

**Стаценко Д.В.**

Київський національний університет технологій та дизайну

**Стаценко В.В.**

Київський національний університет технологій та дизайну

**Злотенко Б.М.**

Київський національний університет технологій та дизайну

**Демішонкова С.А.**

Київський національний університет технологій та дизайну

## ЗАСТОСУВАННЯ МОДЕЛЕЙ МАШИННОГО НАВЧАННЯ ДЛЯ ОПТИМІЗАЦІЇ УПРАВЛІННЯ ІНТЕЛЕКТУАЛЬНИМИ МЕРЕЖАМИ ВІДНОВЛЮВАЛЬНИХ ДЖЕРЕЛ ЕНЕРГІЇ

*В роботі проведено дослідження пов'язані з застосуванням моделей машинного навчання для оптимізації управління інтелектуальними мережами, які під'єднанні до відновлювальних джерел енергії. У статті зазначено, що за останні роки відновлювальні джерела енергії починають займати важливе значення у багатьох галузях людської діяльності. Для оптимізації їх використання останнім часом використовуються інтелектуальні мережі, які дозволяють уникнути витрат енергії та знизити ризики різноманітних ймовірних збоїв.*

*Аналіз літератури показав, що алгоритми машинного навчання використовувалися для аналізу даних від датчиків, прогнозування попиту енергію із заданою точністю, оптимізація зберігання, розподілу енергії, планування систем зберігання енергії в мікромережі, оптимізації розміщення систем зберігання енергії у розподільній мережі, підвищуючи надійність та ефективність мережі.*

*В статті наведено два алгоритми для моделей машинного навчання для навчання однорівневих мереж прямого розповсюдження. Експериментальні результати попередніх досліджень підтвердили ефективність алгоритму машинного навчання за рахунок надзвичайно швидкого навчання з високою продуктивністю узагальнення порівняно із традиційними однорівневими мережами.*

*Зазначено, що оптимізація рою частинок, алгоритм оптимізації, який використовує сукупність частинок для пошуку оптимального рішення. Кожна частка має вектор положення та вектор швидкості, які оновлюються ітераційно на основі найкращого положення частинки та глобального найкращого становища рою.*

*Виконані розрахунки та порівняння із існуючими алгоритмами на основі штучної нейронної мережі, результати чого запропонований алгоритм дозволяє покращити точність прогнозування змін споживання та генерації відновлюваної енергетики та знижує витрати на електроенергію за рахунок оптимізації параметрів алгоритму машинного навчання.*

**Ключові слова:** система регулювання, завдання споживаної з мережі потужності, прогноз генерації, сценарії управління, управління енергоспоживанням, інтелектуальні мережі, відновлювальні джерела енергії, моделі машинного навчання.

**Постановка проблеми.** Сьогодні відновлювані джерела енергії (ВДЕ) займають важливе місце у розвитку багатьох галузей людської діяльності. Їх використання в сучасних мережах стикається з рядом проблем, вирішенням яких займається багато українських та іноземних спеціалістів. Одним з елементів, який використовується з ВДЕ, є застосування інтелектуальних мереж. Управління ВДЕ за допомогою інтелектуальних мережах стикається з проблемами

пов'язаними з невизначеністю та мінливістю ВДЕ. Для вирішення даних проблем існують декілька різних методів. Одним з таких методів є використання машин екстремального навчання (ELM) для оптимізації управлінням ВДЕ в інтелектуальних мережах.

Електрична мережа, що складається з відновлюваних джерел енергії, інтелектуальних приладів, інтелектуальних лічильників та енергоефективних ресурсів, називається інтелектуальною

мережею. Області інтелектуальних мереж включають масову і немасову генерацію, клієнтів, постачальників послуг, розподіл, передачу, базову систему підтримки, ринки та операції. Передовий захист, система зв'язку, підтримка клієнтів, система зберігання енергії, транспортні засоби, що підключаються, розподілені джерела енергії та програми реагування на попит – це піддомени інтелектуальної мережі.

