

Богза М.С.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Волощук В.А.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ У ЗАДАЧАХ МОДЕЛЮВАННЯ ДИНАМІКИ ТЕПЛОНАСОСНИХ УСТАНОВОК

Сучасні тенденції в енергозбереженні та підвищенні енергоефективності ставлять перед дослідниками та інженерами завдання удосконалення технологій, які застосовуються в системах опалення, вентиляції та кондиціонування повітря. Одним з ключових напрямів у цій галузі є оптимізація роботи теплонасосних установок (ТНУ), що забезпечують високий коефіцієнт корисної дії та економію енергоресурсів. В статті розглядаються сучасні підходи до моделювання ТНУ, зокрема аналітичні методи та методи машинного навчання, для підвищення їх ефективності та продуктивності.

Традиційні аналітичні методи, реалізовані в програмних пакетах, таких як MATLAB, COMSOL або Python, дозволяють створювати детальні моделі ТНУ на основі фізичних принципів. Ці моделі враховують різні параметри та умови роботи системи, що забезпечує можливість проведення детального аналізу та прогнозування її поведінки. Однак, з розвитком технологій штучного інтелекту, зокрема машинного навчання, з'явилася можливість застосування нейронних мереж для моделювання таких нелінійних систем, як ТНУ. У статті проаналізовано використання моделей машинного навчання для моделювання динамічних процесів в ТНУ, показано їх ефективність у прогнозуванні енергоспоживання та продуктивності системи.

Результати останніх досліджень демонструють, що моделі машинного навчання можуть досягати високої точності прогнозування параметрів роботи ТНУ, таких як теплова потужність, споживання електричної енергії, коефіцієнт трансформації (COP) та виявлення несправностей. Використання чистих та синхронізованих даних, які представляють різні умови експлуатації, є важливим аспектом успішного застосування таких моделей в алгоритмах керування ТНУ.

Метою даного дослідження є розробка та порівняння аналітичної моделі ТНУ, створеної на базі MATLAB, з моделями машинного навчання. У процесі дослідження визначено переваги та недоліки кожного з підходів, а також запропоновані рекомендації щодо їх використання для оптимізації роботи теплових насосів. Розроблені комп'ютерні моделі ТНУ були провалідовані на основі реальних експериментальних даних, що забезпечило високу точність моделювання.

Висновки дослідження підкреслюють, що застосування моделей машинного навчання, зокрема ANN та Random Forest, дозволяє значно скоротити час розрахунків та підвищити гнучкість системи при обробці різноманітних сценаріїв та умов експлуатації ТНУ. Це відкриває нові можливості для оптимізації роботи теплових насосів та підвищення їх енергоефективності, що є важливим аспектом в умовах сучасних вимог до енергозбереження та екологічної безпеки.

Ключові слова: теплонасосні установки (ТНУ), аналітичні моделі, машинне навчання, нейронні мережі, випадкові ліси, прогнозування, оптимізація

Постановка проблеми. Сучасні тенденції в енергозбереженні та підвищенні енергоефективності вимагають удосконалення технологій, які використовуються в системах опалення, вентиляції та кондиціонування повітря. Одним із важливих аспектів цього процесу є оптимізація роботи теплонасосних установок (ТНУ). Такі установки можуть забезпечити високий коефіцієнт корисної дії та економію енергоресурсів, що робить їх привабли-

вими для широкого застосування у різних галузях [1, 2]. Традиційно для моделювання ТНУ використовуються аналітичні методи, реалізовані в програмних пакетах, таких як MATLAB, COMSOL або Python. Ці методи базуються на фізичних принципах і дозволяють створювати детальні моделі систем, враховуючи різні параметри та умови роботи. Однак, з розвитком технологій штучного інтелекту, з'явилася можливість застосування моделей

машинного навчання для моделювання таких нелінійних систем, як ТНУ [3].

