                     | 47 |
| 1.3.5 Рекурентна нейронна мережа з довго короткостроковою пам'яттю ...                                                                    | 48 |
| 1.3.6 Аналіз ефективності методів прогнозування .....                                                                                     | 50 |
| Висновки до розділу 1 .....                                                                                                               | 54 |
| РОЗДІЛ 2 ПРОГНОЗУВАННЯ ВУЗЛОВОГО НАВАНТАЖЕННЯ ЗА ДОПОМОГОЮ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ГЛИБИННОГО НАВЧАННЯ.....                               | 55 |
| 2.1 Загальні підходи до прогнозування часових рядів .....                                                                                 | 55 |
| 2.2 Методика оцінки якості прогнозу .....                                                                                                 | 57 |
| 2.3 Розробка архітектури штучної нейронної мережі глибинного навчання для прогнозування вузлового навантаження.....                       | 61 |
| 2.4 Однофакторне прогнозування вузлового навантаження .....                                                                               | 69 |
| 2.5 Прогнозування з врахуванням температури на основі однофакторної архітектури ШНМ .....                                                 | 71 |
| 2.6 Комп'ютерна модель короткострокового прогнозування вузлового електричного навантаження.....                                           | 73 |
| Висновки до розділу 2 .....                                                                                                               | 78 |

|                                                                                                                                                                                                   |     |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| РОЗДІЛ 3 ПОРІВНЯННЯ МЕТОДІВ АНАЛІЗУ ДАНИХ ДЛЯ ВИЯВЛЕННЯ АНОМАЛЬНИХ ДАНИХ ТА ПРОПУСКІВ НАВАНТАЖЕННЯ .....                                                                                          | 80  |
| 3.1 Достовіризація даних часових рядів вузлового навантаження .....                                                                                                                               | 80  |
| 3.2 Аналіз вихідних даних.....                                                                                                                                                                    | 82  |
| 3.3 Метод просторової кластеризації DBSCAN.....                                                                                                                                                   | 85  |
| 3.4 Метод «Ізольований ліс» .....                                                                                                                                                                 | 88  |
| 3.5 Метод локального рівня викиду .....                                                                                                                                                           | 92  |
| 3.6 Метод еліптичної обвідної .....                                                                                                                                                               | 95  |
| 3.7 Метод вейвлет перетворення .....                                                                                                                                                              | 102 |
| 3.8. Порівняння методів аналізу даних .....                                                                                                                                                       | 103 |
| Висновки до розділу 3 .....                                                                                                                                                                       | 106 |
| РОЗДІЛ 4 ВРАХУВАННЯ ВПЛИВУ ДОДАТКОВИХ ФАКТОРІВ НА ТОЧНІСТЬ ПРОГНОЗУВАННЯ ВУЗЛОВОГО НАВАНТАЖЕННЯ ТА ВИЗНАЧЕННЯ ЗНАЧЕНЬ ОЧІКУВАНИХ ВТРАТ В ЕЛЕКТРИЧНИХ МЕРЕЖАХ НА ОСНОВІ ВУЗЛОВИХ НАВАНТАЖЕНЬ ..... | 107 |
| 4.1 Прогнозування вузлового навантаження з врахуванням додаткових факторів.....                                                                                                                   | 107 |
| 4.2 Порівняння різних підходів до прогнозування вузлового навантаження з врахуванням додаткових факторів .....                                                                                    | 114 |
| 4.3 Прогнозування втрат електричної енергії в розподільних мережах .....                                                                                                                          | 116 |
| 4.4 Визначення значення очікуваних втрат електричної енергії за допомогою штучних нейронних мереж .....                                                                                           | 120 |
| Висновки до розділу 4 .....                                                                                                                                                                       | 130 |
| ВИСНОВКИ.....                                                                                                                                                                                     | 132 |
| СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....                                                                                                                                                                   | 135 |
| ДОДАТОК А «Список публікацій добувача» .....                                                                                                                                                      | 147 |
| ДОДАТОК Б «Відгук ДТЕК Мережі».....                                                                                                                                                               | 151 |
| ДОДАТОК В «Авторське свідоцтво на комп'ютерну програму».....                                                                                                                                      | 152 |
| ДОДАТОК Г «Довідка про впровадження результатів дисертаційної роботи»                                                                                                                             | 153 |

## ПЕРЕЛІК СКОРОЧЕНЬ

АСКУЕ – Автоматизована система контролю та урахування енергії;  
БР – Балансуючий ринок;  
ВДР – внутрішньо добовий ринок;  
ГАЕС – Гідроакумуюча електростанція;  
ГЕС – Гідро електростанція;  
ДП – Державне підприємство;  
ОЕС – Об’єднана енергетична система;  
ОСП – Оператор системи передачі;  
ОСР – Оператор системи розподілу;  
РДН – Ринок на добу наперед;  
ТВЕ – Технологічні втрати в електричних мережах;  
ТЕС – Теплова електростанція;  
ТЕЦ – Теплоелектроцентрально;  
ШНМ – Штучна нейронна мережа;  
ARIMA (Autoregressive integrated moving average) – Інтегрована модель авторегресії ковзного середнього;  
DBSCAN (Density-based spatial clustering of applications with noise) –Алгоритм просторової кластеризації з присутністю шуму;  
EE (Elliptic envelope) – Метод еліптичної обвідної;  
ENTSO-e (European network of transmission system operators for electricity) – Європейська мережа системних операторів передачі електроенергії;  
GPU (Graphics processing unit) - Графічний процесор;  
IEEE (Institute of electrical and electronics engineers) – Інститут інженерів електротехніки та електроніки;  
IF (Isolation forest) – Метод «ізолюваного лісу»;  
LOF (Local outlier factor) – Метод локального рівня викиду;  
LRD (Local reachability density) – Розрахунок локальної досяжності;  
LSTM (Long short-term memory) – Довго короткострокова пам'ять;

MAPE (Mean absolute percentage error) – Середня абсолютна похибка у відсотках;

MLP (Multilayer perceptron) – Багатошаровий перцептрон;

MSE (Mean square error) – Середньоквадратична похибка;

RMSE (Root mean square error) – Середньоквадратична похибка вимірювання;

SCADA (Supervisory control and data acquisition) – Диспетчерське управління і збір даних;

VAR (Vector auto regression) – Векторна авторегресія;

## ВСТУП

### **Обґрунтування вибору теми дослідження.**

Прогнозування вузлового електричного навантаження в електричних мережах набуває особливої актуальності сьогодні, що зумовлено сучасними потребами щодо підвищення ефективності вирішення широкого спектру задач, таких як поточне планування та оперативне керування режимами роботи електроенергетичної системи, а також планування роботи різних учасників ринку електричної енергії. Точність прогнозів навантажень сприяє підвищенню економічності завантаження генеруючого обладнання, ефективності керування електричними мережами, точності формування графіків купівлі-продажу втрат електричної енергії на ринку електричної енергії, а також зниженню вартості електричної енергії для кінцевих споживачів.

Так, наприклад, прогноз вузлових навантажень необхідний для оптимізації майбутніх та корегування поточних режимів електричних мереж, формування оперативних диспетчерських команд, а також для подання заявок на купівлю та продаж електроенергії операторів систем розподілу (ОСР) [6], що зумовлює необхідність отримання прогнозних даних для закупівлі електроенергії на різних сегментах ринку [7,8]. При незадовільних результатах прогнозування, виникає значний небаланс енергії [9, 10], який має бути усунуто на балансуєчому ринку електроенергії по завищеним цінам [11], що відповідно збільшує витрати ОСР, Оператора системи передачі (ОСП) [12].

Сьогодні забезпечення надійного та ефективного функціонування усіх сегментів ринку електричної енергії є важливим завданням [13], що безпосередньо впливає на вартість електричної енергії для кінцевого споживача [14] та ефективність функціонування ОЕС України [15]. Крім того застосування прогнозних значень та методів прогнозування необхідне для планування режимів роботи енергосистеми. Враховуючи правила ринку електричної енергії [16], оператори системи розподілу та передачі повинні компенсувати втрати

електричної енергії купівлею електричної енергії. Наразі в енергосистемі України втрати електроенергії під час її розподілу у певних регіонах можуть досягати 20%, тоді як у більшості розподільних електричних мереж вони перевищують 10% [17]. При тому у більшості європейських країн даний показник знаходиться в межах 4-6%. В першу чергу це зумовлено застарілістю електричних мереж та неточними прогнозами навантажень. Також розрахунок втрат в більшості випадків проводиться за рахунок коефіцієнтів втрат як і визначаються за даними максимуму навантаження в літній та зимовий період.

Ринок електричної енергії «на добу наперед» (РДН) передбачає купівлю та продаж електричної енергії за маржинальними цінами, з доставкою на наступний день після проведення торгів [18-20]. Якщо прогнозування навантаження не дає задовільних результатів, учасники ринку зіткнуться з небалансом електроенергії, який потрібно буде докупувати на балансуючому ринку, що призведе до збільшення вартості електроенергії [10,21]. Важливо, що сьогодні оператори систем розподілу також мають купувати втрати електричної енергії на РДН [17].

Застосування методів прогнозування на основі штучних нейронних мереж є одним із найпоширеніших сучасних методів прогнозування, завдяки своїй високій точності та ефективності. Це стало можливим завдяки розвитку обчислювальних засобів і дозволило створювати багатofакторні моделі та проводити розрахунки з можливістю використання значних об'ємів даних без великих затрат часу. Більшість досліджень спрямовані на вдосконалення методів прогнозування часових рядів, а однією з концепцій вдосконалення є використання сучасних методів прогнозування на основі штучних нейронних мереж, а також їх модифікація та комбінація з іншими методами для вирішення різних завдань.

При побудові статистичних моделей процесу споживання електричної енергії вирішальне значення має якість вихідної інформації. Наявність пропусків та аномально великих значень у ряді даних, на якому проводиться оцінка параметрів моделі, призводить до недостатнього узагальнення характеру процесу та виникнення систематичних похибок.

Все це зумовлює необхідність розробки нових методів короткострокового прогнозування навантаження вузлів у розподільних електричних мережах з застосуванням штучних нейронних мереж та методів аналізу даних для виявлення та заміни аномальних значень навантаження вузлів з метою підвищення точності їх прогнозування, а також застосування прогнозів вузлових навантажень задля підвищення точності визначення значень очікуваних втрат в розподільних мережах під час їх закупівлі операторами систем розподілу на ринку електричної енергії України.

Значний внесок в розвиток теорії короткострокового прогнозування зробили Peter W. Sauer, M. Shahidehpour, G. Claire, P. Tosi, J. Gonggoffer, L. Servi, Шумілова Г.П., а також українські науковці Черненко П.О., Блінов І.В., Данилюк О.В., Ткаченко Р.О., Лежнюк П.Д., Мірошник В.О.

Разом із тим задачам прогнозування вузлових навантажень та визначення втрат не приділено значної уваги, наявні методи не враховують вплив додаткових факторів та не розглядаються варіанти побудови різних архітектур, що зумовлює доцільність досліджень щодо застосування штучних нейронних мереж для прогнозування вузлового електричного навантаження та втрат електричної енергії.

### **Зв'язок роботи з науковими програмами, планами, темами.**

Дисертаційна робота складається з теоретичних і практичних досліджень згідно з планами науково-дослідних робіт які проводились в Інституті електродинаміки НАН України:

«Розвиток засобів комп'ютерного моделювання ЕЕС для оперативного та короткострокового прогнозування навантаження та рівня стійкості ОС України», шифр «Система-6», 2019 - 2020рр. №ДР 0115U005309 (виконавець);

«Розробка методів та засобів короткострокового прогнозування вузлових електричних навантажень електроенергетичних систем в ринкових умовах», шифр: «Прогноз», 2019 - 2020рр. № ДР 0119U002810 (виконавець);

«Науково-технічні засади розвитку та керованості сегменту розосереджених джерел енергії в структурі генеруючих потужностей

електроенергетичних систем», шифр «Сегмент», 2021 - 2022рр. №ДР 0117U007711 (виконавець);

«Прогнозування сумарного небалансу електричної енергії в ОЕС України та його вплив на кінцеву вартість електричної енергії», шифр «Небаланс», 2021-2022рр. №ДР 0121U111848.

**Мета і завдання дослідження.** Метою роботи є розробка нових методів короткострокового прогнозування навантаження вузлів в розподільних електричних мережах із застосуванням штучних нейронних мереж та методів аналізу даних для виявлення та заміни аномальних значень навантаження вузлів з метою підвищення точності їх прогнозування.

Для досягнення мети були поставлено та вирішено наступні завдання:

- проведено аналіз існуючих методів короткострокового прогнозування потужності вузових електричних навантажень;
- досліджено методи короткострокового прогнозування вузових електричних навантажень на основі штучних нейронних мереж;
- досліджено залежності вузового навантаження від температури повітря;
- розроблено модель штучної нейронної мережі глибинного навчання для короткострокового прогнозування вузових навантажень;
- досліджено та вдосконалено методи аналізу даних для виявлення та вилучення аномальних та пропущених даних;
- розроблено метод багатофакторного короткострокового прогнозування вузового електричного навантаження з використанням штучної нейронної мережі глибинного навчання;
- розроблено моделі прогнозування вузлів навантажень з використанням штучних нейронних мереж глибинного навчання задля визначення втрат в електричних мережах.
- розроблено тестову модель електричної мережі використовуючи дані вузового електричного навантаження.
- проведено аналіз правильності розроблених моделей;

*Об'єкт дослідження* – вузлове електричне навантаження операторів систем розподілу.

*Предмет дослідження* – моделі та методи короткострокового прогнозування вузлового електричного навантаження.

**Методи дослідження.** Для вирішення поставлених в роботі завдань використовувалися: методи аналізу часових рядів, методи машинного навчання, методи оптимізації, методи математичної статистики, комп'ютерне моделювання, як метод дослідження, методи розрахунку режимів роботи електричних мереж. Дослідні програми написані мовою програмування Python.

#### **Наукова новизна отриманих результатів.**

1. Вперше розроблено метод багатofакторного короткострокового прогнозування вузлового електричного навантаження з використанням штучної нейронної мережі з модулем довго-короткострокової пам'яті (LSTM – Long-short term memory) та обхідним з'єднанням і паралельною гілкою прихованих шарів для обробки та врахування впливу зовнішніх факторів, що дозволило зменшити похибку прогнозування вузлового навантаження у порівнянні з іншими методами прогнозування.

2. Розроблено новий метод аналізу даних для виявлення та заміни аномальних значень та пропусків значень вузлового електричного навантаження за рахунок виконання двоетапного аналізу з використанням методу кластеризації даних (DBSCAN – Density-based spatial clustering of applications with noise) та декомпозиції часових рядів, а також заміни аномальних значень за допомогою лінійної інтерполяції, що дозволило зменшити кількість виявлення хибних значень та в подальшому підвищити точність короткострокового прогнозування вузлових навантажень.

#### **Практичне значення отриманих результатів** полягає у розробленні:

- Розроблено комп'ютерну програму на основі штучної нейронної мережі глибинного навчання, яка дозволяє підвищити точність та стабільність короткострокового прогнозування вузлового електричного навантаження з

врахуванням зовнішніх факторів, що дозволяє отримувати прогнольні значення вузлового навантаження з більшою точністю.

- Розроблено метод аналізу даних для виявлення та заміни аномальних значень та пропусків даних вузлового навантаження за допомогою методів кластеризації та декомпозиції часових рядів, що дозволяє зменшити кількість виявлення хибних значень та підвищити точність короткострокового прогнозування вулових навантажень.

- Завдяки підвищенню точності прогнозування вузлового навантаження стало можливим підвищення точності визначення очікуваного значення втрат електричної енергії в розподільній електричній мережі на основі ретроспективних даних для закупівлі втрат операторами систем розподілу на ринку електричної енергії України, що є більш ефективним, ніж визначення втрат електричної енергії за допомогою коефіцієнтів втрат.

- Розроблено моделі прогнозування вузлів навантажень з використанням штучних нейронних мереж глибинного навчання задля визначення очікуваного значення втрат в електричних мережах, що дозволило зменшити похибку визначення очікуваного значення втрат електричної енергії в розподільних мережах, під час формування їх погодинного графіка закупівлі операторами систем розподілу на ринку електричної енергії України.

Результати роботи використано під час підготовки аналітичних матеріалів щодо виявлення аномальних значень в даних вузлового електричного навантаження для ТОВ «ДТЕК Мережі». Лист щодо практичної значущості отриманих результатів наведено в Додатку Б.

Отримані результати впроваджені в навчальному процесі під час формування складових навчально-методичного забезпечення, зокрема і практичних робіт, з дисциплін «Оптовий та роздрібний ринок електричної енергії» та «Системи ринків електричної енергії» для підготовки магістрів наукового та професійного спрямування за спеціальністю 141 «Електроенергетика, електротехніка та електромеханіка» (Освітні програми: «Системи забезпечення споживачів електричною енергією» та «Енергетичний

менеджмент, електропостачання та інжиніринг електротехнічних комплексів») в Інституті енергозбереження та енергоменеджменту НТУ України «КПІ ім. І. Сікорського». Довідка щодо впровадження робіт наведено в Додатку Г.

Складові роботи впроваджені під час виконання науково-дослідних робіт інституту електродинаміки, зокрема і в частині розробки комп'ютерної програми для розрахунків короткострокових прогнозів вузлового навантаження, а також розробки моделі оцінки вартості похибки прогнозу, що дозволяють зменшити витрати на закупівлю електричної енергії на балансуєчому ринку для операторів системи розподілу.

Подано заявку та отримано авторське свідоцтво на комп'ютерну програму «Модель розрахунку цін та тарифів на електричну енергію» 115250 від 13.10.22, наведено в Додатку В.

#### **Особистий внесок добувача**

Безпосередньо автором здійснено:

- інформаційний пошук та аналіз літературних джерел за темою дисертації;
- аналіз підходів та методів прогнозування для задач енергетики;
- розроблення методу експоненційного згладжування Холта - Вінтерса для порівняння методів однофакторного прогнозування вузлового навантаження;
- розроблення архітектури штучних нейронних мереж глибинного навчання для прогнозування вузлового навантаження;
- розроблення комп'ютерної програми для прогнозування вузлового електричного навантаження на основі штучних нейронних мереж глибинного навчання для учасників ринку електричної енергії;
- визначення впливу та зв'язку температури повітря на вузлове навантаження.
- удосконалення методу багатфакторного короткострокового прогнозування вузлового електричного навантаження на основі штучних нейронних мереж;
- аналіз методів методів кластеризації для виявлення аномальних значень;

- розроблення алгоритму двоетапного аналізу даних для виявлення та заміни аномальних значень;
- розроблення моделі прогнозування вузлів навантажень з використанням штучних нейронних мереж глибинного навчання задля визначення значення очікуваних втрат в розподільних електричних мережах;
- розроблення методу прогнозування агрегованого значення втрат в електричних мережах на основі використання штучних нейронних мереж;
- розроблення тестової електричної мережі для розрахунку втрат електричної енергії.

Наукові роботи опубліковані у співавторстві з Бліновим І.В., Черненком П.О., Мірошником В.О., Кучанським В.В., Сичовою В.В., Лоскутовим С.С.

Співавторами наукових праць є наукові керівники та науковці, спільно з якими проведені дослідження. У наукових працях, опублікованих у співавторстві, дисертанту належить фактичний матеріал і основний творчий доробок.

Співавторами наукових праць дисертанта захищені такі дисертації:

Мірошник В.О. «Короткострокове прогнозування електричного навантаження енергосистем з використанням штучних нейронних мереж глибокого навчання», Київ, 2021. 164с.

Блінов І.В. «Наукові основи організації взаємодії сегментів ринку електричної енергії» Київ, 2018. 510с.

Постановка мети та завдань, обговорення результатів проведені разом з науковим керівником.

**Апробація результатів дисертації.** Основні положення роботи викладено та обговорено на науково-практичних конференціях різного рівня: "Проблеми сучасної електротехніки - 2020" (м. Київ, 2020); XXXVIII науково-технічна конференція молодих вчених та спеціалістів інституту проблем моделювання в енергетиці ім. Г.Є. Пухова НАН України (м. Київ 2020); VIII Всеукраїнська науково-практична конференція молодих учених «Наукова молодь-2020», (м.

Київ, 2020); «Контроль і управління в складних системах» (м. Вінниця, 2020); «Сучасний стан та перспективи розвитку електроенергетики» (м. Київ, 2021); 2022 IEEE KhPI Week on advanced technology dedicated to the centenary of institute of education and science in power engineering, electronics and electromechanics NTU«KhPI» (м. Харків, 2022), IEEE International Conference on Energy Smart Systems (ESS 2022) (м. Київ, 2022);

Основні положення дисертаційної роботи і результати досліджень доповідались та обговорювались на: наукових семінарах відділу моделювання електроенергетичних об'єктів та систем, а також в літній школі Інституту електродинаміки НАН України.

### **Обсяг і структура дисертації**

Дисертаційна робота виконана на 154 сторінках машинописного тексту, складається зі вступу, 4 розділів, загальних висновків, списку використаних джерел та додатків. Обсяг основного тексту дисертації становить 135 сторінок друкованого тексту. Робота ілюстрована 25 таблицями, 46 рисунками. Список використаних джерел містить 103 найменувань, з них 51 кирилицею та 52 латиницею.

# **РОЗДІЛ 1**

## **КОРОТКОСТРОКОВЕ ПРОГНОЗУВАННЯ ВУЗЛОВОГО ЕЛЕКТРИЧНОГО НАВАНТАЖЕННЯ В УМОВАХ ФУНКЦІОНУВАННЯ РИНКУ ЕЛЕКТРИЧНОЇ ЕНЕРГІЇ УКРАЇНИ**

### **1.1 Задачі прогнозування в новій моделі ринку електричної енергії України**

Починаю з 1997 року в Україні працював оптовий ринок електроенергії створений за прикладом англійського пулу, який функціонує за схемою «Єдиного покупця» [22, 23]. Всю електроенергію вироблену електростанціями купував ДП «Енергоринок», який перепродавав її обленерго та постачальникам за нерегульованим тарифом. Генеруючі компанії подавали цінові заявки на основі яких ДП «Енергоринок» визначав склад генеруючих агрегатів ґрунтуючись на прогнозі споживання в ОЕС України. При цьому державою гарантувалась фіксована ціна на електроенергію для побутових споживачів, яка була нижчою ніж оптова ціна, і при цьому включала тарифи на розподіл, передачу та витрати ДП «Енергоринок». Для компенсації обленерго різниці в цінах використовувався механізм дотаційних сертифікатів, за яким оптова ринкова ціна для постачальників за нерегульованим тарифом була вищою.

Регулювання ринку проводилось Національною комісією регулювання електроенергетики (НКРЕ), яка реалізовувала цінову та тарифну політику, проводила регулювання діяльності суб'єктів ринку та затверджувала правила користування електричною енергією.

В рамках ринку «Єдиного покупця» конкурентним можна вважати сегмент постачальників за нерегульованим тарифом, які в залежності від наявності дешевих обігових коштів та розумно підбраного портфелю споживачів могли пропонувати гнучкі схеми оплати. Проте обленерго суттєво обмежували доступ незалежним постачальникам до споживачів, В рамках проведеної реформи, обленерго розділено на дві незалежні компанії, оператор системи розподілу,

який надає послуги з розподілу електричної енергії мережами 0,4 – 110 кВ та енергопостачальна компанія, яка безпосередньо займається купівлею-продажем електроенергії кінцевим споживачам. На дані енергопостачальні компанії покладено функції постачання універсальної послуги для населення та малих непобутових споживачів [24]. Універсальна послуга передбачає продаж електричної енергії кінцевим споживачам за фіксованою ціною, яка встановлюється Національною комісією, що здійснює державне регулювання у сферах енергетики та комунальних послуг (НКРЕКП) [25].




Рис. 1.1 Схема ринку «Єдиного покупця»

Введена з 01.07.2019 року нова модель оптового ринку електричної енергії [13, 26] передбачає можливість купувати і продавати електричну енергію на конкурентних засадах. Оптовий ринок розбивається на чотири сегменти [18, 27]: ринок двосторонніх договорів (ДД), ринок «на добу наперед» (РДН) [18], внутрішньодобовий ринок (ВДР) та балансуючий ринок (БР) [28].

У продавців та покупців електричної енергії з'являється можливість укласти прямі довгострокові договори на постачання електричної енергії по обраному графіку та за взаємовигідними цінами.

На ринку «на добу наперед» торгується електроенергія зі строком постачання на наступну добу. Ціна на РДН визначається окремо для кожної години доби згідно з принципом граничного ціноутворення [29, 30]. Згідно з даним принципом гранична ціна є точкою перетину графіків сукупного попиту та пропозиції і завжди має бути ціною останнього прийнятого кроку заявки на продаж, тобто рівною або нижчою від ціни останньої заявки на купівлю. При подачі заявок продавці і покупці вказують об'єм та ціну. Заявки приймаються до 12 години доби, що передує добі постачання.

На ВДР в учасників ринку є можливість додатково закупити необхідну електричну енергію або продати надлишок в межах однієї доби, але не раніше ніж за 60 хв до години постачання. При цьому заявки приймаються починаючи з 15 години доби, що передує добі постачання.

На балансуєчому ринку оператор системи передачі купує послуги з балансування [31 – 33]. Правилами ринку передбачено, що постачальниками послуг балансування можуть бути і виробники і споживачі, але для виробників (крім станцій з відновлюваними джерелами енергії) участь в БР є обов'язковою.

Після отримання адміністратором розрахунків фактичних даних по споживанню електричної енергії в добу постачання, для всіх учасників ринку розраховуються платежі для покриття небалансів.

Сукупні витрати учасників ринку на компенсацію власних небалансів розраховуються за формулою:

$$B_{\Sigma}^{HB} = \sum_{i=1}^n B_t^{HB} (\text{грн}) \quad (1.1)$$

Вартість небалансів для окремої години може бути як від'ємна, так і додатна, оскільки при наявності в учасника ринку профіциту він викупується ОСП за ціною небалансів:

$$B_t^{HB} = \{\varepsilon_t \cdot C_t^{HB}, \varepsilon_t > 0 - \varepsilon_t \cdot (C_t^{PDH} - C_t^{HB}), \varepsilon_t < 0 \quad (1.2)$$

де  $C_t^{HB}$  - ціна небалансів для  $t$ -ї години за результатами сесії балансуєчого ринку, грн/МВт·год

$C_t^{PDH}$  - ціна на ринку «на добу» наперед для  $i$ -ї години, грн/МВт·год

$\varepsilon_t$  - похибка прогнозу обсягу технологічних втрат електроенергії для  $i$ -ї години (МВт · год), яка розраховується за формулою:

$$\varepsilon_t = W_t^\phi - W_t^\pi \quad (1.3)$$

де  $W_t^\phi$  – фактичний обсяг втрат, МВт·год;

$W_t^\pi$  – прогнозний обсяг втрат, МВт·год.

При цьому ціна небалансів розраховується, як середньозважена ціна купівлю послуг з розвантаження та завантаження у постачальників послуг балансування. Постачальниками послуг балансування можуть бути як виробники, так і великі споживачі. Для генерації участь в БР є обов’язковою.

Асиметрія формули 1.2 стимулює покупців завищувати обсяги в заявках на РДН та ВДР, що призводить до систематичних відхилень комерційного графіку від фактичного споживання.

До лютого 2022 року «Бурштинський енергоострів» був виділений в окрему цінову зону в якій визначення граничної ціни РДН та БР проводиться незалежно від решти ОЕС. Це зумовлено тим, що в силу мережевих обмежень ціна в ОЕС була б не виправдано завищеною. Проведені в [17] розрахунки показували, що таке підвищення могло сягати 10%.

Враховуючи що 26 лютого 2022 року енергосистема України була відключена від об’єднаної енергосистеми Білорусії та Росії для планових випробувань, 16 березня 2022 року відбулась екстрена синхронізація Бурштинського енергоострову з енергосистемою України та приєднанням України до ENTSO-E [34] що зумовило припинення існування Бурштинського енергоострову та відповідно окремо виділених цінових зон для нього [35].