Інтелектуальні мережі мають переваги та забезпечують більшу ефективність, надійність та безпечність доставки електроенергії до користувачів з додатковими можливостями зв'язку та управління. Вони можуть відслідковувати та управляти потоком енергії у реальному часі [1, 2].

В результаті чого знижуються втрати енергії та ймовірність збоїв, наприклад відключення електроенергії.

За своєю природою ВДЕ, на даний момент, важко спрогнозувати, що призводить до коливань енергії, змін у генерації та споживанні.

Використання інтелектуальних мереж може вирішити питання коливань за рахунок використання передових датчиків, систем автоматизації та контролю для балансування генерації та споживанні енергії в режимі реального часу [3-5].

Управління енергією в інтелектуальних мережах призведе до зменшення викидів парникових газів, що в свою чергу позитивно вплине на захист навколишнього середовища. Оптимізуючи розподіл та зберігання енергії, інтелектуальні мережі можуть знизити потребу в джерелах енергії на основі викопного палива та підтримати інтеграцію відновлюваних джерел енергії [6]. Загалом управління енергією в інтелектуальних мережах має важливе значення для створення більш ефективного, надійного та стійкого енергетичного майбутнього. Оптимізація управління відновлюваними джерелами енергії відноситься до процесу використання передових методів та технологій для максимізації ефективності та результатив-

ності систем відновлюваної енергії в енергосистемі. Це включає аналіз величезних обсягів даних від датчиків та інших джерел для прогнозування моделей генерації та споживанні енергії, оптимізації зберігання та розподілу енергії, а також забезпечення стабільності мережі [7, 8].

Машинне навчання (МН) – галузь дослідження штучного інтелекту, зосереджена на розробці та вивченні статистичних алгоритмів, здатних “навчатися” використовуючи дані та узагальнюватися на них, відповідно виконувати завдання без наявних інструкцій. Алгоритми машинного навчання можна використовувати для аналізу даних від датчиків інтелектуальних мереж та прогнозування моделей генерації та споживанні енергії з високою точністю.

Це може допомогти операторам мереж оптимізувати розподіл, зберігання та використання енергії, а також мінімізувати втрати енергії [9].

Інші методи оптимізації управління відновлюваною енергією включають передові системи зберігання енергії, програми реагування на споживання та технології балансування мережі. Системи зберігання енергії, такі як батареї, можуть використовуватися для зберігання надлишкової енергії, що виробляється відновлюваними джерелами у періоди низького та високого попиту. Програми реагування на попит можуть стимулювати споживачів скорочувати споживання енергії в періоди пікового попиту, що допоможе збалансувати енергосистему і знизити потребу в джерелах енергії [10]. Технології балансування мережі, такі як гнучкі міжмережні з'єднання та інтелектуальні інвертори, можуть допомогти збалансувати попит та пропозицію енергії у різних регіонах та періодах часу.

Відновлювані джерела енергії, такі як сонячна, вітрова та гідроенергетика, відіграють вирішальну роль у скороченні викидів вуглекислого газу. Інтелектуальні мережі з їх розширеними можливостями зв'язку та управління пропонують

