

УДК 004.896:004.78:621.643

DOI <https://doi.org/10.32782/3041-2080/2025-5-8>

ВИКОРИСТАННЯ ФЕДЕРАТИВНОГО НАВЧАННЯ З КООРДИНАТНИМИ МІТКАМИ ДЛЯ AR-МОДЕЛЮВАННЯ ТЕРМОДИНАМІЧНИХ ПРОЦЕСІВ У МЕЖАХ ПРОМИСЛОВИХ ТРУБОПРОВІДНИХ МЕРЕЖ

Полупан Володимир Володимирович,

кандидат технічних наук, доцент,

доцент кафедри автоматизації та комп'ютерних технологій систем управління

імені професора А. Ладанюка

Національного університету харчових технологій

ORCID ID: 0009-0007-8076-1369

Новаковський Павло Олександрович,

аспірант кафедри автоматизації та комп'ютерних технологій систем управління

імені професора А. Ладанюка

Національного університету харчових технологій

ORCID ID: 0009-0007-8418-7747

Робота присвячена створенню інтелектуальної системи предиктивного теплового контролю в промислових трубопроводах на основі федеративного навчання. Основна увага зосереджена на реалізації децентралізованої архітектури, в межах якої edge-пристрої (локальні обчислювальні модулі по типу NVIDIA Jetson Nano) самостійно навчають моделі без передавання сирих сенсорних даних до центрального сервера. Для обробки часових рядів сенсорної інформації, зокрема перепадів температур, швидкості потоку та концентрації речовин, використано Temporal Convolutional Networks (TCN), які забезпечують паралельне згорткове прогнозування без зворотного зв'язку. Для локального виявлення аномалій застосовано ансамблеву модель XGBoost, що дає змогу формувати чисельну оцінку відхилення термодинамічного профілю. Процес участі вузла у глобальному циклі федеративного навчання ініціюється на основі власної часової оцінки аномалій, яка визначає, наскільки поточна модель не відповідає локальним спостереженням. У разі перевищення порогу вузол формує оновлення моделі, шифрує його та передає до агрегатора. Постагрегаційне оновлення відбувається за допомогою змішування глобальної моделі з локальною через ваговий коефіцієнт, після чого проводиться коротка фаза локального донавчання. Просторова прив'язка реалізована через AR-мітки з унікальним 40-бітним ідентифікатором, закодованим у центрі 8×8 бінарної матриці. Для перевірки архітектури реалізовано цифровий двійник у Unity3D із симульованими термодинамічними процесами, з апроксимацією рівнянь Нав'є-Стокса. До кожного сегмента прив'язано edge-вузол, який в реальному часі обмінюється даними через gRPC. Ефективність алгоритмів просторового виявлення міток перевірено за умов симульованого розмиття та змін освітлення. AR-візуалізація була реалізована на основі теплової траєкторії, що дає змогу наочно відображати зони ризику та динамічні аномалії в межах трубопроводу. Подальші дослідження можуть бути спрямовані на масштабування системи для багаторівневих трубопровідних мереж, розширення кількості контрольованих параметрів та впровадження адаптивної оптимізації теплових режимів на основі мультиагентного узгодження.

Ключові слова: edge-пристрої, просторове позиціонування, цифровий двійник, децентралізоване керування, часова нейронна мережа, радіальне ядро спаду.

Polupan Volodymyr, Novakovskyi Pavlo. Using federated learning with fiducial markers for are modeling of thermodynamic processes within industrial pipeline networks

The described work focuses on the development of an intelligent predictive thermal control system for industrial pipelines based on federated learning. The main emphasis is placed on implementing a decentralized architecture in which edge devices (local computing modules such as NVIDIA Jetson Nano) independently train models without transmitting raw sensor data to a central server. To process time series of sensor information-including temperature differentials, flow rate, and solute concentration-Temporal Convolutional Networks (TCNs) are employed, enabling parallel convolutional forecasting without recurrence. For local anomaly detection, an ensemble XGBoost model is used, allowing the computation of a numerical deviation score for thermodynamic profiles. A node's participation in the global federated learning cycle is initiated based on its own temporal anomaly score, which determines the degree of deviation between the current model and local observations. If this score exceeds a threshold, the node generates a model update, encrypts it, and transmits it to the aggregator. Post-aggregation updates occur through weighted blending of the global model with the local one, followed by a brief phase of localized retraining. Spatial binding is achieved via AR markers containing a unique 40-bit identifier encoded in the center of an 8×8 binary matrix. To validate the architecture, a digital twin was implemented in Unity3D, simulating thermodynamic processes

using approximated Navier-Stokes equations. Each pipeline segment is linked to a corresponding edge node, which exchanges data in real time via gRPC. The efficiency of marker detection algorithms was tested under conditions of simulated blur and varying illumination. AR visualization was realized based on thermal trajectory mapping, enabling intuitive display of risk zones and dynamic anomalies within the pipeline. Future research may focus on scaling the system for multi-level pipeline networks, expanding the range of monitored parameters, and implementing adaptive optimization of thermal regimes through multi-agent coordination.

Key words: edge devices, spatial localization, digital twin, decentralized control, temporal neural network, radial decay kernel.

Вступ. Зростання складності і масштабності промислових трубопровідних мереж, особливо в секторі харчової промисловості та розподілу теплової енергії, створює суттєві виклики для підтримання стабільного й адаптивного теплового контролю. Традиційно регулювання температури в таких мережах здійснюється або за допомогою централізованих систем supervisory керування, або шляхом використання локальних edge-контролерів, налаштованих окремо для кожної ділянки. Проте централізовані підходи мають обмеження масштабованості та затримок, особливо за умов змінного навантаження або теплових дестабілізацій, тоді як децентралізовані edge-системи зазвичай позбавлені розуміння глобального контексту функціонування трубопроводу, що призводить до часткової оптимізації, надмірних запасів безпеки та нерівномірної енергоефективності в різних зонах.

Ще однією проблемою є відсутність послідовної системи просторової прив'язки в умовах великих або модульних трубопровідних схем. Під час використання мобільних роботизованих систем, ремонтних бригад або автоматизованих систем сканування для калібрування, інспекції та оновлення edge-модулів критичною є точна ідентифікація фізичних сегментів трубопроводу. За відсутності надійного механізму просторового зіставлення моделі керування можуть втрачати відповідність своїй фізичній зоні. Ця проблема особливо загострюється в динамічних виробничих середовищах, де трубопроводи можуть бути переміщені або реконфігуровані.

Аналіз попередніх досліджень та публікацій дає змогу констатувати фрагментованість та неоднорідність стану вивчення окресленої наукової проблематики. Зокрема, М. Лі, А. Шахбуддін, М. Зайнаб [1] описали розроблення мобільного застосунку доповненої реальності "AR Pipeline Visualiser" (ARPV) для візуалізації підземних водопровідних труб у кампусі Universiti Teknologi Malaysia (Технологічний університет Малайзії). Традиційна методика локалізації підземних комунікацій потребує дорогого обладнання, значного досвіду працівників і є повільною. ARPV вирішує ці проблеми, забезпечуючи

просту та наочну візуалізацію трубопроводів через камеру смартфона. Застосунок використовує Unity3D, Mapbox SDK і сенсори смартфона для визначення місця розташування та орієнтації пристрою, після чого накладає графічні моделі труб на реальну сцену. Просторові дані (GeoJSON) зберігаються на сервері Mapbox. Користувач може отримувати інформацію про атрибути труб (тип, рік встановлення, тиск, діаметр, потенціал прориву), переглядати їх у кольоровій класифікації та взаємодіяти з ними через інтерфейс. Польове тестування показало, що застосунок ефективно підвищує ситуаційну обізнаність і полегшує роботу на місці. Однак були виявлені недоліки, як-от затримки в роботі на малопотужному пристрої та низька точність позиціонування (похибка до 2 м замість бажаних 0,3 м). У висновках запропоновано майбутні покращення, а саме підтримка офлайн-режиму, покращення графічної візуалізації та оптимізація продуктивності.

Розробленням системи AR для підвищення продуктивності в умовах будівництва офшорних установок займалися С. Чой та Дж.-С. Парк [2]. Основна проблема, яку вирішують зазначені науковці, полягає у складності точного позиціонування та керування мітками в масштабних конструкціях, таких як плавучі заводи. Запропоновано методику точної реєстрації міток з використанням фотограмметрії та поєднання природних ознак з кутовими точками міток, що забезпечує стабільне суміщення сцени AR з координатною системою CAD. Розроблена система дає змогу працівникам самостійно орієнтуватися на об'єкті, виконувати інсталяційні та інспекційні роботи без креслень та виявляти помилки монтажу. Система використовує мобільну AR-платформу "Project Tango" з попередньо встановленими мітками, які автоматично реєструються у глобальній системі координат. Для усунення похибок позиціонування за великого обсягу руху реалізовано гібридну оптимізацію (Bundle Adjustment), яка поєднує дані з природних ознак та міток. Реалізовано функції прозорості, фільтрації дисциплін, обрізки огляду, швидкої прив'язки креслень до CAD, а також самонавігацію до місць монтажу. Проведені польові випробування довели

ефективність системи: час інспекції скорочено у 2–8 разів порівняно з традиційним підходом. Запропоноване рішення впроваджене на кількох міжнародних проєктах (Petronas FLNG2, BP Argos FPU, ENI Coral FLNG) і активно використовується понад 100 працівниками. У майбутньому планується адаптувати технологію для шоломів доповненої реальності (HoloLens) та інтегрувати з LiDAR для повноцінного 3D-сканування й точного вимірювання у реальному часі.

У межах дослідження Б.-К. Чен, П. Видейру, К. Гuedes Соареш [3] запропоновано комплексну реалізацію цифрового двійника для підводних трубопроводів, яка охоплює весь життєвий цикл об'єкта, від проєктування і будівництва до обслуговування, оцінки технічного стану та продовження строку служби. Запроваджено структуру цифрового двійника як інтеграцію фізичного об'єкта, віртуальної моделі та двосторонньої передачі даних. Вперше представлено метод автоматизованого створення цифрового двійника в процесі будівництва із застосуванням LiDAR, GPS / IMU, ГІС та комп'ютерного зору для фіксації геометрії трубопроводу та його зварних з'єднань. Обґрунтовано оновлення цифрової моделі на основі даних інспекцій за допомогою штучного інтелекту, зокрема CNN, для автоматизованого виявлення корозії та деформацій. Запроваджено підхід до предиктивного технічного обслуговування на базі даних з польових сенсорів, моделювання залишкового ресурсу (RFL – Remaining Functional Life) та застосування нейронних мереж (ANN, LSTM) для прогнозування технічного стану.

У дослідженні колективу науковців (К. Іное, С. Огаке, К. Кобаясі та ін.) [4] описано розроблення мобільного застосунку з AR, призначеного для візуалізації та реєстрації підземних водопровідних труб без потреби попереднього розкопування або встановлення міток. Система працює на смартфоні з використанням ARCore та GPS, автоматично виявляє площину поверхні та відображає 3D-моделі труб у реальному просторі. Це дає змогу будівельникам і технічним працівникам бачити наявні труби та додавати нові безпосередньо на місці монтажу. Застосунок має дві основні функції: реєстрацію нових труб з фіксацією координат і глибини, а також відображення поточного місцеперебування користувача на карті Google Maps. Для створення моделей труб використано Unity з пакетами Metamesh (для простих форм) і Probuilder (для складних, вигнутих труб). Отримані моделі можуть бути налаштовані, існує функція зміни кольору, матеріалу тощо. Крім того, система

підтримує імпорт цифрових даних із SHP-файлів (GIS), які перетворюються на CSV за допомогою Python та бібліотек GeoPandas і OpenCV. Реалізована також можливість оцифрування паперових карт, на яких вручну нанесено положення труб – з подальшим автоматичним розрахунком координат і генерацією цифрової моделі. Польові випробування показали ефективність системи як у приміщенні, так і на дворі. Однак точність роботи залежить від якості GPS-модуля смартфона та температурних умов.

Беручи до уваги охарактеризовані напрацювання з окресленої тематики, можемо констатувати, що питання, пов'язане з розробленням системи контролю за термодинамічними процесами промислових трубопровідних систем все ще залишається недостатньо вивченим та потребує подальшого опрацювання. Відповідно, метою статті є розроблення системи AR-моделювання термодинамічних процесів в межах промислових трубопровідних мереж з використанням федеративного навчання з координатними мітками та часовою нейронною мережею.

Методи та методики дослідження. Методологічна основа дослідження ґрунтується на поєднанні теоретичних та експериментальних підходів для розроблення і перевірки інтелектуальної системи предиктивного теплового контролю промислових трубопроводів на базі федеративного навчання з доповненою реальністю (AR).

У теоретичній частині дослідження визначено архітектурні принципи децентралізованого керування на основі федеративного навчання. Ключовою методикою є реалізація циклу глобального і локального оновлення моделей штучного інтелекту без передавання сирих сенсорних даних. Для локального аналізу часових рядів температури, швидкості потоку та концентрацій речовин використано Temporal Convolutional Networks (TCN), що забезпечують ефективне паралельне згорткове прогнозування термодинамічних профілів без зворотного поширення помилки у часі. Для підвищення точності детектування локальних аномалій застосовано ансамблеву модель XGBoost, що дає змогу формувати числову оцінку рівня відхилення поточного стану від очікуваного термодинамічного режиму.

Процедура федеративного навчання передбачає, що кожен edge-вузол (зокрема, NVIDIA Jetson Nano) самостійно навчає локальну модель на основі власних сенсорних даних. За виявлення значущих відхилень від нормативних параметрів вузол ініціює створення та

зашифровану передачу оновлення до центрального агрегатора. Змішування глобальної моделі з локальними відбувається з урахуванням вагового коефіцієнта, після чого проводиться коротка фаза локального донавчання для забезпечення адаптивності до специфічних умов сегмента трубопроводу.

Особлива увага в методиці приділена забезпеченню просторової ідентифікації окремих сегментів трубопровідної мережі. Для цього використано AR-мітки з унікальним 40-бітним ідентифікатором, закодованим у центрі бінарної матриці розміром 8×8 . Ці мітки дають змогу точно співвіднести кожен edge-вузол з фізичним сегментом мережі, що є критично важливим під час реконфігурації або переміщення трубопроводів. Для перевірки стійкості методів просторового позиціонування проведено симуляції в умовах штучного розмиття зображень міток і зміни освітлення.

Експериментальна частина реалізована шляхом створення цифрового двійника трубопровідної мережі у середовищі Unity3D з використанням наближених рівнянь Нав'є-Стокса для моделювання термодинамічних процесів. Кожен сегмент у цифровому двійнику оснащено edge-вузлом, що взаємодіє із сервером через протокол gRPC для обміну даними в режимі реального часу. AR-візуалізація термодинамічного стану реалізована через проєкцію теплової траєкторії на фізичний об'єкт, що дає змогу в режимі реального часу відображати зони потенційного ризику та аномалії на місцевості.

Для порівняння та валідації вибраної методики проведено аналіз на основі опрацьованих практик у сфері AR-візуалізації трубопровідних мереж, описаних у роботах М. Лі та ін. (AR Pipeline Visualiser) [1], С. Чоя і Дж.-С. Парка (точна реєстрація AR-міток у масштабних офшорних установках) [2] та Б.-К. Чена й колег (комплексний цифровий двійник підводних трубопроводів) [3]. Запозичено методи фотограмметрії, гібридної Bundle Adjustment-оптимізації та GIS-інтеграції для уточнення координатної прив'язки та підвищення стабільності AR-сцени.

Таким чином, загальна методика поєднує:

- розроблення децентралізованої системи збору та обробки сенсорних даних;
- використання TCN і XGBoost для локального моделювання й аномалійного моніторингу;
- процедуру федеративного оновлення моделей з шифруванням даних;
- впровадження AR-міток для просторової прив'язки;
- побудову та тестування цифрового двійника із симуляцією теплових процесів.

Результати. В контексті регуляції термодинамічних процесів трубопроводів промислового виробництва федеративне навчання представляється як ефективна парадигма, згідно з якою кордонні (edge) пристрої (локальні обчислювальні пристрої, розташовані безпосередньо поруч із сегментами) можуть спільно навчати моделі предиктивного теплового контролю без потреби переносу первинних сенсорних даних до центрального сервера. Федеративне навчання реалізується за допомогою використання певної кількості edge-моделей. Згідно з цим принципом кожна з цих моделей розгортається на відповідній окремій контрольній одиниці фізичної системи (в цьому випадку – сегменті трубопроводу) задля вивчення характеристик локальної термодинаміки, формуючи так званий вузол.

Таким чином, кожний вузол функціонує як повністю автономна обчислювальна одиниця, виконуючи завдання предиктивного аналізу та підтримки прийняття рішень в межах свого безпосереднього оточення в реальному часі. У центрі їхньої внутрішньої архітектури лежить часова нейронна мережа Temporal Convolutional Network (TCN), вибір якої обумовлений її здатністю моделювати залежності від часу послідовності без потреби у механізмах зворотного зв'язку. TCN здійснює оброблення безперервного потоку вхідних сенсорних даних, тобто перепади температур, швидкості потоку та концентрації розчинених речовин, задля формулювання коротко- та середньострокових тенденцій, притаманних характеристиці роботи системи. Її згортова структура дає змогу здійснювати паралельну обробку поширення стабільних градієнтів [5]. Проте припускається, що $x_{1:t} \in \mathbb{R}^{d \times t}$ означає послідовність вхідних ознак до певного часу t , де d відповідає розмірності простору вхідних даних. Мережа генерує передбачувану траєкторію $y^{t+1:t+H}$, використовуючи розширені причинні згортки, які визначаються так:

$$y_t^{(l)} = \sum_{k=0}^{K-1} W_k^{(l)} \cdot y_{t-d-k}^{(l-1)} + b^{(l)}, \quad (1)$$

де $W_k^{(l)}$ позначає вагові коефіцієнти ядер згортки на рівні l ,

d є коефіцієнтом розширення, а K – розміром рецептивного поля.

Структура вузлів також передбачає спрощену реалізацію алгоритму XGBoost, яка передбачає архітектуру на базі дерева рішень, що дає змогу вузлу класифікувати поведінку на факт того, чи відхиляється вона від вивчених

нормальних патернів, таким чином формулюючи чисельну оцінку аномалій у межах мілісекунд. Враховуючи віконну матрицю функцій $X_t \in \mathbb{R}^{W \times d}$ та пов'язані з нею цільові вихідні дані y_t , які кодують бінарну або безперервну оцінку аномалій, ансамблева модель зменшує регуляризовану цільову функцію:

$$\mathcal{L}(\theta) = \sum_{i=1}^n \ell(\hat{y}^i, y^i) + \sum_{k=1}^K \Omega(f_k), \quad \Omega(f_k) = \gamma T_k + \frac{1}{2} \lambda \|\omega_k\|^2, \quad (2)$$

де f_k позначає регресійне дерево k ,

T_k є кількістю його листів, а ω_k є пов'язаними ваговими коефіцієнтами [6].

Функція втрат $\mathcal{L}$ може також бути спеціалізованою на виявленні точкових аномалій, зсувів у тенденціях або нестабільності теплового профілю – шляхом підлаштування її форми, для чого зазвичай застосовуються логістична функція втрат для класифікації, або квадратична помилка для регресії. Модель видає локальну оцінку $\sigma_t \in \mathbb{R}$, яка кількісно визначає ступінь відхилення на кожному часовому кроці.

В межах циклу федеративного навчання кожен вузол незалежно ініціює процес локального навчання, виходячи з потоків даних, зібраних у відповідному внутрішньому середовищі цього вузла. Ці графіки навчання мають певну періодичність, але можуть динамічно адаптуватися залежно від важливості вжиття певного заходу. Задля збереження приватності даних та забезпечення обчислювальної децентралізації навчання відбувається тільки на пристрої без зовнішнього направлення перенесення необроблених сенсорних даних або контекстних метаданих.

Рішення щодо участі в одному повному циклі (раунді) федеративної агрегації обумовлюється кількісною мірою аномалій, яка формулюється на базі власних помилок передбачення вузла. Цей показник, який визначається часовою оцінкою аномалій (temporal anomaly score) St , відображає накопичене розходження між спостережуваним та передбаченими моделлю тепловими градієнтами за часове вікно фіксованого розміру нещодавніх зразків W [7]. Припускається, що $\Delta T^{(x_{k,t})}$ відображає відповідний прогноз моделі. Тоді оцінка аномалій обчислюється таким чином:

$$S_t = W \sum_{k=1}^k \Delta T(x_{k,t}) - \Delta T^{(x_{k,t})}, \quad (3)$$

яка в результаті надає скалярне значення, що збільшується у відповідь на виявлення аномалій.

Коли S_t перевищує попередньо задане порогове значення τ , вузол флагує свої поточні параметри моделі як застарілі або недостатні та ініціює оновлення для зовнішньої синхронізації.

Оновлення моделі складається не з первинних градієнтів, а із закодованої дельти між поточними локальними параметрами моделі θ_t та їхньою попередньою синхронізованою версією θ_t^0 , яка виражається так:

$$\Delta \theta_t = \theta_t - \theta_t^0, \quad (4)$$

та перед передаванням зашифровується за допомогою гоморфної, або багатосторонньої, схеми шифрування.

Часова незалежність зберігається впродовж кожного циклу. Вузол не залежить від позиційної обізнаності, світової пози чи прив'язаної до мітки персоналізації під час генерації модельної дельти. Аномальна оцінка представляється лише як часовий конструкт, який вилучається з історичних даних.

Кожний сегмент трубопроводу у системі фізично позначається координатною міткою, яка кодує ідентифікаційні дані, необхідні для просторової прив'язки в межах локального контексту на edge-вузлі [8]. Ці мітки складаються з багат шарового композитного матеріалу, який включає прозоре полікарбонатне покриття для забезпечення стійкості до стирання, шар анодованого алюмінію для висококонтрастної візуалізації за умов нестабільного освітлення та сталюну основу для структурної стійкості.

Формат кодування даних складається з бінарної матриці 8×8 , структурованої за сітковим патерном, що дає змогу безперешкодне вилучення даних за умов викривлення форми або розташування елементів зображення. Зовнішня межа матриці слугує вирівнювальним елементом і бар'єром для заглушення шуму, тоді як решта матриці – область 6×6 , містить 40-бітний ідентифікатор. Процес декодування залежить від статистичного поділу інтенсивностей пікселів по цій області – фактично застосовується стратегія адаптивного порогоування (adaptive thresholding) [9]. Припускається, що μ_1 відображає середнє значення інтенсивності пікселя усіх областей, які підпадають під класифікацію заданого порогового значення, а μ_2 – нижче нього.

Показник рівномірності розподілу сегментів пікселів кількісно визначається за допомогою частки пікселя $\alpha \in [0,1]$, що відображає частину підпорогових (тобто темних) пікселів у основній сітці, тоді як частка світлих пікселів відповідає $\beta = 1 - \alpha$. Декодована сила ідентифікатора мітки у обчислюється так:

$$\gamma = \alpha \beta (\mu_1 - \mu_2)^2, \quad \text{де } \alpha + \beta = 1. \quad (5)$$

Це нелінійне формулювання підкреслює сильну бімодальну відмінність у відтінках сірого, пеналізуючи неоднозначні контрастні

межі. Високе значення означає добре визначену сегментацію та справне кодування мітки.

Після визначення координатної мітки камерою edge-вузла наступний крок полягає у виявленні відносної пози цієї мітки у локальній системі координат камери. Фундаментальне припущення полягає в тому, що фізичні простори та розташування 4 кутів мітки є попередньо відомими та фіксованими. Ці дійсні світові позиції позначаються як ${}_M P_i \in \mathbb{R}^3$, де кожний $i = 1, 2, 3, 4$, в результаті чого формується плоский чотирикутник, як показано на рис. 1.

Мета полягає в оцінці матриці жорсткого перетворення (rigid transformation matrix) $T_C \in SE(3)$, яка відображає кожну точку мітки ${}_M P_i$ у її локальній системі координат до її відповідної спостережуваної проєкції ${}_C P_i \in \mathbb{R}^2$, у зображенні, зафіксованому камерою. Це виражається таким чином:

$${}_C P_i = K \cdot \Pi \cdot T_C \cdot {}_M P_i, \quad T_C = [R \mid t], \quad (6)$$

де $R \in SO(3)$ відповідає матриці обертання, яка описує орієнтацію мітки відповідно до положення камери, а $t \in \mathbb{R}^3$ є вектором зсуву, який визначає походження мітки відповідно до об'єктиву камери. $K \in \mathbb{R}^{3 \times 3}$ позначає внутрішню матрицю камери, яка кодує фокусну відстань та зсув головної точки, тоді як Π є проєктивним оператором, який конвертує гомогенні тривимірні координати у двовимірний простір зображення:

$$\Pi \cdot \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} = \begin{bmatrix} x/z \\ y/z \\ 1 \end{bmatrix} \quad (7)$$

Задля обчислення T_C система розв'язує задачу перспективного узгодження n -точок (Perspective-n-Point (PnP) problem) [10], згідно з якою має бути знайдена найбільш придатна поза для цієї множини відомих тривимірних точок та їхніх виявлених двовимірних проєкцій, що, як правило, досягається за допомогою процесу ітеративного уточнення, в ході якого мінімізується помилка повторної проєкції:

$$T_C = \operatorname{argmin}_t \sum_{i=1}^4 \|K \cdot \Pi \cdot T_C \cdot {}_M P_i - p_i\|^2, \quad (8)$$

де $p_i \in \mathbb{R}^2$ відповідає фактичним спостережуваним двовимірним координатам зображень кутів мітки, тобто виявленим візуальним сенсором вузла.

Оптимізація здійснюється за посередництва алгоритму Левенберга-Марквардта, тобто на кожній ітерації обчислюється помилка проєкції між передбаченими і спостережуваними точками, формується якобіан цієї помилки відносно параметрів пози (обертання + зсув), оновлюються параметри пози на крок, який зменшує суму квадратів помилок. Усі ці кроки повторюються до збіжності [11].

В результаті описаного каскаду процесів, що знаходять інформацію про позу мітки відносно камери, уможлиблюється точне позиціонування AR візуалізаційних оверлеїв та контрольної підсистеми, прив'язаної до конкретної фізичної ділянки.

Задля того щоб забезпечити послідовну просторову узгодженість між розподіленими вузлами, вживають заходу просторової реєстрації,




Рис. 1. Взаємне розташування систем координат камери та мітки у процесі проєкції на фокальну площину [2]

який узгоджує локально спостережувані положення міток з уніфікованою світовою системою координат. Головна мета полягає у перетворенні тривимірної точки ${}_M P_i \in \mathbb{R}^3$, визначеної в описаній раніше локальній системі координат мітки j , у глобальну світову ${}_W P_i \in \mathbb{R}^3$, оскільки осі камери, стандартизовані згідно з умовністю OpenCV, не є узгодженими зі світовою системою координат, яка реалізується у AR-платформах за рахунок рендерингових рушіїв, як, наприклад OpenGL. Тож це перетворення здійснюється в межах 3 стадій:

$${}_W P_{ij} = {}_D T \cdot ({}_C T \cdot {}_C T_j)^T \cdot {}_M P_{ij}. \quad (9)$$

Неузгодженість систем координат компенсується за рахунок введення матриці осьового перетворення TCD, яка здійснює статичне обертання та переупорядкування осей:

$${}_D T = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (10)$$

відображаючи типові поворот та зміну осі [12]. Поза пристрою, у світових координатах $TDW \in SE(3)$ вилучається за допомогою технологій зовнішньої локалізації, наприклад візуально-інерційної одометрії.

В контексті загального перетворення ${}_D T \cdot ({}_C T \cdot {}_C T_j)^T$, транспонування складеної матриці перетворення забезпечує правильне обертання та зв'язування (ланцюгову композицію) перетворень, оскільки локальна поза ${}_C T_j$ спочатку визначається в напрямку від мітки до камери, але для правильного застосування до точок, заданих у координатах мітки, вона потребує інверсії.

Таким чином, після навчання локальних моделей в межах їхніх відповідних edge-вузлів вони є пов'язаними з окремим фізичним сегментом інфраструктури, визначаючись унікальним ідентифікатором близької AR-мітки. Цей зв'язок є формою персоналізації моделі на базі ідентифікатора мітки, згідно з якою навчена характеристика роботи моделі відображає характеристики оточення та робочих процесів, які є безпосередньо релевантними до того сегмента, де ця модель була навченою.

Цей механізм персоналізації реалізується шляхом модифікації цілі навчання моделі за допомогою введення терма просторової релевантності, який прилаштовує внесок кожного зразка локальних даних залежно від його близькості до частини фізичної інфраструктури, призначеної до відповідного вузла. Припускається,

що θ позначає набір навчуваних параметрів моделі, призначеної до вузла i . Таким чином, $\{(x_{ij}, y_{ij})\}_{j=1}^{M_i}$ відповідає набору локальних навчальних вибірок, забраних на цьому вузлі, де кожна з них відповідає вектору вимірювань та пов'язаний з ним цільовій величині для прогнозування. Персоналізована функція втрат визначається таким чином:

$$L_i(\theta) = \sum_{j=1}^{M_i} \omega_{ij} \cdot \ell(\theta, x_{ij}, y_{ij}), \quad (11)$$

де $\ell(\theta, x_{ij}, y_{ij})$ є втратаю індивідуальної навчальної вибірки, а скалярний ваговий коефіцієнт $\omega_{ij} \in [0,1]$ регулює цю втрату відповідно до просторової відстані від центру мітки.

Іншими словами, якщо $\vec{r}_{ij}$ позначає двовимірну або тривимірну позицію точки вимірювання, а $\vec{r}_i^*$ є центральною координатою мітки, пов'язаної з моделлю, тоді ваговий коефіцієнт визначається за посередництва радіального ядра спаду (radial decay kernel):

$$\omega_{ij} = \exp(-\lambda \cdot \|\vec{r}_{ij} - \vec{r}_i^*\|^2), \quad (12)$$

де λ контролює швидкість спаду. Отже, відбувається пріоритезація спостережень, фізично ближчих до мітки вузла, водночас вагові коефіцієнти периферійних або проміжних точок даних підлягають зменшенню.

Для перевірки описаної архітектури було розгорнуто симуляційне середовище, яке імітує структуру трубопроводу у вигляді цифрового двійника. Кожен сегмент оснащено локальним edge-пристроєм на базі модуля NVIDIA Jetson Nano, вибраного за поєднання апаратного прискорення тензорних обчислень на GPU та низького енергоспоживання. До кожного вузла підключено камеру Sony IMX219, яка забезпечує високу точність виявлення міток. Програмне забезпечення на пристроях реалізовано на основі мінімального дистрибутиву Ubuntu з використанням Docker-контейнерів, у яких розгорнуто стек федеративного навчання: TensorFlow Federated (TFF) для розподіленої координації моделей та OpenCV для обробки поз міток у реальному часі.

Цифровий двійник реалізовано на прикладі трубопроводу бродильного комплексу пивоварні у гібридному середовищі симуляції та візуалізації, побудованому на основі Unity3D, до якого інтегровано спеціальний модуль симуляції рідини. Цей модуль імітує динаміку температури та концентрації розчинених речовин, базуючись на апроксимаціях рівнянь Нав'є-Стокса та емпіричних таблицях розчинності. Кожен віртуальний сегмент у середовищі відповідає



Рис. 2. Трубопровідна система бродильного комплексу пивоварні (реальна фотографія та візуалізація цифрового двійника з AR-пристрою)

окремому реальному edge-вузлу і в реальному часі обмінюється з ним інформацією про тепловий стан, оцінку аномалії та вагові коефіцієнти моделі через gRPC-протокол у симульованій edge-мережі з контрольованими параметрами затримки та джитера. Фрагмент виробничої ділянки та відповідного цифрового двійника показано на рис. 2.

Мітку кожного сегмента змодельовано відповідно до фізичної структури – у вигляді 8×8 бінарної матриці, із застосуванням симульованого розмиття руху та варіацій освітлення, щоб перевірити ефективність алгоритмів виявлення. Після декодування поз мітки використовуються для просторового закріплення AR-елементів у віртуальному середовищі. Ці елементи відображають прогнозовану теплову траєкторію:

$$\hat{y}^{t+1:t+H} \quad (13)$$

з кольоровим кодуванням за значущістю аномалії от безпосередньо на відповідній ділянці трубопроводу.

Висновки. Використання Temporal Convolutional Networks дало змогу ефективно моделювати часові залежності змін температури, швидкості потоку та концентрації речовин. Вбудовані моделі XGBoost дали можливість забезпечити високоточне та швидке виявлення локальних термодинамічних аномалій у режимі реального часу. Участь вузлів у глобальному циклі оновлення моделей реалізується на основі метрики локальної нестабільності, що підвищує ефективність глобального навчання без втрати локальної чутливості.

Розроблений механізм просторової ідентифікації за допомогою AR-міток забезпечує фізичну прив'язку моделей до конкретних сегментів трубопроводу, що дає змогу підтримувати узгодженість між локальними даними, моделями та фізичними об'єктами навіть за умов зміни конфігурації або переміщення обладнання. Верифікація системи у цифровому середовищі з використанням Unity3D підтвердила її здатність до адаптивного реагування в умовах нестабільної термодинаміки.

ЛІТЕРАТУРА:

1. Li M.C., