

**І. А. ГЕТЬМАН**

кандидат технічних наук, доцент,  
доцент кафедри комп'ютерних інформаційних технологій  
Донбаська державна машинобудівна академія  
ORCID: 0000-0003-1835-425

**Ю. А. СОЛОД**

магістр кафедри комп'ютерних інформаційних технологій  
Донбаська державна машинобудівна академія  
ORCID: 0009-0000-2350-8403

**М. А. ДЕРЖЕВЕЦЬКА**

кандидат економічних наук,  
доцент кафедри цифрових технологій та проектно-аналітичних рішень  
Технічний університет «Метінвест Політехніка»  
ORCID: 0000-0002-9952-4992

## ДОСЛІДЖЕННЯ ЗАСТОСУВАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПІДВИЩЕННЯ ТОЧНОСТІ ПРОГНОЗУВАННЯ ТЕМПЕРАТУРИ НАВКОЛИШНЬОГО СЕРЕДОВИЩА

Штучні нейронні мережі стають все більш популярним інструментом у дослідженні та прогнозуванні погодних умов. Використання цих мереж для прогнозування температури навколишнього середовища на короткочасний період має великий потенціал у сферах, де точні та швидкі прогнози є критично важливими. Попередження про погоду вважаються ключовими інформаційними продуктами, оскільки вони допомагають захистити життя та майно від небезпек, пов'язаних з екстремальними погодними умовами. Велике значення має не лише сам факт попередження, а й достовірність та своєчасність отриманої інформації. Метою роботи було збільшення точності прогнозування температури та вибір найбільш ефективної моделі нейронної мережі для вирішення задачі прогнозування температури. Погодні параметри для дослідження були зібрані з кліматичного центру даних та поділені на три набори (навчальний, тестувальний та валідаційний). Було проведено навчання та тестування нейронних мереж. Як перспективний підхід для збільшення точності прогнозу було обрано рекурентну нейронну мережу (RNN) та комбінацію нейронних мереж (згорткової та повнозв'язної). З використанням наборів даних за цими моделями було зроблено прогноз майбутньої температури. Перевірка точності цих прогнозів проводилась за допомогою метрик якості, таких як середня абсолютна похибка (MAE), середня квадратична похибка (MSE), середня абсолютна відсоткова похибка (MAPE). Доведено, що запропоновані моделі мають похибку у 15.46% та 14.22% для прогнозування температури рекурентною нейронною мережею та їх комбінацією. Результати підтверджують, що запропоновані моделі мають потенціал для успішного застосування при прогнозуванні температури.

**Ключові слова:** прогнозування температури, комбінація нейронних мереж, рекурентні нейронні мережі, метрики якості.

I. A. GETMAN

Ph.D. (Technology),

Lecturer at the Department of Computer Information Technologies

Donbass State Engineering Academy

ORCID: 0000-0003-1835-425

Y. A. SOLOD

Master at the Department of Computer Information Technologies

Donbass State Engineering Academy

ORCID: 0009-0000-2350-8403

M. A. DERZHEVETSKA

Ph.D. (Economics),

Lecturer at the Department of Digital Technologies

and Project-Analytical Solutions

Technical University "Metinvest Polytechnic" LLC

ORCID: 0000-0002-9952-4992

## EXPLORING THE APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR IMPROVED ACCURACY IN ENVIRONMENTAL TEMPERATURE PREDICTION

*Artificial neural networks are becoming increasingly popular tools in researching and forecasting weather conditions. The use of these networks for predicting ambient temperature in the short term holds great potential in fields where accurate and rapid forecasts are critically important. Weather warnings are considered key informational products as they help protect lives and property from dangers associated with extreme weather conditions. The reliability and timeliness of the received information are of significant importance, not just the fact of the warning itself. The aim of the research was to increase the accuracy of temperature forecasting and select the most effective neural network model for addressing the temperature prediction task. Weather parameters for the research were collected from the climate data center and divided into three datasets (training, testing, and validation). Neural networks were trained and tested. A recurrent neural network (RNN) and a combination of neural networks (convolutional and fully connected) were chosen as promising approaches to increase forecast accuracy. Using these models with the datasets, forecasts of future temperatures were made. The accuracy of these forecasts was verified using quality metrics such as mean absolute error (MAE), mean squared error (MSE), and mean absolute percentage error (MAPE). It was demonstrated that the proposed models have errors of 15.46% and 14.22% for forecasting temperature with the recurrent neural network and its combination, respectively. The results confirm that proposed models have the potential for successful application in temperature forecasting.*