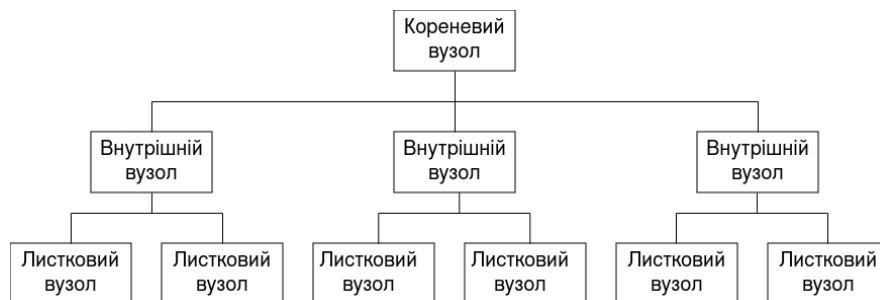


Рис. 1. Управління відновлюваною енергією в інтелектуальних мережах

перспективну платформу для інтеграції відновлюваних джерел енергії в енергосистему [10-11]. Методи МН стали потужним інструментом оптимізації керування відновлюваними джерелами енергії в інтелектуальних мережах. Алгоритми машинного навчання можуть аналізувати величезні обсяги даних від датчиків інтелектуальних мереж та прогнозувати структуру попиту та пропозиції енергії, оптимізувати зберігання та розподіл енергії, а також забезпечувати стабільність мережі. У даній роботі розглядаються різні методи машинного навчання, які можна використовувати для оптимізації управління відновлюваними джерелами енергії в інтелектуальних мережах, їх переваги, обмеження та проблеми [6].

**Аналіз останніх досліджень і публікацій.**

У кількох дослідженнях алгоритми машинного навчання використовувалися для аналізу даних від датчиків інтелектуальних мереж і прогнозування попиту енергію із заданою точністю [12].

Ще одним застосуванням машинного навчання в управлінні відновлюваними джерелами енергії є оптимізація зберігання та розподілу енергії. У дослідженні використовувався алгоритм навчання з підкріпленням для оптимізації планування систем зберігання енергії в мікромережі, що дозволило досягти значного зниження витрат на електроенергію та пікового попиту. Аналогічним чином проводилися дослідження з використанням генетичного алгоритму для оптимізації розміщення систем зберігання енергії у розподільній мережі, підвищуючи надійність та ефективність мережі [9] [13].

У кількох дослідженнях також вивчалось використання машинного навчання для прогнозування вироблення поновлюваної енергії. Наприклад, в дослідженні використовувалася нейронна мережа для прогнозування генерації сонячної фотоелектричної енергії з точністю більше 95%. У інших дослідженнях використовували алгоритм глибокого навчання для прогнозування вироблення енергії вітру, досягнувши точності понад 90% [14].

Крім методів МН, також були досліджені інші стратегії оптимізації для управління відновлюваною енергією в інтелектуальних мережах. Було запропоновано гібридний алгоритм оптимізації, який поєднує в собі нечітку логіку та оптимізацію рою частинок для оптимізації виробництва та розподілу відновлюваної енергії в мікромережі [3].

**Постановка завдання.** Метою статті є застосування моделей машинного навчання з оптимізацією рою частинок для оптимізації управління

інтелектуальними мережами відновлювальних джерел енергії.

**Виклад основного матеріалу.** Модель машинного навчання (МН) для навчання однорівневих мереж прямого розповсюдження (ОМНР) на надзвичайно високих швидкостях. Єдині параметри, що вимагають навчання, – це ваги між останнім прихованим шаром та вихідним шаром. Експериментальні результати попередніх досліджень підтвердили ефективність алгоритму МН за рахунок надзвичайно швидкого навчання з гарною продуктивністю узагальнення порівняно із традиційними ОМНР. Функцію МН можна записати як

$$f(x_i) = \sum_{l=1}^L \beta_l h_l(x) = h(x) B \quad (1)$$

де  $x_i = [x_{i1}, x_{i2}, \dots, x_{iN}] \in R^N$  – вхідний вектор,  $\omega_l = [\omega_{l1}, \omega_{l2}, \dots, \omega_{lN}] \in R^N$  – ваговий вектор, з'єднує  $l$ -й прихований вузол і вхідний вектор, це упередженість  $l$ -ого прихованого вузла,  $\beta_l = [\beta_{l1}, \beta_{l2}, \dots, \beta_{lN}] \in R^M$  – ваговий вектор  $l$ -й прихований вузол до вихідних вузлів,  $L$  – будь-яка кількість прихованого цільового шару МН, і  $\sigma()$  – нелінійна функція активації, що дозволяє апроксимувати цільову функцію до компактного підмножини. Для вихідної функції можна зазначити, що  $B$ -вихідна вагова матриця, та  $h(x) = [h_1(x), \dots, h_L(x)]$  – це нелінійне відображення об'єктів.

$$Hb = \gamma \quad (2)$$

де  $H$  – це вихідні дані прихованого шару, матриця і  $\gamma$  – цільова матриця даних.

