

ЗАСТОСУВАННЯ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ПРОГНОЗУВАННЯ ТЕПЛООВОГО СТАНУ ПОВІТРЯНО-ГРУНТОВОГО ТЕПЛООБМІННИКА

Отримано 11 лют. 2025 р.; рекомендовано до публікації 27 черв. 2025 р.
Доступно онлайн 30 черв. 2025 р.

Басок Б. І.¹, Новіцька М. П.², Зур'ян О. В.³,
Сильнагін М. Д.⁴, Давиденко Д. Б.⁵

Автор для кореспонденції: Басок Борис,
e-mail: borys.basok@gmail.com

Анотація. У роботі було використано штучну нейронну мережу для прогнозування теплового стану повітряно-грунтового теплообмінника. Навчання, тестування та валідацію штучної нейронної мережі проведено з використанням експериментальних даних, що були отримані в Інституті технічної теплофізики та Інституті відновлюваної енергетики НАН України. Для розрахунків було використано просту нейронну мережу *Sequential*. Як вхідні параметри для нейронної мережі використовувались температура повітря на вході в теплообмінник, його вологість та температура на виході за попередню годину. Для розрахунків використовувався інтерфейс прикладного програмування *Tensorflow API* та його модуль *Keras*. Базова модель складалась з використанням одного прихованого шару та 10 нейронів. У роботі наведено аналіз впливу різних факторів на показники ефективності моделі, а саме кількості нейронів прихованого шару, кількості шарів, кількості ітерацій, різних оптимізаторів та функцій активації. Експериментальні дані для аналізу в усіх розглянутих варіантах було поділено у пропорції 70, 15 і 15 % для навчання нейронної мережі, її валідації та тестування, відповідно. Розглянуто три варіанти моделей з використанням різних даних як вхідних нейронів. У результаті виявлено, що коефіцієнт середньоквадратичного відхилення для тестової частини масиву даних варіюється від 0,05 до 0,949 °C. Мінімальне середнє відхилення прогнозованих даних від експериментальних було в моделі з використанням температури повітря на вході в повітряно-грунтовий теплообмінник, вологості й температури на виході за попередню годину, воно становило -0,001 °C. Тестування запропонованих моделей показало, що штучна нейронна мережа прогнозує температуру на виході з повітряно-грунтового теплообмінника з урахуванням впливу погодних умов із задовільною точністю. Відповідно, штучні нейронні мережі можна використовувати для прогнозування теплового стану повітряно-грунтового теплообмінника, наприклад теплового насоса, для якого погодні умови є одним з основних визначальних факторів. Для налаштування теплонасосних систем необхідні експериментальні дані, що представляють опис теплового стану ґрунтів неглибокого залягання та реальної геології.

Ключові слова: штучна нейронна мережа, повітряно-грунтовий теплообмінник, моделювання, прогнозування теплового режиму, тепловий стан ґрунту.

¹ д-р. техн. наук, проф.
<https://orcid.org/0000-0002-8935-4248>

² канд. техн. наук
<https://orcid.org/0000-0003-2867-101X>

³ д-р техн. наук
<https://orcid.org/0000-0002-2391-1611>

⁴ аспірант
<https://orcid.org/0009-0001-7826-5776>

⁵ аспірант
<https://orcid.org/0009-0003-5791-1980>

^{1, 2, 4, 5} Інститут технічної теплофізики
НАН України, м. Київ, Україна

¹ Національний технічний університет
України «Київський політехнічний інститут імені Ігоря Сікорського», м. Київ,
Україна

³ Інститут відновлюваної енергетики
НАН України, м. Київ, Україна

APPLICATION OF AN ARTIFICIAL NEURAL NETWORK FOR PREDICTING THE THERMAL STATE OF AN AIR-SOIL HEAT EXCHANGER

Received Feb. 11, 2025; accepted Jun. 27, 2025
Available online Jun. 30, 2025

Basok B.¹, Novitska M.², Zurian O.³,
Sylniahin M.⁴, Davydenko D.⁵

Author for correspondence: Basok Borys,
e-mail: borys.basok@gmail.com

¹ Dr. of Science, prof.
<https://orcid.org/0000-0002-8935-4248>

² Cand. of Science
<https://orcid.org/0000-0003-2867-101X>

Abstract. In this paper, an artificial neural network was used to predict the thermal state of an air-soil heat exchanger. The artificial neural network was trained, tested, and validated using experimental data obtained at the Institutes of Engineering Thermophysics and Renewable Energy of the National Academy of Sciences of Ukraine. A simple Sequential neural network was used for calculations. The input parameters for the neural network were the air temperature at the heat exchanger inlet, its humidity, and the outlet temperature for the previous hour. The Tensorflow API and its Keras module were used for calculations. The base model was built using one hidden layer and 10 neurons. The paper analyzes the influence of various factors, namely the number of hidden layer neurons, the number of layers, the number of iterations, various optimizers, and activation functions on the model's performance. The experimental data for analysis in all the considered variants were divided in the proportions of 70%, 15%, 15% for training the neural network, its validation, and testing, respectively. Three variants of models using different data as input neurons are considered. As a result, the root mean square error for the test part of the data set varies from 0.05 to 0.949 °C. The mean bias error of the predicted data from the experimental data was found in the model using the air inlet temperature of the air-soil heat exchanger, humidity, and outlet temperature for the previous hour, and it was -0.001 °C. Testing of the proposed models showed that the artificial neural network predicts the temperature at the outlet of the air-soil heat exchanger, taking into account the influence of weather conditions, with satisfactory accuracy. Accordingly, artificial neural networks can be used to predict the thermal state of an air-soil heat exchanger, such as a heat pump, for which weather conditions are one of the main determining factors. In order to set up heat pump systems, experimental data are needed to describe the thermal state of shallow soils and the actual geology.