Спрощена схема нової моделі ринку представлено на рис.1.2.




Рис. 1.2 Узагальнена схема нової моделі ринку

Крім зміни механізмів оптової закупівлі електричної енергії реформою передбачено збільшення ролей на ринку. Так на ряду з постачальниками за вільними цінами та постачальниками універсальної послуги, учасниками оптового ринку можуть бути трейдери (ТР), які проводять діяльність з перепродажу електричної енергії, та великі підприємства (кваліфіковані споживачі, КС), які приймають участь в ринку виключно для забезпечення власного споживання.

З запуском нового ринку змінилась погодинна структура генерації. Як видно з рис. 1.3 графік виробництва електроенергії на великих ТЕС став значно нестабільнішим.

На графіку відпуску електроенергії ТЕЦ (Рис 1.4) можна помітити більш виражену добову періодичність. До 01.07.2019р. для ТЕЦ був встановлений постійний тариф (1827,49 грн./МВт.год в червні 2019р. згідно даних ДП «Енергоринок»), що відображається в більш нерівномірному графіку відпуску до запуску нового ринку. Враховуючи цінові обмеження, які для поза пікових годин (23 – 07) склали 959,12 грн/МВт·год відпускати енергію в нічні години стало

економічно не вигідно. При цьому, реагуючи на кон'юнктуру ринку, ТЕЦ почали нарощувати обсяги відпуску в пікові години.




Рис. 1.3. Виробництво електроенергії на ТЕС




Рис. 1.4. Виробництво електроенергії на ТЕЦ

Більш нерівномірними також стали графіки ГЕС та ГАЕС. Збільшення нерівномірності ТЕС/ТЕЦ та затримки з впровадженням ринку допоміжних послуг [36] призводив до суттєвого дефіциту резервів в зоні ОЕС України. В середньому необхідний за критерієм n-1 обсяг резервів в 1000 МВт покривається на 55%, що призвело до більш інтенсивного використання маневрових потужностей ГЕС/ГАЕС [37–39]. В перші дні роботи ринку значно збільшилась кількість аварійних команд від диспетчерів ПрАТ «НЕК «Укренерго» для завантаження та розвантаження агрегатів ГЕС та ГАЕС.

Також можна відзначити нехарактерні режими роботи ГЕС/ГАЕС, на рис. 1.5. та 1.6 видно, що ГАЕС розвантажувались в пікові години доби та зменшує споживання на закачку води в нічні години (в середньому в 2 рази). В свою чергу збільшився відпуск електроенергії ГЕС в нічні години.




Рис. 1.5 Виробництво електроенергії на ГЕС




Рис. 1.6 Виробництво електроенергії на ГАЕС

Виникають обмеження щодо можливості використання потужностей ГЕС у планових обсягах виробітку електричної енергії. В результаті диспетчери енергосистеми вимушені зупиняти/пускати пилувугільні енергоблоки з метою

забезпечення надійності роботи ОЕС України, при цьому ТЕС зазнають додаткові збитки через відсутність механізму оплати таких послуг. Також є випадки обмеження імпорту електроенергії та відпуску електроенергії вітровими електростанціями.

Всі наведені вище фактори суттєво ускладнюють диспетчерське управління енергосистемою.

Метою реформування ринку є підвищення конкуренції, як між виробниками, так і покупцями електричної енергії, що повинно підвищити ефективність роботи всієї галузі [40, 41]. Наразі держава, з метою зниження цінових шоків, які характерні для ранніх стадій запуску ринку, встановлює граничні ціни на організованих сегментах ринку (РДН, ВДР та БР) та регулює ціну електричної енергії для побутових споживачів. Але безперечними перевагами нової моделі є прозорі механізми ціноутворення та посилення відповідальності учасників ринку за спричинені небаланси, але при цьому суттєво зросла вартість та складність адміністрування взаємовідносин між учасниками ринку.

Схема роботи ринку електричної енергії спрямована на мінімізацію виникнення заборгованостей, проте невирішеним досі залишається питання погашення заборгованості, що виникла до 01.07.2019 року

Сучасні реалії обґрунтовують цілу низку нових задач прогнозування, серед яких можна виділити:

- Прогнозування відпуску електричної енергії виробниками з відновлюваних джерел енергії [42 - 45];
- Прогноз графіків вузлових навантажень споживачів для різних сегментів ринку електричної енергії [46- 48];
- Прогнозування небалансів електричної енергії [8-10];
- Визначення втрат електричної енергії [49];
- Прогнозування графіків споживання споживачів на роздрібному ринку електричної енергії [50-52];
- Прогнозування цін на ринку електричної енергії та інші [53-56];

Важливо, що з технологічної точки зору використання короткострокового прогнозування вузлового навантаження, а також прогнозування втрат, зокрема і на основі вузлового навантаження дозволяє зменшити не тільки похибку прогнозування, а й час обробки даних та зменшення економічних затрат на втрати електроенергії.

## **1.2 Короткострокове прогнозування вузлового навантаження**

Прогнозування навантаження необхідне для розв'язання задач планування та управління режимами енергосистеми. Для розв'язання даної задачі було розроблено ряд методів прогнозування, як класичних методів часових рядів ARIMA і методів експоненційного згладження Холта-Вінтерса, так і з застосуванням штучних нейронних мереж різного типу. Прогнозування за тривалістю поділяється на: оперативне (від декількох хвилин до доби), короткострокове (від одної до декількох діб), довгострокове (до року). Застосування методів обумовлено точністю прогнозів та тривалістю обрахунків. В деяких випадках до досить точних та ефективних методів, намагаються внести якість особливості які б могли покращити або розширити спектр застосування.

Застосування методів прогнозування на основі штучного інтелекту є одним із найпоширеніших сучасних методів прогнозування, за рахунок своєї високої точності та ефективності. В роботі [57] для прогнозування вулових навантажень було розроблено алгоритм на основі штучних нейронних мереж з методом оптимізації зворотного поширення та додаванням алгоритму авторегресії.

Завдяки методу авторегресії проводиться попередня обробка даних, а також налаштування та оцінка параметрів моделі. Після чого ці параметри використовуються для тренування моделі вже методом ШНМ ЗП. Дослідження проводилось на даних PJM Markets і Operations database. Дані включають в себе 96 вузлів за період з 2014 по 2015 років. Дослідження включали в себе декілька тестів. В першому з тестів проводилось прогнозування одного вузла у різні дні.

Інший тест використовував ті ж самі дані, але для 8 вузлів і результати прогнозування порівнювались із сумарним прогнозом. Використовуючи дані системи SCADA міста Хезе (Китай) за 2015 рік. Проводилось порівняння методів ШНМ зворотного поширення та методу ШНМ зворотного поширення з алгоритмом авторегресії

Використання методу ШНМ показав кращі або рівні результати, але при цьому швидкість обчислення даного методу була більшою, важливою особливістю було врахування додаткових даних, таких як температура, також доречно відмітити що дослідження проводилось на реальних даних різних країн.

Також на основі ШНМ з використанням алгоритму нечіткої логіки був побудований модуль під назвою PROTREN [58] який призначений для визначення початку перехідних процесів з високою точністю та надійністю. Модуль використовується для мінімізації різких змін навантаження.

Нейронечітка система складається з декількох штучних нейронних мереж: Велика нейронна мережа визначає початкові особливості сигналу і проводить пробний прогноз; Нечіткий процесор який являє собою паралельно реалізований модуль PROTREN; ШНМ яка визначає трендові рішення (збільшення, зменшення тренду); І остання ШНМ яка отримує результати від ШНМ та модулю PROTREN і видає фінальний результат.

Даний метод може покращити продуктивність прогнозування за допомогою методу ШНМ. Нечітко логічна методологія використовується для виявлення тренду що виникає в даних протягом декількох днів. Для перевірки ефективності моделі проводилось два тести в обох випадках інформація про температуру уже була включена в дані. В одному тесті проводився добовий прогноз навантаження великого промислового споживача. В другому тесті проводився погодинний прогноз для ізолюваної енергосистеми. Для дослідження використовувались дані з ізолюваної енергосистеми острова Крит з 1997 по 1999. Метод ШНМ з використанням алгоритму нечіткої логіки показав кращі результати ніж звичайний метод ШНМ. Також даний модуль є частиною

системи TELOS (Суб'єктів передачі та розповсюдження з навчанням та онлайн самокорекцією).

Для отримання точних прогнозів вузлових навантажень дуже важливим є наявність повних та достовірних даних. За відсутності точних та постійних даних телевимірів, прогноз вузлових навантажень проводять на основі сумарного навантаження використовуючи коефіцієнти пропорційності, які визначаються завдяки обробці контрольних вимірів вузлів навантаження. При чому точність таких результатів прогнозу відносно достатня при плануванні режимів. Використання методу інверсії ШНМ яке описано в статті [59] повинен забезпечити ефективний прогноз як активної, так і реактивної потужності за умови відсутності постійних даних вузлів навантаження.

Даний метод використовує класичний багатошаровий персептрон та алгоритм зворотного поширення похибки, який за даними вузлового навантаження розраховує прогноз сумарного навантаження по вузлах і проводить оптимізацію параметрів мережі. Як і в подальшому використовуються при інверсії. Прогноз сумарного навантаження по енергосистемі розраховується за рахунок нечіткої нейронної мережі. Для дослідження ефективності прогнозування даним методом використовувались ретроспективні дані енергосистеми республіки Комі яка складається з 15 вузлів. Дослідження було розділене на дослідження прогнозу вузлових навантажень на добу наперед з даними 2000 року з годинною дискретністю. І дослідження внутрішньодобового прогнозу вузлових навантажень за даними 1997 року з дискретністю від 5 до 30 хв. Результати дослідження порівнювались із методом розрахунку вузлових навантажень за коефіцієнтами пропорційності. Метод інверсії має меншу похибку прогнозу ніж звичайний підхід на основі коефіцієнта пропорційності.

Окрім методів на основі ШНМ є ще класичні методи прогнозування, до прикладу метод експоненційного згладження Холта-Вінтерса [60]. Даний метод так само як і метод ARIMA широко застосовуються завдяки своїй простоті, надійності та потребі лише в однофакторних даних. Модель експоненційного

згладження складається з функції згладжування  $St$ , тренду  $bt$ , та сезонної складової  $It$ .

Вона також має безліч модифікацій як з додаванням автокореляції, або з додаванням додаткового сезонного індексу. Для дослідження та перевірки ефективності даного методу використовували як односезонний метод експоненційного згладжування, так і двох сезонний і порівнювали їх із методом сезонної ARIMA та методом багатомірної регресії. Дослідження проводилось на даних вузла Хейворд (Нова Зеландія) за період з 21 липня 2005 року по 16 серпня 2006 року і включали в себе часові серії з півгодинної дисперсії навантажень. Останні чотири тижні вибірки використовувались для перевірки точності прогнозування всіх моделей.

Для регулювання помилки в моделях Холта – Вінтерса (одно і двох сезонній) використовувалась автокореляція даних, що позитивно впливає на результати оцінки точності.

Метод сезонної ARIMA показав найкращі результати прогнозування, хоча двох сезонна модель експоненційного згладження показала теж досить гарний результат прогнозування навантаження. Важливо зазначити що для перевірки ефективності методів використовувались реальні дані.

Ще одним з методів який використовують для прогнозування навантаження є метод опорних векторів (SVM). Метод використовувався для короткострокового прогнозування навантаження на добу наперед. Цей метод посилює адаптивну здатність моделей під різні типи днів. Імітує взаємозв'язок між активним навантаженням системи і вузла, також між активною та реактивною потужністю вузла і ще зв'язок середніх значень потужностей усіх вузлів. До прикладу в статті [61] він описується і застосовується в управлінні енергосистемою провінції Шаньдун в Китаї.

Самоадаптивна динамічна модель дозволяє розглядати електричну мережу як взаємозалежну систему розділену на рівні та зони відповідно до рівня напруги. Прогнозування здійснюється для сумарного навантаження, використовуючи рекурсивні найменші квадрати опорних векторів (RLS-SVM), а

модель динамічного прогнозування множинних активних коефіцієнтів розподілу навантаження та коефіцієнтів вузлових сил розв'язується методом Калмана.

Для перевірки прикладу розглядалась мережа провінції Шаньдун і представлена двошарова система. Вищий шар - це сумарний рівень активного навантаження, а нижній шар - це еквівалентний вузол навантаження мережі 500 кВ. Мережа 500 кВ охоплює всі райони Шаньдун і має власне представлення, з 13 еквівалентних навантажень та 8 еквівалентних генераторів.

Дослідження проводилось за даними навантаження вузлів за 20 листопада 2006 року. Дані утворюють 288 наборів даних з 5 хвилинним інтервалом. Для перевірки ефективності даний метод опорних векторів порівнювали з нелінійною авторегресивною нейронною мережею [62] для прогнозування активного навантаження вузла та з адаптивним фільтром Калмана для прогнозування вузлових коефіцієнтів потужності.

13 вузлових навантажень можна розділити на три типи, в залежності від структури навантаження та характеристики. Навантаження 1 типу включають в себе вузли 1, 3, 4, 5, 8 і 12, навантаження змінюються гладко з сильною регулярністю. Навантаження типу 2 є індустріальними користувачами, такими як вузли 6, 9, 11 та 13. Вони складають певний відсоток у структурі навантаження, що призводить до невеликих коливань реактивної потужності. Інші вузли можна класифікувати як навантаження типу 3, які включають гірничодобувні та металургійні підприємства, а також паперові підприємства та значну частку їх навантаження. Що призводить до більших коливань реактивної потужності.

Ефективність прогнозування оцінювалась середньою відносною похибкою. Похибки окремих вузлів відрізнялись в межах декількох десятих, а в інших відрізнялись більше ніж на відсоток. Це може бути зумовлено відсутністю повноцінних даних окремих вузлів. Тому можна зробити висновок що при наявності не дуже точних даних похибка даних методів є відносно задовільною.

Також на основі методу опорних векторів була побудована модель для прогнозування вузлових навантажень з урахуванням мережевих обмежень [63].

Дана модель має попередньо незалежне прогнозування вузлового навантаження, і включає в себе метод непрямой оцінки навантаження, так як це дозволяє отримати зв'язок між різними вузлами енергосистеми і отримати кращі результати прогнозування. Для цього методу була побудована еквівалентна вузлова енергосистема яка складається з чотирьох вузлів.

В дослідженні порівнювали методи опорних векторів з врахуванням різних змінних стану та класичний метод опорних векторів. В одному випадку в якості змінних стану використовували потік потужності віток, в іншому навантаження вузлів.

Вибір змінних демонструє різні результати прогнозування, але кращі ніж при прогнозуванні звичайним методом опорних векторів, також неврахування вузлів з поганою достовірністю покращує загальну точність прогнозування.

Для порівняння ефективності розробленої, в рамках даного дослідження, штучної нейронної мережі глибинного навчання пропонується порівнювати її з методом потрійного експоненційного згладження та векторної авторегресії, які детально описано далі.

### **1.3 Аналіз класичних методів для вибору методу для вузлового навантаження**

#### **1.3.1 Метод експоненційного згладження**

Експоненційне згладження [64] це один з найпопулярніших класичних методів короткострокового прогнозування часових рядів. Існує ряд модифікацій даного методу: одинарне, подвійне та потрійне експоненційне згладження. Одинарне експоненційне згладження використовується для прогнозування стаціонарного часового ряду без трендової та сезонної складових. Подвійне експоненційне згладження є розширенням методу при наявності тренду. Потрійне експоненційне згладження включає сезонну складову. В залежності від характеру часового ряду трендова та сезонна складові можуть бути як адитивними, так і мультиплікативними.

Рівняння для прогнозу часового ряду з використанням методу потрійного експоненційного приймають вигляд:

$$S_t = \alpha \frac{y_t}{I_{t-L}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (1.4)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (1.5)$$

$$I_t = \beta \left( \frac{y_t}{S_t} \right) + (1 - \beta)I_{t-L} \quad (1.6)$$

$$F_{t+m} = (S_t + mb_t)I_{t-L+m} \quad (1.7)$$

де  $y_t$  - спостереження

$S$  - згладжене спостереження

$b$  - коефіцієнт тренду

$I$  - сезонний індекс

$F$  - прогноз на  $m$  періодів вперед

$t$  - індекс, що позначає період часу

$\alpha, \beta$  і  $\gamma$  – константи, знаходяться в межах 0, 1 для мінімізації помилки.

Для оцінки параметрів  $\alpha, \beta$  і  $\gamma$  найчастіше використовується метод Хука-Дживса [65]. Даний метод належить до класу прямих методів оптимізації і не потребує розрахунку градієнта функції втрат по параметрах.

Множина напрямків для пошуку обмежується множиною координат кожної змінної. Пошук починається з встановлення базисних параметрів, для кожної змінної встановлюються крок з яким вони будуть змінюватись. До змінних які входять в функцію  $f(x)$  додається крок, і розраховується пробне значення. Якщо функція  $f(x)$  в пробній точці менша ніж у попередній то вона вважається правильною і змінна оновлює своє значення. Якщо функція не зменшилась тоді робиться крок в протилежний напрямок, збільшення або зменшення змінної. Якщо функція в обох випадках не зменшується, то змінну можна вважати оптимальною, або для отримання більш точних величин, можна зменшувати величину кроку. Пошук оптимальних параметрів проводиться послідовно для кожної змінної.

Спочатку задаються початкові значення  $x^0$ ,  $\varepsilon$  – обмеження для зупинки алгоритму,  $\Delta_1^0, \Delta_2^0, \dots, \Delta_n^0$  - початкові значення приростів, повинні бути менше або рівні  $\varepsilon$ ,  $i=1, k=0, \lambda$  – прискорюючий множник прямує до нуля.

$$x_i^{k+1} = \{x_i^k + \Delta_i^k, \quad f(x_1^k, \dots, x_i^k + \Delta_i^k, \dots, x_n^k) < f(x_1^k, \dots, x_i^k, \dots, x_n^k) x_i^k + \Delta_i^k, \quad f(x_1^k, \dots, x_i^k + \Delta_i^k, \dots, x_n^k) < \min f(x_1^k, \dots, x_i^k, \dots, x_n^k) x_i^k, (x_1^k, \dots, x_i^k - \Delta_i^k, \dots, x_n^k) \} \quad (1.8)$$

Якщо  $i < n$ , то  $i = i + 1$  і повторюється рівняння (1.8)

Якщо  $i = n$ , перевіряється успішність пошуку, якщо  $f(X^{k+1}) < f(X^k)$  то переходимо до рівняння (1.9), якщо  $f(X^{k+1}) \geq f(X^k)$  то переходимо до умови  $\Delta_i < \varepsilon$ .

$$X^{zr} = X^{k+1} + \lambda(X^{k+1} - X^k) \quad (1.9)$$

де  $X^{zr}$  - точка допоміжного пошуку для отримання точки  $X^{dp}$

$X^{dp}$  - новий базис

Якщо  $X^{dp} \neq X^{zr}$ ,  $X^{k+1} = X^{dp}$ , а  $X^k$  - точка старого базису

Після чого можна перейти до наступної умови, якщо  $X^{dp} = X^{zr}$  то вважаються неуспішними  $X^{dp}$ ,  $X^{zr}$  анулюються і  $X^{k+1}$  залишається точкою нового базису, а  $X^k$  точкою старого базису, повторюється рівняння (1.8).

Якщо  $\Delta_i < \varepsilon$  то пошук закінчується і  $X^* = X^k$ , якщо  $\Delta_i > \varepsilon$  необхідно зменшити крок і повторити рівняння (1.8).

Після того як отримали оптимальні параметри змінних ( $\alpha$ ,  $\beta$  і  $\gamma$ ) їх можна використати для методу потрійного експоненційного згладження.

### 1.3.2 Метод векторної авторегресії

Векторна авторегресія (VAR, Vector Auto Regression) [66] є набором часових рядів, в яких поточні значення залежать від попередніх значень. Векторні моделі авторегресії будуються на основі стаціонарних часових рядів, і найпростіша векторна авторегресійна модель представлена рівнянням (1.10).

$$\begin{cases} x_{t1} = a_{10} + a_{11}x_{t-1,1} + a_{12}x_{t-1,2} + \varepsilon_{t1} \\ x_{t2} = a_{20} + a_{21}x_{t-2,1} + a_{22}x_{t-1,2} + \varepsilon_{t2} \end{cases} \quad (1.10)$$

Вона складається з  $a_{10}$ ,  $a_{20}$  які являють собою вільні параметри, з параметрів авторегресії  $a_{ij}$ , та взаємно не корельованого білого шуму, змінні

мають певний лаг який задається. При чому кількість рівнянь дорівнює кількості змінних. Рівняння (1.11) являє собою вид рівняння (1.10) з кількістю змінних  $k$ :

$$\begin{aligned}
 \{x_{t1} &= a_1 + a_{11}^{[1]}x_{t-1,1} + \dots + a_{1k}^{[1]}x_{t-1,k} + a_{11}^{[2]}x_{t-2,1} + \dots + a_{1k}^{[2]}x_{t-2,k} + \dots \\
 &+ a_{11}^{[p]}x_{t-p,1} + \dots + a_{1k}^{[p]}x_{t-p,k} + \varepsilon_{t1} x_{t2} \\
 &= a_2 + a_{21}^{[1]}x_{t-1,1} + \dots + a_{2k}^{[1]}x_{t-1,k} + a_{21}^{[2]}x_{t-2,1} + \dots + a_{2k}^{[2]}x_{t-2,k} + \dots \\
 &+ a_{21}^{[p]}x_{t-p,1} + \dots + a_{2k}^{[p]}x_{t-p,k} + \varepsilon_{t2} \dots x_{tk} \\
 &= a_k + a_{k1}^{[1]}x_{t-1,1} + \dots + a_{kk}^{[1]}x_{t-1,k} + a_{k1}^{[2]}x_{t-2,1} + \dots + a_{kk}^{[2]}x_{t-2,k} + \dots \\
 &+ a_{k1}^{[p]}x_{t-p,1} + \dots + a_{kk}^{[p]}x_{t-p,k} + \varepsilon_{tk}
 \end{aligned}
 \tag{1.11}$$

де  $k$  – кількість змінних;

$p$  – число лагу.

Також рівняння (1.11) може мати і векторно-матричний вигляд (1.12):

$$\begin{aligned}
 (x_{t1} \ x_{t2} \ \dots \ x_{tk}) &= (a_1 \ a_2 \ \dots \ a_k) + \\
 &\left( a_{11}^{[1]} \ \dots \ a_{1k}^{[1]} \ a_{21}^{[1]} \ \dots \ a_{2k}^{[1]} \ \dots \ a_{k1}^{[1]} \ \dots \ a_{kk}^{[1]} \right) (x_{t-1,1} \ x_{t-1,2} \ \dots \ x_{t-1,k}) + \dots + \\
 &\left( a_{11}^{[p]} \ \dots \ a_{1k}^{[p]} \ a_{21}^{[p]} \ \dots \ a_{2k}^{[p]} \ \dots \ a_{k1}^{[p]} \ \dots \ a_{kk}^{[p]} \right) (x_{t-p,1} \ x_{t-p,2} \ \dots \ x_{t-p,k}) + (\varepsilon_{t1} \ \varepsilon_{t2} \ \dots \ \varepsilon_{tk})
 \end{aligned}
 \tag{1.12}$$

Або його представлення у вигляді рівняння (1.13):

$$X_t = a + A^{[1]}X_{t-1} + \dots + A^{[p]}X_{t-p} + \vec{\varepsilon}_t \tag{1.13}$$

У випадку коли часові ряди є нестационарними тоді застосовується векторна модель з корекцією похибок (VECM - vector error correction models):

$$\Delta y_t = \Pi y_{t-1} + \Gamma_1 \Delta y_{t-1} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + \varepsilon_t \tag{1.14}$$

де

$$\Pi = -(I_k - A_1 - \dots - A_p)$$

$$\Gamma_i = -(A_{i+1} + \dots + A_p), \quad i=1, \dots, p-1$$

де  $I_k$  – індивідуальна змінна

$y_{t-1}$  – нестационарна змінна

Параметри обох моделей перевіряються за допомогою методу найменших квадратів.

До переваг моделей векторної авторегресії можна віднести:

- Можливість оцінки параметрів методом найменших квадратів;
- Відсутність поділу змінних на екзогенні та ендогенні;
- Більш точна та проста модель для виконання прогнозів.

До недоліків даних моделей відносяться:

- Складний процес визначення порядку VAR моделі;
- При більшій кількості змінних та лагів необхідна більша кількість даних для оцінки параметрів;
- Коефіцієнти VAR моделі є не інтерпретованими.

Важливим етапом при побудові VAR моделі є перевірка її на стійкість (тест Гренджера). Даний тест оснований на причинно наслідкових зв'язках між часовими рядами. Загалом тест включає дві гіпотези: що змінна  $X_t$  не являється причиною зміни змінної  $Y_t$ , і  $Y_t$  не являється причиною зміни  $X_t$ . Спочатку проводиться оцінка авторегресивної моделі методом найменших квадратів. Також важливо враховувати, чутливість результатів тесту до величини лагу. Після оцінки проводиться перевірка нульових гіпотез основна мета, щоб в кожній регресії, коефіцієнти при лагах другої змінної дорівнювали нулю. Відповідно дані гіпотез перевіряються з використанням F- тестів або LM – тестів.

### **1.3.3 Штучні нейронні мережі для прогнозування часових рядів (Багатошаровий перцептрон)**

Найпростішим типом штучних нейронних мереж є багатошаровий перцептрон (MLP) [67]. Дана мережа може складатись з декількох прихованих шарів нейронів, вихід кожного шару задається формулою:

$$a_i = f(x) = \sigma(\theta_i \cdot a_{i-1} - b_i) \quad (1.15)$$

де  $\sigma$  – активаційна функція, найбільш розповсюдженою є функція логістичної сигмоїди:

$$\sigma(Z) = \frac{1}{1+e^{-Z}}; \quad (1.16)$$

$\theta_i$  – матриця вагових коефіцієнтів шару  $i$ ;

$a_{i-1}$  – вихідний вектор попереднього шару;

$b_i$  – вектор порогових значень.

Інформація передається від входу до виходу, при цьому нейрони в кожному шарі не залежать від інших нейронів в тому ж шарі.

Процес навчання загалом полягає в отриманні значень вагових коефіцієнтів та порогів нейронної мережі, які мінімізують функцію втрат:

$$\hat{\theta} = \arg \arg L(y, x, \theta) , \quad (1.17)$$

де  $\theta$  – параметри нейронної мережі  $\theta = [\theta_1, \dots, \theta_i]$ .

В задачах прогнозування часових рядів в якості функції втрат найчастіше виступає середня різниця квадратів відхилень прогнозних значень від фактичних:

$$L(y, x, \theta) = \frac{1}{2n} \sum_{t=1}^n (y_t - \hat{y}_t(x, \theta))^2 \quad (1.18)$$

Для обмеження перенавчання додатково використовують регуляризацию  $\Omega(\theta)$

$$L(\theta) = \frac{1}{2n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 + \Omega(\theta), \quad (1.19)$$

$$\Omega(\theta) = \lambda \|\theta\|_2^2 \quad (1.20)$$

де  $\lambda$  - гіперпараметр для контролю впливу регуляризації.

При прямому поширенні розраховуються вихідні значення нейронної мережі. Для мережі з одним прихованим шаром нейронів вихідне значення розраховується згідно з формулами:

$$z_1 = \sum_{i=1}^n \theta_1 x_t - b_1; \quad (1.21)$$

$$a_1 = \sigma(z_1); \quad (1.22)$$

$$z_2 = \sum_{i=1}^n \theta_2 a_1 - b_2; \quad (1.23)$$

$$a_2 = \sigma(z_2); \quad (1.24)$$

$$z_3 = \sum_{i=1}^n \theta_3 a_2 - b_3; \quad (1.25)$$

$$\hat{y}_t = a_3 = \sigma(z_3), \quad (1.26)$$

де  $\sigma$  – активаційна функція;

$w_i$  – вагові параметри;

$x_i$  – вектор вхідного шару;

$b$  – зміщення;

$a_1, a_2$  – вектори прихованих шарів;

$\hat{y}_t, a_3$  – вектор вихідного шару.