$$H = \begin{bmatrix} \sigma(w_1 x_1 + b_1) & \dots & \sigma(w_L x_L + b_L) \\ \vdots & \ddots & \vdots \\ \sigma(w_1 x_n + b_1) & \dots & \sigma(w_1 x_n + b_1) \end{bmatrix}_{N \times L} \quad (3)$$

$$\beta = \begin{bmatrix} \beta_l^T \\ \vdots \\ \beta_L^T \end{bmatrix}, \text{ та } \gamma = \begin{bmatrix} \gamma_l^T \\ \vdots \\ \gamma_L^T \end{bmatrix}_{N \times M} \quad (5)$$

$$B = H^+ \gamma \quad (6)$$

де  $H^+$  псевдоінверсія Мура-Пенроуза  $H$ , яку можна обчислити з використанням різних методів, таких як методи ортогонального проектування, метод виключення Гауса і однозначне розкладання, вхідний шар позначається  $X$ , прихований шар –  $H$ , вихідний шар –  $Y$ , а кількість нейронів у прихованому шарі –  $N$ . Вихідні дані прихованого шару визначаються за формулою:

$$H = g(WX + b) \quad (7)$$

де  $W$  – матриця переходу вхідних до прихованих вагів,  $b$  – вектор зміщення, а  $g$  – функція активації.

Функція активації, яка використовується в МЕН, зазвичай є сигмовидною або радіальною базисною функцією.

Вихідні дані моделі ELM визначаються так:

$$H = HW_{out} \quad (8)$$

Оптимізація рою частинок (ОРЧ) – алгоритм оптимізації, який використовує сукупність частинок для пошуку оптимального рішення. Кожна частка має вектор положення та вектор швидкості, які оновлюються ітераційно на основі найкращого положення частинки та глобального найкращого становища рою.

Положення та швидкість кожної частки оновлюються наступним чином:

$$v_i(t+1) = wv_i(t) + c_1r_1(p_i - x_i(t)) + c_2r_2(g - x_i(t)) \quad (9)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (10)$$

де  $v_i(t)$  та  $x_i(t)$  – швидкість і положення частки  $i$  в момент часу  $t$ ,  $w$  – інерційна вага,  $c_1$  та  $c_2$  – константи прискорення,  $r_1$  та  $r_2$  – випадкові числа між 0 та 1, – особисте найкраще положення частки  $i$ , а  $g$  – глобальне найкраще положення рою.

Модель МН можна оптимізувати за допомогою ОРЧ, щоб знайти оптимальні значення вхідної матриці прихованих ваг  $W$  та вектора зміщення  $b$ . Функція придатності, що використовується в алгоритмі ОРЧ, є середньоквадратичною помилкою між прогнозованим вихідним сигналом моделі МН і фактичним вихідним сигналом.

Вектор положення кожної частинки в рої є можливим розв'язанням задачі оптимізації, тобто набір значень  $W$  і  $b$ . Швидкість кожної частки представляє напрямок і величину зміни положення. Найкраще становище кожної частки оновлюється, якщо значення пристосованості покращується, при цьому оновлюється також глобальне найкраще становище рою.

Після того, як алгоритм ОРЧ зійдеться, оптимальні значення  $W$  і  $b$  можна використовувати для прогнозування моделей попиту та пропозиції енергії, оптимізації зберігання та розподілу енергії, а також покращення керування відновлюваними джерелами енергії в інтелектуальних мережах.

Для перевірки ефективності використання запропонованого алгоритму оптимізації рою частинок проведено розрахунки середньоквадратичної помилки та нормалізованого середньоквадратичної помилки для двох випадків.

В першому використовуємо результати розрахунку алгоритму на основі штучної нейронної мережі (ШНМ), в другому результати запропонованого алгоритму моделі машинного навчання з оптимізацією рою частинок (МН ОРЧ).

Розрахунок проводився для трьох інтелектуальних мереж ВДЕ, а саме:

1. Вітрової енергії.
2. Гідроенергетики.
3. Сонячної енергії.

На рис. 2 показана порівняльна діаграма середньоквадратичної помилки, що демонструє різні значення існуючої ШНМ та запропонованого алгоритму МН ОРЧ. Вісь  $Y$  відповідає за набір даних вищезазначених мереж, а вісь  $X$  вказує на частоту помилок.




Рис. 2. Порівняльна діаграма середньоквадратичної помилки

Відповідно до отриманих значень ефективність запропонованого алгоритму складає в середньому 21,1%. Найкращий результат показує розрахунки для інтелектуальних мереж ВДЕ на основі вітрової енергії, найменший для сонячної.

На рис. 3 показана порівняльна діаграма нормалізованої середньоквадратичної помилки, що демонструє різні значення існуючої ШНМ та запропонованого алгоритму МН ОРЧ.

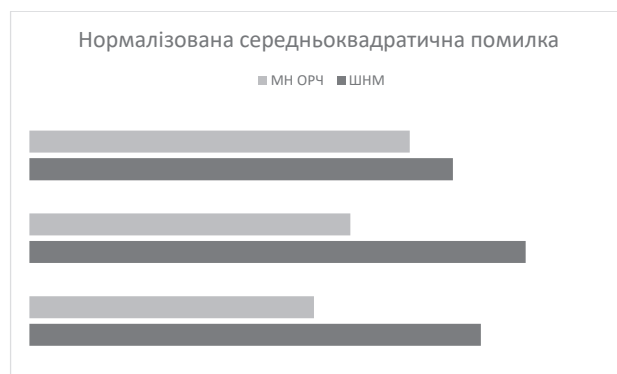


Рис. 3. Порівняльна діаграма нормалізованої середньоквадратичної помилки

Як і в попередньому випадку ефективність алгоритму МН ОРЧ показує кращі результати і складає в середньому 27,5%.

**Висновки.** В статті розглянуто використання алгоритму моделі машинного навчання з оптимізацією рою частинок для оптимізації керування системами відновлюваних джерел енергії в інтелектуальних мережах.

Запропонований підхід дозволяє покращити точність прогнозування змін споживання та генерації відновлюваної енергетики та знижує витрати

на електроенергію за рахунок оптимізації параметрів алгоритму машинного навчання.

Отримані результати вказують на те, що підхід НМ ОРЧ має більш ефективні показники точності прогнозування та зниження витрат ніж інші методи оптимізації. Запропонований підхід може бути використаний у різних інтелектуальних системах відновлюваної енергетики.