Key words: artificial neural network, air-soil heat exchanger, modeling, thermal regime prediction, thermal state of the soil.

³ Dr. of Science
<https://orcid.org/0000-0002-2391-1611>

⁴ Postgraduate
<https://orcid.org/0009-0001-7826-5776>

⁵ Postgraduate
<https://orcid.org/0009-0003-5791-1980>

^{1, 2, 4, 5} Institute of Engineering Thermophysics of NAS of Ukraine, Kyiv, Ukraine

¹ National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute», Kyiv, Ukraine

³ Institute of Renewable Energy of the National Academy of Sciences of Ukraine, Kyiv, Ukraine

Використані позначення та скорочення

API – application programming interface, інтерфейс прикладного програмування

MAPE – mean absolute percentage error, середня абсолютна похибка у відсотках

MBE – mean bias error, середнє відхилення;

RMSE – root mean square error, середньоквадратична похибка прогнозу

ANN – штучна нейронна мережа

ПВХ – полівінілхлорид

ШНМ – штучна нейронна мережа

oi – значення, прогнозовані штучною нейронною мережею

ti – експериментальні значення

n – кількість прогнозованих точок

Індекси

1 – ШНМ, в якій як вхідні дані було використано температуру повітря на вході в повітряно-ґрунтовий теплообмінник

2 – ШНМ, в якій як вхідні дані було використано температуру та вологість повітря на вході в повітряно-ґрунтовий теплообмінник

3 – ШНМ, в якій як вхідні дані було використано температуру, вологість повітря на вході в повітряно-ґрунтовий теплообмінник, а також температуру повітря на виході з повітряно-ґрунтового теплообмінника за попередню годину

ШНМ – прогнозоване штучною нейронною мережею

Вступ

Сьогодні в різних галузях науки, техніки та економіки зростає інтерес до використання штучних нейронних мереж (ШНМ). Багато в чому популярність ШНМ пояснюється можливістю їх ефективного застосування у випадках, коли класичні аналітичні методи спрацьовують неефективно [1]. ШНМ можуть бути застосовані для моделювання та прогнозування в енергетичних теплотехнічних системах типу повітряного теплового насоса, системі ґрунтової вентиляції, системі повітряної теплової завіси тощо. Огляд публікацій щодо використання ШНМ

при прогнозуванні ефективності роботи теплообмінних апаратів різних типів, зокрема й повітряно-ґрунтового, наведено в [2].

У цій роботі зроблено прогнозування функціонування теплообмінника за допомогою штучної нейронної мережі. У науковій літературі є значна кількість робіт, що описують системи з використанням теплообмінників такого типу [3–11]. Вони вважаються ефективними для зменшення витрат на опалення та кондиціонування будівель. Відомо, що при вентиляції приміщень втрачається приблизно 15 % теплоти, використаної на

опалення будинків. Ці витрати можливо скоротити при застосуванні системи вентиляції з використанням повітряно-ґрунтових теплообмінників.

Повітряно-ґрунтовий теплообмінник являє собою систему трубопроводів, що облаштовані в ґрунті на певній глибині верхнього шару, по яких в будівлю постачається припливне повітря довкілля. Недоліком таких систем в разі експлуатації в умовах реального клімату є їх неефективність певний проміжок часу впродовж року.

У [7], наприклад, авторами використано техніку ШНМ для прогнозування роботи повітряно-ґрунтових теплообмінників різної довжини. Як вхідні параметри ШНМ використовували температуру ґрунту на глибині залягання теплообмінника, температуру земної поверхні, температуру повітря, вологість, витрату теплоносія в теплообміннику та його довжину. Було перевірено вплив кожного з параметрів на ефективність прогнозування. Автори дійшли висновку, що найвпливовішими параметрами є температура повітря й температура ґрунту на глибині залягання. У роботі було розглянуто два типи моделей: детерміністичну (основану на рівняннях збереження) та інтелектуальну (з використанням штучної нейронної мережі), точність моделей становила, відповідно, 5,3 та 2,6 %.

Метою цієї роботи є прогнозування температури на виході з повітряно-ґрунтових теплообмінників, що розташовані в м. Києві. Для досягнення мети було створено декілька варіантів ШНМ. Навчання ШНМ відбувалось з використанням експериментальних даних, що отримані в Інституті технічної теплофізики НАН України.

Опис експериментального стенду ґрунтової вентиляції

Річні масиви даних для тренування ШНМ було отримано на повномасштабному стенді для дослідження теплофізичних процесів у системі ґрантової вентиляції експериментального пасивного будинку Інституту технічної теплофізики [12]. Інноваційна система вентиляції цієї енергоефективної будівлі за допомогою повітряно-ґрунтового теплообмінника є одним із напрямів підвищення її енергоефективності. Експериментальний стенд містив приймальний пристрій, теплообмінник ґрунт-повітря та вимірювальну систему [6]. Приймальний пристрій був розташований у захищеному від прямого сонячного випромінювання місці. Теплообмінник ґрунт-повітря кільцеподібної форми (труба ПВХ Ø 110) довжиною 43 м. п., облаштовано на глибині 2,5 м. Для прокачування повітря в теплообміннику було використано вентилятор Вентс ТТ 150 PRO. Вимірювальна система складалась із термоанемометра Testo та напівпровідникових датчиків BME280 з вторинним приладом на основі мікропроцесора, що реєструють температуру, вологість та тиск атмосферного повітря. У процесі експерименту проводились вимірювання значень швидкості, температури, вологості й тиску повітря у приймальному пристрої та вихідному каналі теплообмінника (на ділянці гідродинамічної й теплової стабілізації потоку). Абсолютні похибки вимірювання термоанемо-

метра Testo 405-V1 становили: для температури – 0,3 °C; для швидкості – 0,1 м/с.