**Key words:** temperature prediction, neural network combination, recurrent neural networks, quality metrics.

### Постановка проблеми

Погода має великий вплив на різні сторони життя людини. Прогнози температури використовуються в багатьох місцях. Наприклад, комунальними компаніями для оцінки попиту на постачання енергії протягом найближчих днів. Також вони важливі для сільського господарства, адже погода прямо впливає на кількість врожаю [1]. Помітний економічний ефект дає використання метеорологічної інформації в авіації, будівництві і багатьох інших сферах. Для виконання прогнозування на початку проводять моніторинг (збір даних про поточний стан атмосфери) [2]. Дані для метеорологічних прогнозів збирають на спеціалізованих метеорологічних станціях. За зміною навколишнього середовища розрізняють глобальний, державний, регіональний, локальний і детальний моніторинг. Різниця між ними в тому, яку територію вони охоплюють. Найбільшу територію охоплює глобальний моніторинг (міждержавна система), найменшу – детальний (система підприємств, родовищ).

Система прогнозування з роками залишається незмінною, а саме використовують чисельні (гідродинамічні) методи. Вони включають в себе вирішення системи гідродинамічних рівнянь [3]. За підсумками відомостей про метеодані створюється комп'ютерна модель атмосфери – програма, в якій з урахуванням систем рівнянь гідротермодинаміки виконуються метеорологічні прогнози. Вирішення цієї системи – складна задача та точність такого прогнозу складає близько 70% для прогнозу на 5–10 днів [4]. Точність таких прогнозів залежить від швидкості розрахунку обчислювальних систем, кількості та якості інформації, що надходить з метеостанцій. Чим більше буде даних, тим точніше буде розрахунок.

Існує й інший метод для отримання прогнозованих даних температури – статистичний. Він дозволяє спрогнозувати різні метеоеlementи на певний період часу, використовуючи дані про стан погоди за минуле і сьогоднішнє. До нього й відносяться нейронні мережі. Основа статистичного методу полягає в узагальненні усіх отриманих даних з вибірки і навчання нейронних мереж. Воно відбувається таким чином, що при отриманні у вихідному шарі початкових метеоданих, нейронна мережа віддавала би результат щодо подальшого значення температури,

заснований на математичній обробці даних. Цей метод прогнозування засновується лише на використанні минулих даних, тому доволі чутливий до можливих «викидів», тож якнайкраще показує тенденцію зміни температури за певний період часу у майбутньому. Для нас це є важливою перевагою, адже в такому випадку ми отримуємо прогнозоване значення, яке майже дорівнює фактичному значенню.

#### Аналіз останніх досліджень і публікацій

Існує багато варіантів архітектури штучних нейронних мереж, але в залежності від них та заданих налаштувань буде змінюватися точність отриманого нами результату. Питанням комплексного аналізу застосування штучних нейронних мереж (ШНМ) приділяли увагу багато вчених.

