

УДК 004.89:536.24:620.179.16

DOI <https://doi.org/10.32782/3041-2080/2026-6-5>

РОЗРОБКА СИСТЕМИ ПІДТРИМКИ УХВАЛЕННЯ РІШЕНЬ ДЛЯ ПРЕДИКТИВНОГО ТЕПЛОВОГО КОНТРОЛЮ В ТРУБОПРОВІДНИХ СИСТЕМАХ

Новаковський Павло Олександрович,

аспірант кафедри автоматизації та комп'ютерних технологій систем управління

імені професора А. П. Ладанюка

Національного університету харчових технологій

ORCID ID: 0009-0007-8418-7747

Розроблена система підтримки ухвалення рішень (DSS) для прогнозного теплового керування трубопроводами ґрунтується на створенні цифрового двійника, який відображає геометрію, матеріали, середовище та датчики трубопроводу. Така модель дає змогу прогнозувати розподіл температур, виявляти аномалії, моделювати втрати тепла та формувати керувальні дії в реальному часі. У центрі системи працює модуль прогнозування, який оцінює майбутній стан температурного поля на основі поточних даних і фізичних закономірностей теплопередачі. Для цього використовують як емпіричні моделі, так і неймережеві предиктори. Навчання моделі виконується до досягнення високої точності, після чого вона інтегрується в DSS і може оновлюватися за новими даними. Нечітка логіка в системі дає змогу враховувати невизначеність, оперуючи поняттями типу «перегрів» чи «нестабільність». Вхідні дані перетворюються на ступені належності до цих понять, після чого застосовують нечіткі правила ухвалення рішень. Результати цих правил перетворюються на конкретні дії системи, наприклад, зниження потужності нагріву. Крім того, система містить модуль навчання з підкріпленням, який автоматично вдосконалює стратегію керування, аналізуючи наслідки дій у змінних умовах. Він обирає ті дії, які забезпечують підтримання температур у допустимих межах, енергоефективність та запобігання аваріям. Для врахування впливу сегментів один на одного застосовують імовірнісні графові моделі – Байєсівські мережі, які моделюють поширення теплових ефектів уздовж трубопроводу. У процесі експериментальної перевірки модель DSS продемонструвала високу точність: результати симуляцій підтвердили, що система здатна точно відтворювати реальні температурні профілі трубопроводу. Обґрунтовано, що система забезпечує можливість масштабування на складні мережеві трубопровідні структури, включно з розгалуженими магістралями та багатокомпонентними вузлами. Розширена інтеграція цифрового двійника з реальними сенсорними даними дає змогу виявляти потенційні відхилення та прогнозувати розвиток несправностей задовго до їх фактичного прояву. Установлено, що вдосконалений процес прогнозування сприяє адаптивному керуванню тепловими режимами, що знижує експлуатаційні витрати та підвищує загальну надійність трубопровідної інфраструктури. Доведено, що застосування комбінованого підходу, який поєднує методи штучного інтелекту, математичного моделювання та нечіткої логіки, підвищує стійкість системи до шумів, неповноти даних та нелінійної поведінки фізичних процесів. Також проведено пілотну експериментальну оцінку з використанням набору даних SCADA моніторингу трубопровідних систем нафтогазової галузі, що охоплює 12 місяців безперервних вимірювань із частотою 1 Гц. Прогнозування температур реалізовано на основі наскрізної нейронної мережі, орієнтованої на короткострокові інкрементальні зміни температури, у поєднанні з керуванням на базі алгоритму Proximal policy optimization. Отримані результати підтвердили високу точність прогнозування та ефективність адаптивного керування: середній час повного циклу ухвалення рішень не перевищував 18,5 мс, а параметр накопиченої дисконтованої нагороди зріс на 74 % з одночасним зменшенням його дисперсії більш ніж на 60 %.

Ключові слова: цифровий двійник, нечітка логіка, навчання з підкріпленням, Байєсівська мережа, дефазифікація, марковський процес ухвалення рішень.

Novakovskiy Pavlo. Development of a decision support subsystem for predictive thermal control in pipeline systems

The developed Decision Support System (DSS) for predictive thermal control of pipelines is based on a standardized digital twin that represents the geometry, materials, environmental conditions, and sensor layout of the pipeline. This virtual model enables accurate simulation of heat transfer, detection of anomalies, modeling of heat losses, and generation of control actions in real time. At the core of the system lies a forecasting module that predicts future temperature distributions based on current conditions and physical heat transfer patterns. These predictions are generated using empirical models or neural network-based predictors, trained to high accuracy and continuously updated as new data becomes available. The DSS incorporates fuzzy logic to manage uncertainty by using linguistic variables such as “overheating”, “low gradient”, and “instability”. Sensor inputs are transformed into degrees of membership to these concepts, which are then processed through expert-defined fuzzy rules. The outcome is translated into concrete control actions, such as adjusting heating power, through a defuzzification process. A reinforcement learning module is also integrated to autonomously refine control strategies. By interacting with the pipeline model, it learns optimal

