



УДК 004.85

# РОЗРОБКА ТА ІНТЕГРАЦІЯ МОДЕЛІ ТЕПЛООВОГО НАСОСА НА ОСНОВІ НЕЙРОННОЇ МЕРЕЖІ В СЕРЕДОВИЩЕ SIMULINK ДЛЯ МОДЕЛЮВАННЯ СИСТЕМИ ОПАЛЕННЯ БУДИНКУ

## DEVELOPMENT AND INTEGRATION OF A HEAT PUMP MODEL BASED ON A NEURAL NETWORK INTO THE SIMULINK ENVIRONMENT FOR MODELING A HOUSE HEATING SYSTEM

Богза М. С. Волощук В.А.  
Bogza M. S. Voloshchuk V. A.

Національний технічний університет України "Київський політехнічний інститут імені Ігоря Сікорського", Київ, Україна

ORCID: <https://orcid.org/0009-0009-7320-5377>, <https://orcid.org/0000-0003-0687-8968>

E-mail: [n.bohza@gmail.com](mailto:n.bohza@gmail.com), [vlvolodya@gmail.com](mailto:vlvolodya@gmail.com)

Copyright © 2024 by author and the journal "Automation of technological and business – processes".

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0>



DOI:

**Анотація.** У статті детально описано процес розроблення та інтеграції в середовище Simulink моделі теплонасосної установки на основі нейронної мережі LSTM. Ця модель дає можливість моделювати роботу системи теплозабезпечення будинку з урахуванням змінних зовнішніх умов. Завдяки високій точності та гнучкості, модель може бути використана як основа для синтезу та дослідження різних алгоритмів керування системою теплозабезпечення. Це відкриває нові можливості для оптимізації енергоспоживання та підвищення ефективності роботи теплонасосних систем. Результати моделювання можуть бути використані для розроблення інтелектуальних систем керування, які адаптуються до змінних умов експлуатації та підвищують енергоефективність будівлі.

Процес розробки моделі включав кілька ключових етапів. Спочатку було підготовлено великий масив даних, необхідних для навчання моделі, на основі аналітичної моделі теплонасосної установки. Після цього була розроблена нейронна мережа, оптимізована за допомогою алгоритму Adam і функції втрат середньоквадратичної помилки (MSE). Важливою частиною роботи стала конвертація розробленої моделі в код на мові C з використанням бібліотеки keras2c, що дало можливість інтегрувати модель у середовище Simulink через блок S-function.

Проведені тести показали, що інтегрована модель у Simulink не тільки зберегла високу точність прогнозів, але й значно перевершила початкову модель на Python за швидкістю обчислень. Це досягається завдяки оптимізації коду та ефективному використанню обчислювальних ресурсів. Отримані результати демонструють перспективність запропонованого підходу для задач динамічного моделювання ТНУ, синтезу систем керування такими установками та вирішення задач підвищення їх енергоефективності.

**Abstract.** The article describes in detail the process of developing and integrating a model of a heat pump unit based on the LSTM neural network into the Simulink environment. This model makes it possible to simulate the operation of a building's heat supply system, taking into account changing external conditions. Due to its high accuracy and flexibility, the model can be used as a basis for synthesizing and studying various control algorithms for the heat supply system. This brings new opportunities for optimizing energy consumption and improving the efficiency of heat pump systems. The modeling results can be used to develop intelligent control systems that adapt to changing operating conditions and improve the energy efficiency of a building.

The model development process involved several key steps. First, a large data set was prepared to train the model, based on an analytical model of the heat pump system. After that, a neural network was developed and optimized using the Adam algorithm and the mean square error (MSE) loss function. An important part of the work was the conversion



of the developed model into C code using the keras2c library, which made it possible to integrate the model into the Simulink environment through the S-function block.

Tests have shown that the integrated Simulink model not only kept the high accuracy of predictions, but also significantly outperformed the original Python model in terms of computing speed. This is achieved through code optimization and efficient use of computing resources. The obtained results demonstrate the prospects of the proposed approach for dynamic modeling of thermal power plants, synthesis of control systems for such plants, and solving problems of improving their energy efficiency.

**Ключові слова:** тепловий насос, нейронна мережа, Simulink, LSTM, S-функція, енергоефективність, моделювання опалення, оптимізація.