У цій роботі аналізувався масив даних вимірювань повітряно-ґрунтового теплообмінника між 7 вересня та 21 листопада 2018 року. Вимірювання відбувалось із різними інтервалами. Частину даних було отримано з інтервалом вимірювань у 1 хв, а основний масив даних з інтервалом у 10 хв.

Штучна нейронна мережа

Застосована в цій роботі методологія складається з чотирьох основних кроків: моніторинг, моделювання, валідація та оцінка.

Моделювання, валідація й тестування ШНМ виконувались за допомогою інтерфейсу прикладного програмування Tensorflow API (Application Programming Interface), та його модуля keras, що містить інструменти для впровадження нейронних мереж різного типу. У цій роботі використовувалась проста модель Sequential. У базовій моделі був присутній один прихований шар та 10 нейронів (рис. 1, а). У подальшому для визначення ефективної кількості нейронів та шарів розглянуто декілька варіантів моделей з більшою кількістю прихованих шарів (рис. 1, б). Крім того, розглянуто використання різних типів оптимізаторів та функцій активації з метою визначення оптимальнішого варіанта для розв'язання такого типу задач. У всіх зазначених випадках масив аналізованих експериментальних даних розбивали у пропорції 70, 15 і 15 % для навчання нейронної мережі, її валідації й тестування, відповідно.

Дані перед навчанням нормалізувались за максимальним та мінімальним значеннями параметрів у масиві експериментальних даних за формулою

$$X_{\text{шнм}} = \frac{(X - \min X)}{(\max X - \min X)}$$

де $X_{\text{шнм}}$ – значення, що спрямовувались для навчання нейронної мережі, $\min X$ – мінімальне значення параметра в масиві експериментальних даних, $\max X$ – максимальне значення параметра в масиві експериментальних даних. Отже, всі параметри в $X_{\text{шнм}}$ варіювались у межах [0 ... 1].

При компіляції базової моделі використовувався оптимізатор adam та середньоквадратична похибка mse для розрахунку функції втрат (loss function). Розрахунок базової моделі проводився в межах 600 ітерацій. Розмір одночасного пакета даних (batch size) при навчанні базової моделі становив 50.

Після навчання дані приводились до реальних значень за формулою

$$Y = Y_{\text{шнм}}(X_{\text{шнм}}) \cdot (\max Y - \min Y) + \min Y$$

де $Y_{\text{шнм}}(X_{\text{шнм}})$ – значення, прогнозовані штучною нейронною мережею, для отримання яких нейронній мережі потрібно вказати параметри $X_{\text{шнм}}$, $\min Y$ – мінімальне значення вихідного параметра в масиві

експериментальних даних, $\max Y$ – максимальне значення вихідного параметра в масиві експериментальних даних. У цьому разі це мінімальне та максимальне

значення температури на виході з теплообмінника серед масиву даних, на якому тренувалась нейронна мережа.




Рис. 1. Модель штучної нейронної мережі: а – з одним прихованим шаром, б – з кількома прихованими шарами

Fig. 1. Model of an artificial neural network, a – with one hidden layer, b (б) – with several hidden layers

Крім базової моделі ШНМ у роботі створено ще два варіанти з різними вхідними нейронами. У першій базовій моделі (ШНМ1) як вхідні дані використовувалась температура повітря на вході в повітряно-ґрунтовий теплообмінник. У другій (ШНМ2) – температура та вологість повітря на вході в повітряно-ґрунтовий теплообмінник. У третій моделі (ШНМ3) до вхідних даних другої моделі додано також температуру повітря на виході з повітряно-ґрунтового теплообмін-

ника за попередню годину. В усіх трьох моделях використовувався один вихідний нейрон, і це була температура на виході з повітряно-ґрунтового теплообмінника.

Показники ефективності ШНМ

Для аналізу ефективності запропонованих моделей на основі штучних нейронних мереж було використано такі показники ефективності табл. 1.

Таблиця 1. Статистичні показники ефективності

Table 1. Statistical performance indicators

Показник ефективності	Performance indicator	Формула
Середньоквадратична похибка прогнозу	RMSE (root mean square error)	$\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - t_i)^2}$
Середня абсолютна похибка у відсотках	MAPE (mean absolute percentage error)	$\frac{1}{n} \sum_{i=1}^n \left \frac{o_i - t_i}{t_i} \right \times 100$
Середнє відхилення	MBE (mean bias error)	$\frac{1}{n} \sum_{i=1}^n (o_i - t_i)$

Середньоквадратична похибка прогнозу (RMSE) найчастіше використовується для оцінки якості прогнозу ШНМ. Що нижче значення RMSE, то точнішим є прогноз даних. Однак наявність кількох прогнозів, які є набагато гіршими за решту, може сильно вплинути на цей показник через піднесення відхилень у квадрат та обчислення середнього їх значення. Тому бажано також використовувати й інші показники ефективності. MBE є показником середнього відхилення прогнозованих значень від відповідних виміряних даних. Позитивне значення MBE вказує на завищення прогнозованих даних, і навпаки. Середнє абсолютне відхилення (розбіжність) у відсотках MAPE є мірою точності прогнозування для вибраного методу прогнозування в статистиці.

Результати та обговорення

Результати розрахунку базової моделі, що містили різну кількість нейронів у прихованому шарі, представлено в табл. 2.