Г'янеш Шривастава виявив, що архітектури ШНМ, такі як BPN, RBFN, найкраще створені для прогнозування хаотичної поведінки та достатньо ефективні для прогнозування мусонних дощів, а також інших явищ прогнозування параметрів погоди в меншому географічному регіоні [5]. Дорошенко А.Ю. запропонував власну архітектуру нейронної мережі, яка дозволяє прогнозувати помилки прогнозів чисельної регіональної моделі, з метою подальшого коригування прогнозу неперервних метеорологічних величин [6]. Кайфен Бі займався системою прогнозу погоди за допомогою глибокого навчання та розглядав точне середньострокове глобальне прогнозування погоди за допомогою 3D-нейронних мереж (3D Earth-specific transformer 3DEST) [7]. Ajina розробив додаток, завдяки якому можна як прогнозувати погоду в конкретному місті, так і порівнювати різні погодні умови в різних містах [8]. К. Абгішек, Baboo, Shereef представили дослідження використання мережі прямого зв'язку із зворотним розповсюдженням та розглядали застосовність підходу ШНМ шляхом розробки ефективних і надійних нелінійних прогностичних моделей для аналізу погоди [9; 10]. Зараз найчастіше для прогнозування температури використовуються ШНМ, які пропонував Брайан Сміт [11].

#### Формулювання мети дослідження

Метою роботи є збільшення точності прогнозування температури та вибір найбільш ефективної моделі нейронної мережі для вирішення задачі прогнозування температури.

#### Викладення основного матеріалу дослідження

Для досягнення мети були використані дві основні архітектури нейронних мереж: рекурентна мережа та комбінація мереж (згортової та повнозв'язної мереж).

Розпочато дослідження з моделі рекурентної мережі, після чого перейшли до комбінації нейронних мереж. Основною метою є створення та навчання мережі, яка може передбачати температуру на найближчий час для конкретної станції та конкретного дня, враховуючи погоду за попередній дні (вхідні дані). У дослідженні розглядалися чотири погодні змінні: температуру, вологість, швидкість вітру та атмосферний тиск.

Вхідний набір даних складається з 248 зразків, що відповідають 31 дню місяця, розташованих у стовпцях на аркуші Excel, який пізніше імпортується в програму. Кожен рядок таблиці містить інформацію яка збиралася на метеостанції впродовж місяця. Спостереження проводились кожні 3 години: о 00:00, 03:00, 06:00, 09:00, 12:00, 15:00, 18:00 і 21:00 по Гринвічу. Для використання нейронними мережами всі зібрані дані було розбито на три групи: тренувальні (60% зразків), тестувальні (20%) та валідаційні (20%).

Для дослідження було зібрано 248 зразків вхідних даних, але відомо, що навчання нейронної мережі краще з більшим обсягом вибірки. Тому існуючий набір даних було збільшено в 3 рази (744 зразки).

Рекурентні нейронні мережі уявляють собою нейронні мережі із зворотним зв'язком між різними шарами нейронів. Наявність в ній зворотного зв'язку дозволяє передавати інформацію від одного кроку навчання мережі до іншого. Для нормалізації вхідних даних рекурентної нейронної мережі була використана функція активації виду гіперболічного тангенса. Це дозволило стабілізувати та нормалізувати вхідні дані перед подальшим їхнім аналізом мережею. Процес навчання RNN включав обчислення значень прихованого шару на кожному кроці навчання. Він здійснювався за допомогою алгоритму Backpropagation Through Time (BPTT), що розширює стандартний алгоритм зворотного поширення помилок (backpropagation) на випадок часових послідовностей. Тривалість навчання та розмір пакету оптимізували експериментально.

Відповідний вибір кількості шарів і кількості нейронів в кожному з них потребують експериментів. У початковому експерименті було два рекурентні шари. Після чого збільшували їх кількість та змінювали кількість нейронів в них до отримання більш точних результатів прогнозу. На кожному кроці навчання значення прихованого шару нейронної мережі  $k_t \in IR^m$  обчислювали за формулою:

$$k_t = f(Wx_t + Uk_{t-1} + b_k) \quad (1)$$

де:  $x_t \in IR^m$  – вхідний вектор в момент часу  $t$ ;  $W \in IR^{m \times n}$ ,  $U \in IR^{m \times n}$  та  $b_k \in IR^{m \times n}$  – параметри нейронної мережі, які обчислюються при навчанні;  $f$  – функція активації.