Розрахунок градієнта методом зворотного поширення проводиться за формулами наведеними нижче:

$$\begin{aligned} g_{\theta_3} &= \frac{dL}{da_3} \cdot \frac{da_3}{dz_3} \cdot \frac{dz_3}{d\theta_3}, & g_{b_3} &= \frac{dL}{da_3} \cdot \frac{da_3}{dz_3} \cdot \frac{dz_3}{db_3} \\ g_{\theta_2} &= \frac{dL}{da_3} \cdot \frac{da_3}{dz_3} \cdot \frac{dz_3}{da_2} \cdot \frac{da_2}{dz_2} \cdot \frac{dz_2}{d\theta_2}, & g_{b_2} &= \frac{dL}{da_3} \cdot \frac{da_3}{dz_3} \cdot \frac{dz_3}{da_2} \cdot \frac{da_2}{dz_2} \cdot \frac{dz_2}{db_2} \\ g_{\theta_1} &= \frac{dL}{da_3} \cdot \frac{da_3}{dz_3} \cdot \frac{dz_3}{da_2} \cdot \frac{da_2}{dz_2} \cdot \frac{dz_2}{da_1} \cdot \frac{da_1}{dz_1} \cdot \frac{dz_1}{d\theta_1}, & g_{b_1} &= \frac{dL}{da_3} \cdot \frac{da_3}{dz_3} \cdot \frac{dz_3}{da_2} \cdot \frac{da_2}{dz_2} \cdot \frac{dz_2}{da_1} \cdot \frac{da_1}{dz_1} \cdot \frac{dz_1}{db_1} \end{aligned}$$

де  $\frac{dL}{da} = (y_i - \hat{y}_i)$ , для сигмоїдальної функції активації  $\frac{da}{dz} = \sigma(x) \cdot (1 - \sigma(x))$ ,

$$\frac{dz}{d\theta} = a_{t-1}.$$

Після розрахунку значень градієнта похибки можна використовуватись один з алгоритмів оптимізації першого порядку.

### 1.3.4 Рекурентна нейронна мережа




Рис. 1.7 Схема рекурентної нейронної мережі

Рекурентні нейронні мережі відносяться до нейронних мереж прямого поширення, але з деякими особливостями. Нейрони використовують не тільки вхідну дані, але і дані від самих себе за попередній прохід. Завдяки цьому ШНМ може враховувати важливу інформацію про дані попередніх значень періодів часового ряду. Одним з видів рекурентних нейронних мереж є нейронна мережа Елмана. На рисунку 1.7 представлено схему рекурентної нейронної мережі Елмана. Дана нейронна мережа подібна на класичний перцептрон, але додатково має набір контекстних блоків які з'єднані з прихованим шаром. З кожною ітерацією на вхід контекстних блоків подаються значення прихованого шару. І таким чином це дозволяє зберігати інформацію для наступних прогнозів. Мережа Елмана визначається за такими функціями :

$$h_t = \sigma_h(W_h x_t + U_h h_{t-1} + b_h) \quad (1.27)$$

$$y_t = \sigma_y(W_y h_t + b_y) \quad (1.28)$$

де  $x_t$  – вектор вхідного шару,

$h_{t-1}$  – вектор прихованого шару,

$y_t$  – вектор вихідного шару,

$\sigma_h, \sigma_y$  – активаційна функція,

$W_h$  - вагові параметри,

$b_h$  - зміщення,

$U_h$  - параметри контекстного блоку.

Недоліком рекурентних нейронних мереж Елмана є проблема розмиття градієнта, тобто зменшення норм градієнта в процесі проходження через шари. Цю проблему було вирішено за допомогою комірок пам'яті які реалізована в рекурентних нейронних мережах з довгостроково короткостроковою пам'яттю.

### **1.3.5 Рекурентна нейронна мережа з довго короткостроковою пам'яттю**

Довгострокова короткострокова пам'ять (Long – short term memory LSTM) [68] являє собою особливу архітектуру рекурентної нейронної мережі, яка має можливість навчатись на довгострокових залежностях. Структура LSTM мережі дуже схожа на рекурентну, але замість одного шару нейронної мережі є цілих чотири які взаємодіють між собою певним чином. Відповідно детальний процес розрахунку починається з вибору інформації яку можна замінити згідно з умовани сигмоїдного шару (або шар фільтра забування) який описаний в рівнянні (1.29). Після чого наступний шар визначає значення які потрібно оновити (1.30) і будує вектор значень  $\tilde{C}_t$  який можна додати в стан комірки (1.31). Потім необхідно замінити старий стан комірки  $C_{t-1}$  на новий  $C_t$  за рівнянням (1.32). Останній крок полягає в розрахунку вихідної інформації за допомогою декількох фільтрів (1.33, 1.34). На рисунку 3 представлено схему LSTM мережі.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1.29)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1.30)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (1.31)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (1.32)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (1.33)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (1.34)$$

де  $\sigma$  – активаційна функція;

$W_f, W_i, W_c, W_o$  – вагові коефіцієнти;

$b_f, b_i, b_c, b_o$  – коефіцієнти зсуву;

$x_t$  – вхідні дані;

$h_{t-1}, h_t$  – прогнознi значення;

$\tilde{C}_t$  – вектор корекції комірки пам'яті;

$C_t, C_{t-1}$  – стан комірки пам'яті.

На кожному прикладі  $x_t$ , вектори пам'яті ( $C$ ) та вихідні значення попереднього кроку LSTM ( $h$ ) отримують початкові значення рівні нулю. Вектор  $\tilde{C}_t$  представляє новий варіант значень пам'яті, а вектори  $f_t$  та  $i_t$  регулюють ступінь оновлення вектора пам'яті новими значеннями. За рахунок того, що значення  $W_f, W_i$  і  $b_f, b_i$  оцінюються під час навчання. Нейронна мережа виконує регулювання динаміки оновлення  $C$  оптимальним чином з точки зору мінімізації функції втрат. Крім того, наявність вектора пам'яті допомагає зменшити ефект розмиття або вибуху градієнта під час зворотного поширення помилки. Це спільно з використанням обхідного з'єднання, яке згладжує поверхню похибки нейронної мережі, дозволяє значно прискорити навчання та отримати меншу похибку прогнозування.

LSTM відноситься до групи нейронних мереж глибинного навчання через наявність рекурентних зв'язків і можливість уникати ефект зменшення градієнта похибки.




Рис 1.8 Схема рекурентного модулю LSTM

Крім цього сам метод LSTM має ряд варіацій. Методи рекурентних нейронних мереж використовується для класифікації, розпізнавання тексту та мови. В енергетиці найбільш поширеним завданням є обробка часових рядів і краще всього з цією задачею справляються рекурентні нейронні мережі типу LSTM [69]. Так як вони перевершують за точністю просту рекурентну мережу. Використання додаткових параметрів такі як погодні фактори, астрономічні фактори або економічні, напряду впливають на ефективність навчання, узагальнюючу здатність та точність моделі.

### 1.3.6 Аналіз ефективності методів прогнозування

Одним з перших етапів дослідження включає порівняння класичних методів прогнозування для задач оперативного одно факторного прогнозування вузлових навантажень. Для прогнозування було розроблено алгоритм на основі методу потрійного експоненційного згладжування Холта-Вінтерса, даний метод описано в розділі 1.3.1. Для порівняння точності прогнозування було використано нейронну мережу глибинного навчання типу LSTM, яка описана в [46] В якості даних для прогнозування було використано вибірку з восьми вузлів континентальної частини енергосистеми ENTSO-е Данії за період з 2012 по 2014 з погодинною дискретністю. Фактична та еквівалентні схеми енергосистеми наведені на рисунку 1.9.




Рис. 1.9 Фактична та еквівалентна схема енергосистеми Данії

Оцінка точності прогнозування проводилась за допомогою функції MAPE, а її опис та аналіз отриманих результатів наведено в розділі 2.2 роботи. В таблиці 1.1 наведено похибки оперативного однофакторного прогнозування вузлового навантаження.

Таблиця 1.1

### Похибки одно факторного оперативного прогнозу

| Вузли                                                         | 1   | 2   | 3   | 4   | 5   | 6   | 7   | 8   |
|---------------------------------------------------------------|-----|-----|-----|-----|-----|-----|-----|-----|
| Метод потрійного експоненційного згладжування Холта- Вінтерса | 7,7 | 5,8 | 5,3 | 5.4 | 7,6 | 7,7 | 7,7 | 7.9 |
| Нейронна мережа глибинного навчання типу LSTM                 | 1,4 | 1,6 | 1,3 | 1,5 | 1,3 | 1,1 | 1,2 | 1,4 |

На рисунку 1.10 наведено результати добового прогнозу для вузла навантаження 1.




Рис. 1.10 Результати добового прогнозу першого вузла




Рис. 1.11 Результати добового прогнозу другого вузла




Рис. 1.12 Результати добового прогнозу третього вузла

На рисунках 1.11-1.12 наведено результати добового прогнозу для вузлів навантаження 2,3.




Рис. 1.13 Результати добового прогнозу четвертого вузла

З результатів оперативного однофакторного прогнозування видно, що метод експоненційного згладжування демонструє погодинну похибку в діапазоні 5-8%, що є гіршим у порівнянні з штучними нейронними мережами. При цьому швидкість обчислення ШНМ є більшою, що обумовлено процесом навчання нейронної мережі. Похибка прогнозу нейронної мережі становить в межах 1-2%.

Наведені результати підтверджують доцільність застосування методів прогнозування на основі штучних нейронних має ряд переваг перед класичними методами прогнозування. Ефективність ШНМ полягає в їх адаптивності до ретроспективних даних, швидкості навчання та обчислення та можливість врахування додаткових факторів. Розвиток архітектури яких наведено в наступних розділах роботи.

## ВИСНОВКИ ДО РОЗДІЛУ 1

1. Показано важливість впровадження нового ринку електроенергії України, як етапу розвитку енергетики України. Виконано аналіз нової моделі ринку електричної енергії України у порівнянні з ринком «єдиного покупця» та визначено, що оператори системи розподілу та оператор системи передачі мають прямі економічні стимули для підвищення точності короткострокових прогнозів технологічних втрат (ТВЕ). Внесені зміни до умов функціонування ринку спрямовані на покращення його роботи та посилення енергетичних зв'язків з європейськими енергетичними компаніями.

2. На основі аналізу представлених літературних джерел виявлено, що наведені дослідження щодо прогнозування навантаження в енергетичних системах спрямовані на забезпечення їх стійкості та ефективності роботи. Розглянуто різні методи прогнозування з огляду на доцільність їх використання для прогнозування вузлових навантажень, зокрема класичні статистичні методи та методи, що базуються на штучних нейронних мережах.

3. Виконано чисельний аналіз ефективності методів прогнозування, а саме методу експоненційного згладжування Холта - Вінтерса та методу на основі штучної нейронної мережі типу LSTM. Результати прогнозування показали, що використання методу прогнозування на основі штучної нейронної мережі глибинного навчання є більш ефективними у порівнянні з класичним методом прогнозування, мають меншу похибку прогнозу є гнучкими в роботі та налаштуванні під відповідні завдання.

4. Наведені результати підтверджують доцільність застосування методів прогнозування на основі штучних нейронних має ряд переваг перед класичними методами прогнозування. Ефективність ШНМ полягає в їх адаптивності до ретроспективних даних, швидкості навчання та обчислення та можливість врахування додаткових факторів. Розвиток архітектури цих ШНМ наведено в наступних розділах роботи.

*Результати експериментальних досліджень даного розділу наведено в таких публікаціях:* Посилання [8],[17],[42-44],[46-47],[49-50],[69], див. Список використаних джерел стор. 136-147.

## РОЗДІЛ 2

### ПРОГНОЗУВАННЯ ВУЗЛОВОГО НАВАНТАЖЕННЯ ЗА ДОПОМОГОЮ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ГЛИБИННОГО НАВЧАННЯ

#### 2.1 Загальні підходи до прогнозування часових рядів

Для багатокрокового прогнозування часових рядів можна використати наступні підходи [70].

Рекурсивний підхід (Rec - Recursive strategy) являє собою одинарну модель яка тренується для виконання однокрокового прогнозу наперед з урахуванням послідовності введення. Вихідний прогноз рекурсивно повертається і вважається правильним. Цей процес описано нижче:

```
 $x \leftarrow x_t$   
 $\theta \leftarrow$  порожній масив  
 $k \leftarrow 1$   
while  $k < n_o + 1$  do  
     $o \leftarrow f(x)$   
     $\theta \leftarrow \text{concatenate}(\theta, o)$   
     $x \leftarrow \text{concatenate}(x[1:], \text{vectorize}(o))$   
     $k \leftarrow k + 1$   
end while  
return  $o$  as  $\hat{y}_t$ 
```

Прямий підхід (Direct strategy) полягає у побудові набору незалежних предикторів  $f_k$  кожен з яких забезпечує прогноз. Даний підхід видає скалярні значення, але вхідний вектор є однаковим для всіх, даний процес описано нижче:

```
 $x \leftarrow x_t$   
 $\theta \leftarrow$  порожній масив  
 $k \leftarrow 1$   
while  $k < n_o + 1$  do
```

$$\theta \leftarrow concatenate(\theta, f_k(x))$$

$$k \leftarrow k + 1$$

**end while**

**return**  $o$  as  $\hat{y}_t$

Підхід (DirRec - Direct and Recursive strategy) являє собою комбінацію двох попередніх прикладів подібно до прямого підходу, але кожен предиктор визначається на наборах вхідних даних які з кожним циклом збільшуються. Процес роботи даного підходу описано нижче:

$$x \leftarrow x_t$$

$$\theta \leftarrow \text{порожній масив}$$

$$k \leftarrow 1$$

$$\text{while } k < n_o + 1 \text{ do}$$

$$o \leftarrow f_k(x)$$

$$\leftarrow concatenate(\theta, o)$$

$$x \leftarrow concatenate(x[1:], vectorize(o))$$

$$k \leftarrow k + 1$$

**end while**

**return**  $o$  as  $\hat{y}_t$

МІМО підхід (Multiple input - Multiple output) один предиктор  $f$  тренується для прогнозу усього проміжку за один раз, відмінністю даного підходу є вихідні векторні значення.

$$\hat{y}_t = f(x_t)$$

DIRMO (Direct and Multiple input - Multiple output strategy) підхід являє собою компроміс між прямим підходом та МІМО. Особливістю даного підходу є те, що він поділяє прогноз на покроковий з довжиною кроку  $s$ . І відповідно ітерація часу становитиме  $\lceil \frac{n_o}{s} \rceil$ .

В залежності від задач прогнозування та типу використаних даних необхідно застосовувати один з наведених підходів. Для прогнозування

вузлового навантаження оптимальний є прямий підхід так як дані вузлового навантаження зв'язані між собою.

## 2.2 Методика оцінки якості прогнозу

З огляду на дослідження які було розглянуто про можливості застосування методів прогнозування, виникає необхідність в виборі параметра оцінки цих прогнозів. Для оцінки задач регресії використовують ряд метрик, для визначення похибок можна виділити такі методи: середня абсолютна похибка у відсотках (MAPE) [71], середньоквадратична похибка (відхилення) (MSE), середня абсолютна похибка (MAE) [72], середньоквадратична похибка вимірювання (RMSE) [72], середня абсолютна масштабована похибка (MASE), середньоквадратичне відхилення (RMS). Кожен з даних методів має свої переваги в залежності від необхідної задачі. Для розрахунку величини похибки прогнозу при прогнозуванні вузлового та сумарного електричного навантаження застосовуються MAPE, MSE, RMSE.

*Середньо абсолютна похибка у відсотках (MAPE)*

Широко розповсюдженим методом оцінювання похибки прогнозу є розрахунок величини MAPE (mean absolute percentage error):

$$MAPE = \frac{1}{n} \sum_{t=1}^n APE_t, \quad (2.1)$$

де

$$APE_t = \frac{|W_t - PR_t|}{W_t} \cdot 100\%, \quad (2.2)$$

$PR_t$  - прогноз на  $t$ -ту годину,

$n$  – кількість годин в тестовій виборці,

$APE_t$  – абсолютне відхилення відносно фактичних значень у відсотках.

Перевагою даної формули є легкість інтерпретації результатів. До її недоліків можна віднести неоднаковий штраф для прогнозних значень вище і нижче фактичного, оскільки при прогнозних значеннях близьких до нуля

максимальне значення  $APE$  не перевищує 100%, а при пере прогнозі верхньої межі не існує.

При оцінці якості векторного прогнозу при відборі моделей важливим є однозначна інтерпретація показника точності. Оскільки  $MAPE$  розраховується для кожного вузла окремо, необхідним для адекватного відбору прогнозних моделей є приведення показників точності до одного числа. На разі пропонується використовувати критерій мінімальної максимальної  $MAPE$  вузла. При його застосуванні оцінкою похибки ( $E(m_l)$ ) прогнозу моделі  $m_l$  буде максимальне значення  $MAPE$  вузлів:

$$E(m_l) = \max\{j = 1 \dots k\}, \quad (2.3)$$

де  $k$  – кількість вузлів.

Серед множини моделей ( $M$ ) обраною буде модель для якої значення  $E(m_l)$  буде мінімальним:

$$m^* = \arg \min E(m_l). \quad (2.4)$$

Іншим варіантом оцінки може бути розрахунок середнього  $MAPE$  вузлів або розрахунок норми вектора ( $MAPE_1, MAPE_2, \dots, MAPE_j$ ).

На ряду з точністю та стабільністю, однією з основних вимог до результатів прогнозування вузлових навантажень є некорельованість похибок окремих вузлів між собою. Навіть при нульових середніх похибках вузлів, при наявності кореляції, похибка сумарного навантаження може виявитись значною, що може призвести до суттєвих похибок розрахунку втрат. Для оцінки кореляції між похибками вузлів пропонується використовувати число обумовленості матриці похибок  $E_l \in R^{n \times k}$ .

З формальної точки зору число обумовленості матриці [73] показує наскільки сильно змінюється результат множення матриці на вектор при малих збуреннях вхідного вектора.

Маючи систему лінійних рівнянь:

$$Ax = b \quad (2.5)$$

Для визначення обумовленості матриці, в першу чергу, необхідно визначитись з нормою для векторів  $x$ . Найбільш розповсюдженою є Евклідова норма:

$$\|x\| = \sqrt{\sum_{i=1}^n |x_i|^2} \quad (2.6)$$

При перемноженні вектора  $x$  на матрицю  $A$  отримаємо новий вектор  $Ax$  норма якого відрізнятиметься від норми вектора  $x$ , для визначення чутливості  $A$  визначають максимальне та мінімальне значення нового вектору  $Ax$  яке представлено рівнянням (2.7,2.8):

$$Q = \frac{\|Ax\|}{\|x\|} \quad (2.7)$$

$$q = \frac{\|Ax\|}{\|x\|} \quad (2.8)$$

Відношення  $Q$  до  $q$  називається числом обумовленості матриці  $A$  і позначається як  $cond(A)$ :

$$cond(A) = \frac{Q}{q} = \frac{\frac{\|Ax\|}{\|x\|}}{\frac{\|Ax\|}{\|x\|}} \quad (2.9)$$

Якщо  $q = 0$ , то  $cond(A) = +\infty$  - матриця неповного рангу. Якщо число обумовленості більше тим ближче матриця до неповного рангу. Чим ближче матриця до одиничної матриці, тим ближче число обумовленості до 1.

При використанні Евклідової норми число обумовленості можна розрахувати, як відношення максимального і мінімального сингулярних чисел матриці.

При наявності значної кореляції між вузлами число обумовленості буде збільшуватись, що дасть можливість відібрати прогностну модель з найменшою кореляцією похибок прогнозу навантаження вузлів.

*Середньоквадратична похибка MSE*

Ще одним параметром оцінки який використовується при дослідженню методів прогнозування є середньоквадратична похибка MSE (Mean squared error):

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.10)$$

де  $n$  – кількість значень прогнозу;

$Y$  – вектор фактичних значень;

$\hat{Y}$  – Вектор з прогнозованих значень.

Дана параметр оцінки вимірює квадратичну різницю між прогнозним та фактичним значенням. Похибка MSE має майже завжди позитивне значення.

Крім того, якщо взяти квадратний корінь MSE ми отримаємо середньоквадратичне відхилення RMSE (Root mean squared error) або ж стандартна похибка:

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (\hat{y}_t - y_t)^2}{T}} \quad (2.11)$$

де  $\hat{y}_t$  – прогнозне значення;

$y_t$  – регресійні значення;

$T$  – період.

RMSE дозволяє враховувати не лише систематичні помилки, але також і випадкові.

*Середня абсолютна похибка MAE*

Дана функція MAE (mean absolute error) використовується для визначення похибок між парними спостереженнями, що виражають одне і теж саме явище.

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n} \quad (2.12)$$

де  $y_i$  – прогнозе значення;

$x_i$  – фактичне значення;

$n$  – кількість значень прогнозу.

Похибка MAE наївного прогнозу за весь період :

$$MAE_{naive} = \frac{\sum_{i=2}^n |y_i - y_{i-1}|}{n-1} \quad (2.13)$$

*Середня абсолютна масштабована похибка MASE*

MASE (mean absolute square error) міра точності прогнозів, має переваги у порівнянні з іншими методами розрахунку помилок прогнозу. Даний підхід дозволяє порівнювати прогнози наборів даних з різними масштабами. Дана похибка використовується для розрахунків сезонних та не сезонних часових

рядів. Похибка MASE визначається співвідношенням середньої абсолютної похибки MAE та алгоритму наївного прогнозу MAE.

$$MASE = \frac{MAE}{MAE_{naive}} \quad (2.14)$$

MASE дає вказівку на ефективність алгоритму прогнозування щодо наївного прогнозу. Його значення більше одиниці означає, що алгоритм працює погано порівняно з наївним прогнозом.

MASE стійкий до проблеми, з якою стикається середня абсолютна відсоткова помилка (MAPE), коли фактичний результат часового ряду на будь-якому кроці часу дорівнює нулю. У цій ситуації MAPE дає нескінченний вихід, що не має сенсу. Однак слід зазначити, що для часового ряду з усіма значеннями, що дорівнюють нулю на всіх кроках, вихід MASE також не буде визначено, але такі часові ряди нереалістичні.

MASE не залежить від масштабу прогнозу, оскільки він визначається за допомогою співвідношення помилок у прогнозі. Це означає, що значення MASE будуть подібними, якщо ми прогнозуємо високоцінні часові ряди, такі як кількість пакетів інтернет-трафіку, що перетинають маршрутизатор щогодини, порівняно з прогнозованою кількістю пішоходів, що перетинають жвавий світлофор щогодини.

### *Середньоквадратичне відхилення RMS*

RMS (root mean square) є окремим випадком узагальненого середнього. Функція RMS має вигляд:

$$x_{RMS} = \sqrt{\frac{1}{n}(x_1^2 + x_2^2 + \dots + x_n^2)} \quad (2.15)$$

## **2.3 Розробка архітектури штучної нейронної мережі глибинного навчання для прогнозування вузлового навантаження**

В роботі [74] аргументуються, що причиною ефективності глибинних нейронних мереж є їх природна можливість відображати композиційні залежності виду:

$$f(x_1, \dots, x_n) = h_1 \left( h_2 \left( h_3 \left( h_4 (\dots h_l (x_{n-k}, \dots, x_n)) \right) \right) \right) \quad (2.16)$$

де  $h_i$  можна інтерпретувати як вихід прихованого шару нейронів.

Нейронна мережа, яка має більше прихованих шарів, може більш точно апроксимувати складні функціональні залежності, що дає змогу досягти кращих результатів.

Значного збільшення кількості шарів в мережі вдалось досягти завдяки використанню обхідних з'єднань (shortcut connections) [75] між шарами прихованих нейронів. В роботі використовуються згорткові шари. Вихід блоку з обхідним зв'язком можна записати:

$$y = \theta_2 \cdot \sigma(\theta_1 \cdot x + b_1) + b_2 + x.$$

В цій же роботі автори запропонували архітектуру на базі блоків з обхідними зв'язками *ResNet*, яка включає 152 згорткових шари. На момент створення дана нейронна мережа досягла найкращих результатів в конкурсі по розпізнаванню зображень (ISVRC, 2015). Враховуючи універсальний характер обхідних з'єднань вони можуть бути адаптовані для використання в задачі короткострокового прогнозування ЕН.

В дослідженні [76] було показано, що така структура мережі еквівалентна ансамблю простих нейронних мереж. Завдяки наявності обхідних з'єднань, інформація проходить від входу до виходу через декілька шляхів, кожен з яких має різну кількість шарів. Це дозволяє градієнту похибки пройти через меншу кількість шарів, що зменшує вплив нестабільності градієнта при навчанні (тобто зменшення або збільшення норми градієнта при розповсюдженні через шари ШНМ).

У роботі [77] пояснюється, що ефект обходу шляхом передачі інформації допомагає згладжувати гіперплощину функції втрат, що сприяє полегшенню процесу навчання глибоких нейронних мереж. Автори роботи вважають, що цей ефект є наслідком геометрії гіперплощини функції втрат.

Використання обхідних з'єднань показало високу ефективність в задачі короткострокового прогнозування сумарного електричного навантаження [78].

Для прогнозування вузлового навантаження за допомогою одного фактора запропоновано використовувати гібридну архітектуру з модулем LSTM, багатошаровим перцептроном та обхідними з'єднаннями net1 (зображені на рис. 2.1). Вихід модуля LSTM вводиться в багатошаровий перцептрон з двома прихованими шарами (Dense\_1, Dense\_2). Розмірність Dense\_1 обирається більшою за  $n$ , розмірність Dense\_2 дорівнює  $n$ , оскільки вихід перцептрона поелементно додається до входу нейронної мережі. У випадку одного фактора обхідні з'єднання не використовують додаткові матриці вагових коефіцієнтів.

В якості активаційної функції прихованого шару MLP використовується функція *selu* (scaled exponential linear unit) [79], яка має вигляд:

$$selu = \lambda \{ z \quad ae^z - a \quad z > 0 \quad z \leq 0 \quad (2.17)$$

де  $z$  – лінійна комбінація виходів попереднього шару  $z = Wx$ ,  $x$  – вектор-рядок виходів попереднього шару;

$\lambda, a$  – параметри, які необхідні для забезпечення властивості саморегуляризації, при цьому рекомендовані значення параметрів  $a = 1,6733$  та  $\lambda = 1,0507$ .




Рис. 2.1. Блок-схема мережі net1

Вихід нейронної мережі задається формулою:

$$\hat{y}_t = x_t + W_2 \cdot \text{selu}(W_1 \cdot h_t + b_1) + b_2. \quad (2.18)$$

Загальна кількість параметрів кожного шару наведено в таблиці 2.1. Значення наводяться для даних США (10 вузлів).

Таблиця 2.1

### Параметри нейронної мережі net1

| Назва шару         | Розмірності      | Кількість параметрів |
|--------------------|------------------|----------------------|
| Input (InputLayer) | [(None, 25, 10)] | 0                    |
| Recurent (LSTM)    | (None, 10)       | 840                  |
| Dense_1 (Dense)    | (None, 20)       | 220                  |
| Dense_2 (Dense)    | (None, 10)       | 210                  |

Для навчання даної нейронної мережі запропоновано використовувати алгоритм оптимізації ADAM [80]. Для оновлення вагових коефіцієнтів використовується градієнт функції похибки, а також квадрат градієнта для оцінки кривизни. Процедура оновлення вагових коефіцієнтів має наступний алгоритм:

$$w_t = w_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (2.19)$$

де  $t$  – номер ітерації процедури навчання;

$w_t, w_{t-1}$  – вектори вагових коефіцієнтів на ітерації  $t$  та  $t-1$ ;

$\alpha$  – крок навчання, рекомендоване значення 0,001;

$\epsilon$  – константа яка запобігає похибкам обчислення при діленні на 0, зазвичай  $\epsilon = 10^{-8}$ ;

$\hat{m}_t$  – вектор скоригованих експоненційно згладжених значень градієнта, який обчислюється за процедурою:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (2.20)$$

де  $m_t$  – експоненційно згладжений вектор градієнта:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.21)$$

де  $g_t$  – градієнт функції похибки;

$\beta_1$  – коефіцієнт згладження;

$\hat{v}_t$  – вектор скоригованих експоненційно згладжених значень квадрата градієнта, який обчислюється за процедурою:

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.22)$$

де  $v_t$  – експоненційно згладжений вектор квадрата градієнта:

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.23)$$

Квадрат градієнта розраховується поелементно. На першій ітерації  $m_0$  та  $v_0$  ініціалізуються нульовими векторами.