decisions that maintain thermal stability, minimize energy consumption, and prevent hazardous conditions. To capture causal dependencies between pipeline segments, the DSS employs Bayesian networks, which model how thermal effects propagate along the structure. These probabilistic graphs help assess how local heating can influence adjacent segments and overall system behavior. In experimental validation using M2PLink simulation software, the DSS demonstrated high predictive accuracy. The comparison between predicted and simulated temperature distributions showed strong alignment, confirming the system's ability to replicate real thermal dynamics and respond effectively to operational changes. It is substantiated that the system provides the ability to scale to complex network pipeline structures, including branched trunks and multi-component nodes. The extended integration of the digital twin with real sensor data allows to detect potential deviations and predict the development of faults long before their actual manifestation. It is established that the improved forecasting process contributes to adaptive control of thermal regimes, which reduces operating costs and increases the overall reliability of the pipeline infrastructure. It is proven that the use of a combined approach, which combines methods of artificial intelligence, mathematical modeling and fuzzy logic, increases the system's resistance to noise, incomplete data and nonlinear behavior of physical processes. An additional pilot experimental evaluation was also conducted using an independent SCADA dataset for monitoring oil and gas pipeline systems, covering 12 months of continuous measurements sampled at a frequency of 1 Hz. Temperature forecasting was implemented using a feedforward neural network focused on short-term incremental temperature changes, combined with control based on the Proximal Policy Optimization algorithm. The obtained results confirmed high forecasting accuracy and effective adaptive control: the average duration of the complete decision-making cycle did not exceed 18.5 ms, while the cumulative discounted reward increased by 74% with a simultaneous reduction of its variance by more than 60%.

Key words: digital twin, fuzzy logic, reinforcement learning, Bayesian network, defuzzification, Markov decision process.

Вступ. У сучасних умовах розвитку промислової інфраструктури надійність й ефективність трубопровідних систем стають критично важливими чинниками для забезпечення стабільного розподілу енергії та ресурсів. Зі зростанням складності експлуатаційних процесів і мінливістю зовнішніх умов традиційні методи керування втрачають свою ефективність. З огляду на це, інтеграція інтелектуальних технологій, а саме цифрових двійників та методів машинного навчання, є перспективним напрямом. Це дослідження присвячене розробці системи підтримки ухвалення рішень (DSS) для прогнозного теплового керування трубопроводами, яка базується на цифровому відображенні об'єкта для моделювання, моніторингу та оптимізації теплових процесів.

У дослідженні Ю. Ван, С. Лін та ін. [1] представлено інтелектуальну систему моніторингу стану тискових трубопроводів, що поєднує цифровий двійник, модель шумозаглушення та механізм ухвалення рішень на основі глибокого навчання. Звернено увагу на проблему виявлення аномальних звуків у складних промислових умовах, де традиційні акустичні сенсори виявляються малоефективними через вплив фонових шумів від вентиляторів, клапанів та іншого обладнання. Запропонована система базується на створенні фізично обґрунтованого цифрового двійника трубопроводу, що дає змогу здійснювати моніторинг стану в реальному часі. У центрі системи міститься вдосконалена модель шумозаглушення, яка поєднує зашумлювач-автокодувальник (denoising autoencoder – DAE) і генеративну змагальну

мережу (generative adversarial network – GAN). GAN використовується для покращення якості реконструкції звуку, тоді як DAE забезпечує стійкість до зашумлених або частково пошкоджених сигналів. Для ухвалення рішень щодо виявлення аномального звуку застосовується LSTM-мережа, яка здатна враховувати тимчасовий контекст сигналу й на основі очищених акустичних даних ідентифікувати відхилення в роботі трубопроводу. У статті також описано експериментальну платформу, побудовану для моделювання тискових умов та збору як зашумлених, так і чистих сигналів у трьох діапазонах тиску (5, 10, 15 PSI). Проведені дослідження демонструють, що запропонована система дає змогу підвищити якість сигналів на понад 3 дБ і досягти точності моніторингу стану трубопроводу на рівні понад 91 %, що наближається до показників для чистих, безшумних даних. Крім того, проведено порівняльний аналіз із класичними методами (WPD, DAE, CGAN), що підтвердив перевагу запропонованого підходу як у точності діагностики, так і в стабільності роботи в умовах різних шумових рівнів. У висновках наголошено на потенціалі подальшого розвитку системи через симуляцію додаткових аномальних станів, оптимізацію архітектури для промислових умов і можливу інтеграцію з геопросторовими даними.

Можливість підвищення ефективності управління цілісністю трубопровідних систем шляхом упровадження індивідуального підходу до кількісної оцінки ризиків (quantitative pipeline risk assessment model – QPRAM) в умовах Казахстану розглянуто такими дослідниками, як Д. Аділова та

А. Мірзоев [2]. На відміну від традиційної моделі управління технічним станом, запропонована методологія базується на детальному аналізі ймовірностей відмов (probability of failure – PoF) і потенційних наслідків (consequences of failure – CoF), які розраховуються на кожному метрі трубопроводу. У дослідженні застосовано інструментарій QPRAM і платформу NIMA для обробки промислових даних, що дало змогу створити просторово диференційовану карту ризиків для нафтопроводу Х довжиною 225 км. Завдяки динамічній сегментації та аналізу загроз, як-от зовнішня корозія та втручання третіх сторін, вдалося визначити найбільш вразливі ділянки інфраструктури, де ризик відмови був найвищим. Особливу увагу приділено економічним і соціальним наслідкам можливих аварій, що дало змогу комплексно оцінити ступінь небезпеки для кожного сегмента. Отримані результати свідчать про ефективність впровадження моделі QPRAM у практику інженерного управління.