**Keywords:** heat pump, neural network, Simulink, LSTM, S-function, energy efficiency, heating model, optimization.

### Вступ

У сучасних системах теплозабезпечення будинків дедалі більше уваги приділяється використанню теплонасосних установок (ТНУ) як ефективних і екологічно чистих технологій[1, 2]. Однак традиційні методи моделювання таких систем часто не враховують нелінійність процесів, що відбуваються в ТНУ. Це призводить до недостатньої точності прогнозування енергоспоживання та ефективності системи в цілому. Крім того, інтеграція складних моделей у існуючі системи управління є складним завданням, яке вимагає значних обчислювальних ресурсів. Ця проблема набуває особливої актуальності в умовах зростаючого попиту на енергоефективні технології, що підштовхує до пошуку нових підходів для моделювання та інтеграції ТНУ[3]. Одним із таких підходів є застосування нейронних мереж, які здатні більш точно моделювати складні фізичні процеси, однак їх інтеграція в стандартні системи моделювання, такі як Simulink, потребує додаткових досліджень.

### Аналіз літературних даних і постановка проблеми

У дослідженні[4] автори використали Matlab Simulink для побудови та навчання штучної нейронної мережі (ШНМ) для моделювання теплонасосної установки з використанням холодоагенту R134a. Згідно зі схемою, представлена нейронна мережа є багатошаровим перцептроном (MLP) з одним прихованим шаром, що містить десять нейронів. Вхідний шар складається з чотирьох нейронів, які отримують дані про температури випаровувача, конденсатора, перегріву та переохолодження. Вихідний шар, що складається з трьох нейронів, використовується для прогнозування коефіцієнта корисної дії (COP) та теплоємностей випаровувача і конденсатора. Навчання мережі здійснювалося за допомогою алгоритму Левенберга–Марквардта, що забезпечило високу точність прогнозування, підтвержену високими значеннями коефіцієнтів детермінації ( $R^2$ ). Такий підхід демонструє ефективність застосування нейронних моделей, що здатні з високою точністю передбачати складні термодинамічні параметри, що є важливим як з точки зору оптимізації енергоспоживання, так і підвищення ефективності систем охолодження.

У статті [5] автори використали інструменти Matlab Simulink для моделювання системи теплового насоса на базі ґрунтових джерел тепла (GSHP). Зокрема, вони застосували моделі, засновані на штучних нейронних мережах, для ідентифікації динаміки системи теплового насоса та прогнозування температурного поля ґрунту. У дослідженні були розглянуті різні моделі, серед яких особливу увагу приділено моделі Hammerstein-Wiener та моделям на основі нейронних мереж, таких як NARX і Elman Neural Network. Matlab Simulink був використаний для реалізації та тестування цих моделей, а також для валідації їхньої точності шляхом порівняння прогнозованих значень з експериментальними даними. Використання нейронних мереж у Simulink дозволило авторам підвищити точність моделювання системи теплового насоса, що підтверджується низькими значеннями середньої абсолютної помилки (MAE) та середньоквадратичної помилки (MSE) для моделі NARX, яка показала найкращі результати серед розглянутих підходів.

У статті [6] автори використали штучні нейронні мережі (ШНМ) для моделювання коефіцієнта продуктивності (COP) системи охолодження розумного складу на базі холодоагенту CO<sub>2</sub>. Для реалізації моделей було використано середовище Matlab Simulink, де моделі на основі ШНМ були налаштовані для прогнозування масової витрати холодоагенту та споживання електроенергії компресорами в системі охолодження. Авторами було розроблено ансамбль моделей ШНМ, кожна з яких моделює конкретний тип компресора, що використовується в системі. Для навчання моделей використовувалися дані, зібрані з веб-інтерфейсу виробника компресорів Bitzer, а також емпіричні значення для різних умов роботи системи. Моделі були налаштовані та тренувані з використанням функції активації гіперболічного тангенсу та оптимізатора Adam, що дозволило забезпечити високу точність прогнозів, яка оцінюється на основі середньої абсолютної відсоткової похибки (MAPE), яка в окремих випадках досягала 1,87%. Цей підхід дозволив авторам створити детальні моделі, які можуть бути інтегровані в системи управління для оптимізації роботи систем охолодження у складських комплексах. Використання Matlab Simulink в поєднанні з ШНМ дозволило підвищити точність моделювання та забезпечити надійні дані для подальшої оптимізації роботи інтелектуальних систем управління.