Аналіз останніх досліджень і публікацій. Дослідники проаналізували використання штучних нейронних мереж (ANN) для моделювання динамічних процесів ТНУ, демонструючи їх ефективність у прогнозуванні енергоспоживання та продуктивності систем [4]. Розроблені моделі А та В на основі ANN показали високу точність в прогнозуванні параметрів роботи теплових насосів, таких як теплова потужність, споживання електричної енергії, коефіцієнт трансформації (COP) та виявлення несправностей. Модель А відзначається здатністю швидко виявляти відмови компресора та несподівані зупинки, що робить її перспективним інструментом для системного виявлення несправностей. Модель В виявилася відмінним інструментом для прогнозування енергоспоживання та COP, що допомагає виробникам покращувати параметри ТНУ, а власникам будівель – моніторити продуктивність. Важливим аспектом успішного застосування ANN є наявність чистих та синхронізованих даних, які представляють різні умови експлуатації. Стаття підкреслює, що ANN забезпечує швидкий і точний метод аналізу динаміки наявних даних, що є перевагою порівняно з традиційними фізичними моделями, які часто вимагають більш складного підходу та додаткових даних від виробників.

В роботі [5] проаналізовано використання нейронних мереж для оптимізації режимів роботи циркуляційного насоса в складі ТНУ на основі даних про джерело тепла та навантаження. Модель штучної нейронної мережі (ANN) була розроблена для прогнозування оптимальної швидкості води, що дозволило покращити продуктивність системи без значного збільшення витрат або зміни основних компонентів існуючої системи кондиціонування. Використання синтетичних наборів даних навантаження у вигляді часових рядів для навчання моделі ANN забезпечило високу точність прогнозування, навіть за суворих погодних умов. Модель продемонструвала надійні результати завдяки алгоритму зворотного розповсюдження помилки, що дозволило точно контролювати швидкість потоку води в межах рекомендованого діапазону. Збільшення COP на 0.88% і 6.23% відповідно при низькій швидкості води та використанні насоса зі змінною швидкістю забезпечило економічну ефективність та потенціал для зменшення енергоспоживання.

У статті [6] досліджено ефективність використання методів випадкових лісів (RF) та нейронних

мереж з зворотною передачею помилки для прогнозування продуктивності ґрунтових теплових насосів. Дослідження базується на двох роках експлуатаційних даних, зібраних в освітній будівлі у холодній зоні Китаю. Основні показники продуктивності, такі як коефіцієнт трансформації та енергетичний коефіцієнт ефективності, були успішно спрогнозовані за допомогою Random Forest моделі з середньою відносною помилкою менше 5%. Порівняння моделей показало, що Random Forest має переваги в точності та швидкості у порівнянні з нейронною мережею зворотного поширення. Зокрема, Random Forest модель виявилася менш чутливою до змін кількості вхідних змінних і забезпечила високу точність навіть при їх зменшенні. Це дослідження підтверджує, що Random Forest є потужним інструментом для прогнозування та управління продуктивністю систем ґрунтових теплонасосних установок, сприяючи покращенню їх енергоефективності та зниженню експлуатаційних витрат.

У статті [7] досліджено використання моделей машинного навчання для прогнозування коефіцієнта трансформації (COP) систем теплових насосів. Зібрані дані експлуатації теплових насосів були використані для розробки моделей штучної нейронної мережі (ANN), методу опорних векторів (SVM), випадкового лісу (RF) та алгоритму k-найближчих сусідів (KNN). Результати показали, що ANN модель забезпечила найвищу точність прогнозування з відносною помилкою –3.6% і найшвидший час обчислення, задовольняючи критерії ASHRAE. Використання ANN моделі в системі автоматизації будівель підтвердило її ефективність та придатність для реального часу моніторингу продуктивності, що підкреслює її потенціал для підвищення енергоефективності теплових насосів.