Як видно з табл. 2, найменша RMSE виявилась при розрахунках з 80 нейронами, однак слід зауважити, що відхилення коливалося у сотих частках градуса Цельсія, а беручи до уваги те, що експериментальні вимірювання виконувались із точністю $\pm 0,5$ °C, то розрахунки навіть з найменшою кількістю нейронів дають фактично прийнятний прогноз. Подальші розрахунки було виконано з 80 нейронами.

Таблиця 2. Показники ефективності тестової частини даних базової моделі, що містить різну кількість нейронів у прихованому шарі**Table 2. Performance indicators of the test data part of the base model containing different numbers of neurons in the hidden layer**

Кількість нейронів у прихованому шарі	Вхідні дані	RMSE, °C	MAPE, %	MBE, °C
10	T _{вх}	1.11	6.31	-0.03
20	T _{вх}	1.09	6.40	-0.02
40	T _{вх}	1.07	6.26	0.06
80	T _{вх}	0.99	5.62	-0.04
160	T _{вх}	1.00	5.58	-0.09

У табл. 3 представлено результати розрахунків з використанням різної кількості прихованих шарів у ШНМ та однаковою кількістю нейронів у кожному прихованому шарі, а саме 80. Як видно з табл. 3, найменша RMSE виявилась при розрахунках з 4, 5, 7 прихованими шарами,

однак слід зауважити, що відхилення коливалося у сотих частках градуса Цельсія. Подальші розрахунки з метою зменшення затрат машинного часу виконувались з 4 прихованими шарами і 80 нейронами в кожному прихованому шарі.

Таблиця 3. Показники ефективності тестової частини даних базової моделі, що містить різну кількість прихованих шарів**Table 3. Performance indicators of the test data part of the base model containing different numbers of hidden layers**

Кількість прихованих шарів	Вхідні дані	RMSE, °C	MAPE, %	MBE, °C
1	T _{вх}	0.99	5.62	-0.04
2	T _{вх}	0.99	5.52	-0.08
3	T _{вх}	0.95	5.40	-0.07
4	T _{вх}	0.94	5.29	0.02
5	T _{вх}	0.94	5.30	-0.03
6	T _{вх}	0.96	5.40	0.03
7	T _{вх}	0.94	5.32	-0.03
8	T _{вх}	0.95	5.34	-0.03

Результати розрахунку моделі, що включали різні варіанти оптимізаторів, представлено в табл. 4. У роботі приділено увагу таким оптимізаторам як: Adam [15], Adadelata [14], Adagrad [16], Adamax [15], ftrl [13], Nadam [17], RMSprop [18], SGD [19]. Як видно з табл. 4, у варіантах оптимізаторів adam, nadam, RMSprop показник ефективності RMSE становить трохи менше 1 °C. Причому він знижується зі збільшенням кількості ітерацій. Для кожного окремого оптимізатора представлені розрахунки з кількістю ітерацій 1000, 2000, 3000. На рис. 2 представлено залежність функції втрат від кількості ітерацій для оптимізаторів nadam та adadelata. Графіки функції втрат оптимізаторів adam, nadam та RMSprop схожі між собою. На початковому етапі ітераційного процесу вони наближаються до певного значення, а потім роблять ще один стрибок і знижуються до нижчого значення (рис. 2, а). Графіки функції втрат оптимізаторів adagrad, adamax, ftrl, SGD схожі на функцію втрат оптимізатора adadelata, тобто асимптотично наближаються до одного значення (рис. 2, б).

Ще одним з параметрів для налаштування моделі штучної мережі є одночасний пакет даних, або batch size. Це кількість зразків, які опрацьовує модель перед оновленням модельних параметрів. Що менше це число, то частіше модель проводить оновлення й то довше йде розрахунок. Вибір правильного розміру цього параметра є балансом між обчислювальною ефективністю, використанням пам'яті та ефективністю моделі. Менший розмір може привести до кращої ефективності, але ціною стабільності та більших обчислювальних витрат. Оскільки модель містила невеликий об'єм даних для навчання, то обробка відбувалась досить швидко. Тому одночасний пакет даних був вибраний невеликим, а саме 50, з метою покращення ефективності моделі.

Наступні розрахунки проводились з використанням 4 прихованих шарів, 80 нейронів у прихованому шарі та оптимізатора adam. На рис. 3 представлено вплив різних типів функцій активації на показники ефективності моделі. Можна побачити, що відхилення в показниках RMSE коливалося у сотих частках градуса Цельсія.




Рис. 2. Функція втрат для основного і валідаційного масиву даних залежно від номера ітерації при тренуванні ШНМ1, _____ – масив даних для тренування, _____ – частина даних для валідації; а – оптимізатор nadam, б – оптимізатор adadelta

Fig. 2. Loss function for the main and validation datasets depending on the iteration number when training ANN1, _____ – training dataset, _____ – part of the validation data; a – nadam optimizer, b (б) – adadelta optimizer

Таблиця 4. Показники ефективності моделей, отримані на тестовій частині масиву даних, які не використовувались при навчанні ШНМ, за умови використання різних типів оптимізаторів

Table 4. Performance indicators of the models obtained on the test part of the data set that was not used for training the ANNs provided with different types of optimizers are used

Оптимізатор	Кількість ітерацій	RMSE, °C	MAPE, %	MBE, °C
adam	1000	0.987	5.563	0.026
	2000	0.983	5.617	-0.097
	3000	0.971	5.535	0.039
adadelta	1000	1.133	6.577	-0.020
	2000	1.129	6.499	-0.035
	3000	1.130	6.492	-0.036
adagrad	1000	1.128	6.492	-0.035
	2000	1.122	6.485	-0.035
	3000	1.118	6.483	-0.035
adamax	1000	1.074	6.273	-0.002
	2000	1.004	5.751	-0.079
	3000	0.980	5.591	-0.028
ftrl	1000	1.142	6.639	-0.013
	2000	1.136	6.534	-0.029
	3000	1.135	6.497	-0.037
nadam	1000	0.994	5.696	-0.047
	2000	0.976	5.570	-0.031
	3000	0.970	5.578	0.015
RMSprop	1000	1.003	5.650	-0.060
	2000	0.996	5.462	-0.006
	3000	0.991	5.496	0.018
SGD	1000	1.099	6.452	-0.076
	2000	1.085	6.380	-0.045
	3000	1.077	6.313	-0.025

Як видно на рис. 3, уточнення показника RMSE є незначним, але інші статистичні показники можна покращити.