У статті[7] автори використали Matlab Simulink для моделювання динаміки компресорів у промисловій системі охолодження на основі CO<sub>2</sub>, зосередившись на оптимізації енергоспоживання. Модель була побудована за допомогою штучної нейронної мережі (ШНМ), що дозволило точно прогнозувати електричне навантаження та охолоджувальну потужність компресорів на основі доступних експлуатаційних даних. Використання інструментів Matlab Simulink і ШНМ дало змогу авторам створити модель із одним прихованим шаром, що містить 45 нейронів, яка була тренувана з використанням алгоритму оптимізації Adam. Це дозволило досягти



високої точності моделювання, що підтверджується низьким значенням середньоквадратичної похибки (MSE) — всього 0,08% для обох наборів даних, використаних для навчання та валідації. Модель також інтегрується в систему інтелектуального управління, що оптимізує використання енергії в реальних умовах експлуатації, підвищуючи ефективність системи охолодження та знижуючи витрати на енергію.

У статті[8] автори застосували інструменти Matlab Simulink для моделювання динаміки теплового насоса з використанням глибоких нейронних мереж для прогнозування енергоспоживання і коефіцієнта продуктивності системи опалення та охолодження. Вони розробили моделі для передбачення електричного споживання теплового насоса і загального енергоспоживання системи на основі даних, зібраних в освітньому закладі. Моделі були створені з використанням нейронних мереж із зворотним розповсюдженням помилки, що складаються з кількох шарів і нейронів, оптимізованих для досягнення високої точності прогнозування. Особливу увагу приділили вибору змінних для моделей, що значно підвищило точність моделювання. Під час моделювання використовувалися різні часові інтервали, що дозволило авторам виявити залежності та фактори, які мають найбільший вплив на продуктивність системи. Це підкреслює ефективність моделей на основі нейронних мереж, здатних точно відтворювати складну поведінку теплових насосів в реальних умовах експлуатації.

#### Мета і завдання дослідження

Метою даного дослідження є розробка та інтеграція моделі теплового насоса на основі нейронних мереж у середовище Simulink для підвищення точності та ефективності моделювання систем опалення. Це досягається шляхом створення нейронної мережі, яка здатна адаптуватися до динамічних змін параметрів теплопередачі та забезпечувати більш точне прогнозування роботи теплового насоса в реальних умовах. Подальша трансформація моделі у код на мові C та її інтеграція у Simulink за допомогою спеціально розробленої S-функції дозволяє дослідити можливості застосування такої моделі для оптимізації роботи систем опалення. В результаті, передбачається, що розроблена модель забезпечить більш ефективне використання енергоресурсів та сприятиме підвищенню енергоефективності будинків.

#### Методи і матеріали досліджень

Для розробки моделі теплового насоса на основі нейронної мережі критично важливо забезпечити наявність достатнього обсягу тренувальних даних. Для цього було використано аналітичну модель ТНУ, створену в попередніх дослідженнях[9, 10], яка дозволила згенерувати великий масив даних про роботу ТНУ в умовах динамічного теплового навантаження. Ця модель відзначається високою точністю, проте вона є вимогливою до обчислювальних ресурсів, що потребує ретельного підходу до її застосування. Приклад зібраних даних показано на рис. 1.


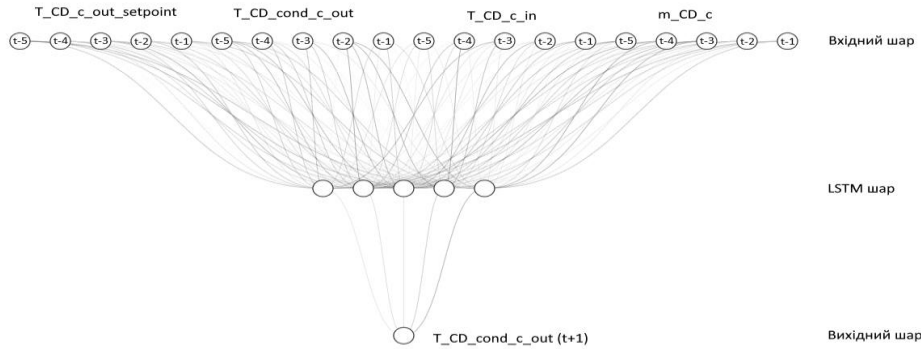


Рис. 1. Тренувальні дані для нейронної моделі ТНУ  
Fig. 1. Training data for the neural model of a heat pump