Актуальність даного дослідження полягає в порівнянні ефективності аналітичних моделей на базі MATLAB та моделей машинного навчання для моделювання ТНУ. Використання таких моделей дає можливість враховувати складні взаємозв'язки між параметрами системи та забезпечити точне передбачення її поведінки за різних умов експлуатації при цьому оптимізуючи використання обчислювальних ресурсів. Це відкриває нові можливості для оптимізації роботи теплових насосів та підвищення їх енергоефективності.

Постановка завдання. Метою даного дослідження є розробка та порівняння аналітичної моделі теплового насоса, створеної на базі MATLAB, з моделями машинного навчання.

У процесі дослідження будуть визначені переваги та недоліки кожного з підходів, а також запропоновані рекомендації щодо їх використання для оптимізації роботи теплових насосів.

Виклад основного матеріалу. Принцип аналітичного моделювання роботи теплового насосу базується на використанні математичних рівнянь, що описують фізичні процеси в кожному з компонентів системи. Аналітична модель враховує термодинамічні властивості робочого тіла, рівняння теплового балансу для випарника та конденсатора, а також параметри компресора і розширювального клапана. Такі моделі дозволяють проводити детальний аналіз роботи теплового насосу, прогнозувати його поведінку за різних умов експлуатації та оптимізувати його налаштування для підвищення енергоефективності. На рис. 1 представлена схема теплової насосної установки типу «вода-вода».

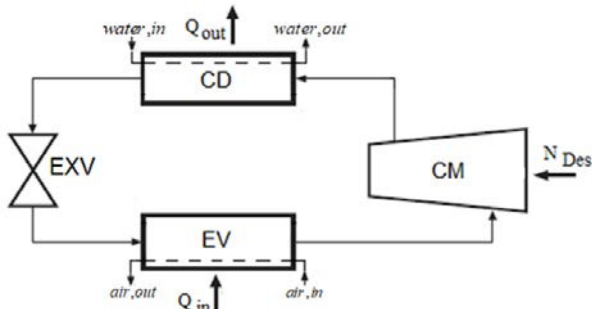


Рис. 1. Розрахункова схема теплонасосної установки

Система складається з чотирьох основних компонентів: конденсатора (CD), випарника (EV), компресора (CM) та дросельного вентиля (EXV). Вода надходить до конденсатора через вхідний

патрубок (water,in), де вона нагрівається і виходить через вихідний патрубок (water,out), передаючи теплоту Q_{out} . Робоче тіло, яке стискається у компресорі (CM), підвищує свою температуру і тиск, після чого надходить до конденсатора, де відбувається віддача тепла воді.

Після конденсатора робоче тіло проходить через дросельний вентиль (EXV), де його тиск і температура знижуються. Потім робоче тіло потрапляє до випарника (EV), де воно поглинає тепло Q_{in} від води, що надходить через вхідний патрубок (water,in) і виходить через вихідний патрубок (water,out). Таким чином, тепло, відібране із води у випарнику, переноситься і віддається у конденсаторі, забезпечуючи ефективне нагрівання. Схема демонструє основні етапи процесу передачі тепла в тепловій насосній установці, підкреслюючи роль кожного компонента у цьому циклі. На рис. 2 зображено комп'ютерну модель Simulink, яка використовує рівняння теплового балансу для моделювання динаміки теплового насосу [8, 9].

Розроблену комп'ютерну модель теплової насосної установки було провалідовано на основі реальних експериментальних даних, що забезпечило високу точність моделювання. Результати валідації показали, що середня абсолютна відсоткова помилка (MAPE) склала 10,5%, що задовольняє умови дослідження і підтверджує адекватність моделі для використання у практичних застосуваннях.