С. Аль-Джаміль з колегами [3] розглянули використання методів машинного навчання для автоматизованого виявлення витоків у трубопроводах, зосереджуючись на параметрах, що пов'язані з внутрішньою корозією. Аналіз базувався на відкритому наборі даних, який містив 10 293 записи з 8 числовими характеристиками, включно з температурою і тиском на гирлі свердловини, дебітами газу й нафти, вмістом води, молекулярною масою CO₂ та газовою густиною. Цільова змінна – ступінь корозії (corrosion rate – CR) – була перетворена з неперервної в бінарну класифікацію: значення понад 0,211 позначалися як «висока корозія», інші – як «низька». Після нормалізації даних (масштабування min-max) та поділу на навчальну й тестову вибірки в пропорції 70:30, для забезпечення надійності застосовувалася 10-кратна кросвалідація. Було випробувано п'ять моделей: Support Vector Machine (SVM), Decision Tree (DT), Random Forest (RF), K-Nearest Neighbour (KNN) і Gradient Boosting (GB), які оцінювалися за метриками точності, повноти, влучності, F1-оцінки та площі під ROC-кривою (AUC). Первинний аналіз показав, що SVM до оптимізації забезпечила найвищу точність – 96,1 %, за нею йшла RF із результатом 91,56 %. Після налаштування гіперпараметрів за допомогою GridSearchCV ефективність SVM зросла до 97,43 %, причому найкращі результати були досягнуті з RBF-ядром ($C = 1000$, $\gamma = 0.1$). Також покращилися результати інших моделей, зокрема Gradient Boosting – з 87,39 % до 90,25 %. Модель DT, натомість, продемонструвала найнижчі показники точності

і після оптимізації – 84,97 %. Результати аналізу матриці сплутаності підтвердили зменшення помилок класифікації для моделі SVM: кількість помилково класифікованих випадків «високої корозії» скоротилася зі 178 до 119, а «низької» – з 224 до 145. Оптимізована модель також показала високий рівень розмежування між класами, про що свідчить AUC = 0.97 на ROC-кривій.

Беручи до уваги всі наукові розробки, дотичні до досліджуваної наукової проблематики, необхідно зазначити, що питання, пов'язане з розробкою системи підтримки ухвалення рішень для контролю процесами трубопровідних систем, усе ще залишається недостатньо дослідженим та потребує подальшого опрацювання.

Методи та методики дослідження. Метою роботи є розробка системи підтримки ухвалення рішень для прогнозного теплового керування трубопровідними системами, що поєднує цифрового двійника, методи нечіткої логіки, навчання з підкріпленням і ймовірнісні графові моделі.

Методичну основу дослідження становить комплексний підхід, що поєднує математичне моделювання теплопереносу, методи штучного інтелекту, нечітку логіку, алгоритми навчання з підкріпленням та ймовірнісні графові моделі. Для формування системи підтримки ухвалення рішень (DSS) застосовано низку взаємопов'язаних методичних процедур, спрямованих на створення, навчання та експериментальну перевірку цифрового двійника трубопровідної системи та інтегрованих алгоритмів керування її тепловим режимом.

Першим етапом стала побудова цифрового двійника, який відтворює геометричні, фізико-технічні та експлуатаційні характеристики трубопроводу. Для цього застосовано методи параметричного моделювання та розв'язання рівнянь теплопереносу в умовах нестационарних процесів. Цифровий двійник забезпечує симуляцію температурних полів, моделювання втрат тепла, теплових перехідних процесів, виявлення аномалій та прогнозування розвитку несправностей. Отримана модель є базовим інструментом для навчання алгоритмів прогнозування та ухвалення рішень.

Для оцінювання майбутнього стану системи використано методи прогнозного моделювання, включно з емпіричними моделями теплопереносу та нейромережевими предикторами. Прогнозування температурного поля реалізовано через обчислення матриці змін температур ΔM на інтервалі $t + \Delta t$ відповідно до залежності $M = M_t + \Delta M$, що дає змогу

моделі адаптивно враховувати теплові градієнти, властивості середовища та зовнішні впливи. Навчання прогнозної моделі здійснювалося на основі мінімізації функції втрат $L(M, M)$, що вимірює відхилення прогнозованих значень від фактичних. Для оптимізації параметрів застосовано градієнтний спуск та його сучасні модифікації (зокрема, метод Adam), що забезпечують швидку збіжність та високу точність передбачення. Навчання проводилося в режимі офлайн на основі симуляційних даних та вимірних профілів температур, а подальше донавчання – у режимі онлайн для врахування деградації матеріалів, сезонної варіативності та інших змін.

Важливим елементом методичного підходу стала нечітка логіка, яка дає змогу враховувати невизначеність і неповноту даних сенсорної мережі. У дослідженні визначено лінгвістичні змінні «перегрів», «низький градієнт» та «нестабільність», для яких розроблено функції належності $\mu(x)$, що задають ступінь належності конкретних температурних значень до відповідних нечітких множин. Етапи фазифікації, застосування правил типу IF-THEN та дефазифікації реалізовані відповідно до стандартної структури нечіткого виводу Мамдані. Для отримання чіткого керувального сигналу застосовано метод центру ваги, що забезпечує безперервність та стабільність керування.

Подальша оптимізація керувальних дій забезпечувалася за допомогою алгоритмів навчання з підкріпленням (Reinforcement Learning, RL). Завдання формалізовано у вигляді марковського процесу ухвалення рішень, у якому станом є вектор температурних значень уздовж трубопроводу, діями – зміни в режимах нагріву або охолодження, а нагородою – функціонал, що враховує відхилення температур від нормативних меж, енерговитрати та ризик виникнення аварійних режимів. Використано функцію цінності стану $V(s)$, що дає змогу агенту оцінювати довгострокові наслідки дій та формувати оптимальну стратегію керування, адаптовану до динамічних умов роботи трубопроводу. Навчання RL-модуля проводилося в імітаційному середовищі цифрового двійника, що забезпечило безпечне відпрацювання стратегій без ризику втручання в реальний об'єкт.