#### Список літератури:

1. Kumar, K.P.; Saravanan, B. Recent techniques to model uncertainties in power generation from renewable energy sources and loads in microgrids. *Renewable and Sustainable Energy Reviews*, Vol. 71, pp 348–358, 2017.
2. Leonori, S.; Martino, A.; Frattale Mascioli, F.M.; Rizzi, Microgrid Energy Management Systems Design by Computational Intelligence Techniques. *Appl. Energy*, Vol. 277, 115524, 2020.
3. Cabrera-Tobar, A.; Massi Pavan, A.; Blasuttigh, N.; Petrone, G.; Spagnuolo, G. Real time Energy Management System of a photovoltaic based e-vehicle charging station using Explicit Model Predictive Control accounting for uncertainties *Energy Grids Netw.* Vol. 31, 100769, 2022.
4. Zia, M.F.; Elbouchikhi, E.; Benbouzid, M. Microgrids energy management systems: A critical review on methods, solutions, and prospects *Appl. Energy*, Vol. 222, pp. 1033–1055, 2018.
5. Meng, L.; Sanseverino, E.R.; Luna, A.; Dragicevic, T.; Vasquez, J.C.; Guerrero, J.M. Advanced energy management strategy for microgrid using real-time monitoring interface *Renew. Sustain. Energy Rev.* Vol. 60, pp. 1263–1273, 2016.
6. Ullah, Z.; Wang, S.; Wu, G.; Xiao, M.; Lai, J.; Elkadeem, M.R. Advanced energy management strategy for microgrid using real-time monitoring interface. *Energy Storage*, Vol. 52, 104814, 2022.
7. Agüera-Pérez, A.; Palomares-Salas, J.C.; González de la Rosa, J.J.; Florencias-Oliveros, O. Weather forecasts for microgrid energy management: Review, discussion and recommendations. *Appl. Energy*, Vol. 228, 265–278, 2018.
8. Raya-Armenta, J.M.; Bazmohammadi, N.; Avina-Cervantes, J.G.; Sáez, D.; Vasquez, J.C.; Guerrero, J.M. Energy management system optimization in islanded microgrids: An overview and future trends. *Renew. Sustain. Energy Rev.*, Vol. 149, 111327, 2021.
9. Zhu, J.; Dong, H.; Zheng, W.; Li, S.; Huang, Y.; Xi, L. Review and prospect of data-driven techniques for load forecasting in integrated energy systems. *Appl. Energy*, Vol. 321, 119269, 2022.
10. Ali, S.; Zheng, Z.; Aillerie, M.; Sawicki, J.P.; Péra, M.C.; Hissel, D. Energy management system optimization in islanded microgrids: An overview and future trends. *Energies*, Vol. 14, 4308, 2021.
11. Brearley, B.J., Bose, K.R., Senthil, K., Ayyappan, G. KNN approaches by using ball tree searching algorithm with minkowski distance function on smart grid data. *Indian Journal of Computer Science and Engineering*, Vol.13, no.4, pp.1210-1226, 2022.
12. Leonori, S.; Martino, A.; Frattale Mascioli, F.M.; Rizzi, Microgrid Energy Management Systems Design by Computational Intelligence Techniques. *Appl. Energy*, Vol. 277, 115524, 2020.
13. Macana, C.A.; Mojica-Nava, E.; Pota, H.R.; Guerrero, J.; Vasquez, J.C. A distributed real-time energy management system for inverter-based microgrids. *Electr. Power Syst. Res.*, Vol. 213, 108753, 2022.
14. Carli, R.; Cavone, G.; Pippia, T.; De Schutter, B.; Dotoli, M.. Robust Optimal Control for Demand Side Management of Multi-Carrier Microgrids. *IEEE Trans. Autom. Sci. Eng.*, Vol. 19, 1338–1351, 2022.

#### **Statsenko D.V., Statsenko V.V., Zlotenko B.M., Demishonkova S.A. APPLICATION OF MACHINE LEARNING MODELS TO OPTIMIZE MANAGEMENT OF RENEWABLE ENERGY SOURCES INTELLIGENT NETWORKS.**

*In the work, research is conducted related to the application of machine learning models to optimize the management of intelligent networks connected to renewable energy sources. The article states that in recent years, renewable energy sources are beginning to play an important role in many areas of human activity. To optimize their use, intelligent networks have recently been used to avoid energy losses and reduce the risks of various possible failures.*

*The analysis of the literature showed that machine learning algorithms were used to analyze data from sensors, predict energy demand with a given accuracy, optimize storage, energy distribution, plan energy storage systems in microgrids, optimize the placement of energy storage systems in the distribution network, increasing the reliability and efficiency of the network.*

*The article presents two algorithms for machine learning models for training one-level forward propagation networks. Experimental results of previous studies have confirmed the effectiveness of the machine learning algorithm due to extremely fast learning with high generalization performance compared to traditional single-level networks.*

*It is stated that particle swarm optimization, an optimization algorithm that uses a collection of particles to find an optimal solution. Each particle has a position vector and a velocity vector that are updated iteratively based on the particle's best position and the global best swarm position.*

*Calculations and comparisons with existing algorithms based on an artificial neural network were performed, the results of which the proposed algorithm improves the accuracy of forecasting changes in the consumption and generation of renewable energy and reduces electricity costs due to the optimization of machine learning algorithm parameters.*

**Key words:** *regulation system, task of power consumed from the network, generation forecast, control scenarios, energy consumption management, intelligent networks, renewable energy sources, machine learning models.*