Результат на виході, тобто значення прогнозованої температури було розраховано за формулою:

$$y_t = f(Wk_t + b_y) \quad (2)$$

Початково у кожному шарі встановили кількість у 50 нейронів. Після чого змінювали їх значення для досягнення кращого результату. Результат записується, щоб побачити, наскільки добре мережа здатна передбачити результат, використовуючи скориговані ваги мережі.

Інша архітектура, за якою було виконано прогнозування, – це комбінація нейронних мереж. У ній використовувались шари двох видів нейронних мереж, а саме повнозв'язної та згорткової. Повнозв'язані шари дозволяють агрегувати ознаки, отримані з попередніх шарів, і створюють зв'язок між ними для фінального прогнозу. А згорткові шари можуть ефективно обробляти різні типи вхідних даних, такі як зображення чи послідовності числових значень та виявляти локальні шаблони та ознаки. В нашому випадку вони виявляли локальні залежності між температурою, швидкістю вітру, атмосферним тиском та вологістю. Для цієї архітектури використовували функцію активації ReLU (Rectified Linear Unit) для нелінійності.

З огляду на те, що повнозв'язні шари допомагають агрегувати ознаки, тому першим шаром було обрано саме його. Повнозв'язний шар у нейронній мережі складався з  $n$  нейронів, а саме з 64. Кожен нейрон повністю з'єднаний з кожним вхідним значенням. Якщо приймати  $x_1, x_2, \dots, x_n$  вхідні значення, а  $w_1, w_2, \dots, w_n$  – ваги, то вихід у обчислюється за формулою:

$$y = f(w_1 * x_1 + w_2 * x_2 + \dots + w_n * x_n + b) \quad (3)$$

де:  $w_1, w_2, \dots, w_n$  – ваги, присвоєні кожному вхідному з'єднанню;  $x_1, x_2, \dots, x_n$  – вхідні значення;  $b$  – зсув або bias;  $f()$  – функція активації, яка введе нелінійність в модель.

Після чого передавали інформацію на згортковий шар. Це дозволяє визначити кількість внутрішніх представлень (feature maps), що відображаються в моделі. Для початку встановлювали 32 фільтри та розмір  $4 \times 4$ .

Загортковий шар розраховували за такою формулою:

$$x^l = f(x^{l-1} * k^l + b^l) \quad (4)$$

де:  $x^l$  – вихід шару  $l$ ;  $f()$  – функція активації;  $b^l$  – коефіцієнт зсуву ядра  $l$ ;  $*$  – операція згортки входу  $x$  з ядром  $k$ .

Наступним використовували шар згорткового пулінгу, щоб виділити найважливіші ознаки. Було повторено згортковий шар та шар пулінгу. Зроблено декілька таких блоків для виокремлення ієрархічних ознак. У кінці знову було перейдено до повнозв'язного шару.

Для оцінки точності прогнозування були використані метрики, такі як середня абсолютна похибка (MAE), середня квадратична похибка (MSE), середня абсолютна відсоткова похибка (MAPE). Кожен експеримент був проведений на окремих наборах даних для уникнення перенавчання та забезпечення узагальненості результатів.

У результаті було отримано, що при використанні 2 шарів RNN з кількістю нейронів 50 в кожному шарі середня квадратична похибка склала 1.68, середня абсолютна похибка склала 1.109. Після розрахунку середньої абсолютної відсоткової похибки між фактичними значеннями та прогнозованими значеннями було отримано такий результат  $MAPE = 15.4561$ . Це говорить про те, що середня абсолютна відсоткова похибка між фактичними та прогнозованими значеннями становить приблизно 15.46%. Чим менше значення MAPE, тим краще прогноз. Таким чином, якщо середня температура становить  $20^\circ\text{C}$ , то прогноз з такою помилкою може відхилитися в середньому на приблизно  $3.09^\circ\text{C}$  від фактичної температури.

При додаванні ще одного шару RNN з 50 нейронами похибка трохи збільшилась.  $MSE = 2.11$   $MAE = 1.23$ .