Для розробки моделі ТНУ на основі нейронної мережі було використано Python[11] та TensorFlow[12]. Задача полягала в розрахунку значення фактичної температури виходу з випарника в наступний момент часу. Для цього було обрано рекурентну нейронну мережу на базі Long Short-Term Memory (LSTM) [13] з одним шаром, що складається з п'яти нейронів. На рис. 2 демонструється обрана архітектура LSTM моделі, яка була зображена за допомогою ресурсу [14]. Вона була обрана через її здатність ефективно обробляти послідовні дані та враховувати залежності між історичними значеннями в часових рядах. Модель використовувала входні дані у вигляді п'яти попередніх значень ( $\text{lag} = 5$ ) для кожного з параметрів: уставка температури на виході конденсатора ( $T_{CD\_c\_out\_setpoint}$ , K), виміряне значення температури на виході конденсатора ( $T_{CD\_cond\_c\_out}$ , K), виміряне значення температури на вході в конденсатор ( $T_{CD\_c\_in}$ , K) та масова витрата теплоносія ( $m_{CD\_c}$ , кг/с). Це дозволило моделі враховувати як короткострокові, так і середньострокові залежності між змінними.

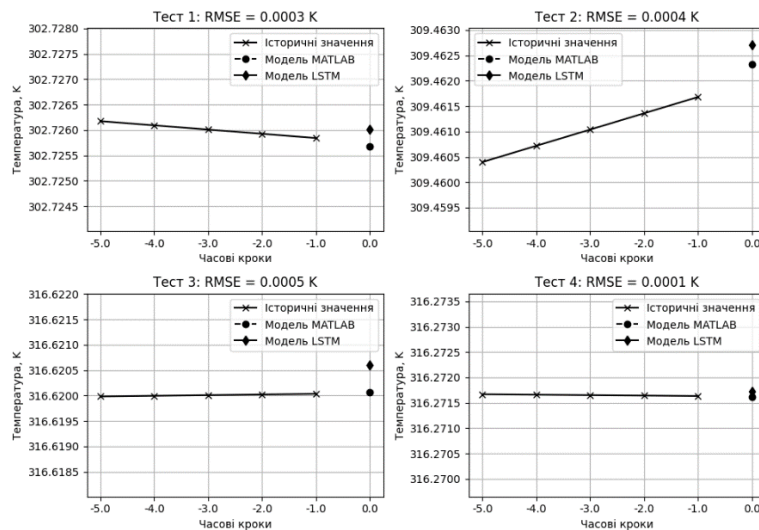


**Рис. 2. Архітектура LSTM моделі**  
**Fig. 2. Architecture of the LSTM model**

На першому етапі було підготовлено дані. Весь набір даних був поділений на тренувальний та валідаційний набори у співвідношенні 80% до 20%.

Нейронна мережа була побудована за допомогою бібліотеки TensorFlow. Для оптимізації процесу тренування використовувався алгоритм Adam[15], а функцією втрат обрано середньоквадратичну помилку (MSE)[16], що дозволяє мінімізувати різницю між прогнозованими та фактичними значеннями.

Процес тренування моделі був налаштований таким чином, щоб дані подавались у вигляді послідовностей через невеликі пакети даних, що дозволяє оптимізувати використання пам'яті. Модель тренувалась протягом 200 епох, але було застосовано механізм ранньої зупинки (EarlyStopping)[17] з параметром терпіння (patience), встановленим на 10 епох. Це дозволило автоматично зупинити тренування, якщо валідаційна похибка не знижувалась протягом зазначеного числа епох, зберігаючи найкращі ваги моделі. Отже, тренування тривало 111 хвилин та забезпечило MSE моделі на валідаційних даних на рівні  $2.13e-08$ , що підтверджує її здатність точно прогнозувати температуру виходу з випарника в умовах динамічної системи. На рис. 3 зображено приклад процесу тестування моделі на валідаційних даних.



**Рис. 3. Процес валідації моделі**  
**Figure 3. Model validation process**

Для конвертації LSTM-моделі в мову C було використано бібліотеку keras2c[18], яка дозволяє перетворювати моделі, створені в Keras, у C-код, що легко інтегрується в проекти. Бібліотека keras2c генерує три окремі C-файли на основі вихідної моделі Keras. Ці файли включаються до проекту разом із вихідним кодом бібліотеки keras2c, який доступний на GitHub. Вихідний код keras2c містить численні математичні операції, необхідні для обробки різних шарів моделі.

Після конвертації нейронної моделі теплового насоса в мову C, наступним кроком була її інтеграція в середовище Simulink[19] для використання у моделі системи опалення. Для цього був застосований блок S-function, який дозволяє виконувати користувацький C-код безпосередньо в Simulink. Щоб інтегрувати нейронну мережу в цей блок, необхідно було написати окремий C-файл, в якому були визначені основні параметри та логіка роботи блоку. У ньому прописано директиви, які визначають назву та рівень S-функції відповідно, методи для ініціалізації розмірів S-функції, частот дискретизації, обчислення виходів S-функції, завершення роботи S-функції та вимоги до вхідних та вихідних параметрів, а також логіку обробки даних. Зокрема, включено функції для стандартизації вхідних даних, виклику нейронної моделі та обробки вихідних значень.



Після написання цього файлу, разом із згенерованими keras2c C-файлами, було проведено компіляцію за допомогою команди MEX у середовищі MATLAB. Це дозволило отримати скомпільований файл з розширенням `.mexw64`, який можна безпосередньо використовувати в Simulink. Шлях до цього файлу було вказано у відповідному S-function блоці в моделі Simulink, що забезпечило коректну роботу нейронної мережі під час симуляції. Таким чином, модель теплого насоса на основі нейронної мережі була успішно імплементована в середовищі Simulink і готова до використання для прогнозування температурних режимів у системі опалення.

Нейронна модель є рекурентною, що означає її здатність враховувати послідовність попередніх значень для точного прогнозування. В даному випадку модель потребує п'яти попередніх значень для кожного вхідного параметра, що забезпечує можливість врахування динаміки процесу у часі. Для реалізації цього було використано блоки `'MATLAB Function'` в Simulink, які виконують функції черги типу FIFO (First-In, First-Out) на п'ять елементів. Реалізація такого підходу зображена на рис. 4.

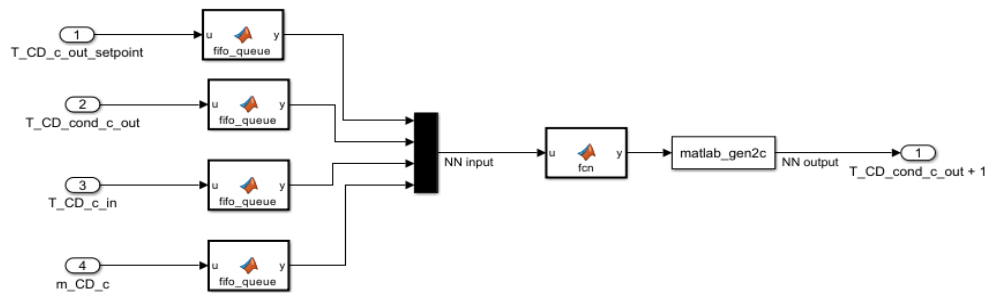


Рис. 4. Використання нейронної мережі через блок S-function

Fig. 4. Using a neural network using the S-function block

Ці блоки забезпечують збереження та оновлення послідовності останніх п'яти значень кожного параметра під час симуляції. Крім того, вони реалізують ініціалізацію початковими значеннями, що дозволяє моделі коректно функціонувати з самого початку симуляції. Кожен новий вхідний сигнал додається до черги, а найстаріше значення видаляється, зберігаючи таким чином актуальний набір даних для рекурентної нейронної мережі.

Завдяки такому підходу модель отримує всі необхідні дані для прогнозування наступного значення вихідної температури з випарника, що дозволяє їй ефективно враховувати тимчасові залежності між значеннями параметрів і забезпечувати більш точні результати в системі ТНУ.

При інтеграції моделі ТНУ на основі нейронної мережі в середовищі Simulink, особлива увага приділялася забезпеченню високої точності та швидкості роботи. Враховуючи, що модель повинна функціонувати в Simulink, критично важливо було не лише зберегти точність прогнозів, досягнуту під час тренування моделі в середовищі Python, але й оптимізувати швидкість обчислень після трансформації моделі на мову C та її інтеграції у вигляді блоку S-function.

#### Результати досліджень

Для оцінки точності та швидкості роботи різних версій моделі було проведено серію тестів, в яких порівнювалися три реалізації: оригінальна модель на Python, трансформована модель на мові C, і кінцевий блок S-function в Simulink. Як тестовий набір було використано 10,000 пар даних з валідаційного набору, що дозволило здійснити об'єктивну оцінку продуктивності кожної реалізації.

На етапі порівняння точності всі три реалізації показали близькі результати, підтверджуючи, що перетворення моделі на мову C та її подальша інтеграція в Simulink не призвели до значних втрат у точності. Це стало можливим завдяки ретельному налаштуванню процесу обробки даних, що було здійснено безпосередньо перед і після виклику моделі, забезпечуючи коректну обробку даних на кожному етапі.

Щодо швидкості роботи, тестування показало значні покращення після трансформації моделі на мову C. Якщо оригінальна модель на Python, через використання інтерпретованої мови програмування, потребувала більше часу на кожну ітерацію, то версія на C продемонструвала помітне скорочення часу обчислень. Це пояснюється оптимізацією коду під специфіку низькорівневих операцій, характерних для мови C, що дозволяє ефективніше використовувати обчислювальні ресурси.

Блок S-function, який був створений на основі згенерованого C-коду, також показав високі результати щодо швидкості роботи, що робить його ідеальним для інтеграції в реальні системи, де важливо забезпечити обробку даних у режимі реального часу. Використання MEX-компіляції дозволило створити високопродуктивний блок, що може бути безпосередньо інтегрований в модель Simulink, зберігаючи при цьому всі переваги оригінальної нейронної мережі та забезпечуючи необхідну продуктивність для використання в реальних умовах. Результати порівняння моделей показано в Таблиці 1.

Таблиця 1. - Результати тестування моделей

10000 ітерацій	Оригінальна модель	Модель на C	Модель в S-Function
RMSE, K	1.735089e-03	1.735122e-03	1.735122e-03
Середній час на ітерацію, сек.	8.45e-02	7.85e-06	5.2e-05



Таким чином, усі ці етапи та ретельна перевірка на точність і швидкість роботи дозволили інтегрувати нейронну модель теплового насоса в Simulink з мінімальними втратами якості і з максимальною ефективністю.

### Висновки

У ході даного дослідження було успішно розроблено та інтегровано модель ТНУ на основі нейронної мережі в середовищі Simulink для чисельного дослідження такої установки в складі системи теплозабезпечення будинку. Визначено, що традиційні методи моделювання теплових насосів мають обмеження у врахуванні нелінійних процесів, що призводить до похибок у прогнозуванні енергоспоживання та ефективності системи в цілому. Використання рекурентної нейронної мережі типу LSTM дозволило вирішити цю проблему, забезпечивши точніше моделювання теплових режимів системи теплозабезпечення.

Розробка моделі включала кілька важливих етапів: збір і підготовка тренувальних даних, побудова та оптимізація нейронної мережі, конвертація моделі в код на мові С з використанням бібліотеки keras2c та інтеграція цього коду в середовище Simulink за допомогою S-функції. Проведені тести показали, що інтегрована модель здатна зберігати високу точність прогнозування, при цьому значно знижуючи час обчислень, що є критичним для використання в режимі реального часу.

Порівняння трьох реалізацій моделі — оригінальної на Python, трансформованої на мові С та інтегрованої у вигляді S-функції в Simulink — показало, що запропонований підхід дозволяє досягти високої ефективності та швидкості роботи без значних втрат у точності.

Таким чином, розроблена нейронна модель теплового насоса є перспективним інструментом для підвищення енергоефективності систем теплозабезпечення будинків. Інтеграція цієї моделі в середовище Simulink відкриває нові можливості для оптимізації роботи ТНУ, дозволяючи більш точно прогнозувати їхню роботу в умовах динамічних змін параметрів та забезпечувати ефективне використання енергоресурсів. Майбутні дослідження можуть бути спрямовані на подальше вдосконалення моделі, зокрема на адаптацію до різних типів ТНУ та умов експлуатації, а також на інтеграцію з іншими компонентами системи керування.

### Список використаних джерел

- [1]. Vincenzo Bianco, Federico Scarpa, Luca A. Tagliafico. Applied Thermal Engineering. 2017. №114. С.938–947. DOI: 10.1016/j.applthermaleng.2016.12.058.
- [2]. Xing, C., Ding, Q., Jiang, A., Cheng, W., & Zhou, D. 2015. Dynamic operational optimization of air source heat pump heating system with the consideration of energy saving. . IFAC-Pap. 2015. Т. 48. № 8. С. 740-745. DOI: 10.1016/j.ifacol.2015.09.057.
- [3]. Aprea, C., Greco, A., & Maiorino, A. 2017. An application of the artificial neural network to optimize the energy performances of a magnetic refrigerator. International Journal of Refrigeration. Попередня онлайн публікація. DOI: 10.1016/j.ijrefrig.2017.06.015
- [4]. Bahadır Erman Yuce. Bitlis Eren University Journal of Science and Technology. 2020. №10(2). С.84–87. DOI: 10.1016/j.applthermaleng.2016.12.058.
- [5]. Ahmet Kose, Eduard Petlenkov. System Identification Models and Using Neural Networks for Ground Source Heat Pump with Ground Temperature Modeling. 2016 International Joint Conference on Neural Networks (IJCNN). 2016. С.2850–2855. DOI: 10.1109/IJCNN.2016.7727676.
- [6]. Sven Myrdahl Opalic, Morten Goodwin, Lei Jiao, Henrik Kofoed Nielsen, Angel Alvarez Pardinas, Armin Hafner, Mohan Lal Kolhe. ANN Modelling of CO2 Refrigerant Cooling System COP in a Smart Warehouse. Journal of Cleaner Production. 2020. №260. С. 120887. DOI: 10.1016/j.jclepro.2020.120887.
- [7]. Sven Myrdahl Opalic, Morten Goodwin, Lei Jiao, Henrik Kofoed Nielsen, Mohan Lal Kolhe. Modelling of Compressors in an Industrial CO2-Based Operational Cooling System Using ANN for Energy Management Purposes. In: J. Macintyre et al. (Eds.), Engineering Applications of Neural Networks, Communications in Computer and Information Science, vol 1000. Springer, Cham. 2019. С. 43–54. DOI: 10.1007/978-3-030-20257-6\_4.
- [8]. Jun Kwon Hwang, Geun Young Yun, Suk Ho Lee, Hyeonjoon Seo, Mat Santamouris. Using Deep Learning Approaches with Variable Selection Process to Predict the Energy Performance of a Heating and Cooling System. Renewable Energy. 2019. DOI: 10.1016/j.renene.2019.10.113.
- [9]. Волощук В. А., Шиндилюк П. В., Некрашевич О. В., Богза М. С., Гікало П. В. Дослідження динамічних характеристик теплонасосної установки типу «повітря-вода». Вчені записки ТНУ імені В.І. Вернадського. Серія: Технічні науки. 2023. Т. 34. № 73. С. 36-44. DOI: 10.32782/2663-5941/2023.3.2/07.
- [10]. Волощук В. А., Шиндилюк П. В., Некрашевич О. В., Богза М. С., Гікало П. В. Дослідження динамічних характеристик теплонасосної установки типу «вода-вода». Вчені записки ТНУ імені В.І. Вернадського. Серія: Технічні науки. 2023. Т. 34. № 2. С. 36-44. DOI: 10.32782/2663-5941/2023.3.2/07.
- [11]. Python Software Foundation. Python Language Reference, version 3.10. Available at: <https://www.python.org>. Accessed: 24.08.2024.
- [12]. Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, et al. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org. Accessed: 24.08.2024.
- [13]. Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A Search Space Odyssey. IEEE Transactions on Neural Networks and Learning Systems, 28(10), 2222-2232. DOI: 10.1109/TNNLS.2016.2582924.



- [14]. Lenail, A.D.A. Neural Network SVG Visualizer [Computer Software]. 2015. Available online: <http://alexlenail.me/NN-SVG/index.html> Accessed: 24.08.2024.
- [15]. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980. 2014.
- [16]. Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82. DOI: 10.3354/cr030079.
- [17]. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press..
- [18]. Rory Conlin, Keith Erickson, Joseph Abbate, Egemen Kolemen. Keras2c: A Library for Converting Keras Neural Networks to Real-Time Compatible C. *Engineering Applications of Artificial Intelligence*. 2021. №100. C. 104182. DOI: 10.1016/j.engappai.2021.104182.
- [19]. MathWorks. Simulink, Version R2022b. Natick, Massachusetts: The MathWorks Inc., 2022. Available at: <https://www.mathworks.com/products/simulink.html>. Accessed: 24.08.2024.

### References

- [1]. Vincenzo Bianco, Federico Scarpa, Luca A. Tagliafico. *Applied Thermal Engineering*. 2017. №114. C.938–947. DOI: 10.1016/j.applthermaleng.2016.12.058.
- [2]. Xing, C., Ding, Q., Jiang, A., Cheng, W., & Zhou, D. 2015. Dynamic operational optimization of air source heat pump heating system with the consideration of energy saving. *IFAC-Pap.* 2015. T. 48. № 8. C. 740-745. DOI: 10.1016/j.ifacol.2015.09.057.
- [3]. Aprea, C., Greco, A., & Maiorino, A. 2017. An application of the artificial neural network to optimize the energy performances of a magnetic refrigerator. *International Journal of Refrigeration*. Попередня онлайн публікація. DOI: 10.1016/j.ijrefrig.2017.06.015
- [4]. Bahadır Erman Yuce. *Bitlis Eren University Journal of Science and Technology*. 2020. №10(2). C.84–87. DOI: 10.1016/j.applthermaleng.2016.12.058.
- [5]. Ahmet Kose, Eduard Petlenkov. System Identification Models and Using Neural Networks for Ground Source Heat Pump with Ground Temperature Modeling. 2016 International Joint Conference on Neural Networks (IJCNN). 2016. C.2850–2855. DOI: 10.1109/IJCNN.2016.7727676.
- [6]. Sven Myrdahl Opalic, Morten Goodwin, Lei Jiao, Henrik Kofoed Nielsen, Angel Alvarez Pardinias, Armin Hafner, Mohan Lal Kolhe. ANN Modelling of CO2 Refrigerant Cooling System COP in a Smart Warehouse. *Journal of Cleaner Production*. 2020. №260. C. 120887. DOI: 10.1016/j.jclepro.2020.120887.
- [7]. Sven Myrdahl Opalic, Morten Goodwin, Lei Jiao, Henrik Kofoed Nielsen, Mohan Lal Kolhe. Modelling of Compressors in an Industrial CO2-Based Operational Cooling System Using ANN for Energy Management Purposes. In: J. Macintyre et al. (Eds.), *Engineering Applications of Neural Networks, Communications in Computer and Information Science*, vol 1000. Springer, Cham. 2019. C. 43–54. DOI: 10.1007/978-3-030-20257-6\_4.
- [8]. Jun Kwon Hwang, Geun Young Yun, Suk Ho Lee, Hyeongjoon Seo, Mat Santamouris. Using Deep Learning Approaches with Variable Selection Process to Predict the Energy Performance of a Heating and Cooling System. *Renewable Energy*. 2019. DOI: 10.1016/j.renene.2019.10.113.
- [9]. Voloshchuk, V. A., Shyndylyuk, P. V., Nekrashevych, O. V., Bohza, M. S., Gikalo, P. V. (2023). Research of dynamic characteristics of the air-to-water heat pump system. *Scientific Notes of V. I. Vernadsky Taurida National University. Series: Technical Sciences*, 34(73), 36-44. DOI: 10.32782/2663-5941/2023.3.2/07.
- [10]. Voloshchuk, V. A., Shyndylyuk, P. V., Nekrashevych, O. V., Bohza, M. S., Gikalo, P. V. (2023). Research of dynamic characteristics of the water-to-water heat pump system. *Scientific Notes of V. I. Vernadsky Taurida National University. Series: Technical Sciences*, 34(2), 36-44. DOI: 10.32782/2663-5941/2023.3.2/07
- [11]. Python Software Foundation. Python Language Reference, version 3.10. Available at: <https://www.python.org>. Accessed: 24.08.2024.
- [12]. Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, et al. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from [tensorflow.org](https://www.tensorflow.org). Accessed: 24.08.2024.
- [13]. Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). *LSTM: A Search Space Odyssey*. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232. DOI: 10.1109/TNNLS.2016.2582924.
- [14]. Lenail, A.D.A. Neural Network SVG Visualizer [Computer Software]. 2015. Available online: <http://alexlenail.me/NN-SVG/index.html> Accessed: 24.08.2024.
- [15]. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980. 2014.
- [16]. Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82. DOI: 10.3354/cr030079.
- [17]. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press..
- [18]. Rory Conlin, Keith Erickson, Joseph Abbate, Egemen Kolemen. Keras2c: A Library for Converting Keras Neural Networks to Real-Time Compatible C. *Engineering Applications of Artificial Intelligence*. 2021. №100. C. 104182. DOI: 10.1016/j.engappai.2021.104182.
- [19]. MathWorks. Simulink, Version R2022b. Natick, Massachusetts: The MathWorks Inc., 2022. Available at: <https://www.mathworks.com/products/simulink.html>. Accessed: 24.08.2024.