Для моделювання причинно-наслідкових зв'язків та передавання теплових впливів між сегментами трубопроводу застосовано Байєсівські мережі. Цей метод дав змогу описати залежності між суміжними сегментами та оцінювати ймовірність настання критичних теплових станів, з огляду на умовні й спільні розподіли.

Байєсівські мережі виконували функцію додаткового діагностичного шару DSS, що сприяло виявленню невідповідностей, прихованих аномалій та потенційно небезпечних тенденцій у розподілі температур.

Експериментальна перевірка системи містила імітаційні дослідження, порівняння прогнозованих та реальних температурних профілів, оцінювання точності моделей і стабільності ухвалених рішень.

Результати. Розробка системи підтримки ухвалення рішень (decision support system – DSS) для прогнозного теплового керування трубопроводами передбачає створення стандартизованого цифрового відображення об'єкта. У ньому структурні та експлуатаційні властивості трубопровідної системи, включно з геометрією, матеріалами, умовами середовища й розташуванням датчиків, описують у вигляді єдиної схеми, здатної інтерпретуватися алгоритмами аналізу й моделювання. Це дає змогу формувати цілісну віртуальну модель трубопроводу з можливістю підключення математичних моделей теплопередачі, виявлення аномалій, аналізу теплових режимів і слабких ділянок, моделювання теплових втрат, затримок та їх наслідків у вигляді нестационарних температурних профілів. На основі них система, використовуючи поєднання лінгвістичних правил нечіткої логіки та стратегій навчання з підкріпленням, здатна в реальному часі виробляти обґрунтовані керувальні дії, запобігати ризикам й оптимізувати роботу трубопроводу в умовах змін навколишнього середовища та внутрішніх параметрів.

Для керування тепловим режимом трубопроводу DSS містить компонент прогнозування майбутнього стану системи. Прогнозна модель оцінює, як зміниться температурний розподіл уздовж трубопроводу в найближчому майбутньому, з огляду на поточний стан і динаміку процесів. Так, прогноз наступного стану подається як:

$$P(M_t) = M_t + \Delta M \quad (1)$$

де M_t – матриця поточних температур, а ΔM – матриця змін температур за прогнозований інтервал часу. Поточне поле температур коригується на основі прогнозованої дестабілізації, що розраховується на основі тенденцій та фізичних закономірностей теплопереносу. В описаній системі $\mathcal{M}$ може обчислюватися через емпіричну модель або нейромережевий предиктор, який урахує поточні градієнти температур, витрати середовища, теплообмін із довкіллям тощо. Упровадження сурогатних моделей (спрощених моделей, які

апроксимують поведінку складних об'єктів) дає змогу здійснювати швидке передбачення й оперативне ухвалення рішень у системах керування кліматом.

Прогнозна модель будується на даних про попередню поведінку системи, включно з реакціями трубопроводу на зміни навантаження чи зовнішніх умов. Припускається, що M_t описує теплову карту системи в часі t . Тоді модель прогнозує стан у час $t + \Delta t = f(M_t, u_t)$, де u_t – можливі керувальні дії або дестабілізація. У спрощеному вигляді це представлено формулою прогнозу наступного стану, тобто майбутні зміни додаються до поточного стану.

Для налаштування моделі використовується процедура мінімізації різниці між прогнозованими та реальними значеннями, що, як правило, проводиться шляхом градієнтного спуску. У процесі навчання моделі визначається функція втрат $L(M, \hat{M})$ – міра невідповідності між фактичним станом M (який спостерігається згодом) та прогнозованим $\hat{M}$. Найпоширенішим вибором є квадратична функція втрат, яка акцентується на великих похибках. Згідно з нею похибка обчислюється як

$$L(M, \hat{M}) = \sum_{i,j} (m_{i,j} - \hat{m}_{i,j})^2 \quad (2)$$

тобто сумуються квадрати різниць для всіх точок просторової сітки (індекси i, j). Мета навчання полягає в тому, щоб знайти такі параметри моделі, за яких L мінімізується на навчальних даних. Градієнтний спуск забезпечує ітеративне покращення прогнозу: обчислюється градієнт $\frac{\partial L}{\partial M}$ – напрямок найшвидшого зростання помилки, а модель оновлюється в протилежному напрямку на малий крок α :

$$\Delta \hat{M} = -\alpha \frac{\partial L(M, \hat{M})}{\partial \hat{M}} \quad (3)$$

якщо модель недооцінює температуру в певній точці (отримано $\hat{m}_{i,j} < m_{i,j}$), градієнт буде негативним, і коригування додасть позитивну величину, наближаючи прогноз до реального значення. У сучасних реалізаціях використовують ефективні варіанти градієнтного спуску, як-от метод Адама, що динамічно масштабує кроки навчання для різних параметрів [4]. У підсистемі прогнозування трубопроводу градієнтний спуск використовується на етапі офлайн-навчання моделей. Модель навчається доти, поки її прогнози не узгоджуються з експериментальними даними з необхідною точністю. Після навчання налаштована модель вбудовується в DSS для оперативного використання. У процесі експлуатації

можливе її донавчання (on-line learning), якщо накопичуються нові дані – це допомагає врахувати поступові зміни в системі (старіння ізоляції, сезонні коливання тощо).

Нечітка логіка (fuzzy logic) дає змогу враховувати невизначеність і нечіткість в умовах ухвалення рішень, оперуючи лінгвістичними змінними – поняттями, близькими до людського опису станів системи [5]. У контексті теплового керування трубопроводами введено три ключові лінгвістичні змінні: «перегрів», «низький градієнт» та «нестабільність». Вони відображають експертні уявлення про стан системи.

Для кожної лінгвістичної змінної визначаються функції належності $u(x)$, які відображають ступінь належності чіткого значення x до нечіткого поняття. Наприклад, для змінної «перегрів» функція належності може бути задана як кусково-лінійна функція (piecewise linear function):

$$\mu_{\text{перегрів}}(x) = \begin{cases} 0, & x \leq T_{\text{норм}} \\ \frac{x - T_{\text{норм}}}{T_{\text{крит}} - T_{\text{норм}}}, & T_{\text{норм}} < x < T_{\text{крит}} \\ 1, & x \geq T_{\text{крит}} \end{cases} \quad (4)$$

Така функція належності є монотонно зростаючою. Простіше кажучи, за температури нижче $T_{\text{норм}}$ ступінь перегріву $u_{\text{перегрів}}$ дорівнює нулю, за перевищення $T_{\text{крит}} - u_{\text{перегрів}} = 1$ (максимальний перегрів), а в інтервалі між ними – лінійно зростає від 0 до 1. Це відображає експертне правило про плавний перехід від нормального режиму до небезпечного перегріву.

Аналогічно визначають функції належності для змінних «низький градієнт» та «нестабільність». Для градієнта може бути задана нечітка множина «низький» так, що за малої різниці температур між сегментами $u_{\text{градієнт}}$ наближається до 1, а за великої різниці – до 0. Змінна «нестабільність» може мати функцію належності, що оцінює варіації температури: стабільний режим (малі коливання) відповідає низькому значенню $u_{\text{нестабільність}}$, а хаотичні температурні флуктуації – значенню, близькому до 1. Важливо, що врахування не лише самого значення параметра, а і його тренду може підвищити точність нечіткого висновку [6].

Після фазифікації вхідних даних (перетворення чітких значень сенсорів на ступені належності до нечітких термів) система застосовує нечіткі правила типу IF-THEN (якщо – то) для ухвалення рішень. Нечітке правило формально записується за допомогою логічних зв'язок між лінгвістичними змінними. Наприклад, експертне правило для системи теплового керування

може бути сформульоване так: ЯКЩО «перегрів» є високим і «градієнт» низьким, ТОДІ знизити потужність нагріву.

Результатом застосування нечітких правил є набір вихідних нечітких змінних, які потім мають бути перетворені в конкретні числові значення для виконання системою. Цей етап називається дефазифікацією. Найпоширенішим є метод центру ваги (Center of Gravity), коли обчислюється центр мас об'єднаної вихідної нечіткої множини. Формула центроїдної дефазифікації:

$$z^* = \frac{\int_Z \mu_{\text{вих}}(z) \cdot z dz}{\int_Z \mu_{\text{вих}}(z) dz} \quad (5)$$

де $\mu_{\text{вих}}(z)$ – об'єднана функція належності вихідної змінної (наприклад, ступінь «рекомендованого зниження потужності» для різних можливих рівнів зниження), а інтегрування виконується по всій області Z значень вихідної змінної. Отримане значення z^* позначає чіткий результат, який система підтримки ухвалення рішень видає як рекомендацію або керувальну дію.

Далі в поточному дослідженні передбачена інтеграція модуля навчання з підкріпленням (Reinforcement Learning, RL), який відповідає за автоматичне набуття оптимальної стратегії керування шляхом проб і помилок у взаємодії з моделлю трубопровідної системи, по суті, вдосконалюючи процес ухвалення рішень на базі нечіткої логіки. В основі RL лежить формулювання завдання ухвалити рішення у вигляді марковського процесу ухвалення рішень (Markov Decision Process, MDP). В MDP середовище описується множиною станів s , агент може виконувати певні дії a , переходячи між станами, і за кожен крок отримує числову нагороду r , що є показником «корисності» дії в такому стані. Мета агента полягає в максимізації очікуваної сумарної нагороди. Формально критерій оптимальності задається через функцію цінності стану $V(s)$ як очікування дисконтованої суми винагород:

$$V(s) = E \left[\sum_{t=0}^T \gamma^t r(s_t, a_t) \mid s_0 = s \right] \quad (6)$$

де $0 < \gamma \leq 1$ – коефіцієнт дисконту (відображає зменшення ваги майбутніх винагород), а T – горизонт планування. Ця функція $V(s)$ оцінює довгострокову корисність перебування в стані s і дотримання певної стратегії дій.

Компонент навчання з підкріпленням у складі DSS реалізовано з використанням алгоритму Proximal Policy Optimization (PPO), який обрано завдяки його стабільності під час навчання в завданнях безперервного керування.

У завданні теплового керування трубопроводом стан s визначається як розподіл температур по сегментах трубопроводу в цей момент часу [7]. Вектор стану може мати вигляд:

$$s = [T_1, T_2, \dots, T_n] \quad (7)$$

де T_i – виміряна або оцінена температура сегмента i . Так, стан містить інформацію про тепловий профіль уздовж усього трубопроводу.

Динаміка переходів між станами при виконанні дій описується ймовірностями $P(s_{t+1} \mid s_t, a_t)$, заданими або моделлю системи, або емпірично (через імітаційну модель трубопроводу).

Щоб спрямувати навчання агента на досягнення бажаних цілей, необхідно визначити функцію нагороди $r(s, a)$. У завданні дослідження до критеріїв якості керування належать:

- підтримання температури в межах допустимих діапазонів, уникнення різких коливань і локального перегріву;
- мінімізація витрат енергії на нагрів / охолодження;
- запобігання аварійним ситуаціям (тепловим ударами, розривам труб через перегрів або переохолодження).

Комбінуючи ці складники, нагорода може бути задана у вигляді:

$$r(s_t, a_t) = -\alpha \cdot \Delta T_{\text{вих}}(s_t) - \beta \cdot E(a_t) - \gamma' \cdot I_{\text{аварія}}(s_t) \quad (8)$$

де $\Delta T_{\text{вих}}$ – відхилення температур від цільових значень, $E(a_t)$ – споживана енергія, $I_{\text{аварія}}$ – індикатор аварійного стану (0 – у нормі, 1 – якщо стався перегрів вище критичного або інша аварія), а α, β, γ' – вагові коефіцієнти.

Для моделювання причинно-наслідкових зв'язків та невизначеностей у системі використовується ймовірнісна графова модель, а саме Байєсівська мережа, яка становить собою орієнтований ациклічний граф, вузли якого відповідають випадковим величинам (подіям), а дуги відображають умовні залежності між ними. У контексті трубопровідної системи вузлами можуть бути стани сегментів, а дугами – вплив одного сегмента на інші [8].

Крім того, що Байєсівська мережа визначається структурою графа, вона визначається також набором умовних ймовірностей для кожного вузла. Якщо позначити через m_i подію (стан) для сегмента i , то спільний ймовірнісний розподіл станів усіх сегментів $P(m_1, m_2, m_n)$ розкладається згідно зі структурою мережі на добуток умовних ймовірностей вузлів. У загальному випадку: n

$$P(m_1, m_2, m_n) = P(m_1) \prod_{i=2}^n P(m_i \mid \text{батьк.вузли}(m_i)) \quad (9)$$

У найпростішому випадку, якщо структура мережі утворює ланцюжок залежностей між послідовними сегментами (кожен сегмент залежить від попередніх), є можливість апроксимації: $P(M) = \prod_{i=1}^n P(m_i | m_1, m_2, \dots, m_{i-1})$. На практиці ж часто використовується спрощена структура – наприклад, марковський ланцюг, де m_i залежить лише від m_{i-1} (сусіднього попереднього сегмента), що зменшує кількість параметрів.

У завданні цього дослідження Байєсівська мережа має відображати поширення теплових впливів вздовж трубопроводу. Наприклад, якщо один сегмент сильно нагрівається, це може вплинути на сусідні. Байєсівська мережа дає змогу так відстежувати причинні ланцюжки: від перегрітої ділянки через сусідні сегменти – далі вздовж системи [9].

Для перевірки ефективності DSS-моделі проведено експеримент зі штучною симуляцією теплових процесів трубопроводу. Фактичні значення температур уздовж трубопроводу отримані за допомогою фізико-математичного моделювання в середовищі M2PLink – платформі, аналогічній Simulink, що дає змогу будувати блок-схемні моделі й виконувати їх реалістичну симуляцію в реальному часі. Мета експерименту – зіставити прогнозовані DSS температури з «еталонними» температурними даними симулятора та оцінити, наскільки точно модель DSS здатна відтворювати розподіл температур

уздовж трубопроводу в динамічному режимі, як показано на рисунку 1.

Результати показано у вигляді діаграми розсіювання: кожна точка відповідає парі «прогнозована моделлю DSS температура – фактична температура із симуляції» для певних точок трубопроводу. Більшість точок скупчено поблизу діагоналі (лінії ідеальної відповідності), що свідчить про високу точність моделі. Коефіцієнт детермінації досяг $R^2 = 0,9549$, тобто модель DSS пояснює ~95,5 % варіації температури. Інакше кажучи, між прогнозованими та реальними значеннями спостерігається дуже тісний статистичний зв'язок. Такий високий показник кореляції підтверджує, що запропонована DSS-модель майже повністю відтворює температурний розподіл, отриманий із симулятора, і демонструє високу точність прогнозування.

Утім, об'єктивна валідація моделі не може обмежуватися виконанням виключно в межах одного симуляційного середовища. Отже, була проведена додаткова пілотна експериментальна оцінка з використанням незалежного набору даних моніторингу трубопроводу SCADA, отриманого з публічно доступного репозиторію, що містить дані вимірювань датчиків під час роботи трубопроводів нафтогазової галузі [10]. Набір даних охоплює дванадцять місяців безперервних вимірювань, згенерованих у межах симульованого цифрового двійника




Рис. 1. Порівняння прогнозованих DSS і симульованих фактичних температур

SCADA, та містить синхронізовані дані температури, тиску, витрати потоку, енергоспоживання, станів клапанів і робочих параметрів насосів, з частотою семплювання 1 Гц.

Модуль прогнозування температури реалізовано на основі наскрізної нейронної мережі (feedforward neural network – FFNN), призначеної для апроксимації короткострокової динаміки температур уздовж сегментів трубопроводу. Модель зосереджена на прогнозуванні інкрементальних змін температури за малий часовий інтервал.

Нейронна мережа містить три повнозв'язані приховані шари з кількістю нейронів 128, 64 та 64 відповідно. У всіх прихованих шарах використовують функції активації типу Rectified Linear Unit (ReLU – зрізаний лінійний вузол), тоді як вихідний шар застосовує лінійну функцію активації для формування прогнозованих інкрементів температури для кожного сегмента трубопроводу.

Навчання моделі здійснюється з використанням функції втрат середньоквадратичної похибки, оптимізація якої виконується за допомогою алгоритму Adam з коефіцієнтом навчання 0,001. Для навчання застосовано розмір пакета 256 та горизонт навчання 100 епох. Коефіцієнт дисконту в алгоритмі навчання з підкріпленням встановлено на рівні $\gamma = 0,99$, а оновлення політики обмежуються параметром відсікання $\epsilon = 0,2$. Процес навчання проводиться протягом 5 000 епізодів у середовищі цифрового двійника. Оцінювання ефективності системи виконується за допомогою параметра cumulative discounted reward (накопиченої дисконтованої нагороди) як основної метрики, що відображає

довгостроковий баланс між тепловою стабільністю, енергоефективністю та дотриманням обмежень безпеки.

Усі експериментальні дослідження проводили на робочій станції, оснащений процесором класу Intel Core i7 з 8 логічними ядрами та базовою тактовою частотою 2,6 ГГц, а також 16 ГБ оперативної пам'яті, під керуванням операційної системи на базі Linux. Під час обчислень не використовували графічні прискорювачі або спеціалізовані апаратні засоби, а також не застосовували паралелізацію, окрім стандартної багатопотокової обробки.

Середній час формування передбачення для модуля прогнозування становив 8,3 мс на один часовий крок при стандартному відхиленні 1,1 мс, що свідчить про низьку варіативність обчислювальних витрат за різних режимів експлуатації та кількості сегментів трубопроводу. Підсистема нечіткого виводу потребувала додатково 3,2 мс на один часовий крок, що зумовлено насамперед обчисленням функцій належності та виконанням центроїдної дефазифікації. Оцінювання політики та вибір інструкції керування в межах модуля навчання з підкріпленням на основі алгоритму PPO вимагали 4,7 мс на часовий крок, включно з прямими проходками через мережі політики та функції цінності. У результаті повний цикл ухвалення рішень DSS стабільно залишався меншим за 18,5 мс на часовий крок, а максимальна зафіксована затримка не перевищувала 19,6 мс.

Результати, наведені на рисунку 2, демонструють тісну часову відповідність між значеннями температури, прогнозованими DSS, та температурами, зафіксованими системою




Рис. 2. Порівняння прогнозованих DSS та виміряних SCADA значень температури для репрезентативного сегмента трубопроводу




Рис. 3. Динаміка навчання модуля RL на основі алгоритму PPO протягом 5 000 епізодів

SCADA для репрезентативного сегмента трубопроводу.

Крім того, на рисунку 3 наведено динаміку навчання модуля RL на основі алгоритму PPO протягом 5 000 епох.

Середнє значення параметра cumulative reward зросло з $-4,2 \times 10^3$ на початкових етапах навчання до $-1,1 \times 10^3$ після досягнення збіжності, що відповідає відносному покращенню приблизно на 74 %. Водночас дисперсія нагороди зменшилася більш ніж на 60 %, що свідчить про стабілізацію сформованої стратегії керування та зниження її залежності від стохастичних нестабільностей.

Висновки. Запропоноване рішення дає змогу здійснювати точне прогнозування температурного профілю, адаптивне керування та ефективне виявлення теплових аномалій у режимі реального часу. Модель цифрового двійника забезпечує повноцінне відображення фізичних характеристик об'єкта, тоді як інтеграція нейромережових та логічних компонентів дає змогу підвищити адаптивність та точність

провідних дій. Проведене експериментальне моделювання доводить ефективність запропонованого підходу, а високий коефіцієнт детермінації свідчить про надійність і практичну придатність DSS-моделі для застосування в завданнях теплового моніторингу трубопроводів. Проведена пілотна валідація з використанням набору даних SCADA підтвердила узгодженість прогнозів моделі з температурною динамікою трубопроводу та продемонструвала її прогностичну здатність поза межами одного симуляційного середовища. Додатково встановлено, що система відповідає вимогам реального часу, оскільки повний цикл ухвалення рішень виконується з малою затримкою, а використання навчання з підкріпленням забезпечує стабільну збіжність стратегії керування та зниження енерговитрат. Отримані дані підтверджують надійність і практичну результативність DSS-моделі для застосування в завданнях прогнозного теплового моніторингу та керування трубопроводними системами.

ЛІТЕРАТУРА:

1. Wan Yu, Lin Shaochen, Jin Chuanling, Gao Yan, Yang Yang, Wang Kaixuan. Digital Twins and Condition Monitoring for Pressure Pipeline based on Intelligent Acoustic Sensor Framework. *Digital Technologies Research and Applications*. 2025. Vol. 4. P. 120–134. <https://doi.org/10.54963/dtra.v4i1.881>.
2. Adilova Diana, Mirzoev Abdugaffor. Optimizing pipeline integrity management through customized risk modeling: a case study in Kazakhstan. *Kazakhstan Journal for Oil & Gas Industry*. 2024. Vol. 6. P. 77–87. <https://doi.org/10.54859/kjogi108727>.
3. Aljameel S. S., Alomari D. M., Alismail S., Khawaher F., Alkhudhair A. A., Aljubran F., Alzannan R. M. An anomaly detection model for oil and gas pipelines using machine learning. *Computation*. 2022. Vol. 10, No 8. P. 138. <https://doi.org/10.3390/computation10080138>.
4. Shakhovska N., Mochurad L., Caro R., Argyroudou S. Innovative machine learning approaches for indoor air temperature forecasting in smart infrastructure. *Scientific Reports*. 2025. Vol. 15. Article No 47. <https://doi.org/10.1038/s41598-024-85026-3>.

5. Kontogiannis D., Bargiotas D., Daskalopulu A. Fuzzy control system for smart energy management in residential buildings based on environmental data. *Energies*. 2021. Vol. 14, No 3. P. 752. <https://doi.org/10.3390/en14030752>.
6. Fiderek P., Kucharski J., Wajman R. Fuzzy regulator for two-phase gas–liquid pipe flows control. *Applied Sciences*. 2022. Vol. 12, No 1. P. 399. <https://doi.org/10.3390/app12010399>.
7. Sierla S., Ihasalo H., Vyatkin V. A review of reinforcement learning applications to control of heating, ventilation and air conditioning systems. *Energies*. 2022. Vol. 15, No 10. P. 3526. <https://doi.org/10.3390/en15103526>.
8. Uyên Đào, Adumene Sidum, Sajid Zaman, Yazdi Mohammad, Islam T. M. A Bayesian network-based susceptibility assessment model for oil and gas pipelines suffering under-deposit corrosion. *The Canadian Journal of Chemical Engineering*. 2024. Vol. 103. P. 126–136. <https://doi.org/10.1002/cjce.25234>.
9. Ayello, F., Sridhar, N., Mosleh, A., & Jackson, C. (2018). *Demonstration of a multianalytic risk management tool for the California pipeline industry* (Final Project Report, CEC-500-2018-023). California Energy Commission. URL: <https://www.energy.ca.gov/sites/default/files/2021-06/CEC-500-2018-023.pdf>
10. Zara2099. SCADA Pipeline Operations Dataset. *Kaggle Datasets*. CC0: Public Domain. 2024. URL: <https://www.kaggle.com/datasets/zara2099/scada-pipeline-operations-dataset> (accessed: 22.12.2025).

REFERENCES:

1. Wan, Y., Lin, S., Jin, C., Gao, Y., Yang, Y., & Wang, K. (2025). Digital twins and condition monitoring for pressure pipeline based on intelligent acoustic sensor framework. *Digital Technologies Research and Applications*, 4, 120–134. <https://doi.org/10.54963/dtra.v4i1.881>
2. Adilova, D., & Mirzoev, A. (2024). Optimizing pipeline integrity management through customized risk modeling: A case study in Kazakhstan. *Kazakhstan Journal for Oil & Gas Industry*, 6, 77–87. <https://doi.org/10.54859/kjogi108727>
3. Aljameel, S. S., Alomari, D. M., Alismail, S., Khawaher, F., Alkhudhair, A. A., Aljubran, F., & Alzannan, R. M. (2022). An anomaly detection model for oil and gas pipelines using machine learning. *Computation*, 10(8), 138. <https://doi.org/10.3390/computation10080138>
4. Shakhovska, N., Mochurad, L., Caro, R., & Argyroudis, S. (2025). Innovative machine learning approaches for indoor air temperature forecasting in smart infrastructure. *Scientific Reports*, 15, Article 47. <https://doi.org/10.1038/s41598-024-85026-3>
5. Kontogiannis, D., Bargiotas, D., & Daskalopulu, A. (2021). Fuzzy control system for smart energy management in residential buildings based on environmental data. *Energies*, 14(3), 752. <https://doi.org/10.3390/en14030752>
6. Fiderek, P., Kucharski, J., & Wajman, R. (2022). Fuzzy regulator for two-phase gas–liquid pipe flows control. *Applied Sciences*, 12(1), 399. <https://doi.org/10.3390/app12010399>
7. Sierla, S., Ihasalo, H., & Vyatkin, V. (2022). A review of reinforcement learning applications to control of heating, ventilation and air conditioning systems. *Energies*, 15(10), 3526. <https://doi.org/10.3390/en15103526>
8. Uyên, Đ., Adumene, S., Sajid, Z., Yazdi, M., & Islam, T. M. (2024). A Bayesian network-based susceptibility assessment model for oil and gas pipelines suffering under-deposit corrosion. *The Canadian Journal of Chemical Engineering*, 103, 126–136. <https://doi.org/10.1002/cjce.25234>
9. Ayello, F., Sridhar, N., Mosleh, A., & Jackson, C. (2018). *Demonstration of a multianalytic risk management tool for the California pipeline industry* (Final Project Report, CEC-500-2018-023). California Energy Commission. Retrieved from <https://www.energy.ca.gov/sites/default/files/2021-06/CEC-500-2018-023.pdf>
10. Zara2099. SCADA Pipeline Operations Dataset. *Kaggle Datasets*. CC0: Public Domain. 2024. Retrieved from <https://www.kaggle.com/datasets/zara2099/scada-pipeline-operations-dataset> (accessed: 22.12.2025).



Стаття поширюється на умовах
ліцензії відкритого доступу
CC BY 4.0

Дата першого надходження статті до видання: 09.12.2025
Дата прийняття статті до друку після рецензування: 26.12.2025
Дата публікації (оприлюднення) статті: 16.03.2026