Змінюючи кількість нейронів у першому шарі з 50 до 100 у моделі з двома шарами можемо побачити збільшення значення похибок  $MSE = 4.2265$ ,  $MAE = 1.7283$ ,  $MAPE = 26.4\%$ . Тобто з збільшенням кількості нейронів у першому шарі вдвічі точність прогнозу зменшується. Збільшивши кількість нейронів у другому шарі, похибка зменшилась у порівнянні з першим варіантом  $MSE = 2.72$ ,  $MAE = 1.335$ ,  $MAPE = 19.89\%$ .

Під час прогнозування температури за комбінацією нейронних мереж було виявлено, що початковий варіант моделі, що має першим шаром повнозв'язний з 64 нейронами, другим – згортковий з 32 фільтрами та розміром  $4 \times 4$ , третім шар пулінгу та знов повнозв'язний, має значення середньої абсолютної відсоткової похибки  $MAPE = 19.6$ , тобто 19.6%. Значення середньої квадратичної похибки та середньої абсолютної похибки склало:  $MSE = 5.3074$ ,  $MAE = 1.883$ . При збільшенні кількості фільтрів до 64 результат трохи покращився. В цьому випадку  $MSE = 4.7840$ ,  $MAE = 1.7247$ , а  $MAPE = 18.74\%$ . При додаванні ще одного згорткового шару на 64 фільтри маємо покращення прогнозу  $MSE = 2.5241$ ,  $MAE = 1.2898$ , а  $MAPE = 14.36\%$ . При збільшенні кількості нейронів до 150 у повнозв'язному шарі покращення прогнозу майже не відбувається,  $MAPE$  у такому випадку 14.22%.

### Висновки

Дослідження в галузі застосування штучних нейронних мереж у прогнозуванні температури навколишнього середовища відкриває перспективи для подальших досліджень та розвитку нових алгоритмів, спрямованих на поліпшення точності та надійності передбачень у цій сфері.

Отримані результати свідчать про потенційне використання штучних нейронних мереж для прогнозування температури в реальному часі. Такий підхід може знайти широке застосування у сферах, де важлива точність передбачень та реагування на температурні зміни, таких як метеорологія, енергетика та екологія.

## Список використаної літератури

1. Івус Г.П. Спеціалізовані прогнози погоди: підручник. 2012. URL: <http://surl.li/tdgwk>
2. Перелигін Б.В., Ткач Т.Б. Застосування штучних нейронних мереж для обробки інформації в технічних системах моніторингу навколишнього середовища: навч. посіб. Одеса: ОДЕУ, 2014. 218 с. URL: <http://surl.li/rrgro>
3. Хоменко І.А. Динаміка атмосфери: навчальний посібник. Одеса: Одеський державний екологічний університет. 2022. URL: <http://surl.li/tdgrg>
4. Технології у сфері погоди: як далеко зайшли синоптики. URL: <https://marketer.ua/ua/weather-technology-how-far-forecasters-have-come/>
5. Shrivastava G. Application of Artificial Neural Networks in Weather Forecasting: A Comprehensive Literature Review / International Journal of Computer Applications. 2012. Vol. 51, no. 18. P. 17–29. URL: <https://doi.org/10.5120/8142-1867>
6. Дорошенко А.Ю., Шпиг В.М., Кушніренко Р.В. Застосування машинного навчання для уточнення чисельних метеорологічних прогнозів // Проблеми програмування. Київ. 2020. С. 375–385. URL: <https://doi.org/10.15407/pp2020.02-03.375>
7. Bi K. Accurate medium-range global weather forecasting with 3D neural networks. Nature. 2023. URL: <https://doi.org/10.1038/s41586-023-06185-3>
8. Ajina A. Prediction of weather forecasting using artificial neural networks : Journal of Applied Research and Technology. 2023. No. 2. P. 205–211. URL: <https://doi.org/10.22201/icat.24486736e.2023.21.2.1698>
9. Abhishek K. Weather Forecasting Model using Artificial Neural Network: Procedia Technology. 2012. Vol. 4. P. 311–318. URL: <https://doi.org/10.1016/j.protcy.2012.05.047>
10. Baboo S. S., Shereef I. K. An Efficient Weather Forecasting System using Artificial Neural Network. International Journal of Environmental Science and Development. 2010. P. 321–326. URL: <https://doi.org/10.7763/ijesd.2010.v1.63>
11. Smith B. A. Air temperature prediction using artificial neural networks. International Journal of Computational Intelligence Volume 3 Number 3, 2006. URL: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&>
12. Гетьман І., Держевецька М., Бауліна Т., Кухтік Т., & Жуков М. Розробка програмного комплексу для коригування ваги хворих на цукровий діабет на основі використання нейронної мережі з логістичною регресією. *Itsynergy*, (1), 2022. С. 26–46. URL: <https://www.its.istu.edu.ua/ITS/article/view/10>