Ця процедура навчання автоматично коригує крок навчання для кожного параметру і зменшує його з кожною ітерацією, що дозволяє досягати високої ефективності в задачах оптимізації з великою кількістю параметрів, зокрема в задачах прогнозування вузлових навантажень.

Запропонована нейронна мережа реалізована у вигляді комп'ютерної програми мовою програмування Python.

Широкої популярності в задачах обробки часових рядів набувають штучні нейронні мережі з шарами згортки. Згорткові нейронні мережі являють собою особливу архітектуру ШНМ, яка використовується в глибокому навчанні. Найчастіше згорткові штучні нейронні мережі використовуються для класифікації зображень.




Рис. 2.2. Блок-схема мережі net2

На відміну від повно зв'язних шарів в яких кожен нейрон наступного шару з'єднаний з нейроном попереднього в згорткових шарах нейрон наступного шару з'єднаний з декількома нейронами попереднього, які утворюють локальне рецептивне поле нейрона наступного шару. З'єднання відбувається через матрицю-ядро значно меншої розмірності, ніж попередній шар. При цьому ядро однакове для всіх нейронів наступного шару. Значення параметрів ядра визначаються в процесі навчання. Зазвичай використовують декілька ядер, що призводить до паралельної обробки вхідних даних.

В рамках роботи запропоновано архітектуру нейронної мережі (net2) в якій поєднано шари згортки та двонаправлену LSTM (рис. 2.2). Кількість параметрів наведено в таблиці 2.2.

Таблиця 2.2

### Параметри мережі net2

| Назва шару                    | Розмірності      | Кількість параметрів |
|-------------------------------|------------------|----------------------|
| Input (InputLayer)            | [(None, 25, 10)] | 0                    |
| conv1d (Conv1D)               | (None, 24, 168)  | 3528                 |
| conv1d_1 (Conv1D)             | (None, 22, 168)  | 84840                |
| conv1d_2 (Conv1D)             | (None, 19, 168)  | 113064               |
| conv1d_3 (Conv1D)             | (None, 15, 168)  | 141288               |
| max_pooling1d (MaxPooling1D)  | (None, 7, 168)   | 0                    |
| bidirectional (Bidirectional) | (None, 20)       | 14320                |
| Dense_1 (Dense)               | (None, 20)       | 420                  |
| SELU1 (Activation)            | (None, 20)       | 0                    |
| Dense_2 (Dense)               | (None, 10)       | 210                  |

Однією з переваг нейронних мереж є їх гнучкість при використанні зовнішньої інформації [81]. В контексті задачі короткострокового прогнозування вузлового навантаження в якості зовнішніх факторів найчастіше використовуються:

- календарні (година доби, день тижня, місяць року, сезон, номер тижня тощо);
- метеорологічні (температура навколишнього середовища, швидкість та напрям вітру, вологість, хмарність, наявність та тип опадів або природного явища);
- технологічні (навантаження енергоємних підприємств, інформація про режими роботи споживачів регуляторів, технологічні витрати енергії,

доступність альтернативних джерел тепла, впровадження нових технологій та інш.);

- астрономічні (зміна часу сходу та заходу сонця протягом року).

В запропонованій архітектурі можливо використовувати в якості вхідної інформації вузлове навантаження, технологічні параметри, а також календарні особливості та температурні дані.

В рамках даного дослідження [49], для порівняння різних підходів до врахування зовнішніх факторів, використовувались дані про день тижня. Дані закодовано у вигляді цілого значення від 0 до 6, де 0 – понеділок, а 6 – неділя.

Досліджено два підходи:

- додавання додаткового стовпчика до вхідних даних, зовнішня інформація враховується у вигляді віртуального вузла(net1+);
- використання паралельної гілки в архітектурі штучної нейронної мережі.




Рис. 2.3. Блок-схема мережі net3

При першому підході використовувалась нейронна мережа net1 з додатковим вхідним нейроном.

При другому підході інформація про зовнішні фактори подається на паралельний вхід нейронної мережі net3 (рис. 2.3). Кількість параметрів даної нейронної мережі наведено в таблиці 2.3.

Виходом шару Dense2 є матриця вагових коефіцієнтів для шару Dense3. Даний підхід дозволяє повністю змінювати шар Dense3 в залежності від дня тижня.

*Таблиця 2.3*

### Параметри мережі net3

| Назва шару               | Розмірності      | Кількість параметрів |
|--------------------------|------------------|----------------------|
| Input (InputLayer)       | [(None, 25, 10)] | 0                    |
| Input2 (InputLayer)      | [(None, 25, 1)]  | 0                    |
| Recurent (LSTM)          | (None, 10)       | 840                  |
| Recurent0 (LSTM)         | (None, 20)       | 1760                 |
| Dense_1 (Dense)          | (None, 20)       | 220                  |
| Dense_2 (Dense)          | (None, 200)      | 4200                 |
| Dense_3 (Lambda)         | (None, 10)       | 220                  |
| Reshape_inp1<br>(Lambda) | (None, 10)       | 0                    |
| Merge (Add)              | (None, 10)       | 0                    |

## 2.4 Однофакторне прогнозування вузлового навантаження

Для однофакторного прогнозування вузлового навантаження була розроблена штучна нейронна мережа типу LSTM яка описана в розділі 2.3. Також даний метод нейронних мереж глибинного навчання порівнювався з нейронною мережею під назвою eResNet[78] яка була розроблена в Інституті електродинаміки та застосована для прогнозу сумарного навантаження ВДЕ.

В якості ретроспективних даних використано дані 11 вузлів навантаження континентальної частини Європи. Результати прогнозування наведені в таблицях 2.4-2.5. при різних об'ємах вхідних даних,  $l$  – величина лагу даних передісторії,  $\mu$  – середня похибка по всіх вузлах,  $\sigma$  – стандартне відхилення похибки. В таблиці 2.4 наведено результати похибок прогнозування при різних горизонтах прогнозування.

Таблиця 2.4

**Похибки прогнозу для різних нейронних мереж з різною розмірністю вхідних даних**

| Вузли навантаження     | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | $\mu$       | $\sigma$    |
|------------------------|------|------|------|------|------|------|------|------|------|------|------|-------------|-------------|
| Горизонт прогнозування |      |      |      |      |      |      |      |      |      |      |      |             |             |
| LSTM                   |      |      |      |      |      |      |      |      |      |      |      |             |             |
| $l = 24$               | 5,13 | 6,36 | 4,23 | 4,31 | 4,84 | 5,21 | 4,54 | 4,24 | 4,64 | 3,95 | 4,15 | <b>4,69</b> | <b>0,68</b> |
| $l = 48$               | 5,11 | 5,76 | 3,72 | 3,87 | 4,43 | 5,09 | 4,03 | 3,67 | 4,23 | 3,34 | 3,68 | <b>4,26</b> | <b>0,76</b> |
| $l = 72$               | 4,43 | 3,8  | 2,91 | 2,89 | 3,11 | 4,28 | 2,8  | 2,52 | 2,93 | 2,4  | 2,63 | <b>3,16</b> | <b>0,7</b>  |
| $l = 96$               | 3,71 | 3,81 | 2,8  | 2,93 | 2,98 | 3,99 | 2,44 | 2,41 | 2,6  | 2,37 | 2,57 | <b>2,97</b> | <b>0,6</b>  |
| $l = 120$              | 3,26 | 4,13 | 2,95 | 2,94 | 3,3  | 4,39 | 3,12 | 2,64 | 3,2  | 2,4  | 2,7  | <b>3,18</b> | <b>0,6</b>  |
| $l = 144$              | 3,98 | 4,59 | 3,03 | 3,33 | 3,57 | 4,39 | 3,18 | 2,92 | 3,34 | 2,73 | 3,07 | <b>3,47</b> | <b>0,61</b> |
| $l = 168$              | 4,02 | 4,23 | 3,18 | 3,47 | 3,58 | 4,71 | 3,18 | 3,01 | 3,28 | 2,78 | 3,15 | <b>3,51</b> | <b>0,58</b> |
| $l = 192$              | 3,99 | 4,29 | 3,16 | 3,15 | 3,67 | 4,7  | 3,27 | 2,87 | 3,43 | 2,68 | 2,97 | <b>3,47</b> | <b>0,63</b> |
| eResNet                |      |      |      |      |      |      |      |      |      |      |      |             |             |
| $l = 24$               | 11,7 | 11   | 9,6  | 7,2  | 7,85 | 6,87 | 7,15 | 9,29 | 7,53 | 6,85 | 7,23 | <b>8,39</b> | <b>1,74</b> |
| $l = 48$               | 5,13 | 6,36 | 4,23 | 4,31 | 4,84 | 5,21 | 4,54 | 4,24 | 4,64 | 3,95 | 4,15 | <b>4,69</b> | <b>0,68</b> |
| $l = 72$               | 6,1  | 6,91 | 5,75 | 4,99 | 5,57 | 5,96 | 5,09 | 4,82 | 5,22 | 4,9  | 4,92 | <b>5,48</b> | <b>0,66</b> |
| $l = 96$               | 5,64 | 6,46 | 5,37 | 4,51 | 5,18 | 5,58 | 4,71 | 4,41 | 4,8  | 4,67 | 4,42 | <b>5,07</b> | <b>0,65</b> |
| $l = 120$              | 4,54 | 5,55 | 5,14 | 3,74 | 4,57 | 5,1  | 3,87 | 3,68 | 4,04 | 4,03 | 3,66 | <b>4,36</b> | <b>0,67</b> |
| $l = 144$              | 4,25 | 5,01 | 4,62 | 3,53 | 4,09 | 4,91 | 3,59 | 3,34 | 3,68 | 3,51 | 3,35 | <b>3,99</b> | <b>0,62</b> |
| $l = 168$              | 2,99 | 4,36 | 3,66 | 2,75 | 3,36 | 4,12 | 2,84 | 2,65 | 2,9  | 2,67 | 2,76 | <b>3,19</b> | <b>0,61</b> |
| $l = 192$              | 3,02 | 4,22 | 3,39 | 2,72 | 3,31 | 4,11 | 2,63 | 2,5  | 2,76 | 2,58 | 2,54 | <b>3,07</b> | <b>0,62</b> |

**Результати похибок прогнозів при різних горизонтах упередження  
прогнозів**

| Вузли<br>навантаження     | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   | $\mu$       | $\sigma$    |
|---------------------------|------|------|------|------|------|------|------|------|------|------|------|-------------|-------------|
| Горизонт<br>прогнозування |      |      |      |      |      |      |      |      |      |      |      |             |             |
| LSTM                      |      |      |      |      |      |      |      |      |      |      |      |             |             |
| 24                        | 3,71 | 3,81 | 2,8  | 2,93 | 2,98 | 3,99 | 2,44 | 2,41 | 2,6  | 2,37 | 2,57 | <b>2,97</b> | <b>0,6</b>  |
| 48                        | 4,84 | 5,15 | 3,85 | 4,14 | 4,02 | 4,95 | 3,42 | 3,48 | 3,64 | 3,22 | 3,72 | <b>4,04</b> | <b>0,66</b> |
| 72                        | 5,66 | 6,29 | 4,42 | 4    | 4,43 | 5,02 | 3,7  | 3,48 | 3,81 | 3,38 | 3,74 | <b>4,36</b> | <b>0,94</b> |
| 96                        | 5,27 | 6,22 | 5    | 4,29 | 4,48 | 5,37 | 3,78 | 3,66 | 4,04 | 3,72 | 3,97 | <b>4,53</b> | <b>0,83</b> |
| eResNet                   |      |      |      |      |      |      |      |      |      |      |      |             |             |
| 24                        | 2,92 | 4,17 | 3,33 | 2,73 | 3,24 | 4,13 | 2,56 | 2,44 | 2,65 | 2,56 | 2,59 | <b>3,03</b> | <b>0,62</b> |
| 48                        | 3,82 | 5    | 4,34 | 3,36 | 3,78 | 4,63 | 3,14 | 2,98 | 3,27 | 3,23 | 3,16 | <b>3,7</b>  | <b>0,68</b> |
| 72                        | 4,29 | 5,48 | 4,76 | 3,68 | 4,07 | 4,73 | 3,38 | 3,25 | 3,48 | 3,57 | 3,41 | <b>4,01</b> | <b>0,72</b> |
| 96                        | 4,6  | 5,62 | 5,28 | 3,79 | 4,24 | 4,84 | 3,53 | 3,38 | 3,61 | 3,69 | 3,6  | <b>4,2</b>  | <b>0,78</b> |

З наданих результатів можна зробити висновок, що мережа з модулем LSTM є точнішою, ніж мережа eResNet, проте вона має меншу масштабованість. Зі збільшенням кількості вузлів, кількість параметрів мережі eResNet зростає швидше, ніж в мережі з модулем LSTM, що потребує більше обчислювальних ресурсів. Незважаючи на те, що час навчання однієї мережі eResNet менший, завдяки рекурентним операціям в мережі LSTM, загальна кількість обчислювальних ресурсів для навчання 11 нейронних мереж є більшою.

## **2.5 Прогнозування з врахуванням температури на основі однофакторної архітектури ШНМ**

Розвитком дослідження прогнозу вузлового навантаження є розробка та аналіз методів багатфакторного прогнозування [82]. В тому числі прогнозування вузлового навантаження з врахуванням температури повітря в

якості додаткового фактора. Для перевірки точності прогнозування з врахуванням температури повітря використовувалась та ж нейронна мережа глибинного навчання. В якості даних для дослідження використовувались дані експериментальної заступної схеми UESTEE яка складається з 12 вузлів за період з 2013 по 2014. Навчання проводилось на даних за 2013 рік, тестування проводилось на даних за 2014 рік. В якості даних температури повітря використано дані з метеостанцій наближених до центрів навантаження вузлів. Прогноз проводилось на декількох вибірках даних. Вибірki поділяються на робочі та вихідні дні та ці ж вибірки з врахуванням температури. Результати прогнозування наведено в таблицях 2,6-2,7.

*Таблиця 2.6*

**Похибки прогнозів однофакторної моделі та моделі з використанням температурних даних**

| Вузли                  | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   |
|------------------------|------|------|------|------|------|------|------|------|------|------|------|
| Однофакторний прогноз  | 7,52 | 8,15 | 5,70 | 5,92 | 6,14 | 6,60 | 5,76 | 5,61 | 6,46 | 5,50 | 5,37 |
| Прогноз з температурою | 7,29 | 8,2  | 5,14 | 5,81 | 5,73 | 5,69 | 5,21 | 5,69 | 6,38 | 5,35 | 4,99 |

*Таблиця 2.7*

**Похибки прогнозів робочих та вихідних днів з врахуванням температури повітря**

| Вузли                 | 1    | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11   |
|-----------------------|------|------|------|------|------|------|------|------|------|------|------|
| Прогноз робочих днів  | 4,71 | 5,42 | 4,72 | 4,12 | 5,30 | 5,85 | 3,83 | 3,81 | 3,59 | 3,8  | 3,67 |
| Прогноз вихідних днів | 5,69 | 7,8  | 4,87 | 4,85 | 5,53 | 5,9  | 4,24 | 4,47 | 4,25 | 4,64 | 4,99 |

З результатів прогнозування видно що врахування температури повітря дозволяє зменшити похибку прогнозу в межах 0.5% від однофакторного прогнозу. Також прогноз з різними вибірками даних демонструє незначну розбіжність в величині похибки між робочими та вхідними днями що зумовлено різним об'ємом навчальних та тестових вибірок.

## **2.6 Комп'ютерна модель короткострокового прогнозування вузлового електричного навантаження**

На основі розробленої архітектури штучної нейронної мережі яка описана в розділі 2.3. було розроблено комп'ютерну модель. Модель розроблена для прогнозування вузлового електричного навантаження для учасників ринку електроенергії України. Отримання точних прогнозів дозволяє зменшити небаланси електроенергії та зменшує необхідність в закупівлі додаткової електроенергії на балансуєчому ринку, що в свою чергу дозволяє зменшити витрати на електроенергію.

Комп'ютерна модель реалізована у вигляді виконуваного застосунку блок схема якого представлена на рисунку 2.4.



Рис. 2.4 Блок схема комп'ютерної моделі прогнозування вузлового навантаження.

Комп'ютерна модель призначена для використання під управлінням операційної системи Windows.

Програмна модель складається з наступних модулів:

- Програмний інтерфейс з модулем вводу та відображення даних;
- Модуль прогнозування на основі архітектури штучної нейронної мережі LSTM;
- Модуль відображення результатів прогнозування.

Інтерфейс програми має загальне робоче поле наведене на рисунку 2.5 яке розділене на поле вводу та підготовки даних та поле відображення результатів прогнозування та похибок прогнозування.




Рис.2.5 Інтерфейс програми до введення даних

В лівій частині робочого поля відображаються ввідні дані та налаштування та налаштування прогнозу та містить такі поля:

- Поле вибору файлу ввідних даних. Завантаження файлів з ретроспективною інформацією.
- Поле вибору параметрів прогнозу. Вибір діапазону прогнозу та кількості епох навчання.
- Поле відображення похибки прогнозування MAPE. Відображає середню абсолютну похибку прогнозу у відсотках.

Права частина робочого поля відображає результати прогнозування та параметри вибору відображення прогнозних графіків:

- Поле вибору параметрів відображення графіків прогнозування;
- Поле відображення результатів прогнозу. Відображає прогнозні значення за вказаний період прогнозу.

В полі вибору файлу для завантаження, відображається шлях до файлу з ретроспективними даними. Для вибору файлу необхідно натиснути кнопку «Відкрити» після чого відкривається спливаюче вікно вибору файлу (рисунок 2.6.). При виборі файлу необхідно натиснути кнопку «Відкрити» для вказання шляху для завантаження файлу в програму.




Рис.2.6 Вікно вибору файлу для завантаження

Для роботи програми необхідно підготувати дані у вигляді таблиці Excel та зберегти її у файлі формату .csv. Дані формуються стовпцями з обов'язковим вказанням назви стовпця, перший стовець містить діапазон дат. Для роботи програми та коректного прогнозування даних необхідні дані передісторії які використовуються для навчання мережі, тому для отримання задовільних результатів прогнозування мінімальний діапазон даних передісторії повинен бути не менше одного місяця або ж 744 погодинних значення.

При натисканні кнопки «Далі» дані завантажуються в програму аналізуються якщо дані в файлі відповідають умовам роботи програми у вікні вибору параметрів прогнозу з'являться діапазон дат ретроспективних даних за

якими можливо провести прогноз. Прогноз можливо виконати як для однієї доби, так до одного місяця.

При виборі періоду прогнозу усі попередні значення у файлі використовуються для навчання нейронної мережі. Також параметром налаштування прогнозу є вибір кількості епох навчання, що в свою чергу впливає на ефективність навчання нейронної мережі і тривалість опрацювання даних. Після вказання періоду прогнозування та кількості епох для початку прогнозування необхідно натиснути кнопку «Прогноз». Після навчання та прогнозування нейронної мережі усі результати відображаються у відповідних полях (рисунок 2.7).

Прогноз вузлових навантажень

Файл Інструкція

Оберіть файл для завантаження  
F:\Visual\for artic\IF\_dubl\_detect.csv Відкрити Далі

Оберіть параметри прогнозу

Дата з Дата до

14.08.2019 15.08.2019 16.08.2019 17.08.2019 18.08.2019

100 Кількість епох навчання

Прогноз

Результати похибки прогнозу MAPE, %

| Value1 | Value2 | Value3 | Value4 | Value5 | Value6 | Value7 | Value8 | Value9 | Value10 |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|---------|
| 8.48   | 5.15   | 5.9    | 6.38   | 2.62   | 4.24   | 9.01   | 5.81   | 1.8    | 4.55    |

Зберегти результати прогнозу

Вкажіть параметри відображення графіків

Value1 Value2 Value3 Value4 Value5

15.08.2019 16.08.2019 17.08.2019 18.08.2019

Графік

Plot test

Результати прогнозу

| Дата       | Час | Value1  | Value2  | Value3  | Value4 | Value5 | Value6  | Value7  | Value8  | Value9 | Value10 |
|------------|-----|---------|---------|---------|--------|--------|---------|---------|---------|--------|---------|
| 15.08.2019 | 01  | 2748.39 | 2639.03 | 7442.89 | 632.96 | 714.4  | 1656.46 | 3996.24 | 1304.16 | 380.82 | 236.0   |
| 15.08.2019 | 02  | 2703.19 | 2636.71 | 7344.81 | 619.51 | 713.55 | 1616.74 | 3980.58 | 1299.9  | 386.03 | 238.21  |
| 15.08.2019 | 03  | 2588.99 | 2607.35 | 7190.1  | 610.37 | 720.22 | 1585.29 | 3922.13 | 1276.36 | 398.15 | 239.68  |
| 15.08.2019 | 04  | 2514.34 | 2593.88 | 7051.09 | 590.45 | 720.38 | 1526.87 | 3886.55 | 1251.55 | 391.44 | 231.38  |
| 15.08.2019 | 05  | 2406.14 | 2567.49 | 6901.26 | 576.0  | 714.77 | 1456.45 | 3759.89 | 1231.34 | 386.51 | 220.75  |
| 15.08.2019 | 06  | 2281.47 | 2559.92 | 6814.28 | 563.79 | 699.2  | 1411.91 | 3631.5  | 1216.32 | 384.69 | 216.31  |
| 15.08.2019 | 07  | 2215.41 | 2609.25 | 6686.16 | 553.68 | 689.0  | 1361.84 | 3554.07 | 1224.76 | 389.16 | 212.0   |
| 15.08.2019 | 08  | 2052.04 | 2115.4  | 6406.6  | 536.54 | 664.1  | 1241.63 | 3348.7  | 1125.28 | 401.02 | 199.53  |
| 15.08.2019 | 09  | 1839.5  | 2005.92 | 6025.98 | 491.27 | 637.01 | 1147.74 | 3100.23 | 1029.19 | 400.88 | 184.26  |

Рис. 2.7 Інтерфейс програми прогнозування вузлового навантаження з відображенням результатів прогнозування

Після прогнозування в полі «Результати похибки прогнозування MAPE» відображаються величини похибок прогнозу MAPE по кожному вузлі окремо.

В правій частині робочого вікна відображають з прогнозовані значення та додаткові параметри для відображення графіків та їх порівняння з фактичними значеннями. Серед параметрів відображення графіків можна вибрати які вузли відобразити та за яку прогнозу добу. При натисканні кнопки «Графік» в окремому в спливаючому вікні відображається обраний графік представлений на рисунку 2.8.




Рис. 2.8 Графік прогнозних результатів

Усі отримані результати прогнозування можливо зберегти у вигляді таблиці Excel формату .csv, яка буде створена в папці де зберігається програма.

## ВИСНОВКИ ДО РОЗДІЛУ 2

1. Досліджено загальні підходи до прогнозування часових рядів, що описуються п'ятьма методами: рекурсивний, прямий, метод DirRec, MIMO та DIRMО методи. Встановлено, що для прогнозування вузлового навантаження оптимальним є прямий підхід, оскільки дані про вузли навантаження мають зв'язки між собою.

2. Показано, що оцінка точності прогнозування є важливою частиною процесу прогнозування в електричних мережах. Відзначено, що для розрахунку величини похибки прогнозу вузлового та сумарного електричного навантаження можна застосовувати різні методи, кожен з цих методів має свої переваги в залежності від задачі застосування. Показано, що при відборі моделей важливим є однозначна інтерпретація показника точності прогнозу.

3. На основі аналізу публікацій щодо застосування нейронних мереж та особливості їх побудови було визначено, що застосування обхідних з'єднань дозволяє покращити ефективність та точність прогнозування розроблено архітектуру комбінованої нейронної мережі на основі багатошарового перцептрону MPL та блоком довго короткострокової пам'яті LSTM в якості прихованого шару. В якості активаційної функції виступає функція selu. А навчання нейронної мережі відбувається за допомогою алгоритму оптимізації ADAM.

4. Показано, що потужним інструментом для обробки часових рядів є згорткова штучна нейронна мережа. Враховуючи локальну інформацію згорткова нейронна мережа зменшує кількість параметрів, які потрібно навчити. Для задачі короткострокового прогнозування вузлового навантаження розроблено архітектуру нейронної мережі, яка поєднує в собі шари згортки та двонаправлену LSTM. Дана архітектура побудована для прогнозу вузлового навантаження з врахування додаткових факторів.

5. Проведені дослідження показали, що при однофакторному прогнозуванні вузлового електричного навантаження похибка прогнозування залежить від горизонту прогнозування та розмірності вхідних даних. Використання штучної мережі LSTM дозволяє покращити точність прогнозу.

6. Проведено дослідження багатфакторного прогнозу вузлового електричного навантаження з врахуванням температури повітря в якості додаткового фактора за який було визначено що багатфакторний прогноз на основі однофакторної архітектури ШНМ є ефективним методом прогнозування. Результати показали, що врахування температури повітря дозволяє зменшити похибку прогнозу в межах 0.5% від однофакторного. Встановлено, що між прогнозом робочих та вихідних днів є незначні розбіжності в похибці.

7. На основі однофакторної архітектури ШНМ розроблено комп'ютерну модель короткострокового прогнозування вузлового навантаження, яка дозволяє виконувати прогнози вузлового навантаження використовуючи власні ретроспективні дані та можливістю налаштовувати параметри прогнозу.

*Результати експериментальних досліджень даного розділу наведено в таких публікаціях:*

Посилання [8],[49],[69],[81] див.список використаних джерел стор. 136-147.

## **РОЗДІЛ 3**

### **ПОРІВНЯННЯ МЕТОДІВ АНАЛІЗУ ДАНИХ ДЛЯ ВИЯВЛЕННЯ АНОМАЛЬНИХ ДАНИХ ТА ПРОПУСКІВ НАВАНТАЖЕННЯ**

#### **3.1 Достовіризація даних часових рядів вузлового навантаження**

При побудові статистичних моделей процесу споживання електричної енергії вирішальне значення має якість вихідної інформації. Наявність пропусків та аномально великих значень в ряді даних на якому проводиться оцінка параметрів моделі призводить до недостатнього узагальнення характеру процесу та виникнення систематичних похибок.

При підвищенні автоматизації енергосистеми, втілення ідей концепції Smart Grid [83 - 88] на практиці, підвищення кількості просьюмерів вимагає ускладнення інструментів аналізу даних та визначення аномальних значень.

В умовах розвитку гібридних збройних конфліктів на передній план виходить захист енергетичних мереж від кібератак. Особливої актуальності даному питанню додає той факт, що саме Україна стала однією з перших жертв кібератаки на фізичну інфраструктуру енергосистеми [89]. Атака на «Прикарпаттяобленерго» та «Київобленерго» стала можлива завдяки доступу зловмисників до мережі системи SCADA, який було отримано через зараження електронної пошти та документів Microsoft Office.

Іншим вектором атаки може бути вплив на системи нижчого рівня з метою викликати помилкові реакції в автоматичі та АСДУ енергосистеми. Зловмисники можуть проводити маніпуляції з даними вимірювань або зовнішньою інформацією, що спричиняє значний вплив на прогнозування навантаження. Подібні кібератаки можуть нанести значну фінансову шкоду та вплинути на стійкість енергосистеми.

В статті [90] описано особливості прогнозування навантаження в умовах кібератаки на вихідні дані, а саме, як аномальна зміна навантаження впливає на точність прогнозування. За результатами досліджень жодній моделі не вдалось

забезпечити точний прогноз навантаження при значній зміні вихідних даних. Для усіх чотирьох моделей похибка (MAPE) перевищувала 10%, при 40 % змін історичних даних навантаження.