Для подальших розрахунків було вибрано функцію активації softsign, яка при такому самому показ-

нику RMSE, як у функції активації relu, має показник MAPE 5.395 та в п'ять разів менше MBE, тобто середнє відхилення прогнозованих значень. Відповідно, в подальших розрахунках було використано 4 прихованих шари, 80 нейронів у кожному прихованому шарі, вибрано оптимізатор adam та функцію активації softsign. Результати розрахунку моделей, що містили різні вхідні дані, представлено на рис. 4, 5 та в табл. 5.

Оскільки функція втрат усе ще продовжувала тенденцію до зниження по досягненню 5000 ітерацій у моделях, що містили додаткові вхідні нейрони, то розрахунки також було виконано з різною кількістю ітерацій. Як видно з табл. 4, при застосуванні різних типів вхідних нейронів оптимальним стає 20000 ітерацій. При збільшенні цього значення до 40000 ітерацій зростає похибка мережі.




Рис. 3. Показники ефективності моделей, отримані на тестовій частині масиву даних, які не використовувались при навчанні ШНМ, за умови використання різних типів функції активації

Fig. 3. Performance indicators of the models obtained on the test part of the data set that was not used for ANN training, when using different types of activation function

Таблиця 5. Показники ефективності моделей, отримані на тестовій частині масиву даних, які не використовувались при навчанні ШНМ

Table 5. Performance indicators of the models obtained on the test part of the dataset that was not used for ANN training

Назва	Вхідні дані	Кількість ітерацій	RMSE, °C	MAPE, %	MBE, °C
ШНМ1	$T_{вх}$	5000	0.949	5.305	-0.087
ШНМ2	$T_{вх}, H$	5000	0.668	3.454	0.046
		10000	0.636	3.355	-0.084
		20000	0.626	3.207	-0.001
		40000	0.654	3.274	0.078
ШНМ3	$T_{вх}, H, T_{вих}$	5000	0.055	0.215	0.020
		10000	0.051	0.167	-0.003
		20000	0.050	0.145	0.002
		40000	0.061	0.173	-0.002

Як видно з табл. 5, найкраще зіставлення між фактичними та прогнозованими даними є для третьої моделі ШНМ3.

Ця модель є найдоцільнішою при прогнозуванні температури на виході з повітряно-ґрунтового теплообмінника і може точніше спрогнозувати момент, коли

використання повітряно-ґрунтового теплообмінника не є слушним, а також коли є сенс його вмикати й вимикати. Це підтверджується високим рівнем збіжності між експериментальними та прогнозованими даними, наведеними на рис. 4, де для трьох різних ШНМ показано

відповідність між розрахунками та фактичними значеннями. Додаткову переконливість забезпечує рис. 5, який

демонструє точність прогнозу як у межах повного періоду спостережень, так і для окремої доби.




Рис. 4. Порівняння експериментальних та прогнозованих ШНМ даних температур на виході з повітряно-ґрунтового теплообмінника: а – ШНМ1, б – ШНМ2, в – ШНМ3. Порівняння температури на вході та на виході з повітряно-ґрунтового теплообмінника: г – ШНМ1, д – ШНМ2, е – ШНМ3

Fig. 4. Comparison of experimental and predicted ANN data on the temperature at the outlet of the air-soil heat exchanger: а – ANN1, б (б) – ANN2, в – ANN3. Comparison of the temperature at the inlet and outlet of the air-soil heat exchanger: д (г) – ANN1, е (д) – ANN2, ф (е) – ANN3.




Рис. 5. Порівняння експериментальних та прогнозованих ШНМ даних температур на виході з повітряно-ґрунтового теплообмінника: а – весь масив даних від 7 вересня по 21 листопада 2018 року, б – доба 12 вересня 2018 року

Fig. 5. Comparison of experimental and ANN-predicted temperature data at the outlet of the air-soil heat exchanger: а – the entire data set from September 7 to November 21, 2018, б (б) – the day of September 12, 2018

Як підсумок зазначимо, що на прикладі проведеного дослідження можна підтвердити доцільність та ефективність застосування нейронних мереж у теплоенергетиці, наприклад у системах з використанням ґрунтових теплових насосів [20–24]. Технології прогнозування за допомогою штучних нейронних мереж наразі стрімко розвиваються і за відсутності можливості моделювання традиційними методами їх доцільно використовувати для прогнозування.

Висновки

- Навчання, валідація й тестування запропонованих моделей на основі штучної нейронної мережі є достатньо задовільними, щоб передбачити температуру теплоносія теплообмінника з урахуванням впливу погодних умов.
- Штучні нейронні мережі можна використовувати при прогнозуванні теплового стану повітряно-ґрунтового теплообмінника для систем вентиляції й теплових насосів.
- Для налаштування систем ШНМ потрібні багаторічні дані, що представляють адекватний моніторинг стану реальної теплотехнічної системи.
- У подальшому доцільно дослідити поведінку ефективності навчання нейронної мережі при використанні більшого масиву експериментальних даних або додаткових даних, наприклад температури ґрунту на певній глибині залягання.