## References

1. Ivus, G. P. (2012). *Spetsializovani prohnozy pohody* [Specialized weather forecast]. Odessa. URL: <http://surl.li/tdgwk>
2. Perelighin, B.V., Tkach, T.B. (2014). *Zastosuvannia shtuchnykh neuronnykh merezh dlia obrobky informatsii v tekhnichnykh systemakh monitorynhu navkolyshnoho seredovyscha* [Application of artificial neural networks for information processing in technical systems of environmental monitoring] URL: <http://surl.li/rrgro>
3. Khomenko, I.A. (2022). *Dynamika atmosfery* [Atmospheric dynamics: a textbook. Odessa: Odessa State Environmental University]. URL: <http://surl.li/tdgrg>
4. *Tekhnolohii u sferi pohody: yak daleko zaishly synoptyky*. [Weather technology: how far forecasters have come] URL: <https://marketer.ua/ua/weather-technology-how-far-forecasters-have-come/>
5. Shrivastava G. Application of Artificial Neural Networks in Weather Forecasting: A Comprehensive Literature Review / International Journal of Computer Applications. 2012. Vol. 51, no. 18. P. 17–29. URL: <https://doi.org/10.5120/8142-1867>
6. Doroshenko, A. Yu., Shpyg, V.M., Kushnirenko, R.V. (2020) *Zastosuvannia mashynnoho navchannia dlia autochnennia chyselnykh meteorologichnykh prohnoziv* [Application of machine learning to refine numerical meteorological forecasts] P. 375–385. URL: <https://doi.org/10.15407/pp2020.02-03.375>
7. Bi, K. (2023) Accurate medium-range global weather forecasting with 3D neural networks. URL: <https://doi.org/10.1038/s41586-023-06185-3>
8. Ajina, A. (2023) Prediction of weather forecasting using artificial neural networks : Journal of Applied Research and Technology. P. 205–211. URL: <https://doi.org/10.22201/icat.24486736e.2023.21.2.1698>
9. Abhishek, K. (2012) Weather Forecasting Model using Artificial Neural Network: Procedia Technology.. P. 311–318. URL: <https://doi.org/10.1016/j.protcy.2012.05.047>
10. Baboo, S. S., Shereef, I. K. (2010) An Efficient Weather Forecasting System using Artificial Neural Network. International Journal of Environmental Science and Development. P. 321–326. URL: <https://doi.org/10.7763/ijesd.2010.v1.63>
11. Smith, B. A. (2006) Air temperature prediction using artificial neural networks. International Journal of Computational Intelligence URL: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&>
12. Getman, I., Derzhevetska, M., Baulina, T., Kukhtik, T., & Zhukov, M. (2022). *Rozrobka prohramnoho kompleksu dlia koryhuvannia vahy khvorykh na tsukrovyy diabet na osnovi vykorystannia neuronnoi merezhi z lohistychnoiu rehresiiu* [Development of a software complex for adjusting the weight of patients with diabetes based on the use of a neural network with logistic regression]. *Itsynergy*, (1), P. 26–46. URL: <https://www.its.istu.edu.ua/ITS/article/view/10>