Але навіть за відсутності загрози кібератаки спотворені дані та пропуски присутні при роботі енергосистеми в нормальних режимах. Вони можуть бути пов'язані з помилками вимірювань, перешкодами в інформаційному тракті або людським фактором. За своїм характером вони можуть бути одиничні і групові. При побудові математичних моделей для прогнозування різкі зміни навантаження викликані аварійними відключеннями або раптовими технологічними чинниками у великих споживачів слід відносити до аномальних, оскільки вони не відображають взаємозв'язок між навантаженням та зовнішніми факторами, які використовуються в моделі.

У ході дослідження методів короткострокового прогнозування вузлових електричних навантажень в електроенергетичних системах за умов ринку, виникла потреба у поліпшенні методів виявлення аномальних даних (достовірності).

Базовий підхід полягає в кластеризації вихідних даних за допомогою певного алгоритму зі зменшенням його чутливості. Найбільший виявлений кластер в цьому випадку приймається за нормальні дані.

Для перевірки ефективності виявлення аномальних значень та пропущених значень в даних вузлового навантаження було розглянуто декілька найбільш поширених методів аналізу даних. Серед них: метод кластеризації Density-Based Spatial Clustering of Applications with Noise (DBSCAN) [91] - алгоритм кластеризації групує між собою точки які розташовані близько одна до одної, виділяючи точки які не входять в кластер та позначають їх як аномальне значення. Метод «Ізольованих лісів» (IF)[92] забезпечує ефективний та точний спосіб визначення аномалій завдяки формуванню дерева вирішень. Метод локального рівня викиду (LOF)[93] використовує щільність даних та визначення локальних відхилень даних між сусідніми точками для визначення викидів

даних. Наступний метод під назвою Elliptic Envelope (EE)[94] дозволяє виявити викиди у розподіленому гаусовому наборі даних.

Для дослідження використовувались ретроспективні дані 10 вузлів навантаження північно-західної частини США у період з 07.2015 по 08.2019 з дискретністю в одну годину. Для відновлення даних використовували метод лінійної інтерполяції.

Усі представлені методи достовіризації реалізовані і є частиною бібліотеки машинного навчання scikit-learn [94], яка реалізована на мовою програмування Python.

### **3.2 Аналіз вихідних даних**

Оцінку ефективності розробленої моделі запропоновано виконувати з використанням даних з відкритих джерел, що дає змогу порівнювати результати з моделями представленими в інших роботах присвячених даній темі.

Для виконання такої оцінки та подальших досліджень сформовані відповідні набори даних, що містять:

- погодинні дані за 2016 р. турецької енергосистеми, які містять інформацію про навантаження 970 вузлів [95];
- погодинні дані за період з 2015 по 2019 рр. про електричне навантаження розподільчих енергосистем Північно-Західного регіону США, 10 вузлів [96].
- погодинні дані за період з 2012 по 2014 рр. про електричне навантаження 1494 вузли континентальної частини Європи, з яких було виділено окремі вибірки даних : вибірка з 8 вузлів енергосистеми Данії, вибірка з 11 вузлів з мінімальною кореляцією.
- погодинні дані за період з 2017 по 2019 рр. про електричне навантаження 15 вузлів системи АСКУЕ АТ «Вінницяобленерго».

Представлені набори даних дозволять дослідити ефективність запропонованої моделі, як з точки зору великої кількості вузлів, так і

використання довготривалої передісторії для навчання нейронної мережі ГН. В таблиці 3.1 наведено статистичні показники даних США.

*Таблиця 3.1*

**Статичні характеристики декількох вузлів навантаження даних США**

| Вузли                          | 1       | 2     | 3     | 4   | 5   | 6     | 7    | 8     | 9    | 10  |
|--------------------------------|---------|-------|-------|-----|-----|-------|------|-------|------|-----|
| Середнє значення, МВт·год      | 2735    | 2347  | 6295  | 554 | 577 | 1376  | 3396 | 1104  | 230  | 182 |
| Стандартне відхилення, МВт·год | 36836   | 447   | 978   | 112 | 80  | 289   | 640  | 221   | 96   | 46  |
| Max, МВт·год                   | 3340061 | 21556 | 11827 | 998 | 982 | 11297 | 5504 | 11583 | 591  | 397 |
| Min, МВт·год                   | -90964  | 630   | 2600  | -12 | 362 | 748   | 679  | 0     | -819 | 0   |

Аналіз даного набору даних показав наявність аномальних значень, як одиничних, так і групових. За природою виникнення їх можна розділити на два класи: пропущені дані та помилки (від’ємні та аномально великі значення), які виникли в процесі передачі даних. Для подальшого прогнозування вузлового навантаження необхідна розробка алгоритму ідентифікації, видалення та інтерполяції аномальних значень.

Другий набір даних включає 970 вузлів навантаження, ці дані відповідають навантаженню турецьких міст та їх районів. Набір даних отриманий за період 2016 року з погодинною дискретністю. В таблиці 3.2 представлено статичні характеристики декількох вузлів.

**Статичні характеристики декількох вузлів навантаження даних  
Туреччини**

| Вузли                 | 1    | 2     | 3      | 4    | 5     | 6     | 7     | 8     | 9     |
|-----------------------|------|-------|--------|------|-------|-------|-------|-------|-------|
| Середнє значення      | 5,15 | 50,55 | 114,36 | 5,38 | 9,04  | 6,71  | 6,90  | 41,02 | 6,11  |
| Стандартне відхилення | 1,10 | 10,80 | 24,44  | 1,15 | 1,93  | 1,43  | 1,47  | 8,77  | 1,31  |
| Max                   | 8,65 | 84,85 | 191,95 | 9,02 | 15,18 | 11,26 | 11,58 | 68,86 | 10,26 |
| Min                   | 2,82 | 27,66 | 62,58  | 2,94 | 4,95  | 3,67  | 3,78  | 22,45 | 3,34  |

Більш детальний аналіз зібраних на перших етапах дослідження даних про електричне навантаження енергосистеми континентальної частини Європи [97] показав аномально велику кореляцію між вузлами. У цьому наборі даних містяться годинні показники для 1494 вузлів протягом періоду з 2012 по 2014 роки. Під час підготовки даного набору використовувались реальні схеми енергосистеми Європи. Для отримання значень навантаження вузлів було проведено взважування загального навантаження певної країни (або регіону) за щільністю населення в околиці кожного вузла. Саме в результаті такої підготовки даних і виникає значна кореляція між вузлами, оскільки дані відрізняються тільки масштабом. Тому ці дані були використані лише на перших етапах досліджень короткострокового прогнозування.

Четвертий набір даних включав в себе 15 вузлів навантаження АТ «Вінницяобленерго» отриманих від системи АСКУЕ. Вузли навантаження являються розподільчими підстанціями 110 кВ. Набір даних отриманий за період з 10.01.2017 по 06.10.2019 роки з погодинною дискретністю в таблиці 3.3 наведено характеристики вузлів.

**Характеристики вузлів навантаження**

| Вузли                 | 1       | 2       | 3        | 4       | 5       | 6        | 7       | 8       |
|-----------------------|---------|---------|----------|---------|---------|----------|---------|---------|
| Середнє значення      | 2392,53 | 2692,12 | 820,41   | 9789,85 | 2424,58 | 4874,52  | 5325,93 | 4834,09 |
| Стандартне відхилення | 371,88  | 1071,46 | 324,11   | 2629,19 | 713,05  | 1584,56  | 1549,56 | 1604,62 |
| Max                   | 3814    | 6550    | 1920     | 18810   | 5560    | 10283    | 10588   | 9030    |
| Min                   | 1284    | 286     | 12       | 1650    | 1080    | 137      | 1872    | 1590    |
| Вузли                 | 9       | 10      | 11       | 12      | 13      | 14       | 15      |         |
| Середнє значення      | 2281,05 | 1331,67 | 13057,93 | 7019,87 | 355,11  | 11575,04 | 1512,16 |         |
| Стандартне відхилення | 543,53  | 645,37  | 3314,79  | 2092,86 | 103,49  | 4118,05  | 458,03  |         |
| Max                   | 4250    | 4632    | 24773    | 13052   | 696     | 27051    | 3060    |         |
| Min                   | 920     | 12      | 4777     | 3116    | 72      | 3339     | 440     |         |

**3.3 Метод просторової кластеризації DBSCAN**

Одним з перших методів достовіризації який було розглянуто був метод просторової кластеризації програм на основі щільності даних з шумом (DBSCAN -Density-Based Spatial Clustering of Applications with Noise). Він є найбільш відомим методом кластеризації на основі щільності представлений в 1996 році М. Естером та іншими. Перевагою даного методу у порівнянні з іншими є те що він не потребує кількості кластерів як параметрів. Даний метод здатний самостійно визначати кількість кластерів на основі вхідних даних та формувати їх довільних форм. Для апроксимації локальної щільності даних даний метод потребує два основних параметри:  $\epsilon$  - радіус окружності навколо основної точки  $p$ ;  $\text{minPts}$  – мінімальна кількість точок даних, які можуть бути в радіусі для визначення кластера.

Для початку обирається довільна точка від якої формується кластер на основі радіуса  $\epsilon$ , якщо кількість точок які входять в радіус більша ніж мінімальна кількість точок  $\text{minPts}$  то кластер збільшується, це відбувається до моменту поки не закінчатся точки. Після чого обирається нова початкова точка для якої також визначається об'єм кластера. Якщо кількість даних кластера буде меншою ніж мінімальна кількість і дана початкова точка не буде відноситись до інших кластерів то її можна вважати незадовільною або ж «аномальною» яка не відноситься до жодного з кластерів. Також є можливість коли певна основна точка може відноситись до декількох кластерів, її в такому випадку називають «гранична точка».

Нижче наведено результати достовірності даних, отримані за допомогою різних методів, Результати виявлення та заміни аномальних даних для перших чотирьох вузлів навантаження методом DBSCAN зображено на рисунках 3.1-3.4. Як видно з графіків, дані містять аномально пікові значення та пропуски. Даний алгоритм точно виділяє аномальні значення у деяких випадках, а в інших - ні, залежно від радіусу кластеризації та тривалості аномальних пікових значень.

Оскільки обсяг ретроспективних даних досить великий, для демонстрації результатів, було взято відрізок даних в один рік, оскільки обробка великого об'єму даних для деяких методів потребує часу.




Рис.3.1 Кластеризація даних з використанням методу кластеризації DBSCAN, 1 вузла навантаження




Рис.3.2 Кластеризація даних з використанням методу кластеризації DBSCAN, 5 вузла навантаження




Рис.3.3 Кластеризація даних з використанням методу кластеризації DBSCAN, 8 вузла навантаження

Метод DBSCAN є ефективним при аналізі великих виняткових пікових значень, але при довготривалих спотвореннях даних, алгоритм не враховує їх, як можна побачити на графіку 3.3 та 3.4.




Рис 3.4 Кластеризація даних з використанням методу кластеризації DBSCAN, 11 вузла навантаження

### 3.4 Метод «Ізольований ліс»

Вперше цей метод був представлений у 2008. Особливістю методу є можливість чіткого виявлення аномальних значень ніж інші методи, які будують профілі даних і ідентифікують їх на відповідність нормальному профілю. До таких методів можна віднести методи класифікації та кластеризації. Даний же метод використовує алгоритм машинного навчання.

Деревоподібна структура алгоритму дозволяє ізолювати кожен окремий екземпляр. Завдяки чутливості до ізоляції, аномальні значення ізолюються ближче до «коріння» (початку) дерева, а нормальні значення ізолюються на кінцях дерева. Для ефективного функціонування методу та ізолювання аномальних даних необхідно лише дві основних змінних, це кількість дерев які необхідно побудувати та розміри підвибірок даних. Невеликі розміри вибірки дозволяють забезпечувати кращу побудову дерев, завдяки зменшенню розмиттю та маскуванню даних. Даний алгоритм не використовує дані відстані та щільності так як це викликає великі обчислювальні витрати. Також даний метод

здатний масштабуватись для обробки великих обсягів даних та багаторівневих проблем з великою кількістю нерелевантних атрибутів.

Для ізолювання точки даних, алгоритм рекурсивно генерує розділи для вибірки, випадковим чином обираючи атрибути, після чого випадковим чином обираються значення розподілу для атрибутів між мінімальним та максимальним значенням. Визначення довжини по ряду дерев дозволяє отримати оптимальну довжину, відповідно менша довжина шляху означає що даний екземпляр аномальний. Для визначення середньої довжини використовується формула наведена нижче.

$$c(n) = 2H(n - 1) - (2(n - 1)/n) \quad (3.1)$$

де  $H$ - гармонічне число, яке можна оцінити як константу Ейлера ( $\ln(i) + 0,5772156649$ ).

$c(n)$  – середнє значення  $h(x)$ .

Оцінка аномалії  $s$  для значень  $x$  представлена рівнянням (2).

$$s(x, n) = 2 - \frac{E(h(x))}{c(n)} \quad (3.2)$$

де  $E(h(x))$  – середнє значення  $h(x)$  з вибірки «ізолюваних лісів».

Рівняння (2) демонструє взаємозв'язок між  $E(h(x))$  та  $s$  при умовах коли  $0 < s \leq 1$  для  $0 < h(x) \leq n - 1$ .

За результатами рівняння оцінки аномалій можна робити наступні ствердження:

- Якщо приклади повертають значення  $s$  дуже близьке до 1 то вони вважаються аномальними.
- Якщо приклади мають набагато менше значення  $s$ , менше ніж 0,5 тоді їх розцінюють як нормальні значення.
- Якщо всі приклади мають значення  $s \approx 0,5$ , то весь приклад немає жодної виразної аномалії.

Виявлення аномалій проходить у два етапи, спочатку будуються ізоляційні дерева за допомогою підвбірок. Після чого через ці ізоляційні дерева пропускають тестові дані для отримання оцінки аномальності для кожного випадку. Перевірка методу IF демонструє доволі непогані результати виявлення

аномальних значень, але окрім цього даний метод виділяє добові пікові значення як аномальні, це може бути пояснено необхідністю додаткового аналізу методу та масштабування даних. Проте, даному методу для обробки даних потрібний значний час, що не є дуже перспективним порівняно з іншими методами. Результати, отримані за допомогою цього методу, представлені на рисунках 3.5-3.8.




Рис 3.5 Кластеризація даних з використанням методу IF, 1 вузла навантаження




Рис 3.6 Кластеризація даних з використанням методу IF, 5 вузла навантаження




Рис 3.7. Кластеризація даних з використанням методу IF, 8 вузла навантаження




Рис 3.8. Кластеризація даних з використанням методу IF, 11 вузла навантаження

Даний метод не зміг зафіксувати деякі аномальні викиди, що може бути зумовлено нездатністю методу виявляти аномалії при тривалих спотвореннях.

### 3.5 Метод локального рівня викиду

Метод локального рівня викиду (LOF – Local outlier factor) представлений М.М. Бройнінгом, Г. Кригелем для виявлення аномальних точок. Даний підхід використовує виявлення викидів на основі щільності даних для виявлення локальних викидів. По своїй концепції даний метод подібний до методу DBSCAN так як вони обидва використовують допустиму відстань для оцінки локальної щільності.

Розрахунок даного методу складається з декількох етапів:

1) Розрахунок відстані. Для цього використовується «Манхеттенська метрика».

2) Розрахунок відстані до  $k$ -го найближчого сусіда. Величина  $k$  може встановлюватись довільно і вказує на кількість сусідніх даних які враховуються при обчисленні.

3) Розрахунок  $k$ -найближчого сусіднього значення. Це міра максимуму відстані між двома точками і  $k$ - відстанню до другої точки, представлена в рівнянні (3).

$$reach - dist(a, b) = \max\{k - distance(b), dist(a, b)\} \quad (3.3)$$

4) Розрахунок локальної досяжності (LRD- Local reachability density) вказує наскільки близько знаходяться сусідні величини. Розрахунок проводиться за даними величини відстані досяжності розрахованої раніше для кожної точки. Для визначення LRD необхідно визначити відстань досяжності з точки  $a$  до всіх сусідніх  $k$  точок і взяти середнє значення цих чисел. І протилежне середньому значенню  $i$  є параметром LRD тобто чи нижча щільність тим далі точка  $a$  від сусідніх значень. Даний розрахунок представлено в рівняння (4) нижче.

$$LRD(a) = 1 / \left( \frac{\sum(reach-dist(a, n))}{k} \right) \quad (3.4)$$

5) Розрахунок локального рівня викиду (LOF). Величини локальної досяжності LRD кожної точки порівнюються між собою. LOF являє собою відношення між середнім значенням різниці сусідніх LRD з LRD точки  $a$ . Тобто

щільність однієї точки порівняно з щільністю сусідніх точок це і є локальний рівень викиду (5). Відповідно якщо щільність точки менша ніж щільність сусідніх точок, то така точка вважається аномальною.

$$LOF(a) = \left( \frac{\sum(LRD(k))}{k} \right) * LRD(a) \quad (3.5)$$

Метод LOF досить ефективно виявляє аномальні значення, хоча в деяких випадках алгоритм помилково розпізнає добові провали та піки навантаження як аномальні. Крім того, даному алгоритму не вдається розпізнати явні пропуски даних, що можна виправити за допомогою попередньої заміни та інтерполяції пропущених даних. Результати виявлення аномальних значень можна побачити на рисунках 3.9-3.12.




Рис 3.9. Кластеризація даних з використанням методу LOF, 1 вузла навантаження




Рис 3.10. Кластеризація даних з використанням методу LOF, 5 вузла навантаження




Рис 3.11. Кластеризація даних з використанням методу LOF, 8 вузла навантаження

Даний метод також як і попередній не завжди здатний розпізнати аномальні значення при тривалих спотвореннях.




Рис 3.12. Кластеризація даних з використанням методу LOF, 11 вузла навантаження

### 3.6 Метод еліптичної обвідної

Метод Еліптичної обвідної (EE – Elliptic Envelope) для виявлення аномальних даних, даний метод використовує розподілення Гауса. Алгоритм формує еліпс навколо даних на основі надійної коваріації що дозволяє ідентифікувати вихідні дані без впливу викидів. Відповідно будь-які значення які знаходяться поза межею даного еліпсу вважаються викидами. Метод EE моделює дані як високорівневий розподіл Гауса з можливою коваріацією між розмірними ознаками. Тобто даний метод намагається знайти межу еліпса з найбільшою кількістю даних в ньому. Радіус еліпсоїда на кожній осі вимірюється у відстані Махаланобісів. Багатовимірний Гаусовий розподіл є ключовим поняттям алгоритму EE. Це узагальнення одновимірного Гаусового розподілу. Якщо визначено розподіл Гауса за однозначним середнім значенням та дисперсією, то багатовимірний Гаусовий розподіл визначається матрицями для середніх значень та коваріацій. Потім за допомогою багатовимірного розподілу Гауса малюють еліпсоїд, який визначає, що є нормальним, а що - відхиленням.

Для ефективної роботи даного алгоритму він потребує оптимальної величини забруднення, по стандарту дана величина становить 0,1. Недоліком даного методу є те що дані порівнюються з фіксованим центроїдом що якоюсь мірою виділяє надлишкові аномальні значення.

Метод ЕЕ має високу чутливість до виявлення аномалій та пропущених даних, проте його обмеження полягає в зведенні даних до середнього значення, що може впливати на якість прогнозів. Це добре видно на графіках і не є бажаним для завдань прогнозування. Результати аналізу даних методом ЕЕ наведені на рисунках 3.13-3.16.




Рис 3.13 Кластеризація даних з використанням методу ЕЕ, 1 вузла навантаження




Рис 3.14 Кластеризація даних з використанням методу ЕЕ, 5 вузла навантаження

Як видно з наведених графіків даний метод обмежує значення в певному діапазоні, що в свою чергу може негативно вплинути на точність прогнозування.




Рис 3.15 Кластеризація даних з використанням методу ЕЕ, 8 вузла навантаження




Рис 3.16 Кластеризація даних з використанням методу EE, 11 вузла навантаження

Після порівняльного аналізу результатів роботи різних методів виявлення аномальних даних було встановлено, що більшість методів може виявляти як аномальні значення, так і пропущені дані. Метод DBSCAN ефективний для виявлення значних аномальних викидів, але при довготривалих спотвореннях даних алгоритм ігнорує ці значення. Для покращення роботи даного алгоритму необхідно масштабувати дані і змінювати розмірність вхідних даних для більш точної ідентифікації даних. Метод "Ізольованих лісів" показав найгірші результати. Метод EE здатний виявляти як аномальні, так і пропущені дані, але при великих об'ємах ретроспективних даних алгоритм спотворює нормальні дані за усередненим значенням усієї вибірки. Метод локального рівня викиду демонструє найкращі результати з усіх представлених методів, хоча не може виявляти пропущені дані. Проте це можна вирішити за допомогою попереднього виділення та інтерполяції пропущених даних.

Враховуючи переваги та недоліки наведених алгоритмів кластеризації для подальшого використання вирішено використовувати метод DBSCAN, який

об'єднує в собі високу точність та специфічність визначення аномальних викидів та ефективність, з точки зору використання обчислювальних ресурсів.

Подальший аналіз виявив, що алгоритми на базі кластеризації роблять значну кількість хибно позитивних спрацювань у вузлах зі значною добовою та тижневою періодичностями. Для розв'язання даної задачі запропоновано використовувати метод декомпозиції часових рядів за допомогою двосторонніх ковзних середніх з різною глибиною усереднення. Даний підхід дозволив покращити точність виявлення аномальних значень та пропусків електричного навантаження.

Запропонований алгоритм достовірності для одного вузла складається з наступних етапів:

1. Виділення часових зрізів з суцільного часового ряду навантаження  $R^{n \times 1} \rightarrow R^{\frac{n}{24} \times 24}$ .
2. Виявлення в часових зрізах грубих аномальних значень за допомогою методу кластеризації DBSCAN. Аномальними приймаються значення які не відносяться до першого кластеру.
3. Заміна аномальних значень за допомогою лінійної інтерполяції.
4. Розгортка часових зрізів в суцільний ряд навантаження  $R^{\frac{n}{24} \times 24} \rightarrow R^{n \times 1}$ .
5. Декомпозиція часового ряду на трендову, сезонну та залишкову складові.
6. Виявлення аномальних значень (пункт 2) в часовому ряді залишкової складової.
7. Заміна виявлених значень за допомогою лінійної інтерполяції.

Приклад використання алгоритму двоетапного виявлення та заміни аномальних значень наведено на рисунках 3.17-3.22




Рис. 3.17 Визначення аномальних даних методом кластеризації DBSCAN для вузла 1




Рис. 3.18 Визначення аномальних даних методом кластеризації DBSCAN для вузла 2

Результати визначення аномальних даних методом кластеризації DBSCAN для першого етапу аналізу даних.




Рис. 3.19 Декомпозиція даних вузла навантаження 1




Рис. 3.20 Декомпозиція даних вузла навантаження 2




Рис. 3.21 Визначення аномальних даних методом кластеризації DBSCAN з залишкових даних декомпозиції для вузла 1

Застосування двоетапної кластеризації дозволяє точніше виявляти аномальні дані, як в одиничних випадках так і в тривалих періодах.




Рис. 3.22 Визначення аномальних даних методом кластеризації DBSCAN з залишкових даних декомпозиції для вузла 2

### 3.7 Метод вейвлет перетворення

Вейвлет-перетворення широко використовується для аналізу сигналів, фільтрації та перетворення даних. Окрім цього, вейвлет-перетворення знаходить велике застосування в області стиснення даних. У дискретному вейвлет-перетворенні найважливіша інформація про сигнал міститься у високих амплітудах, а менш корисна інформація в низьких. Стиснені дані можна отримати шляхом відкидання низьких амплітуд. Вейвлет-перетворення дозволяє отримати високе співвідношення стиснення в поєднанні з гарною якістю відновленого сигналу.

Вибір конкретного виду та типу вейвлетів в більшості залежить від аналізованих сигналів і завдань аналізу. Опираючись на дослідження які описані в [98] для аналізу даних та для задач короткострокового прогнозування було використано метод вейвлет-перетворення. В першому випадку для виявлення аномальних даних та заміни аномальних даних було проведено розкладання даних до 6 рівнів. Для цього використали вейвлет сімейства Хаара, який зменшує розмірність вибірок вдвічі на кожному рівні. При згортанні даних ми

отримали 6 вибірок даних деталей, та одну вибірку апроксимованих значень. Після чого ми замінюємо значення вибірок деталей на вибірки такої ж розмірності, але з нульовими значеннями після чого проводимо складання вейвлету. Ще варіантом відновлення даних є заміна апроксимованої вибірки.

### 3.8. Порівняння методів аналізу даних

Дослідження методів аналізу даних описано в [21,99]. Для дослідження методів аналізу даних для виявлення та заміни аномальних даних було використано дані північно-західного регіону США який містить дані 10 вузлів навантаження з погодинними значеннями за період з 2015 по 2019 роки.

Оскільки аналіз даного набору даних показав наявність аномальних даних для їх виявлення та заміни було використано алгоритм двох етапної достовіризації який описано в розділі 3.2.4 відповідно для кожного з методів достовіризації. В таблиці 3.4 наведено кількість виявлених аномальних значень за допомогою різних методів.

*Таблиця 3.4*

#### **Кількість виявлених аномальних даних різними методами**

|                                            | DBSCAN | IF   | LOF  | EE   |
|--------------------------------------------|--------|------|------|------|
| Кількість значень віднесених до аномальних | 831    | 5207 | 5148 | 5256 |

З результатів достовіризації видно що метод EE виявив найбільшу кількість аномальних значень, але дані значення неможливо вважати коректними через те, що даний алгоритм виявляє аномальні значення на основі усереднених значень що є неефективним для даних часових рядів які мають сезонну складову. Метод IF демонструє другу по величині кількість виявлених аномальних значень, для ефективного виявлення яких алгоритм використовує вибірки розмірністю в 24 значення що в свою чергу зумовлює значні витрати в часі на обробку значних об'ємів даних. Метод LOF має таку ж саму ситуацію як і EE

алгоритм обмежений усередненими значеннями і в більшості випадків виділяє хибно аномальні значення. Хоча метод DBSCAN демонструє найменшу кількість виявлених аномальних значень, але вони досить точно визначені як аномальні. В таблиці 3.4 наведено результати точності прогнозування використовуючи достовіризовані дані за допомогою різних методів. В якості нейронної мережі використовувалась нейронна мережа глибинного навчання типу LSTM яка була описана вище. В таблиці 3.5 представлено результати похибок прогнозування при вибірках з різною достовіризацією.

З результатів наведених в таблиці 3.5 видно що застосування методів достовіризації дозволяє зменшити похибки прогнозування. Найменшу похибку демонструє метод IF.

*Таблиця 3.5*

**Результати прогнозування при різних достовіризованих вибірках**

| Результати прогнозу | DBSCAN | LOF   | IF   | EE   |
|---------------------|--------|-------|------|------|
| 1                   | 18,43  | 26,52 | 7,42 | 9,33 |
| 2                   | 16,06  | 24,28 | 6,23 | 7,83 |
| 3                   | 7,48   | 12,13 | 3,76 | 3,63 |
| 4                   | 9,65   | 14,16 | 3,87 | 4,75 |
| 5                   | 3,76   | 6,27  | 2,26 | 3,13 |
| 6                   | 7,20   | 12,39 | 6,07 | 6,26 |
| 7                   | 9,45   | 13,62 | 5,54 | 6,42 |
| 8                   | 7,29   | 7,70  | 4,73 | 5,37 |
| 9                   | 3,30   | 5,88  | 2,08 | 2,52 |
| 10                  | 6,96   | 11,34 | 4,79 | 4,84 |
| Середнє значення    | 8,96   | 13,43 | 4,67 | 5,41 |

Для даних енергосистеми Туреччини (970 вузлів) було проведено прогноз з використанням архітектури net1. Дані були доступні за 2016 рік, для навчання використовувались дані за період січень-листопад, оцінка точності проводилась на даних за грудень (744 погодинних значень). В таблиці 3.6 наведено усереднені значення похибок прогнозу.

## Усереднені значення похибки прогнозу енергосистеми Туреччини

| Похибка MAPE                  | net1 з аномальними значеннями | net1 без аномальних значень |
|-------------------------------|-------------------------------|-----------------------------|
| Мінімальна похибка            | 3,3                           | 3,5                         |
| Максимальна похибка           | 12,6                          | 13,4                        |
| Середня похибка               | 6,2                           | 6,3                         |
| Стандартне відхилення похибки | 1,8                           | 1,5                         |

Розподіл похибок прогнозу по вузлах для двох варіантів прогнозу наведено на рис. 3.23.




Рис. 3.23 Розподіл MAPE для даних Туреччини

За результатами достовіризації даних Туреччини встановлено підвищення середню похибку прогнозу з 6,2% до 6,3%. При цьому знизилось стандартне відхилення похибки з 1,8% до 1,5%. Даний ефект можна пояснити значно меншою кількістю вузлів з аномальними значеннями. При великій кількості вузлів без аномальних даних на передній план виходять хибнопозитивні спрацювання алгоритму, які спотворюють дані.

## ВИСНОВКИ ДО РОЗДІЛУ 3

1. Показана важливість достовіризації даних часових рядів вузлового навантаження під час побудови статистичних моделей процесу споживання електричної енергії, оскільки наявність пропусків та аномально великих значень в ряді даних може призводити до недостатнього узагальнення характеру процесу та виникнення систематичних похибок. Відзначена актуальність цієї задачі з огляду на випадки кібератак на енергетичні мережі, маніпуляцій з даними вимірювань або зовнішньою інформацією, що можуть нанести значну фінансову шкоду та вплинути на стійкість енергосистеми.

2. Досліджено методи достовіризації даних для перевірки ефективності виявлення аномалій та пропущених значень в даних вузлового навантаження на основі використання ретроспективної інформації з відкритих джерел.. За результатами дослідження визначено, що найбільш оптимальним методом достовіризації для задач прогнозування вузлового навантаження є методі DBSCAN за рахунок своєї точності та швидкодії.

3. Розроблено алгоритм двоетапної кластеризації даних на основі методу кластеризації DBSCAN для виявлення та заміни аномальних значень та пропусків в даних про вузлове навантаження.

4. Досліджено похибки прогнозування на прикладі даних енергосистеми Туреччини з великою кількістю вузлів та застосуванням методів достовіризації даних, за якими видно що при незначеній кількості аномальних значень похибка прогнозування майже не змінюється.

*Результати експериментальних досліджень даного розділу наведено в таких публікаціях:*

Посилання [21],[43],[99] див.список використаних джерел стор. 136-147.

## РОЗДІЛ 4

# ВРАХУВАННЯ ВПЛИВУ ДОДАТКОВИХ ФАКТОРІВ НА ТОЧНІСТЬ ПРОГНОЗУВАННЯ ВУЗЛОВОГО НАВАНТАЖЕННЯ ТА ВИЗНАЧЕННЯ ЗНАЧЕНЬ ОЧІКУВАНИХ ВТРАТ В ЕЛЕКТРИЧНИХ МЕРЕЖАХ НА ОСНОВІ ВУЗЛОВИХ НАВАНТАЖЕНЬ

### 4.1 Прогнозування вузлового навантаження з врахуванням додаткових факторів

Використовуючи методи достовіризації даних та перевірки впливу додаткових факторів на точність прогнозування, було проведено дослідження яке описано в [8]. Метою якого було визначити зв'язок між навантаження та температурою з додатковим аналізом даних для виявлення аномалій та пропусків. В якості нейронної мережі використовувалась нейронна мережа глибинного навчання типу LSTM яка описана в розділі 2.3, дані про температуру в даному випадку подавались як додатковий віртуальний вузол даних. Дослідження проводилось на даних системи АСКУЕ АТ «Вінницяобленерго», дані якого включали 15 вузлів з погодинною дискретністю за період з 2017 по 2019 рік. Дані температури повітря отримані з метеостанції яка знаходиться в місті Вінниця за індексом 33562. На рисунках 4.1-4.3 наведено результати кореляційного аналізу між вузлами навантаження та температурою для робочих та вихідних днів.

| Вузли | 1 | 2    | 3    | 4     | 5     | 6     | 7    | 8     | 9    | 10    | 11   | 12    | 13   | 14    | 15   |
|-------|---|------|------|-------|-------|-------|------|-------|------|-------|------|-------|------|-------|------|
| 1     | 1 | 0,58 | 0,43 | -0,22 | 0,45  | 0,49  | 0,54 | 0,66  | 0,27 | 0,49  | 0,54 | 0,59  | 0,22 | 0,59  | 0,43 |
| 2     |   | 1    | 0,57 | -0,18 | 0,60  | 0,66  | 0,59 | 0,85  | 0,53 | 0,68  | 0,67 | 0,74  | 0,26 | 0,64  | 0,55 |
| 3     |   |      | 1    | 0,04  | 0,70  | 0,77  | 0,74 | 0,67  | 0,69 | 0,68  | 0,74 | 0,79  | 0,52 | 0,69  | 0,66 |
| 4     |   |      |      | 1     | -0,05 | -0,11 | 0,04 | -0,23 | 0,20 | -0,07 | 0,06 | -0,08 | 0,21 | -0,01 | 0,00 |
| 5     |   |      |      |       | 1     | 0,81  | 0,79 | 0,73  | 0,74 | 0,74  | 0,81 | 0,87  | 0,54 | 0,75  | 0,68 |
| 6     |   |      |      |       |       | 1     | 0,85 | 0,80  | 0,74 | 0,79  | 0,83 | 0,91  | 0,56 | 0,75  | 0,74 |
| 7     |   |      |      |       |       |       | 1    | 0,71  | 0,74 | 0,71  | 0,86 | 0,89  | 0,71 | 0,82  | 0,72 |
| 8     |   |      |      |       |       |       |      | 1     | 0,59 | 0,79  | 0,76 | 0,88  | 0,32 | 0,73  | 0,67 |
| 9     |   |      |      |       |       |       |      |       | 1    | 0,72  | 0,79 | 0,75  | 0,59 | 0,67  | 0,71 |
| 10    |   |      |      |       |       |       |      |       |      | 1     | 0,80 | 0,81  | 0,41 | 0,69  | 0,72 |
| 11    |   |      |      |       |       |       |      |       |      |       | 1    | 0,89  | 0,60 | 0,82  | 0,74 |
| 12    |   |      |      |       |       |       |      |       |      |       |      | 1     | 0,58 | 0,87  | 0,75 |
| 13    |   |      |      |       |       |       |      |       |      |       |      |       | 1    | 0,61  | 0,47 |
| 14    |   |      |      |       |       |       |      |       |      |       |      |       |      | 1     | 0,66 |
| 15    |   |      |      |       |       |       |      |       |      |       |      |       |      |       | 1    |

Рис.4.1 Міжвузлова кореляція робочих днів

| Вузли | 1   | 2    | 3    | 4     | 5     | 6     | 7     | 8     | 9    | 10    | 11    | 12    | 13   | 14    | 15    |
|-------|-----|------|------|-------|-------|-------|-------|-------|------|-------|-------|-------|------|-------|-------|
| 1     | 1,0 | 0,58 | 0,29 | -0,31 | 0,34  | 0,38  | 0,41  | 0,65  | 0,13 | 0,44  | 0,49  | 0,52  | 0,02 | 0,54  | 0,29  |
| 2     |     | 1,0  | 0,56 | -0,24 | 0,60  | 0,63  | 0,63  | 0,85  | 0,48 | 0,67  | 0,71  | 0,76  | 0,18 | 0,71  | 0,50  |
| 3     |     |      | 1,0  | -0,07 | 0,75  | 0,81  | 0,78  | 0,69  | 0,71 | 0,71  | 0,76  | 0,78  | 0,52 | 0,68  | 0,63  |
| 4     |     |      |      | 1,0   | -0,22 | -0,26 | -0,14 | -0,31 | 0,09 | -0,16 | -0,10 | -0,25 | 0,10 | -0,18 | -0,14 |
| 5     |     |      |      |       | 1,0   | 0,83  | 0,82  | 0,77  | 0,76 | 0,78  | 0,80  | 0,87  | 0,53 | 0,77  | 0,65  |
| 6     |     |      |      |       |       | 1,0   | 0,90  | 0,82  | 0,74 | 0,80  | 0,84  | 0,90  | 0,56 | 0,75  | 0,73  |
| 7     |     |      |      |       |       |       | 1,0   | 0,81  | 0,75 | 0,79  | 0,84  | 0,90  | 0,59 | 0,79  | 0,70  |
| 8     |     |      |      |       |       |       |       | 1,0   | 0,59 | 0,80  | 0,83  | 0,92  | 0,33 | 0,80  | 0,67  |
| 9     |     |      |      |       |       |       |       |       | 1,0  | 0,73  | 0,74  | 0,71  | 0,61 | 0,66  | 0,67  |
| 10    |     |      |      |       |       |       |       |       |      | 1,0   | 0,83  | 0,82  | 0,41 | 0,73  | 0,71  |
| 11    |     |      |      |       |       |       |       |       |      |       | 1,0   | 0,88  | 0,45 | 0,80  | 0,70  |
| 12    |     |      |      |       |       |       |       |       |      |       |       | 1,0   | 0,51 | 0,87  | 0,72  |
| 13    |     |      |      |       |       |       |       |       |      |       |       |       | 1,0  | 0,47  | 0,43  |
| 14    |     |      |      |       |       |       |       |       |      |       |       |       |      | 1,0   | 0,61  |
| 15    |     |      |      |       |       |       |       |       |      |       |       |       |      |       | 1     |

Рис. 4.2 Міжвузлова кореляція вихідних днів

| Кореляція вузлів | 1     | 2     | 3     | 4    | 5     | 6     | 7     | 8     | 9     | 10    | 11    | 12    | 13   | 14    | 15    |
|------------------|-------|-------|-------|------|-------|-------|-------|-------|-------|-------|-------|-------|------|-------|-------|
| робочі дні       | -0,66 | -0,76 | -0,34 | 0,33 | -0,42 | -0,47 | -0,48 | -0,79 | -0,25 | -0,57 | -0,58 | -0,63 | 0,13 | -0,53 | -0,40 |
| вихідні          | -0,66 | -0,76 | -0,34 | 0,33 | -0,42 | -0,47 | -0,48 | -0,79 | -0,25 | -0,57 | -0,58 | -0,63 | 0,13 | -0,53 | -0,40 |

Рис. 4.3 Кореляція вузлів навантаження з температурою повітря

Під час аналізу даних було встановлено, що деякі вузли, зокрема вузли 4, 11 та 13, не мають жодного взаємозв'язку з іншими вузлами, що відображається на їх коефіцієнтах кореляції, які становлять від -0.2 до 0.2. У той же час, лише для вихідних днів вузол 4 не має жодного зв'язку з іншими вузлами. Також було відзначено кілька вузлів з високими коефіцієнтами кореляції між ними: 3, 5, 6, 7, 8 та 12, що становлять від 0.7 до 1.

Можна згрупувати вузли 9, 10, 14 та 15, оскільки між ними спостерігається високий коефіцієнт кореляції в межах 0.6-0.7. Також можна згрупувати вузли 1 та 2 з коефіцієнтом кореляції в межах 0.4-0.5. За кореляцією між навантаженням та температурою було визначено, що вузли навантаження мають від'ємний кореляційний зв'язок з температурою.

Було проведено порівняльний аналіз середньодобових графіків навантаження та температури для усіх вузлів за весь період з метою визначення оптимального обсягу навчальних вибірок для зимового та літнього періодів. Після аналізу графіків навантаження АТ «Вінницяобленерго» були виявлені такі особливості залежності навантаження від температури повітря:

- Усі вузли даного набору даних в зимовий період, який можна умовно виділити з 25.09 - 10.10.2017 по 04-05.04.2018, мають залежність від температури.
- Деякі вузли мають лінійну залежність, що відображається у подібній формі графіків навантаження та температури, тоді як інші мають від'ємний кореляційний зв'язок. У цей період спостерігається спад температури та зростання навантаження на вузли.
- З 4 по 9 квітня відбувається різкий спад навантаження, що умовно починає літній період, під час якого навантаження майже не залежить від впливу температури.
- Літній період триває до меж 20-25 вересня 2018 року.
- У деяких вузлах навантаження має значні провали, які можуть бути пов'язані зі святковими днями або аварійними ситуаціями. Наприклад, у вузлі 10 навантаження аномально збільшилося в листопаді 2018 року і перевищило норму в 4 рази.

Тому для навчальних вибірок можна виділити умовно зимовий період з 01.10.2017 по 04.04.2018 та умовно літній з 09.04.2018 по 20.09.2018 з оцінкою прогнозування на останні 7 днів. На рисунках 4.4-4.6 наведено приклади графіків навантаження та температури за вибраний період.



Рис. 4.4 Графіки співвідношення навантаження та температури для вузла №3




Рис. 4.5 Графіки співвідношення навантаження та температури для вузла №4



Рис. 4.6 Графіки співвідношення навантаження та температури для вузла №8

В таблицях 4.1 наведено результати прогнозування достовіризованих та не достовіризованих вибірок даних та з врахуванням температури.

**Результати прогнозування достовіризованих та не достовіризованих даних**

| Тип даних    | Не достовіризовані дані |                  | Достовіризовані дані |                  |
|--------------|-------------------------|------------------|----------------------|------------------|
| Вид прогнозу | Одно-факторний          | Багато-факторний | Одно-факторний       | Багато-факторний |
| 1            | 7,60                    | 8,33             | 6,80                 | 5,86             |
| 2            | 24,49                   | 23,31            | 23,48                | 24,17            |
| 3            | 16,76                   | 16,87            | 16,28                | 15,73            |
| 4            | 13,92                   | 10,52            | 9,78                 | 8,34             |
| 5            | 8,74                    | 8,57             | 8,28                 | 8,66             |
| 6            | 10,60                   | 10,48            | 10,51                | 10,04            |
| 7            | 13,40                   | 14,10            | 13,95                | 13,24            |
| 8            | 7,18                    | 6,93             | 6,68                 | 6,83             |
| 9            | 12,01                   | 12,18            | 11,44                | 11,65            |
| 10           | 20,91                   | 20,55            | 20,27                | 19,74            |
| 11           | 22,57                   | 26,96            | 9,30                 | 8,38             |
| 12           | 6,87                    | 7,01             | 7,01                 | 6,62             |
| 13           | 16,32                   | 23,42            | 9,31                 | 9,31             |
| 14           | 17,69                   | 16,63            | 11,68                | 11,00            |
| 15           | 7,12                    | 7,40             | 7,96                 | 7,95             |
| Середня      | 13,74                   | 14,22            | 11,52                | 11,17            |
| Мінімальна   | 6,87                    | 6,93             | 6,68                 | 5,86             |
| Максимальна  | 24,49                   | 26,96            | 23,48                | 24,17            |

В таблицях 4.2 наведено результати прогнозування різних вибірок достовіризованих даних для зимового та літнього періоду та вибірок робочих та вихідних днів.

**Результати прогнозування робочих та вихідних днів за зимовий та літній період**

| Тип даних    | Зимовий період<br>(01.11.2017-04.04.2018) |             | Літній період (01.05.2018-15.09.2018) |             |
|--------------|-------------------------------------------|-------------|---------------------------------------|-------------|
| Вид прогнозу | Робочі дні                                | Вихідні дні | Робочі дні                            | Вихідні дні |
| 1            | 10,13                                     | 8,34        | 8,79                                  | 11,05       |
| 2            | 10,01                                     | 19,18       | 16,47                                 | 7,29        |
| 3            | 12,36                                     | 39,12       | 19,62                                 | 17,1        |
| 4            | 19,06                                     | 20,65       | 21,02                                 | 19,37       |
| 5            | 6,88                                      | 5,3         | 7,7                                   | 10,6        |
| 6            | 8,44                                      | 4,96        | 12,87                                 | 10,82       |
| 7            | 8,46                                      | 9,68        | 10,24                                 | 9,77        |
| 8            | 9,24                                      | 4,6         | 4,79                                  | 4,82        |
| 9            | 11,37                                     | 6,8         | 5,44                                  | 4,76        |
| 10           | 11,78                                     | 39,03       | 17,95                                 | 22,39       |
| 11           | 6,61                                      | 7,12        | 8,42                                  | 8,78        |
| 12           | 7,59                                      | 3,88        | 4,4                                   | 4,84        |
| 13           | 5,97                                      | 11,78       | 18,84                                 | 13,42       |
| 14           | 6,58                                      | 6,68        | 13,91                                 | 20,91       |
| 15           | 28,3                                      | 13,46       | 25,86                                 | 19,98       |
| Середня      | 10,85                                     | 13,37       | 13,09                                 | 12,39       |
| Мінімальна   | 5,97                                      | 3,88        | 4,4                                   | 4,76        |
| Максимальна  | 28,3                                      | 39,12       | 25,86                                 | 22,39       |

З результатів прогнозування видно що використання методу виявлення аномальних даних та їх заміни дозволяє зменшити середні похибки прогнозу з 13.52 % до 11.52%, також врахування температури повітря додатково дозволяє зменшити похибку з 14.22% до 11.17 %. Загалом точність прогнозування залежить від об'єму вибірок даних.

При використанні додаткових факторів виникає запитання в правильності представлення додаткових факторів. Для цього було проведено дослідження

варіантів застосування додаткових факторів які описані в розділі 2.5. Для перевірки ефективності застосування додаткових факторів було розроблено декілька архітектур нейронних мереж глибинного навчання. Першою мережею була описана раніше мережа глибинного навчання типу LSTM, ще одним варіантом була комбінована нейронна мережа яка містить модулі згортки та модулі LSTM, а також нейронну мережу типу LSTM з двома паралельними входами, на один вхід подаються дані навантаження, а на інший дані по температурі повітря. Дані проходять через повно зв'язні шари після чого вагові коефіцієнти яких сумуються. Для перевірки ефективності використовувались дані США та енергосистеми Туреччини. З різною кількістю вузлів навантаження, для яких було проведено двоетапну достовіризацію. В таблиці 4.3 наведено результати прогнозування за допомогою нейронної мережі типу LSTM (net1) на даних США та з достовіризацією.

*Таблиця 4.3*

#### **Результати прогнозування мережею net1**

| Вузли                      | net1 з аномальними даними | net1 без аномальних даних |
|----------------------------|---------------------------|---------------------------|
| 1                          | 117.2                     | 6.6                       |
| 2                          | 6.6                       | 6.5                       |
| 3                          | 4.1                       | 3.6                       |
| 4                          | 5.9                       | 4.5                       |
| 5                          | 5.1                       | 4.2                       |
| 6                          | 7.9                       | 7.2                       |
| 7                          | 5.2                       | 4.9                       |
| 8                          | 6.3                       | 4.6                       |
| 9                          | 7.6                       | 7.8                       |
| 10                         | 7.6                       | 7.8                       |
| Мінімальна похибка, [%]    | 4.1                       | 3.6                       |
| Максимальна похибка, [%]   | 117.2                     | 7.8                       |
| Середня похибка, [%]       | 17.3                      | 5.8                       |
| Стандартне відхилення, [%] | 35.1                      | 1,6                       |

Наведені результати показують, що усунення аномальних значень значно знижує середню похибку прогнозу з 17,3% до 5,8% та підвищує стабільність прогнозів, зниження стандартного відхилення похибки з 35,1% до 1,6%.

#### **4.2 Порівняння різних підходів до прогнозування вузлового навантаження з врахуванням додаткових факторів**

В таблиці 4.4 наведено результати прогнозування нейронних мереж net1 та net2 (загорткова нейронна мережа) на достовіризованих даних США з застосуванням різних методів прогнозування.

Також наведено результати класичних методів прогнозування описаних в розділі 1. Зокрема таких як методи векторної авторегресії VAR та метод потрійного експоненційного згладжування Холта-Вінтерса.

*Таблиця 4.4*

##### **Результати прогнозування різними методами**

| Вузли                       | net1 | net2 | VAR  | ES   |
|-----------------------------|------|------|------|------|
| 1                           | 6.6  | 19.7 | 11.0 | 10.2 |
| 2                           | 6.5  | 14.0 | 14.4 | 16.2 |
| 3                           | 3.6  | 7.1  | 10.7 | 10.1 |
| 4                           | 4.5  | 9.3  | 6.3  | 10.4 |
| 5                           | 4.2  | 4.2  | 4.9  | 11.6 |
| 6                           | 7.2  | 10.1 | 11.2 | 13.8 |
| 7                           | 4.9  | 10.2 | 8.2  | 13.9 |
| 8                           | 4.6  | 8.6  | 7.4  | 8.6  |
| 9                           | 7.8  | 4.1  | 12.7 | 14.8 |
| 10                          | 7.8  | 8.2  | 6.0  | 13.4 |
| Мінімальна похибка, [%]     | 3.6  | 4.1  | 4.9  | 8.6  |
| Максимальна похибка, [%]    | 7.8  | 19.7 | 14.4 | 16.2 |
| Середня похибка, [%]        | 5.8  | 9.5  | 9.3  | 12.3 |
| Стандартне відхилення , [%] | 1.6  | 4.6  | 3.1  | 2.5  |

З наведених результатів видно, що згортова нейронна мережа поступається за точністю та стабільністю базовій мережі net1. Це можна пояснити значно більшою кількістю параметрів, і, як наслідок, перенавчанням мережі net2. Класичні методи також дають вищу середню похибку прогнозу, 9,3% для векторної авторегресії та 12,3% для методу експоненційного згладжування.

Результати багатofакторного прогнозування двома підходами до подання додаткових факторів наведено в таблиці 4.5.

*Таблиця 4.5*

#### **Результати багатofакторного прогнозування**

| Вузол                      | net1+ | net3 |
|----------------------------|-------|------|
| 1                          | 22.7  | 11.8 |
| 2                          | 19.4  | 12.3 |
| 3                          | 8.7   | 4.2  |
| 4                          | 10.1  | 5.7  |
| 5                          | 4.7   | 3.5  |
| 6                          | 9.5   | 6.6  |
| 7                          | 9.9   | 6.4  |
| 8                          | 7.2   | 5.5  |
| 9                          | 5.0   | 3.4  |
| 10                         | 10.2  | 6.2  |
| Мінімальна похибка, [%]    | 4.7   | 3.4  |
| Максимальна похибка, [%]   | 22.7  | 12.3 |
| Середня похибка, [%]       | 10.7  | 6.5  |
| Стандартне відхилення, [%] | 5.8   | 3.1  |

Використання паралельної гілки в нейронній мережі (net3) для врахування зовнішніх факторів дає значно меншу похибку прогнозу, ніж додавання віртуального вузла в базову нейронну мережу (net1+). Проте, обидва підходи

показують вищі значення похибки в порівнянні з однофакторною нейронною мережею на базі LSTM (net1).

#### 4.3 Прогнозування втрат електричної енергії в розподільних мережах

В новому ринку оператори систем розподілу (ОСР) та оператор системи передачі (ОСП) повинні купувати на електроенергію для покриття втрат у власних мережах [100-102]. Метою такого заходу є зниження вартості електроенергії для всіх категорій споживачів.

Ринок «На добу наперед» РДН являється сегментом ринку на якому здійснюється купівля та продаж електричної енергії на наступний день проведення торгів на добу за вільними цінами. На рисунку 4.7 наведено блок-схему функціонування РДН. Контроль над функціонуванням РДН виконує Оператор ринку.




Рис. 4.7 Блок-схема функціонування РДН

Оператор ринку виконує наступні функції:

- Забезпечує можливість доступу до ринку тим, хто не має довгострокових контрактів,;
- Надає цінові сигнали для усіх учасників ринку;
- Забезпечують систему гарантій учасникам ринку про виконання зобов'язань щодо оплати проданої електроенергії;
- Дозволяють учасникам ринку уточнювати обсяги купівлі та продажу електроенергії при наближенні часу постачання з метою зменшення небалансу.

Враховуючи, прийняті Кабінетом міністрів України, зміни до механізму покладання спеціальних обов'язків, які почали діяти з 01.01.2020 р., фінансова відповідальність за небаланси енергорозподільчих компаній посиляться, оскільки вони будуть змушені закуповувати необхідні обсяги електроенергії на РДН.

Так, наприклад, за даними Міністерства енергетики сумарний відпуск електроенергії в мережу за 2018 р. склав 147 млн МВт·год, при цьому фактичні втрати в мережах ОСР та ОСП становлять 11,58 % або 17 млн МВт·год. На рис. 4.8 представлено графік технологічних втрат електроенергії у відсотках від розподіленої електроенергії.

Потенційний економічний ефект від зниження похибки короткострокового прогнозу можна оцінити за допомогою формул 1.1-1.3, використовуючи середні ціни РДН та ціни небалансів (НБ). Так за період з 01.09.2019 по 20.11.2019 середня ціна на РДН становить 1543 грн/МВт·год, а НБ – 1617 грн/МВт·год. Дані за липень-серпень не використовувались через суттєві коливання пов'язані з запуском ринку.




Рис. 4.8 Обсяги технологічних втрат

Допускаючи симетричність закону розподілу похибки прогнозу, половина погодинних значень похибки буде додатною, а половина від'ємною,

сумарні витрати на компенсацію похибки прогнозу ТВЕ в 1% обчислюється за формулою:

$$B_{\Sigma}^{1\%NB} = \underline{C}_{NB} \cdot 0,01 \cdot \frac{W_{\Sigma TBE}}{2} - (\underline{C}_{NB} - \underline{C}_{РДН}) \cdot 0,01 \cdot \frac{W_{\Sigma TBE}}{2} = \underline{C}_{РДН} \cdot 0,01 \cdot \frac{W_{\Sigma TBE}}{2} \quad (4.1)$$

де  $\underline{C}_{NB}$  – середня ціна небалансів, грн/МВт·год;

$\underline{C}_{РДН}$  – середня ціна РДН, грн/МВт·год;

$W_{\Sigma TBE}$  – сумарний річний об'єм технологічних втрат електроенергії (млн МВт·год), для розрахунків використовувались дані за 2018 р.

Таким чином, зниження похибки прогнозування втрат на 1% дозволить знизити витрати компенсацію небалансів на 131,2 млн. грн на рік, що дозволить знизити тариф на розподіл та тариф на передачу електричної енергії.

В рамках дослідження оцінки вартості похибки прогнозу технологічних втрат в електричних мережах України, було проведено розрахунок вартості похибки прогнозу ТВЕ «На добу наперед». Для розрахунку середньої ціни похибки прогнозу використовувались дані по цінах на ринках РДН та цінам небалансів за четвертий квартал 2019 р., оскільки в перші місяці роботи ринку ціни були завищені і консолідувались у вересні-жовтні. Середньозважена ціна РДН в ОЕС України заданий період склала 1343 грн./МВт·год та 1754 грн./МВт·год в «Бурштинському енергоострові» за середніх погодинних значеннях обсягів у 5050 МВт·год та 487 МВт·год відповідно. Розрахована середня ціна похибки прогнозу становить 225 грн./МВт·год. За даними Міністерства енергетики та захисту довкілля сумарний відпуск електроенергії в мережу за 2018 р. склав 147 млн. МВт·год. В той самий час фактичні втрати в мережах ОСР та ОСП становлять 11,58 % або 17 млн. МВт·год. За 12 місяців 2019 року загальні технологічні витрати електроенергії на її транспортування електричними мережами всіх класів напруги склали 16,4 млн. МВт·год або ті ж самі 11,6 % від загального відпуску електроенергії в мережу. Використовуючи середню ціну похибки прогнозу 225 грн./МВт·год, вартість середньої похибки прогнозу в 5% від сумарних ТВЕ становить 184 млн. грн. на рік в 2019 р.




Рис. 4.9 Середні ціни похибки прогнозу

На рисунку 4.9 наведено графік середніх значень ціни похибки прогнозу в окремі години доби з врахуванням знаку. Від'ємні значення на графіку відповідають ситуації, коли ціна РДН нижча за ціну небалансів на балансуєчому ринку. Отримані результати є очікуваними в частині ціни похибки прогнозу, яка є більшою в пікові години доби (з 08:00 до 23:00). Також відзначено аномальну поведінку графіку в околї 7-8 та 15-17 годин доби.

#### 4.4 Визначення значення очікуваних втрат електричної енергії за допомогою штучних нейронних мереж

На сьогоднішній день в енергосистемі України втрати електроенергії при передачі можуть досягати 20%, при тому, що в більшості країн даний показник втрат знаходиться в межах 4-6%. Це все зумовлено розвитком різних сегментів ринку, та неточними прогнозами навантажень для цих сегментів. Якщо прогнозування буде неточним, то виникне значна різниця між виробництвом енергії та споживанням, що призведе до необхідності докуповувати енергію на балансуєчому ринку електроенергії. Відповідно це збільшує вартість витрат на електроенергію. Враховуючи, що в електричних мережах втрати електроенергії розраховуються досить грубо, за рахунок коефіцієнтів, що визначаються у дні зимового та літнього піків навантаження.

Ринок «на добу наперед» являється сегментом ринку на якому здійснюється купівля та продаж електричної енергії на наступний день проведення торгів на добу за вільними цінами.

Зважаючи на необхідність прогнозування навантаження було запропоновано підхід щодо використання методів прогнозування для визначення втрат електричної енергії в мережах. В якості методів прогнозування використовувались штучні нейронні мережі.

Для зменшення вартості втрат, запропоновано використання сучасних методів штучних нейронних мереж глибинного навчання для розрахунку та прогнозування втрат електричної енергії. Для перевірки ефективності прогнозування втрат електричної енергії було розроблено архітектури штучних нейронних мереж глибинного навчання, прогнозні дані яких використовувались для розрахунку втрат електроенергії.

Для оцінки ефективності використання методів прогнозування навантаження вузлі з метою визначення втрат було розроблено та досліджено кілька підходів.

- Використання прогнозних значень вузлового навантаження для розрахунку втрат електричної енергії.
- Прогнозування навантаження для кожного окремого вузла, з подальшим об'єднання даних для розрахунку електричної енергії."
- Визначення втрат електричної енергії з подальшим їх прогнозом.
- Визначення втрат за допомогою коефіцієнтів втрат які розраховані на даних максимуму навантаження у літній та зимовий період.

Для прогнозування навантаження вузлі використано дві нейронні мережі. Перша мережа, для прогнозу усіх вузлів описана в [100], є рекурентною нейронною мережею типу LSTM з комбінованою архітектурою, що складається з рекурентного модуля LSTM та багатошарового перцептрону з двома прихованими шарами, де в якості активаційної функції використовується SELU. Загальна кількість параметрів мережі наведена в таблиці 4.6. Друга мережа, розроблена в інституті електродинаміки НАН України, є мережею eResNet і

складається з трьох автокодувальних блоків з обхідними з'єднаннями та звичайного багатошарового перцептронну для прогнозу кожного вузла окремо. Особливістю даної архітектури є однакова кількість вхідних та вихідний нейронів. В таблиці 4.7 наведено загальну кількість параметрів мережі eResNet.

На рисунках 4.10-4.11 наведено блок-схеми алгоритмів прогнозування та розрахунку втрат електричної енергії.

*Таблиця 4.6*

#### **Загальна кількість параметрів мережі LSTM**

| <b>Назва шару</b>     | <b>Розмірності</b> | <b>Кількість параметрів</b> |
|-----------------------|--------------------|-----------------------------|
| Input<br>(InputLayer) | [(None, 25, 10)]   | 0                           |
| Recurent (LSTM)       | (None, 10)         | 840                         |
| Dense_1 (Dense)       | (None, 20)         | 220                         |
| Dense_2 (Dense)       | (None, 10)         | 210                         |

*Таблиця 4.7*

#### **Загальна кількість параметрів мережі eResNet**

| <b>Назва шару</b>      | <b>Розмірність</b> |
|------------------------|--------------------|
| AC1 (autocoding block) | (1, 168)           |
| AC2 (autocoding block) | (1, 168)           |
| AC3 (autocoding block) | (1, 168)           |
| Dense_1 (Dense)        | (168, 10)          |
| Dense_2 (Dense)        | (10, 24)           |




Рис. 4.10 Блок-схема алгоритму прогнозу вузлового навантаження та розрахунку втрат




Рис. 4.11 Блок-схема алгоритму для розрахунку та прогнозу втрат

Обидва методи прогнозування були адаптовані під використання ретроспективних даних. Алгоритм оптимізації ADAM [80] використовується для навчання обох алгоритмів.

Для прогнозування та розрахунку втрат електроенергії були використані ретроспективні дані ОСР України, які охоплювали період з 2017 по 2019 роки та включали інформацію про 15 вузлів навантаження. З яких було використано 14 вузлів навантаження для формування тестової енергосистеми та розрахунку втрат.

Подальші дослідження, розвиток методів прогнозування та їх тестування потребують реальної та достовірної ретроспективної інформації про вузлове навантаження та втрати електричної енергії.

В якості основи для побудови тестової електричної мережі було використано схему CIGRE середнього рівня напруги, яка наведено на рисунку 4.12, і яка широко використовується для досліджень режимів електричних мереж.

Для аналізу та моделювання електричних мереж було використано мову програмування Python та бібліотеку Pandapower для аналізу даних. Ця бібліотека є автономним інструментарієм для розробки та аналізу електричних мереж, що включає в себе велику кількість різних моделей електричних мереж, тестових систем та прикладів енергосистем CIGRE [103].

Тестова мережа має 15 вузлів, 18 джерел навантаження і складається з двох трансформаторів потужністю 40 МВА з напругою 110/20 кВ., 14 ліній серед яких 12 кабельних ліній та дві повітряні лінії, та перемикач. Усі елементи які використовуються в даній мережі є елементами бібліотеки Pandapower.

Враховуючи що дана схема побудована на основі реальної європейської мережі, вона значно відрізняється за складом навантаження та параметрами мережі України, тому для коректної роботи алгоритму розрахунку втрат було виконано адаптацію розрахункової схеми задля використання наявних ретроспективних даних.

В таблиці 4.8 наведено параметри схеми, які були замінені для коректної роботи з використанням ретроспективних даних українських електричних мереж.




Рис. 4.12 схема мережі CIGRE

Таблиця 4.8

### Елементи мережі

| Назва елементу  | Тип елементу          | Кількість |
|-----------------|-----------------------|-----------|
| Трансформатори  | 40 MVA 110/20 kV      | 2         |
| Повітряні лінії | 243-AL1/39-ST1A 110.0 | 4         |
|                 | 184-AL1/30-ST1A 20.0  | 2         |
|                 | 149-AL1/24-ST1A 20.0  | 9         |

Враховуючи, що величина навантаження в електричній схемі CIGRE та даних операторів систем розподілу відрізняється, то для коректного

функціонування тестової енергосистеми була проведена заміна кабельних та повітряних ліній на лінії більшого перерізу. Окрім того, дані вузлового навантаження ОСР були відмасштабовані відповідно до величини навантаження тестової електричної мережі CIGRE та розподілені відповідно до величини навантаження вузлів енергосистеми.

Ретроспективні дані вузлового навантаження були розділені на дві частини: навчальну та тестову вибірки. Навчальна вибірка містить усі значення вузлового навантаження, за винятком останніх 744 значень, які були збережені для тестування.

Результати прогнозування втрат за добу та за весь період наведено на рисунку 4.13-4.14.




Рис. 4.13 Погодинні втрати за добу з використанням різних методів прогнозування




Рис. 4.14 Графік прогнозування MAPE за весь період

Для оцінки точності представлених підходів використовувався функція похибки MAPE. В таблиці 4.9 наведено похибки прогнозування втрат електричної енергії.

Таблиця 4.9

#### Похибки прогнозування втрат електричної енергії

| Метод прогнозування втрат         | Величина похибки MAPE, % |
|-----------------------------------|--------------------------|
| Прогноз вузлового навантаження    | 7.51                     |
| Прогноз кожного вузла окремо      | 6.82                     |
| Прогноз втрат електричної енергії | 6.98                     |
| Втрати за коефіцієнтами втрат     | 19.42                    |

Зважаючи на те що величина середнього рівня напруги в енергосистемах України становить 10-35 кВ для достовірнішої оцінки визначення втрат електричної енергії. Було виконано адаптацію тестової мережі відповідно під середній рівень напруги енергосистем України. Для цього було замінено трансформатори, та частину повітряних ліній.

В таблиці 4.10 наведено замінені елементи мережі. Зважаючи що в бібліотеці pandorpower лінії з перерізом більше 150 мм для 10кВ відсутні для ефективної роботи було використано лінії для 20 кВ.

Таблиця 4.10

### Елементи мережі

| Назва елемента  | Тип елемента          | Кількість |
|-----------------|-----------------------|-----------|
| Трансформатори  | 40 MVA 110/10 kV      | 2         |
| Повітряні лінії | 243-AL1/39-ST1A 110.0 | 4         |
|                 | 184-AL1/30-ST1A 20.0  | 2         |
|                 | 149-AL1/24-ST1A 10.0  | 9         |

Визначення втрат проводилось на тих же ретроспективних даних, результати визначення втрат наведено на рисунках 4.15-4.16 та в таблиці 4.11.




Рис. 4.15 Добовий графік погодинних значень втрати




Рис. 4.16 Похиби визначення втрат з використанням різних методів

Таблиця 4.11

### Похибки визначення втрат електричної енергії

| Метод визначення втрат                                                          | Величина похибки MAPE, % |
|---------------------------------------------------------------------------------|--------------------------|
| Розрахунок втрат на основі прогнозу вузлового навантаження                      | 8,70                     |
| Розрахунок втрат на основі прогнозу вузлового навантаження кожного вузла окремо | 6,56                     |
| Прогноз втрат електричної енергії                                               | 7,00                     |
| Визначення втрат електричної енергії за коефіцієнтами втрат                     | 18,72                    |

Виконавши прогнозування та розрахунок втрат усіма підходами ми бачимо що загалом методи прогнозування мають меншу похибку втрат ніж при розрахунку втрат за коефіцієнтами втрат. Також прогнозування втрат та прогноз окремо кожного вузла мають меншу похибку ніж при прогнозуванні усіх вузлів разом. Це може бути пояснене різними взаємозв'язками між вузлами навантаження.

Також на величину втрат електричної енергії впливає зміна опору в лініях електропередач, яка в свою чергу залежить від багатьох зовнішніх факторів таких як температура навколишнього середовища, вологість, швидкість вітру, зміна довжини ліній деформацією проводів внаслідок дії вітрових навантажень та ожеледиці.

## ВИСНОВКИ ДО РОЗДІЛУ 4

1. Виконано дослідження з прогнозу вузлового навантаження з врахуванням зовнішніх факторів, за яким було визначено, що дані вузлового навантаження мають від'ємний кореляційний зв'язок з даними температури.

2. Виконано двоетапну кластеризацію даних для виявлення та заміни аномальних значень, що дозволило зменшити величину похибки прогнозування в тричі у порівнянні з прогнозом на фактичних не підготовлених даних.

3. Встановлено, що в залежності від обсягу ретроспективних вибірок їх сезонного періоду та типу дня тижня, похибка прогнозування вузлового навантаження може змінюватись до 2%.

4. Виконано аналіз даних Міністерства енергетики щодо відпуску та втрат електроенергії за яким втрати в мережах ОСР та ОСП складають 11.58%, для зменшення величини очікуваного значення втрат було запропоновано застосування методів прогнозування.

5. Розроблено модель розрахунку цін та тарифів на електричну енергію, в рамках дослідження прогнозу небалансу електричної енергії в ОЕС України та його вплив на кінцеву вартість електричної енергії. За якою було подано та отримано авторське свідоцтво на комп'ютерну програму «Модель розрахунку цін та тарифів на електричну енергію» 115250 від 13.10.22.

6. Завдяки підвищенню точності прогнозування вузлового навантаження стало можливо підвищення точності прогнозу очікуваних значень втрат електричної енергії в розподільній електричній мережі на основі ретроспективних даних для закупівлі втрат операторами систем розподілу на ринку електричної енергії України, що є більш ефективним, ніж визначення втрат електричної енергії за допомогою коефіцієнтів втрат.

7. Розроблено моделі прогнозування вузлів навантажень з використанням штучних нейронних мереж глибинного навчання задля визначення очікуваного значення втрат в електричних мережах, що дозволило зменшити похибку визначення очікуваного значення втрат електричної енергії в розподільних

мережах, під час формування їх погодинного графіка закупівлі операторами систем розподілу на ринку електричної енергії України.

8. Розроблено електричну мережу для розрахунку втрат електричної енергії на основі тестової електричної мережі CIGRE, виконано порівняння результатів запропонованих методів визначення втрат, які підтвердили їх ефективність у порівнянні з втратами на основі коефіцієнтів втрат.

*Результати експериментальних досліджень даного розділу наведено в таких публікаціях:*

Посилання [8], [17], [42-44], [47], [49-50], [99], див. список використаних джерел стор. 136-147.

## ВИСНОВКИ

В дисертаційній роботі розв'язано актуальну науково-технічну задачу короткострокового прогнозування погодинних значень вузлового електричного навантаження операторів систем розподілу з врахуванням додаткових факторів та їх використання для визначення очікуваних втрат в електричних мережах.

Показано, що на основі прогнозу вузлового навантаження можна ефективно вирішувати низку технологічних задач пов'язаних з управлінням режимом роботи енергосистеми. Так, зі зміною порядку формування графіку покриття навантаження, яка пов'язана з переходом від централізованого планування (яке здійснювало ДП «Енергоринок») до використання комерційних графіків, суттєво збільшилось навантаження на диспетчерську службу ОЕС України. При цьому виникає необхідність в оперативній оцінці режимів електричних мереж, надійність яких залежить від точності прогнозів навантаження в вузлах електричної мережі.

Аналіз методів розв'язання задачі короткострокового прогнозування вузлового навантаження показав, що сучасний апарат штучних нейронних мереж глибинного навчання, за допомогою якого вдалось досягти суттєвого прогресу в суміжних галузях, не використовується для розв'язання даної задачі. У роботі було запропоновано архітектуру штучної нейронної мережі для прогнозування векторів часових рядів, що враховує залежності між електричними навантаженнями суміжних вузлів.

На основі виконаних досліджень розроблено метод багатофакторного короткострокового прогнозування вузлового електричного навантаження з використанням штучної нейронної мережі з модулем довго-короткострокової пам'яті (LSTM – Long-short term memory) та обхідним з'єднанням і паралельною гілкою прихованих шарів для обробки та врахування впливу зовнішніх факторів, що як найкраще підходить для прогнозування вузлового навантаження, як для випадків з тривалими часовими рядами, так і у випадках великої кількості вузлів.

Визначено, що двоетапна достовіризація з використанням алгоритму кластеризації DBSCAN дозволяє суттєво знизити похибки прогнозування навантаження вузлів з значними аномальними викидами, але потребує вдосконалення для випадків тривалих групових викидів. Крім того, для автоматичного застосування алгоритму на даних з великою кількістю вузлів без аномальних значень необхідно знижувати кількість хибнопозитивних реакцій, які можуть спотворювати вихідні дані.

Отримані результати лягли в основу розробки методу аналізу даних для виявлення та заміни аномальних значень та пропусків значень вузлового електричного навантаження за рахунок виконання двоетапного аналізу з використанням методу кластеризації даних DBSCAN та декомпозиції часових рядів, а також заміни аномальних значень, що дозволило зменшити кількість виявлення хибних значень та в подальшому підвищити точність короткострокового прогнозування вузових навантажень.

За результатами аналізу особливостей роботи нового ринку електричної енергії визначено, що в операторів систем розподілу та оператору системи передачі з'являються прямі економічні стимули для підвищення точності короткострокових прогнозів технологічних втрат (ТВЕ). Показано, що сьогодні фінансова відповідальність за небаланси електророзподільчих компаній передбачає закупівлю ними необхідних обсягів електроенергії на вільному ринку.

Розрахунок економічного ефекту від зниження похибки прогнозів ТВЕ енергорозподільчих компаній з горизонтом упередження від 12 до 36 годин («на добу наперед») показує, що зниження похибки на 5% дозволить знизити сумарні витрати для компенсації небалансів на 184 млн на рік (в цінах 2019 року) при середній ціні похибки в 225 грн/МВт·год, що дозволить знизити тарифи на розподіл та тариф на передачу електричної енергії для всіх кінцевих споживачів.

Показано, що сьогодні найбільш розповсюдженим підходом є прямий прогноз часового ряду втрат електричної енергії, проте при такому підході не була врахована топологія мережі, при зміні якої в часовому ряді втрат виникають аномальні викиди, які ускладнюють побудову адекватної моделі та знижують

точність прогнозування. Обґрунтовано доцільність визначення очікуваних значень втрат на основі прогнозу вузлових навантажень з врахуванням параметрів режиму та прямого розрахунку втрат з врахуванням топології мережі.

Завдяки підвищенню точності прогнозування вузлового навантаження стало можливо підвищення точності прогнозних значень втрат електричної енергії в розподільній електричній мережі на основі ретроспективних даних для закупівлі втрат операторами систем розподілу на ринку електричної енергії України, що є більш ефективним, ніж визначення втрат електричної енергії за допомогою коефіцієнтів втрат.

Розроблено моделі прогнозування вузлів навантажень з використанням штучних нейронних мереж глибинного навчання задля визначення втрат в електричних мережах, що дозволило зменшити похибку визначення очікуваного значення втрат електричної енергії в розподільних мережах під час формування їх погодинного графіка закупівлі операторами систем розподілу на ринку електричної енергії України

За результатами теоретичних досліджень розроблено комп'ютерну програму для короткострокового прогнозування вузлового електричного навантаження з врахуванням додаткових факторів, методики аналізу даних для виявлення та заміни аномальних даних та пропусків за допомогою методів кластеризації та декомпозиції часових рядів, рекомендації щодо підвищення точності розрахунку втрат електричної енергії за допомогою прогнозування вузлового навантаження на основі архітектури штучної нейронної мережі.

Практичні результати роботи впроваджено в навчальному процесі Інституту енергозбереження та енергоменеджменту НТУУ «КПІ ім. І. Сікорського», під час виконання науково-дослідних робіт Інституту електродинаміки та розробки аналітичних матеріалів щодо виявлення аномальних значень в даних вузлового електричного навантаження для ТОВ «ДТЕК Мережі»

За результатами теоретичних досліджень прогнозу небалансу електричної енергії в ОЕС України та його вплив на кінцеву вартість електричної енергії, було подано та отримано авторське свідоцтво на комп'ютерну програму «Модель розрахунку цін та тарифів на електричну енергію» 115250 від 13.10.22.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Stanton K. N. Forecasting annual or seasonal peak demand in electric utility systems. K. N. Stanton, P. G. Gupta. *IEEE Trans. Power Appar. and Syst.* 1970. Vol. 8. № 5. P. 951-959.
2. Martin T. The times series approach to short term load forecasting. T. Martin. *IEEE Trans. On Power Systems.* 1987. 2 (3). pp. 785 - 791.
3. Ji Peirong, Xiong Di, Wang Peng, Chen Juan A study on exponential smoothing model for load forecasting. *2012 Asia-Pacific Power and Energy Engineering Conference.* 2012. China. pp. 1-4. DOI: 10.1109/APPEEC.2012.6307555
4. Черненко П.О., Мірошник В.О. Підвищення точності короткострокового прогнозування електричного навантаження за допомогою штучної нейронної мережі з врахуванням зміни структури споживання протягом року. *Праці Інституту електродинаміки Національної Академії Наук України.* 2017. №48. С 5-11. DOI: <https://doi.org/10.15407/publishing2017.48.005>
5. Ceperic E., Ceperic V, Baric A. A strategy for short-term load forecasting by support vector regression machines. *IEEE Transactions on power systems.* 2013. Vol. 28. Issue 4. p. 56-64.
6. Про затвердження Кодексу систем розподілу: Постанова НКРЕКП від 14.03.2018 № 310. Доступ он-лайн: <https://zakon.rada.gov.ua/laws/show/v0310874-18>
7. Блінов І.В. Теоретичні та практичні засади функціонування конкурентного ринку електроенергії. К.: Наукова думка. 2015. 250 с.
8. Шиманюк П.В., Мірошник В.О., Блінов І.В., Черненко П.О. Аспекти врахування температури повітря для підвищення точності короткострокового прогнозування вузлових навантажень. *Енергетика: економіка, технології, екологія.* 2021. №2 С.50-58. DOI: <https://doi.org/10.20535/1813-5420.2.2021.247368>.

9. Blinov I., Miroshnyk V., Sychova V. Comparison of models for short-term forecasting of electricity imbalances. *2022 IEEE 8th International Conference on Energy Smart Systems (ESS)*. 2022. Pp. 1-4. DOI: 10.1109/ESS57819.2022.9969288
10. Сичова В.В. Прогнозування добових графіків сумарних небалансів електричної енергії в ОЕС України. *Технічна електродинаміка*. 2022. № 4. С 59-63. DOI:<https://doi.org/10.15407/techned2022.04.059>.
11. Блінов І.В., Парус Є.В., Іванов Г.А. Імітаційне моделювання функціонування балансуючого ринку електроенергії з урахуванням системних обмежень на параметри режиму ОЕС України. *Технічна електродинаміка*. 2017. № 6. С. 72-79. DOI: <https://doi.org/10.15407/techned2017.06.072>
12. Про затвердження Кодексу систем передачі: Постанова НКРЕКП від 14.03.2018 № 309.
13. Про ринок електричної енергії: Закон України № 2019-VIII від 13.04.2017 р.
14. Ivanov H., Blinov I., Parus Ye. Simulation Model of New Electricity Market in Ukraine. *2019 IEEE 6th International Conference on Energy Smart Systems (ESS)*. 2019. pp. 339-342. DOI: <https://doi.org/10.1109/ESS.2019.8764184>
15. Інтелектуальні електричні мережі: елементи та режими. Під заг. Ред. Акад. НАН України О.В. Кириленко. К.: Ін-т електродинаміки НАН України. 2016. 400 с. ISBN 978-966-02-7913-1.
16. Про затвердження Правил ринку. Постанова Національної комісії, що здійснює державне регулювання у сферах енергетики та комунальних послуг №307 від 14.03.2018.
17. Блінов І.В., Мірошник В.О., Шиманюк П.В. Оцінка вартості похибки прогнозу «на добу наперед» технологічних втрат в електричних мережах України. *Технічна електродинаміка*. 2020. №5. С. 70-73. DOI: <https://doi.org/10.15407/techned2020.05.070>
18. Постанова Національної комісії, що здійснює державне регулювання у сферах енергетики та комунальних послуг №308 від 14.03.2018 «Про затвердження правил ринку «на добу наперед» та внутрішньодобового ринку».

19. Кириленко О.В., Блінов І.В., Парус Е.В. Визначення результатів аукціону з купівлі-продажу електричної енергії. *Проблеми загальної енергетики*. 2010. № 3. С. 5-12.
20. Парус Є.В., Блінов І.В. Складові імітаційної моделі процесів ціноутворення на ринку електричної енергії України. *Праці Інституту електродинаміки НАН України*. 2019. Вип. 53. С. 28-34.
21. Мірошник В.О., Шиманюк П.В. Аналіз методів достовіризації даних для задач короткострокового прогнозування вузлових електричних навантажень. *Праці інституту електродинаміки НАН України*. 2021. №60. С. 51-57. DOI: <https://doi.org/10.15407/publishing2021.60.051>
22. Левінгтон І. Україна – впровадження концепції оптового ринку електроенергії (ОРЕ). *Електропанорама*, 2009, №1-2, С. 40-44.
23. Про схвалення Концепції функціонування та розвитку оптового ринку електричної енергії: Постанова Кабінету Міністрів України від 16.11.2002 р. №1789.
24. Постанова Національної комісії, що здійснює державне регулювання у сферах енергетики та комунальних послуг №312 від 14.03.2018 «Про затвердження правил роздрібного ринку електричної енергії».
25. Дані офіційного сайту НКРЕКП України [Електронний ресурс] – Режим доступу: <http://www.nerc.gov.ua/?id=11889>
26. Блінов І.В. Проблеми функціонування та розвитку ринку електричної енергії України. (за матеріалами наукової доповіді на засіданні Президії НАН України 3 лютого 2021 р.). *Вісник НАН України*. 2021. № 3. С. 20-28. doi: <https://doi.org/10.15407/visn2021.03.020>
27. Борукаєв З., Блінов І., Остапченко К., Чемерис, О., Шкарупило, В. Моделі та засоби автоматизації систем організаційного управління енергоринком. *Publishing House «European Scientific Platform»*. 2022. С. 122. DOI: <https://doi.org/10.36074/mtzasoye-monograph.2022>

28. Кириленко О.В., Блінов І.В., Парус Є.В. Балансуючий ринок електроенергії України та його математична модель. *Техн. електродинаміка*. 2011. № 2. С. 36-43.
29. Блінов І.В., Парус Є.В., Шкарупило В.В. Структура та моделі інформаційної взаємодії учасників ринку електричної енергії. *Вінниця: ГО «Європейська наукова платформа»*. 2021. 114 с. DOI: <https://doi.org/10.36074/stmivvyree-monograph.2021>
30. Кириленко О.В., Блінов І.В., Парус Є.В., Іванов Г.А. Імітаційна модель ринку електричної енергії «на добу наперед» з неявним врахуванням мережевих обмежень енергетичних систем. *Технічна електродинаміка*. 2019. № 5. С. 60-67. DOI: <https://doi.org/10.15407/techned2019.05.060>
31. Іванов Г.А., Блінов І.В., Парус Є.В. Комплексна розрахункова модель ринку на добу наперед та балансуєчого ринку електроенергії України. *Промелектро*. 2016. № 4-5. С. 8-12.
32. Іванов Г.А., Блінов І.В. Складові процесу імітаційного моделювання лібералізованого ринку електричної енергії України. *Електричні мережі та системи*. 2018. № 4-5. С. 58-62.
33. Блінов І.В., Парус Є.В., Іванов Г.А. Імітаційне моделювання функціонування балансуєчого ринку електроенергії з урахуванням системних обмежень на параметри режиму ОЕС України. *Технічна електродинаміка*. 2017. № 6. С. 72-79. DOI: <https://doi.org/10.15407/techned2017.06.072>
34. ENTSOE Operation Handbook. P5 - Policy 5: Emergency Operations.
35. Кириленко О.В., Павловський, В.В., Блінов, І.В. Науково-технічне забезпечення організації роботи ОЕС України в синхронному режимі з європейською континентальною енергетичною системою ENTSO-E. *Технічна електродинаміка*. 2022. № 5. С. 59-66. DOI: <https://doi.org/10.15407/techned2022.05.059>
36. Кириленко О.В., Блінов І.В., Парус Є.В. Оцінка роботи електростанцій при наданні допоміжних послуг з первинного та вторинного регулювання частоти в ОЕС України. *Технічна електродинаміка*. 2013. № 5. С. 55-60.

37. Олефір Д.О., Бабіч В.Ю., Блінов І.В. Актуальні проблеми забезпечення ОЕС України ресурсами регулювання частоти та потужності. *Енергетика: економіка, технології, екологія*. 2021. № 3. С. 39-46.
38. Блінов І.В., Олефір Д.О., Парус Є.В. Модель оптимального використання ресурсів гідроелектростанцій на ринку електричної енергії. *Технічна електродинаміка*. 2022. №2. С. 60-69. DOI: <https://doi.org/10.15407/techned2022.04.042>
39. Blinov I., Olefir D., Parus, E., Kyrylenko O. Improving the Efficiency of HPP and PSHPP Participation in the Electricity Market of Ukraine. *Power Systems Research and Operation. Studies in Systems, Decision and Control*. editors: Kyrylenko O., Denysiuk S., Derevianko D., Blinov I., Zaitsev I., Zaporozhets A. Springer. vol 220. Pp. 51-74. DOI:[https://doi.org/10.1007/978-3-031-17554-1\\_3](https://doi.org/10.1007/978-3-031-17554-1_3).
40. Lin J., Magnago F. Electricity Markets: Theories and Applications. *IEEE Press Series on Power*. 2017. pp. 352.
41. Mantysari P. Electricity Marketplaces. *EU Electricity Trade Law*. Springer. Cham. 2015. pp. 169-346
42. Блінов І.В., Мірошник В.О., Шиманюк П.В. Короткостроковий інтервальний прогноз сумарного відпуску електроенергії виробниками з відновлюваних джерел енергії. *Праці Інституту електродинаміки НАН України*. 2019. №54. С. 5-12. DOI:<https://doi.org/10.15407/publishing2019.54.005>
43. Miroshnyk V., Shymaniuk P., Sychova V., Loskutov S. Short-term load forecasting in electrical networks and systems with artificial neural networks and taking into account additional factors. *Power Systems Research and Operation: Selected problems II*. editors: Kyrylenko O., Denysiuk S. and other. 2022. pp. 87-105. DOI: [https://doi.org/10.1007/978-3-031-17554-1\\_5](https://doi.org/10.1007/978-3-031-17554-1_5).
44. Miroshnyk V., Shymaniuk P., Sychova V. Short term renewable energy forecasting with deep learning neural networks. *Power Systems Research and Operation: Selected problems*. editors: Kyrylenko O., Zharkin A. and other. Springer, 2021. pp. 121–142. DOI: [https://doi.org/10.1007/978-3-030-82926-1\\_6](https://doi.org/10.1007/978-3-030-82926-1_6).