Основною перевагою такого підходу є висока точність моделювання, що дозволяє проводити детальний аналіз та оптимізацію роботи теплової насосної установки. Проте, значним недоліком є високі вимоги до обчислювальних ресурсів. Як показано у таблиці 1, проміжок часу моделю-

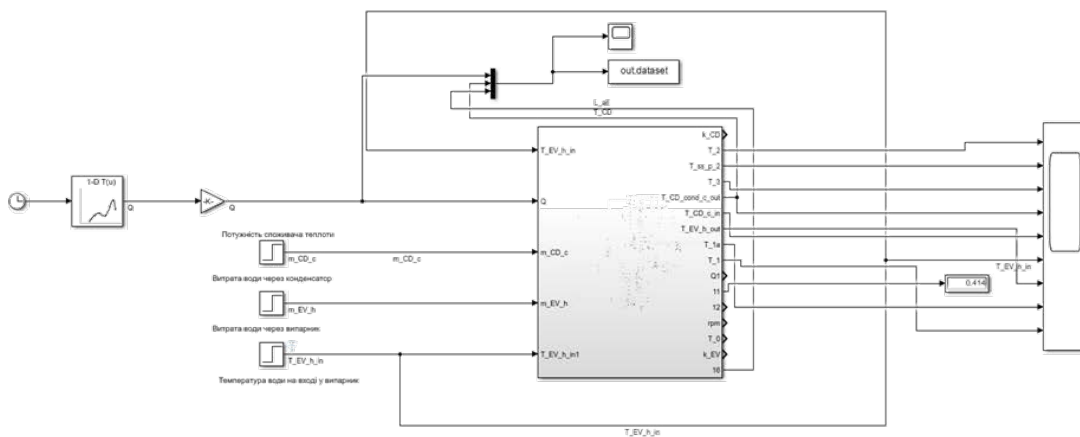


Рис. 2. Модель ТНУ в середовищі Simulink

вання безпосередньо впливає на час розрахунку: для моделювання періоду тривалістю 6000 секунд потрібно 470 секунд обчислювального часу, а для моделювання одного місяця – дві доби обчислювального часу. Це вказує на необхідність використання потужних обчислювальних систем для моделювання довготривалих процесів, таких як опалювальний період, де може виникати помилка розрахунку через обмеження ресурсів.

Таблиця 1

Тривалість процесу моделювання

Проміжок часу моделі (Stop time), с.	Час розрахунку з кроком 0.5 с
120	11
600	85
6000	470
1 місяць	2 доби
Опалювальний період	Помилка розрахунку

Для пришвидшення часу моделювання теплової насосної установки буде розглянуто кілька альтернативних моделей машинного навчання, зокрема метод random forest [10, 11] та рекурентні нейронні мережі [12].

На рис. 3 зображено архітектуру методу Random Forest, який використовується для задач моделювання та прогнозування. Метод Random Forest складається з множини дерев рішень, кожне з яких навчається незалежно на різних підмножинах даних.

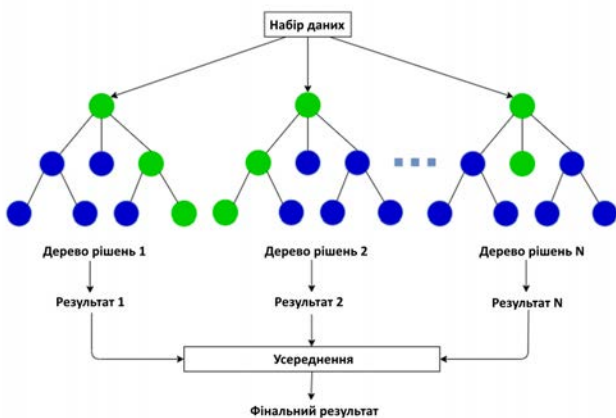


Рис. 3. Схематичне зображення алгоритму Random Forest [8, 9]

Процес починається з того, що початковий датасет ділиться на декілька підмножин, кожна з яких використовується для навчання окремого дерева рішень. Кожне дерево рішень проходить через процес навчання, створюючи свої унікальні гілки і вузли.

Фінальний результат обчислюється шляхом об'єднання всіх результатів окремих дерев. Для класифікаційних задач кінцевий клас визначається тим, який отримав найбільшу кількість голосів від окремих дерев. Для регресійних задач остаточне передбачення є середнім значенням усіх передбачень дерев.