ПОСИЛАННЯ

1. Терейковський І. А., Бушуєв Д. А., Терейковська Л. О. Штучні нейронні мережі: базові положення [Електронний ресурс] : навчальний посібник для здобувачів ступеня бакалавра за освітньою програмою «Системне програмування та спеціалізовані комп'ютерні системи» спеціальності 123 Комп'ютерна інженерія, КПІ ім. Ігоря Сікорського. Електронні текстові дані (1 файл: 1,5 Мбайт). Київ: КПІ ім. Ігоря Сікорського, 2022. 123 с.
2. Ghalandari M., Irandoost Shahrestani M., Maleki A., Safdari Shadloo M., El Haj Assad M. Applications of intelligent methods in various types of heat exchangers: a review. *Journal of Thermal Analysis and Calorimetry*. 2021. 145. P. 1837–1848. <https://doi.org/10.1007/s10973-020-10425-3>
3. Басок Б. І., Новіцька М. П., Кужель Л. М., Божко І. К., Недбайло О. М., Ткаченко М. В., Гончарук С. М. Спосіб забезпечення повітряно-теплової завіси теплою ґрунту. Патент на корисну модель № 88791. МПК: F24F 1/00. 25.03.2014. Бюл. № 6.
4. Недбайло О., Божко І., Ткаченко М. і Андрейчук С. Чисельне моделювання параметрів повітряно-ґрунтових теплообмінників для геотермальної вентиляції. Вентиляція, освітлення та теплогазопостачання. 2020. 35. С. 41–48. DOI:<https://doi.org/10.32347/2409-2606.2020.35.41-48>.
5. Congedo P. M., Lorusso C., Baglivo C., Milanese M., Raimondo L. Experimental validation of horizontal air-ground heat exchangers (HAGHE) for ventilation systems. *Geothermics*. 2019. 80. P. 78–85. <https://doi.org/10.1016/j.geothermics.2019.02.010>
6. Basok B., Pavlenko A., Nedbailo A., Bozhko I., Novitska M., Koshlak H., Tkachenko M. Analysis of the Energy Efficiency of the Earth-To-Air Heat Exchanger. *Rocznik Ochrona Środowiska*. 2022. 24. P. 202–213. <https://doi.org/10.54740/ros.2022.015>
7. Kumar R., Kaushik S.C., Garg S.N. Heating and cooling potential of an earth-to-air heat exchanger using artificial neural network. *Renewable Energy*. 2006. 31. P. 1139–1155. <https://doi.org/10.1016/j.renene.2005.06.007>
8. Басок Б. І., Божко І. К., Кужель Л. М., Недбайло О. М., Ткаченко М. В. Спосіб регулювання температури вентиляційного повітря житлових та громадських приміщень. Патент на корисну модель № 150907. МПК: F24F 7/00. 04.05.2022. Бюл. № 18.
9. Nakorchevskij A. I., Basok B. I., Beljaeva T. G. Problemy gruntovogo akumulirovaniya teploty i metody ih resheniya. [Problems of ground heat storage and methods of their solution]. *Promyshlennaja Teplotekhnika*. [Industrial heating engineering]. 2003. T. 25, № 3. P. 42–50. [in Russian].
10. Bozhko I. K., Nedbailo A. N., Tkachenko M. V. Polivalentnaja sistema teploobespechenija passivnogo doma. [Polyvalent passive house heat supply system]. *Enerhoefektyvnost v budivnytstvi ta arkhitekturi: nauk.-tekhn. zb.: Kyiv. nats. un-t bud-va ta arkhitektury; vidp. red. P. M. Kulikov*. Kyiv, KNUBA. 2015. Vyp. P. 2230. [in Russian]
11. Nakorchevskij A. I., Nedbailo A. N., Basok B. I. Jeksperimentalnaja proverka dostovernosti matematicheskikh modelej gruntovogo akumulirovaniya teploty. [Experimental validation of mathematical models of ground heat storage]. *Promyshlennaja teplotekhnika*. [Industrial heating engineering]. 2006. T. 28. № 2. P. 51–61. [in Russian]
12. Basok B., Novitska M., Goncharuk S., Moroz M., Tymoshchenko A. Experimental Passive House of the Institute of Engineering Thermophysics NAS of Ukraine. in 2019 IEEE 6th International Conference on Energy Smart Systems (ESS). IEEE, Kyiv, Ukraine, 2019. P. 108–111 doi:10.1109/ESS.2019.8764182.
13. McMahan H. B., Holt G., Sculley D., Young M., Ebner D., Grady J., Nie L., Phillips T., Davydov E., Golovin D., Chikkerur S., Liu D., Wattenberg M., Hrafnkelsson A. M., Boulos T., Kubica J. Ad click prediction: a view from the trenches, in: *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and*

- Data Mining. ACM, Chicago Illinois USA, 2013. P. 1222–1230. <https://doi.org/10.1145/2487575.2488200>
14. Zeiler M. D. ADADELTA: An Adaptive Learning Rate Method. 2012. <https://doi.org/10.48550/ARXIV.1212.5701>
 15. Kingma D. P., Ba J. 2014. Adam: A Method for Stochastic Optimization. <https://doi.org/10.48550/ARXIV.1412.6980>
 16. Duchi J., Hazan E., Singer Y. Adaptive Subgradient Methods for Online Learning and Stochastic Optimization. *Journal of Machine Learning Research*. 2011. Vol. 12. No. 61. P. 2121–2159. URL: <https://jmlr.org/papers/v12/duchi11a.html>
 17. Li S., Li D., Zhang Y. Incorporating Nesterov's Momentum into Distributed Adaptive Gradient Method for Online Optimization. 2021 China Automation Congress (CAC), Beijing, China, 22–24 October 2021. URL: <https://doi.org/10.1109/cac53003.2021.9727247>.
 18. Hinton G. Coursera Neural Networks for Machine Learning, lecture 6, 2018.
 19. Bottou L., Bousquet O. The Tradeoffs of Large Scale Learning. *Advances in Neural Information Processing Systems: Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems, Vancouver, British Columbia, 3–6 December 2007*. Vol. 20. P. 161–168.
 20. Басок Б., Дубовський С., Pastushenko E., Нікітін Є., Базеев Є. Теплові насоси як тренд низьковуглецевого розвитку енергетики. *Енерготехнології та ресурсозбереження*. 2023. 75(2). С. 23–44. <https://doi.org/10.33070/etars.2.2023.02>.
 21. Гошовський С. В., Зур'ян О. В. Одноконтурні та двоко-
нтурні теплонасосні системи. Взаємозв'язок фізичних процесів та ефективності. *Відновлювана енергетика*. 2019. № 1. С. 83–93. [https://doi.org/10.36296/1819-8058.2019.1\(56\).83-95](https://doi.org/10.36296/1819-8058.2019.1(56).83-95).
 22. Goshovskii S. V., Zurian O. V. Human-induced load on the environment when using geothermal heat pump wells. *Journal of Geology, Geography and Geoecology*. 2020. Vol. 29. №. 1. С. 57–68. <https://doi.org/10.15421/112006>.
 23. Басок Б. І., Давиденко Б. В., Павленко А. М., Новіков В. Г., Кошлак Г. В. Вплив фільтраційного руху ґрунтових вод на теплоефективність підземного теплообмінного пристрою. *Відновлювана енергетика*. 2022. № 2(69). С. 71–80. DOI: [https://doi.org/10.36296/1819-8058.2022.2\(69\)852](https://doi.org/10.36296/1819-8058.2022.2(69)852)
 24. Basok B., Davydenko B., Koshlak H., Novikov V. Free Convection and Heat Transfer in Porous Ground Massif during Ground Heat Exchanger Operation. *Materials*. 2022. V. 15. 4843. 14 p. DOI: <https://doi.org/10.3390/ma15144843>.
- ## REFERENCES
1. Terejkovskiy I. A., Bushuiev D. A., Terejkovska L. O. Shtuchni neironni merezhi: bazovi polozhennia [Artificial neural networks: basic concepts] [Elektronnyy resurs]: navchalnyy posibnyk dlia zdobuvachiv stupenia bakalavra za osvithoiu prohramoiu «Systemne prohramuvannia ta spetsializovani kompiuterni systemy» spetsialnosti 123 Kompiuterna inzheneriia. KPI im. Ihoria Sikorskoho. Elektronni tekstovi dani (1 fajl: 1,5 Mbajt). Kyiv: KPI im. Ihoria Sikorskoho, 2022. 123 p. [in Ukrainian].
 2. Ghalandari M., Irandoost Shahrestani M., Maleki A., Safdari Shadloo M., El Haj Assad M. Applications of intelligent methods in various types of heat exchangers: a review. *Journal of Thermal Analysis and Calorimetry*. 2021. 145. P. 1837–1848. <https://doi.org/10.1007/s10973-020-10425-3>
 3. Basok B. I., Novitska M. P., Kuzhel L. M., Bozhko I. K., Nedbajlo O. M., Tkachenko M. V., Honcharuk S. M. Sposib zabezpechennia povitriano-teplovoy zavisly teploiu gruntu. [A method of providing the air-thermal curtain with soil heat]. Patent na korysnu model № 88791. MPK: F24F 1/00. 25.03.2014. Biul. № 6. [in Ukrainian].
 4. Nedbajlo O., Bozhko I., Tkachenko M. i Andrejchuk S. Chyselne modeliuвання parametriv povitriano-gruntovykh teploobminnykh dlia heotermalnoi ventyliatsii. [Numerical modelling of parameters of the operational parameters of an earth-to-air heat exchanger for geothermal ventilation]. *Ventylatsiia, osvittennia ta teplohazopostachannia*. [Ventilation, Illumination and Heat Gas Supply]. 2020. 35. P. 41–48. DOI: <https://doi.org/10.32347/2409-2606.2020.35.41-48>. [in Ukrainian]
 5. Congedo P. M., Lorusso C., Baglivo C., Milanese M., Raimondo L. Experimental validation of horizontal air-ground heat exchangers (HAGHE) for ventilation systems. *Geothermics*. 2019. 80. P. 78–85. <https://doi.org/10.1016/j.geothermics.2019.02.010>
 6. Basok B., Pavlenko A., Nedbailo A., Bozhko I., Novitska M., Koshlak H., Tkachenko M. Analysis of the Energy Efficiency of the Earth-To-Air Heat Exchanger. *Rocznik Ochrona Środowiska*. 2022. 24. P. 202–213. <https://doi.org/10.54740/ros.2022.015>
 7. Kumar R., Kaushik S. C., Garg S. N. Heating and cooling potential of an earth-to-air heat exchanger using artificial neural network. *Renewable Energy*. 2006. 31. P. 1139–1155. <https://doi.org/10.1016/j.renene.2005.06.007>
 8. Basok B. I., Bozhko I. K., Kuzhel L. M., Nedbajlo O. M., Tkachenko M. V. Sposib rehuliuвання temperatury ventyliatsijnoho povitria zhytlovykh ta hromadskykh prymyschen. [Method for regulating the temperature of ventilation air in residential and public premises].

- Patent na korysnu model № 150907. MPK: F24F 7/00. 04.05.2022. Biul. № 18. [in Ukrainian]
9. Nakorchevskij A. I., Basok B. I., Beljaeva T. G. Problemy gruntovogo akumulirovaniya teploty i metody ih resheniya. [Problems of ground heat storage and methods of their solution]. Promyshlennaya Teplotekhnika. [Industrial heating engineering]. 2003. T. 25, № 3. P. 42–50. [in Russian].
 10. Bozhko I. K., Nedbajlo A. N., Tkachenko M. V. Polivalentnaya sistema teploobespecheniya passivnogo doma. [Polyvalent passive house heat supply system]. Enerhoefektyvnist v budivnytstvi ta arkhitekturi: nauk.-tekhn. zb.: Kyiv. nats. un-t bud-va ta arkhitektury; vidp. red. P. M. Kulikov. Kyiv, KNUBA. 2015. Vyp. P. 2230. [in Russian]
 11. Nakorchevskij A. I., Nedbajlo A. N., Basok B. I. Jeksperimentalnaya proverka dostovernosti matematicheskikh modelej gruntovogo akumulirovaniya teploty. [Experimental validation of mathematical models of ground heat storage]. Promyshlennaya teplotekhnika. [Industrial heating engineering]. 2006. T. 28. № 2. P. 51–61. [in Russian]
 12. Basok B., Novitska M., Goncharuk S., Moroz M., Tymoshchenko A. Experimental Passive House of the Institute of Engineering Thermophysics NAS of Ukraine. in 2019 IEEE 6th International Conference on Energy Smart Systems (ESS). IEEE, Kyiv, Ukraine, 2019. P. 108–111 doi:10.1109/ESS.2019.8764182.
 13. McMahan H. B., Holt G., Sculley D., Young M., Ebner D., Grady J., Nie L., Phillips T., Davydov E., Golovin D., Chikkerur S., Liu D., Wattenberg M., Hrafnkelsson A.M., Boulos T., Kubica J. Ad click prediction: a view from the trenches, in: Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, Chicago Illinois USA, 2013. P. 1222–1230. <https://doi.org/10.1145/2487575.2488200>
 14. Zeiler M.D. ADADELTA: An Adaptive Learning Rate Method. 2012. <https://doi.org/10.48550/ARXIV.1212.5701>
 15. Kingma D. P., Ba J. 2014. Adam: A Method for Stochastic Optimization. <https://doi.org/10.48550/ARXIV.1412.6980>
 16. Duchi J., Hazan E., Singer Y. Adaptive Subgradient Methods for Online Learning and Stochastic Optimization. Journal of Machine Learning Research, 2011. Vol. 12. No. 61. P. 2121–2159. URL: <https://jmlr.org/papers/v12/duchi11a.html>
 17. Li S., Li D., Zhang Y. Incorporating Nesterov's Momentum into Distributed Adaptive Gradient Method for Online Optimization. 2021 China Automation Congress (CAC), Beijing, China, 22–24 October 2021. URL: <https://doi.org/10.1109/cac53003.2021.9727247> .
 18. Hinton G. Coursera Neural Networks for Machine Learning, lecture 6, 2018.
 19. Bottou L., Bousquet O. The Tradeoffs of Large Scale Learning. Advances in Neural Information Processing Systems: Proceedings of the Twenty-First Annual Conference on Neural Information Processing Systems, Vancouver, British Columbia, 3–6 December 2007. Vol. 20. P. 161–168.
 20. Basok B., Dubovskij S., Pastushenko E., Nikitin Ye., Bazieiev Ye. Teplovi nasosy iak trend nyzkovuhletsevoho rozvytku enerhetyky. [Heat pumps as a trend of low-carbon energy development] Enerhotekhnolohii ta resursozberezhennia. [Energy Technologies & Resource Saving]. 2023. 75(2). P. 23–44. <https://doi.org/10.33070/etars.2.2023.02>. [in Ukrainian]
 21. Hoshovskij S. V., Zurian O. V. Odnokonturni ta dvokonturni teplonasosni systemy. Vzaimozv'iazok fizychnykh protsesiv ta efektyvnosti. [Single-circuit and dual-circuit heat pump systems. Interrelation of physical processes and efficiency] Vidnovliuvana enerhetyka. 2019. No. 1. P. 83–93. [https://doi.org/10.36296/1819-8058.2019.1\(56\).83-95](https://doi.org/10.36296/1819-8058.2019.1(56).83-95). [in Russian]
 22. Goshovskii S. V., Zurian O. V. Human-induced load on the environment when using geothermal heat pump wells. Journal of Geology, Geography and Geoecology. 2020. Vol. 29. No. 1. P. 57–68. <https://doi.org/10.15421/112006>.
 23. Basok B. I., Davydenko B. V., Pavlenko A. M., Novikov V. H., Koshlak H. V. Vplyv filtratsijnoho rukhu gruntovykh vod na teploefektyvnist pidzemnogo teploobminnogo prystroiu. [Influence of groundwater filtration flow on the thermal efficiency of underground heat exchanger] Vidnovliuvana enerhetyka. 2022. №2 (69). P. 71–80. DOI: [https://doi.org/10.36296/1819-8058.2022.2\(69\)852](https://doi.org/10.36296/1819-8058.2022.2(69)852). [in Ukrainian]
 24. Basok B., Davydenko B., Koshlak H., Novikov V. Free Convection and Heat Transfer in Porous Ground Massif during Ground Heat Exchanger Operation. Materials. 2022, V. 15. 4843. 14 p. DOI: <https://doi.org/10.3390/ma15144843>.