45. Ivanov H. A., Blinov I.V., Parus E.V. Architecture of tools of estimating the influence of renewable sources on the electricity cost in Ukraine. *Natural and Technical Sciences*. 2020. VIII (30). Issue 244. pp. 49-52.
46. Черненко П.О., Мірошник В.О., Шиманюк П.В. Однофакторне короткострокове прогнозування вузлових електричних навантажень енергосистеми. *Технічна електродинаміка*. 2020. №2. С. 67-73. DOI:<https://doi.org/10.15407/techned2020.02.067>.
47. Blinov I., Miroshnyk V., Shymaniuk P. Short-term nodal electrical load forecasting with artificial neural networks. *2022 IEEE 8th International Conference on Energy Smart Systems (ESS)*. Pp.12-14. DOI: 10.1109/ESS57819.2022.9969245.
48. Блінов І.В., Мірошник В.О., Лоскутов С.С. Зниження витрат на покриття небалансів учасників балансуючої групи виробників електричної енергії з відновлюваних джерел. *Технічна електродинаміка*. 2023. № 1. С 62-66. DOI: <https://doi.org/10.15407/techned2023.01.062>
49. Shymaniuk P., Miroshnyk V., Blinov I., Estimation of electrical losses in the distribution network based on nodal electrical load forecasts. *2022 IEEE KhPI Week on Advanced Technology (KhPIWeek)*. 2022 pp. 1-4. DOI: 10.1109/KhPIWeek57572.2022.9916407.
50. Блінов І.В., Парус Є.В., Мірошник В.О., Шиманюк П.В., Сичова В.В. Модель оцінки доцільності переходу промислових споживачів до погодинного обліку електричної енергії на роздрібному ринку. *Енергетика: економіка, технології, екологія*. 2021. №1. С. 88-97. DOI: <https://doi.org/10.20535/1813-5420.1.2021.242186>.
51. Куцан Ю.Г., Блінов І.В., Іванов Г.А. Моделювання тарифо- та ціноутворення на роздрібному ринку електричної енергії України в нових умовах функціонування. *Електронне моделювання*. 2017. № 5. С. 71-79.
52. Оптовий та роздрібний ринок електричної енергії: розрахункова робота [Електронний ресурс] : навч. посіб. для студ. які навчаються за спеціальністю 141 «Електроенергетика, електротехніка та електромеханіка». КПІ ім. Ігоря Сікорського; уклад.: І.В. Блінов, Є.В. Парус. Електронні текстові дані (1 файл:

- 1,1 Мбайт). Київ : КПІ ім. Ігоря Сікорського, 2022. 44 с.  
<https://ela.kpi.ua/bitstream/123456789/48521/1/Rynok.pdf>
53. Борукаев З. Х., Остапченко К. Б., Лисовиченко О. И. Модели для определения прогнозной оптовой цены покупки электроэнергии в условиях изменения цен на рынках энергоносителей. Міжвідомчий науково-технічний збірник «Адаптивні системи автоматичного управління». 2015. № 2(26). С.35 – 43.
54. Блінов І.В., Корхмазов Г.С., Попович В.І., Зозуля А.М. Короткострокове прогнозування оптових цін на електричну енергію з використанням радіально-базисних штучних нейронних мереж. *Праці Інституту електродинаміки НАН України*. 2009. Вип. 24. С. 23-31.
55. Борукаев З. Х. Остапченко К. Б., Лисовиченко О. И. Математическое обеспечение методики расчета прогнозной оптовой цены электроэнергии на оптовом рынке. *Енергетика та електрифікація*. 2015. Вип. 9 (385). С. 33 – 43.
56. Блінов І.В., Корхмазов Г.С. Використання штучних нейронних мереж для розв’язання задачі короткострокового прогнозування оптових ринкових цін на електричну енергію. *Праці Інституту електродинаміки НАН України*. Темат. вип. «Енергетичні ринки: перехід до нової моделі ринку двосторонніх контрактів і балансуючого ринку». 2009. С. 15-22.
57. G. Hou, K. Xu, S. Yin, Y. Wang, Y. Han, Z. Wang, Y. Mao, Z. Lei A novel algorithm for multi-node load forecasting based on big data of distribution network. *International Conference on Advanced Electronic Science and Technology (AEST 2016)*. Shenzhen. 2016. Pp 655-667.
58. X. Wang, N. Hatziaargyriou, L.H. Tsoukalas A New Methodology for Nodal Load Forecasting in Deregulated Power Systems. *IEEE Power Engineering Review*. May 2002. Pp 48-51.
59. Г.П. Шуилова, Н.Э. Готман, Т.Б. Старцева Прогнозирование активной и реактивной нагрузки узлов ЭЭС с использованием инверсии искусственной нейронной сети. *Электричество*. №6 2007. с. 7-13.

60. E. Sbai, & M. Simpson Short-term Forecasting of Nodal Electricity Demand in New Zealand. 2019.
61. X.S. Han, L. Han, H.B. Gooi, Z.Y. Pan Ultra-short-term multi-node load forecasting - a composite approach. *IET Generation, Transmission & Distribution*, 2012. Vol. 6. Pp436-444. DOI: 10.1049/iet-gtd.2011.0524.
62. D.M. Falcao, U.H. Bezerra Short-term forecasting of nodal active and reactive load in electric power system'. *IEE Conf. Publication*. 1986. pp. 18–22.
63. A. Han, B. Zhang, Z. Sun, Z. Niu, J. Wang Nodal Load Forecast Model Considering Network Topology. *Constraints IEEE PES Asia-Pacific Power and Energy Conference*. 2016. Xi'an. China. Pp 939-943.
64. J. W. Taylor Short-Term Electricity Demand Forecasting Using Double Seasonal Exponential Smoothing. *The Journal of the Operational Research Society*. Vol. 54. No. 8 (Aug., 2003). pp. 799-805
65. R. Hooke, T.A. Jeeves "Direct search" solution of numerical and statistical problems. *Journal of the ACM*. 8 (2). 1961. pp. 212–229. доступ он-лайн: <https://doi.org/10.1145/321062.321069>
66. Я. Д. Гельруд, Е. А. Узрюмов, В. Л. Рыбак, Векторная модель авторегрессии показателей производственной деятельности строительного предприятия. *Вестн. ЮУрГУ. Сер. Выч. матем. информ.* 2018. том 7. выпуск 3. 19–30. доступ он-лайн: <https://doi.org/10.14529/cmse180302>
67. D.E. Rumelhart, G. E. Hinton, R. J. Williams Learning Internal Representations by Error Propagation. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*. MITP. 1987. pp.318-362.
68. S. Hochreiter, J. Schmidhuber Long Short-term Memory. *Neural computation*. 1997. No 9. Pp 1735-1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>
69. Лоскутов С.С., Шиманюк П.В. Прогнозування сумарного електричного навантаження на кожному з ієрархічних рівнів ОЕС України за допомогою нейронних мереж. *Праці ІЕД НАН України*. 2021. №59. С 81-85. DOI: <https://doi.org/10.15407/publishing2021.59.081>

70. A. Taieb, S. Bontempi, G. Atiya, A.F. & A. Sorjamaa, A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Systems with Applications*. vol. 39. no. 8. 2012 pp. 7067-7083.
71. Paul M. Swamidass Encyclopedia of Production and Manufacturing Management. Reference work. 2000. pp. 462.
72. Willmott, Cort J.; Matsuura, Kenji Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*. 30. 2005. Pp.79–82. doi:10.3354/cr030079
73. A. A. Belsley, E. Kuh, R. E. Welsch "The Condition Number". *Regression Diagnostics: Identifying Influential Data and Sources of Collinearity*. New York: John Wiley & Sons. 1980 pp. 100–104.
74. H.N. Mhaskar, T. Poggio Deep vs. shallow networks: An approximation theory perspective. *Analysis and Applications*. 2016. Vol.14. Issue 6. Pp. 829-848.
75. K.M. He, X.Y. Zhang, S.Q. Ren, J. Sun Deep Residual Learning for Image Recognition. Proc. Conference on Computer Vision and Pattern Recognition. 2016. Pp. 770-778.
76. A.Veit, M. Wilber, S. Velongie Residual networks behave like ensembles of relatively shallow networks. Proc. Advances in Neural Information Processing Systems. 29. 2016. Pp. 550-558.
77. H. Li, Z. Xu, G. Taylor, C. Studer, T. Goldstein Visualizing the loss landscape of neural nets. Proceedings of the 32nd International Conference on Neural Information Processing Systems (NIPS'18). Montréal. 2018. Pp. 6391-6401.
78. П.О. Черненко, В.О. Мірошник Короткострокове прогнозування електричного навантаження електропостачальної компанії з використанням штучної нейронної мережі глибинного навчання. *Праці Інституту електродинаміки НАН України*. 2018р. № 50. С. 5-11.
79. G. Klambauer, T. Unterthiner, A. Mayr, S. Hochreiter Self-Normalizing Neural Networks. *Advances in Neural Information Processing Systems*. 2017. № 30. Pp. 971-980.

80. D.P. Kingma, J. Ba Adam. A Method for Stochastic Optimization. Proc. of the 3<sup>rd</sup> International Conference on Learning Representations (ICLR).
81. Кучанський В.В., Шиманюк П.В., Шкарупило В.В. Розроблення штучної нейронної мережі для прогнозу характеристик перенапруг в електричних мережах. *I International Scientific and Practical Conference «Problemas y perspectivas de la aplicación de la investigación científica innovadora»*. 2021. Рр. 105-109. DOI: <https://doi.org/10.36074/logos-11.06.2021.v1.30>.
82. Черненко П.О. Ієрархічне багатофакторне прогнозування електричного навантаження енергооб'єднання. *Інститут електродинаміки НАН України*. К. 2011. 349 с.
83. Кириленко О.В., Блінов І.В., Денисюк С.П., Зайцев С.О., Васильченко В.І. Впровадження базових міжнародних стандартів Smart Grid в Україні: сучасний стан справ. *Енергетика: економіка, технології, екологія*. 2022. №4.
84. Кириленко О.В., Блінов І.В., Зайцев С.О., Палачов С.О., Васильченко В.І. Впровадження міжнародних та європейських стандартів для розвитку ОЕС України згідно концепції Smart Grid. *Праці інституту електродинаміки НАН України*. 2022. №63. <https://doi.org/10.15407/publishing2022.63.005>
85. Танкевич С.Є., Блінов І.В., Кириленко В.В. Україна та світ: нормативне забезпечення інтелектуальних електроенергетичних систем за концепцією Smart Grid. *Стандартизація, сертифікація, якість*. 2014. № 4 (89). С. 38-44.
86. Кириленко О.В., Блінов І.В., Танкевич С.Є. Smart Grid та організація інформаційного обміну в електроенергетичних системах. *Технічна електродинаміка*. 2012. № 3. С. 47-48.
87. IEC/TR 63097:2017 Smart grid standardization roadmap. 2017. pp 315.
88. SGCG/M490/G\_Smart Grid Set of Standards 25 Version 3.1. CEN-CENELEC-ETSI Smart Grid Coordination Group. 2014. pp. 259.
89. Luo, Jian & Hong, Tao & Fang, Shu-Cherng. Benchmarking robustness of load forecasting models under data integrity attacks. *International Journal of Forecasting*. 34. 2018. 89-104. 10.1016/j.ijforecast.2017.08.004.

90. Robert M. Lee, Michael J. Assante, Tim Conway. Analysis of the Cyber Attack on the Ukrainian Power Grid. Defense Use Case. ([https://ics.sans.org/media/E-ISAC\\_SANS\\_Ukraine\\_DUC\\_5.pdf](https://ics.sans.org/media/E-ISAC_SANS_Ukraine_DUC_5.pdf)).
91. Martin Ester, Hans-Peter Kriegel, Jörg Sander, Xiaowei Xu. A density-based algorithm for discovering clusters in large spatial databases with noise. Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96). Evangelos Simoudis, Jiawei Han, Usama M. Fayyad. AAAI Press, 1996. C. 226–231.
92. Liu, Fei Tony; Ting, Kai Ming; Zhou, Zhi-Hua (December 2008). "Isolation Forest". *2008 Eighth IEEE International Conference on Data Mining*. pp. 413–422. doi:10.1109/ICDM.2008.17. ISBN 978-0-7695-3502-9.
93. Breunig M. M., Kriegel H.-P., Ng R. T., Sander J. R. LOF: Identifying Density-based Local Outliers. Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data. 2000. (SIGMOD). ISBN 1-58113-217-4. doi:10.1145/335191.335388
94. Tarek Amr Hands-On Machine Learning with scikit-learn and Scientific Python Toolkits: A practical guide to implementing supervised and unsupervised machine learning algorithms in Python. *Packt Publishing*. July 24. 2020.
95. M. Peker, A Kocaman, K. Bahar A real data set for a 116-node power transmission system. *Mendeley Data*. v1. 2018. доступ он-лайн: <http://dx.doi.org/10.17632/dv3vjnwwf9.1>
96. U.S. Electric system operating data. доступ он-лайн: [https://www.eia.gov/realtime\\_grid/#/status?end=20190810T17&timeZone=Pacific](https://www.eia.gov/realtime_grid/#/status?end=20190810T17&timeZone=Pacific)
97. T.V. Jensen, P. Pinson RE-Europe, a large-scale dataset for modeling a highly renewable European electricity system. *Sci. Data* 4, 170175 (2017).
98. Tae Woo Joo, Seoung Bum Kim Time series forecasting based on wavelet filtering. *Expert Systems with Applications* Volume 42. 15 May 2015. Pp. 3868-3874. <https://doi.org/10.1016/j.eswa.2015.01.026>.
99. Шиманюк П.В. Достовіризація даних та аналіз методів для задач прогнозування вузлових електричних навантажень в ринкових умовах. VIII

Всеукраїнської науково-практичної конференції молодих вчених «Наукова молодь-2020». м. Київ. С.151-156. 2020.

100. Шиманюк П.В., Мірошник В.О., Блінов І.В. Визначення втрат електричної енергії на основі прогнозів вузлового електричного навантаження. *Енергетика: економіка, технології, екологія*. 2022. №3. С.38-43. DOI: <https://doi.org/10.20535/1813-5420.3.2022.271484>

101. Про затвердження Положення про покладення спеціальних обов’язків на учасників ринку електричної енергії для забезпечення загальносупільних інтересів у процесі функціонування ринку електричної енергії: Постанова Кабінету Міністрів України від 5 червня 2019р. №483. доступ он-лайн: <https://zakon.rada.gov.ua/laws/show/483-2019-%D0%BF>

102. Інформація про роботу електроенергетичного комплексу за 12 місяців 2018 року. Доступ он-лайн: <http://mpe.kmu.gov.ua/minugol/doccatalog/document?id=245374262>

103. “Benchmark Systems for Network Integration of Renewable and Distributed Energy Resources”, ELECTRA, 2014 DOI:[http://e-cigre.org/publication/ELT\\_273\\_8-benchmark-systems-for-network-integrationof-renewable-and-distributed-energy-resources](http://e-cigre.org/publication/ELT_273_8-benchmark-systems-for-network-integrationof-renewable-and-distributed-energy-resources)

## ДОДАТОК А

### Список публікацій здобувача

1. Miroshnyk V., Shymaniuk P., Sychova V. Short term renewable energy forecasting with deep learning neural networks. *Power Systems Research and Operation: Selected problems*. editors: Kyrylenko O., Zharkin A. and other. Springer, 2021. pp. 121–142. DOI: [https://doi.org/10.1007/978-3-030-82926-1\\_6](https://doi.org/10.1007/978-3-030-82926-1_6). (Scopus). (Особистий внесок – розробка нейронної мережі для прогнозу вузлового навантаження з врахування температури повітря).
2. Miroshnyk V., Shymaniuk P., Sychova V., Loskutov S. Short-term load forecasting in electrical networks and systems with artificial neural networks and taking into account additional factors. *Power Systems Research and Operation: Selected problems II*. editors: Kyrylenko O., Denysiuk S. and other. 2022. pp. 87-105. DOI: [https://doi.org/10.1007/978-3-031-17554-1\\_5](https://doi.org/10.1007/978-3-031-17554-1_5). (Scopus). (Особистий внесок – розробка моделей нейронних мереж та проведення, порівняння та оцінка результатів прогнозування).
3. Блінов І.В., Мірошник В.О., Шиманюк П.В. Короткостроковий інтервальний прогноз сумарного відпуску електроенергії виробниками з відновлюваних джерел енергії. *Праці ІЕД НАН України*. 2019. №54. С. 5-12. DOI:<https://doi.org/10.15407/publishing2019.54.005> (Особистий внесок – адаптація нейронної мережі для прогнозування відпуску електричної енергії).
4. Черненко П.О., Мірошник В.О., Шиманюк П.В. Однофакторне короткострокове прогнозування вузлових електричних навантажень енергосистеми. *Технічна електродинаміка*. 2020. №2. С. 67-73. DOI:<https://doi.org/10.15407/techned2020.02.067>. (Категорія «А», Scopus). (Особистий внесок – аналіз та підготовка даних, розробка рекурентної нейронної мережі).
5. Блінов І.В., Мірошник В.О., Шиманюк П.В. Оцінка вартості похибки прогнозу «на добу наперед» технологічних втрат в електричних мережах України. *Технічна електродинаміка*. 2020. №5. С. 70-73. DOI:

<https://doi.org/10.15407/techned2020.05.070> (Категорія «А», Scopus). (Особистий внесок – аналіз та підготовка матеріалів про новий ринок електричної енергії).

6. Лоскутов С.С., Шиманюк П.В. Прогнозування сумарного електричного навантаження на кожному з ієрархічних рівнів ОЕС України за допомогою нейронних мереж. *Праці ІЕД НАН України*. 2021. №59. С 81-85. DOI: <https://doi.org/10.15407/publishing2021.59.081> (Особистий внесок – підготовка матеріалів для розрахунку ієрархічних прогнозів).

7. Блінов І.В., Парус Є.В., Мірошник В.О., Шиманюк П.В., Сичова В.В. Модель оцінки доцільності переходу промислових споживачів до погодинного обліку електричної енергії на роздрібному ринку. *Енергетика: економіка, технології, екологія*. 2021. №1. С. 88-97. DOI: <https://doi.org/10.20535/1813-5420.1.2021.242186>. (Особистий внесок – підготовка та аналіз матеріалів про ринок електроенергії).

8. Шиманюк П.В., Мірошник В.О., Блінов І.В., Черненко П.О. Аспекти врахування температури повітря для підвищення точності короткострокового прогнозування вузлових навантажень. *Енергетика: економіка, технології, екологія*. 2021. №2 С.50-58. DOI: <https://doi.org/10.20535/1813-5420.2.2021.247368> (Особистий внесок – підготовка та розрахунок прогнозних значень вузлового навантаження з врахування температури повітря).

9. Шиманюк П.В., Мірошник В.О., Блінов І.В. Визначення втрат електричної енергії на основі прогнозів вузлового електричного навантаження. *Енергетика: економіка, технології, екологія*. 2022. №3. С.38-43. DOI: <https://doi.org/10.20535/1813-5420.3.2022.271484> (Особистий внесок- розробка архітектури нейронної мережі та розрахунок втрат електричної енергії).

10. Мірошник В.О., Шиманюк П.В. Аналіз методів достовіризації даних для задач короткострокового прогнозування вузлових електричних навантажень. *Праці інституту електродинаміки НАН України*. 2021. №60. С. 51-57. DOI: <https://doi.org/10.15407/publishing2021.60.051> (Особистий внесок – виконання експериментальних досліджень, розробка алгоритму виявлення та заміни аномальних даних).

11. Кучанський В.В., Шиманюк П.В., Шкарупило В.В. Розроблення штучної нейронної мережі для прогнозу характеристик перенапруг в електричних мережах. *I International Scientific and Practical Conference «Problemas y perspectivas de la aplicación de la investigación científica innovadora»*. 2021. Рр. 105-109. DOI: <https://doi.org/10.36074/logos-11.06.2021.v1.30>. (Особистий внесок – опис штучних нейронних мереж).
12. Blinov I., Miroshnyk V., Shymaniuk P. Short-term nodal electrical load forecasting with artificial neural networks. *2022 IEEE 8th International Conference on Energy Smart Systems (ESS)*. Рр.12-14. DOI: 10.1109/ESS57819.2022.9969245. (Scopus). (Особистий внесок - розробка архітектур штучних нейронних мереж).
13. Shymaniuk P., Miroshnyk V., Blinov I., Estimation of electrical losses in the distribution network based on nodal electrical load forecasts. *2022 IEEE KhPI Week on Advanced Technology (KhPIWeek)*. 2022 рр. 1-4. DOI: 10.1109/KhPIWeek57572.2022.9916407. (Scopus). (Особистий внесок - розробка архітектури нейронної мережі та розрахунок втрат електричної енергії).

Продовж.дод. А

**Апробація результатів дисертації**

Основні положення роботи викладено та обговорено на науково-практичних конференціях різного рівня:

1. Шиманюк П.В. Аналіз та визначення типу штучних нейронних мереж для розв'язання задачі прогнозування вузлового навантаження. XXXVIII Науково-технічна конференція молодих вчених та спеціалістів інституту проблем моделювання в Енергетиці ім. Г.Є. Пухова НАН України. м. Київ. С-16-18. 2020.
2. Черненко П.О., Мірошник В.О., Шиманюк П.В. Короткострокове прогнозування вузових електричних навантажень енергосистеми з врахування температури повітря. XV міжнародна конференція "Контроль і управління в складних системах (КУСС-2020)" м. Вінниця. С.1. 2020.
3. Сичова В.В., Шиманюк П.В. Застосування декомпозиції графіків сумарного електричного навантаження для задач їх короткострокового прогнозування. XXXIX Науково-технічна конференція молодих вчених та спеціалістів Інституту проблем моделювання в енергетиці ім. Г.Є. Пухова НАН України. м. Київ. С. 101-103. 2021.
4. Шиманюк П.В. Достовіризація даних та аналіз методів для задач прогнозування вузових електричних навантажень в ринкових умовах. VIII Всеукраїнської науково-практичної конференції молодих вчених «Наукова молодь-2020». м. Київ. С.151-156. 2020.

# ДОДАТОК Б

## Відгук ДТЕК Мережі



ТОВ «ДТЕК Мережі»  
вул. Льва Толстого, 57  
м. Київ, 01032, Україна  
+38 044 594 42 97

Директору  
Інституту електродинаміки НАН  
України  
Академіку НАН України  
Кириленку О.В.

*Щодо практичної значимості  
результатів досліджень*

**Шановний Олександрє Васильовичу!**

Відділ з перспективних технологій ДТЕК Мережі розглянув надіслану Інститутом електродинаміки (ІЕД) НАН України аналітичну довідку «Виявлення аномальних значень в даних вузлового електричного навантаження» щодо актуальності задачі виявлення аномальних значень в контексті побудови прогностичних моделей вузлового навантаження для оцінки втрат в електричних мережах, яку підготовлено в рамках робіт над темою «Розробка методів та засобів короткострокового прогнозування вузлових електричних навантажень електроенергетичних систем в ринкових умовах».

Починаючи з 1.07.2019 в Україні почав функціонувати новий оптовий ринок електричної енергії. Згідно правил ринку операторам систем розподілу, як учасникам ринку необхідно купувати електроенергію для покриття власних втрат. Тому необхідно підвищувати точність короткострокового прогнозування втрат. Не зважаючи на обраний підхід до розв'язання даної задачі, попередній етап підготовки даних включає виявлення аномальних значень для побудови адекватної моделі процесу.

Проведений Шиманюком П.В. в межах зазначеного проекту та дисертаційного дослідження порівняльний аналіз методів кластеризації, які можуть бути використані для виявлення аномальних значень в даних, є перспективним для використання під час розробки систем інтелектуального аналізу даних.

Враховуючи зазначене, і у відповідь на запит Інституту, ДТЕК Мережі, вважає, що проведені дослідження мають практичну цінність та підтримує продовження робіт з підвищення точності прогнозування вузлового навантаження та вдосконалення методів виявлення аномальних значень в даних.

Начальник відділу з перспективних технологій  
ТОВ «ДТЕК Мережі»  
кандидат технічних наук, С.Н.С.



**С. Танкевич**



dtek.com



## ДОДАТОК В

### Авторське свідоцтво на комп'ютерну програму

**УКРАЇНА**



**СВІДОЦТВО**

про реєстрацію авторського права на твір

№ 115250

Комп'ютерна програма «Модель розрахунку цін та тарифів на електричну енергію (дослідна модель)» («EMPM (Electricity market pricing model)»)

(назва твору)

Автор(и) **Білий Ігор Вікторович, Сичова Вікторія Володимирівна, Шеманюк Павло Вячеславович**

(прізвище, ім'я, по батькові)

Авторські майнові права належать **Інституту електрифікації Національної академії наук України, пресп. Перемоги, 56, м. Київ, 03057**

(повна назва фізичної особи або юридичної особи, офіційно підтверджена копією свідоцтва)

Дата реєстрації **13 жовтня 2022 р.**

В.о. Генерального директора  
Державного підприємства  
«Український інститут  
інтелектуальної власності»

  
**Олександр ОПАПАСЕНКО**



## ДОДАТОК Г

### Довідка про впровадження результатів дисертаційної роботи



УКРАЇНА

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ  
імені ІГОРЯ СІКОРСЬКОГО»

03056, м. Київ, пр-т Перемоги, 37; тел. (+38 044) 204-82-82 тел./факс (+38 044) 204-97-88  
<http://www.kpi.ua> e-mail: [mail@kpi.ua](mailto:mail@kpi.ua) ЄДРПОУ 02070921

#### ДОВІДКА

про впровадження (використання) результатів дисертаційної роботи  
**ШИМАНЮКА Павла Вячеславовича**

Навчально-науковий інститут енергозбереження та енергоменеджменту Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського» цією довідкою підтверджує практичне використання (впровадження) результатів дисертаційного дослідження Шиманюка Павла Вячеславовича на тему «Короткострокове прогнозування вузлових електричних навантажень операторів систем розподілу», зокрема, в частині розробки методів прогнозування і формування критерії оцінки якості та стабільності короткострокового прогнозування навантажень. Результати наукових досліджень Шиманюка П.В. використано для підготовки практикумів, які дозволяють поглибити знання студентів щодо можливості застосування методів прогнозування при вирішенні задач енергетики, формування критеріїв оцінки методів та результатів прогнозування.

Зазначені результати використані у програмах навчальних дисциплін в якості складових окремих лекційних тем та практикумів з підготовки магістрів наукового і професійного спрямування за спеціальністю 141 «Електроенергетика, електротехніка та електромеханіка», а саме: «Оптовий та роздрібний ринок електричної енергії» (Освітня програма «Системи забезпечення споживачів електричною енергією») та «Системи ринків електричної енергії» (Освітня програма «Енергетичний менеджмент, електропостачання та інжиніринг електротехнічних комплексів»).

Директор НН ІЕЕ  
д.т.н., професор



Сергій ДЕНИСЮК