Ця архітектура дозволяє моделі Random Forest зменшити ймовірність перенавчання і підвищити загальну точність прогнозування, об'єднуючи в собі сильні сторони багатьох окремих дерев.

Рекурентні нейронні мережі (RNN), зокрема їх варіанти LSTM (Long Short-Term Memory) [13, 14] та GRU (Gated Recurrent Unit) [15, 16], відомі своєю здатністю обробляти послідовності даних і виявляти залежності у часових рядах. Вони можуть бути використані для передбачення динаміки теплових процесів на основі історичних даних, що значно прискорює моделювання у порівнянні з традиційними методами.

Впровадження цих моделей дозволить не лише скоротити час розрахунків, але й підвищити гнучкість системи при обробці різноманітних сценаріїв та умов експлуатації теплової насосної установки. Такий підхід забезпечить більш ефективне використання обчислювальних ресурсів та розширить можливості аналізу та оптимізації системи в реальному часі.

На рисунку 4 зображено набір даних, згенерований за допомогою моделі Simulink та використаний для тренування моделей машинного навчання. Цей набір даних включає ключові параметри системи: Q – теплову потужність, необхідну для забезпечення тепловою енергією споживача (будинку); T_{CD} – температуру теплоносія на виході теплової насосної установки (ТНУ); та L_{all} – електричну потужність, споживану компресором. Період моделювання склав один місяць, що зайняло два дні обчислювального часу моделі Simulink. Частота запису даних становила 0,5 секунди.

Для прогнозування споживання електричної енергії ТНУ, було використано метод випадкового лісу (RandomForestRegressor). Даний підхід дозволяє створити ансамбль рішень шляхом побудови множини дерев рішень, що значно покращує точність прогнозів порівняно з одиничними моделями.

Для оптимізації гіперпараметрів моделі було використано метод GridSearchCV [17], який здійснює перебір заданих значень параметрів з подальшим вибором найбільш оптимальних. Зокрема, в даному дослідженні було обрано два ключові параметри: кількість дерев у лісі




Рис. 4. Набір тренувальних даних

($n_estimators$) та максимальна глибина дерев (max_depth). Значення параметрів, що розглядалися для $n_estimators$, були наступні: 100, 200, 500 та 1000, а для max_depth – None, 10, 20 та 30.

Процес оптимізації моделі здійснювався на основі крос-валідації, що дозволяє зменшити ймовірність перенавчання моделі та забезпечити більш надійні результати. Як оцінку точності моделі було обрано корінь середньоквадратичної помилки (RMSE) [18], оскільки вона є стандартною метрикою для задач регресії та добре підходить для порівняння точності різних моделей.

Результати пошуку оптимальних параметрів показали, що найкращі значення були досягнуті при $max_depth = 30$ та $n_estimators = 100$. Модель з цими параметрами була навчена на тренувальному наборі даних і використана для прогнозу-

вання на валідаційному наборі. Значення RMSE на валідаційному наборі склало 258 Вт, що свідчить про задовільну точність моделі в умовах даного дослідження. Час тренування склав 16 хвилин та 10 секунд. Один із тестувальних сценаріїв зображено на рис. 5.

Отримані результати демонструють ефективність методу випадкового лісу для прогнозування споживання електричної енергії теплової насосної установки, забезпечуючи адекватну точність при відповідних налаштуваннях параметрів моделі.

Для прогнозування споживання електричної енергії ТНУ залежно від теплового навантаження була розроблена модель на основі Long Short-Term Memory (LSTM) – типу рекурентної нейронної мережі (RNN). Модель LSTM вибрана через її здатність враховувати довгострокові залежності в часових рядах, що є критично важливим для точного прогнозування у складних динамічних системах, таких як теплонасосні установки.

Для побудови моделі LSTM, дані були нормалізовані шляхом обчислення середнього значення та стандартного відхилення для тренувальної частини набору даних.

Потім, підготовлені дані були організовані у вигляді тензорів, з яких сформовані набори даних для тренування та валідації. Вони були кешовані, перемішані та розділені на підмножини для подальшого тренування моделі [19, 20, 21].

На Рис. 6 представлена архітектура нейронної мережі яка була створена за допомогою ресурсу [22]. Вона складається з двох прихованих шарів, де кожен шар складається з LSTM (Long Short-Term Memory) нейронів. Вхідний шар мережі складається з 6 нейронів, які отримують початкові дані.

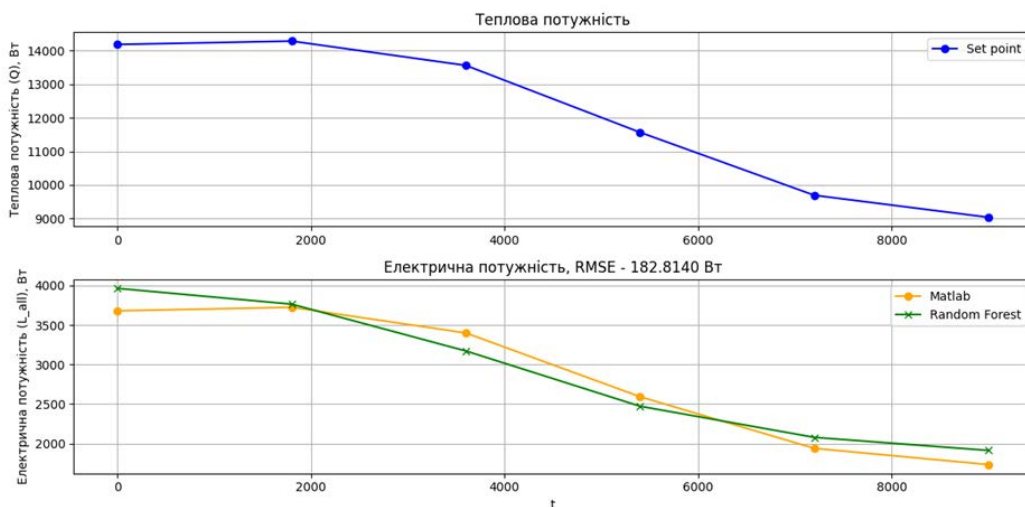


Рис. 5. Використання моделі RandomForest




Рис. 6. Архітектура нейронної мережі

Ці нейрони з'єднані з 10 нейронами першого прихованого шару, що моделює складні часові залежності у вхідних даних. Далі, перший прихований шар з'єднаний з другим прихованим шаром, який також містить 10 нейронів. Другий прихований шар з'єднаний з вихідним шаром, який складається з 6 нейронів, що генерують кінцеві результати мережі. Така архітектура дозволяє ефективно обробляти послідовності даних, зберігаючи інформацію про попередні стани і використовуючи її для покращення точності прогнозування.

Модель була скомпільована з використанням оптимізатора Adam[23] і функції втрат MSE (mean squared error). Час тренування склав 55 хвилин та 2 секунди. Значення RMSE на валідаційному наборі склало 37 Вт, що свідчить про високу точність моделі в умовах даного дослідження. Один із тестувальних сценаріїв зображено на рис. 7.

На рис. 8 зображено використання моделі RandomForest та LSTM на одному тестувальному сценарії. Показник RMSE для RandomForest моделі є 48 Вт, а для LSTM 25 Вт.

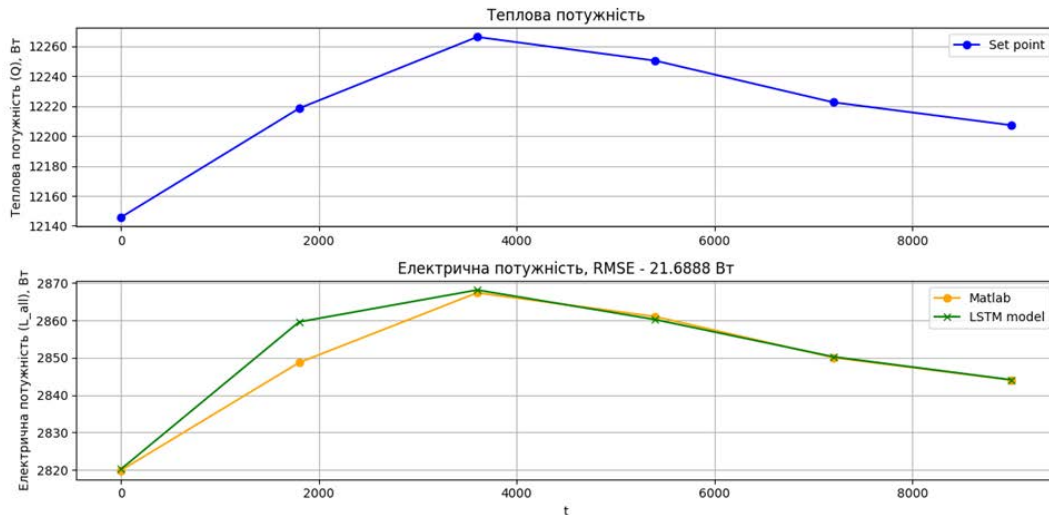


Рис. 7. Використання моделі LSTM




Рис. 8. Тестування обох моделей на валідаційному наборі даних

Висновки. В результаті дослідження було розроблено дві моделі з використанням методів машинного навчання: Random Forest та LSTM (Long Short-Term Memory). Обидві моделі оцінювалися за критеріями швидкості тренування, точності та здатності до оптимізації.

Модель Random Forest продемонструвала швидкий час тренування завдяки наявності вбудованих інструментів для оптимізації параметрів. Середній час роботи цієї моделі для 10 тестових сценаріїв склав лише 0.005 секунди. Це робить її надзвичайно ефективною для швидкого розгортання та використання в реальних умовах.

У свою чергу, модель на базі LSTM вимагала значно більше часу для підготовки даних та самого процесу тренування. Середній час роботи

цієї моделі для 10 тестових сценаріїв склав 0.35 секунди. Незважаючи на це, LSTM забезпечує значно вищу точність прогнозування.

При оцінці на валідаційному наборі даних модель Random Forest досягла RMSE на рівні 258 Вт, тоді як модель LSTM показала значно кращий результат з RMSE на рівні 37 Вт. Це свідчить про те, що LSTM значно точніше прогнозує залежність електричної енергії від теплового навантаження в системі теплового насосу.

З урахуванням показників точності та швидкодії, модель LSTM була обрана як оптимальна для задач розрахунку та моделювання залежності електричної енергії від теплового навантаження в теплонасосній установці. Це рішення базується на її високій точності, незважаючи на більший час тренування та складність підготовки даних.

Список літератури:

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. Fadnes, F. S., Banihabib, R., & Assadi, M. 2023. Using Artificial Neural Networks to Gather Intelligence on a Fully Operational Heat Pump System in an Existing Building Cluster. Energies. 2023. Т. 16. № 5. С. 3875. DOI: 10.3390/en16093875.
5. Chae, S., Bae, S., & Nam, Y. 2023. Performance improvement of air-source heat pump via optimum control based on artificial neural network. Energy Reports. 2023. Т. 10. С. 460–472. DOI: 10.1016/j.egy.2023.06.051.
6. Lu, S., Li, Q., Bai, L., & Wang, R. 2019. Performance predictions of ground source heat pump system based on random forest and back propagation neural network models. Energy Conversion and Management. 2019. Т. 197. С. 111864. DOI: 10.1016/j.enconman.2019.111864.
7. Shin, J.-H.; Cho, Y.-H. Machine-Learning-Based Coefficient of Performance Prediction Model for Heat Pump Systems. Applied Sciences. 2022. Т. 12. С. 362. DOI: 10.3390/app12010362.
8. 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.
9. 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.
10. Breiman L. Random Forests. Machine Learning. 2001. Vol. 45. No. 1. P. 5–32. DOI: 10.1023/A:1010933404324.
11. Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., ... Duchesnay É. Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research. 2011. Vol. 12. P. 2825–2830.
12. Rumelhart D. E., Hinton G. E., Williams R. J. Learning representations by back-propagating errors. Nature. 1986. Vol. 323. No. 6088. P. 533–536. DOI: 10.1038/323533a0.
13. Hochreiter S., Schmidhuber J. Long Short-Term Memory. Neural Computation. 1997. Vol. 9. No. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.
14. Gers F. A., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. Neural Computation. 2000. Vol. 12. No. 10. P. 2451–2471. DOI: 10.1162/089976600300015015.
15. Cho K., Van Merriënboer B., Bahdanau D., Bengio Y. On the Properties of Neural Machine Translation: Encoder-Decoder Approaches. arXiv preprint arXiv:1409.1259. 2014.
16. Chung J., Gulcehre C., Cho K., Bengio Y. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. arXiv preprint arXiv:1412.3555. 2014.

17. Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., ... Duchesnay É. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825-2830.
18. Afram, A., & Janabi-Sharifi, F. (2014). Review of modeling methods for HVAC systems. *Applied Thermal Engineering*, 67*(1-2), 507-519. <https://doi.org/10.1016/j.applthermaleng.2014.03.055>
19. Keras Documentation. Available online: <https://keras.io> (accessed on 26 December 2018).
20. Google. TensorFlow; Google LLC.: Mountain View, CA, USA, 2021
21. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. 2nd ed. O'Reilly Media, Inc.: Sebastopol, CA, USA, 2019.
22. Lenail, A.D.A. Neural Network SVG Visualizer [Computer Software]. 2015. Available online: <http://alexlenail.me/NN-SVG/index.html> (accessed on 27 June 2024).
23. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980. 2014.

Bogza M.S., Voloshchuk V.A. APPLICATION OF MACHINE LEARNING METHODS IN THE PROBLEMS OF MODELING THE DYNAMICS OF THERMAL POWER PLANTS

Modern trends in energy saving and energy efficiency are challenging researchers and engineers to improve technologies used in heating, ventilation and air conditioning systems. One of the key areas in this field is the optimization of heat pump units (HPUs), which provide high efficiency and energy savings. This article discusses modern approaches to modeling CHPs, including analytical and machine learning methods, to improve their efficiency and productivity.

Traditional analytical methods implemented in software packages such as MATLAB, COMSOL, or Python allow creating detailed models of thermal fluids based on physical principles. These models take into account various parameters and operating conditions of the system, which makes it possible to conduct a detailed analysis and predict its behavior. However, with the development of artificial intelligence technologies, in particular machine learning, it has become possible to use neural networks to model nonlinear systems such as TSUs. The article analyzes the use of machine learning models for modeling dynamic processes in TSUs, showing their effectiveness in predicting energy consumption and system performance.

The results of recent studies show that machine learning models can achieve high accuracy in predicting the parameters of CHP operation, such as thermal power, electricity consumption, coefficient of transformation (COP), and fault detection. The use of clean and synchronized data representing different operating conditions is an important aspect of the successful application of such models in the control algorithms of the CHP.

The purpose of this study is to develop and compare an analytical model of the heating and power plant based on MATLAB with machine learning models. In the course of the study, the advantages and disadvantages of each approach are identified, and recommendations for their use to optimize the operation of heat pumps are proposed. The developed computer models of the CHPs were tested on the basis of real experimental data, which ensured high modeling accuracy.

The conclusions of the study emphasize that the use of machine learning models, in particular ANN and Random Forest, can significantly reduce the calculation time and increase the flexibility of the system when processing various scenarios and operating conditions of CHP. This opens up new opportunities for optimizing the operation of heat pumps and improving their energy efficiency, which is an important aspect in the context of modern requirements for energy saving and environmental safety.

Key words: heat pump units (HPU), analytical models, machine learning, neural networks, random forests, forecasting, optimization.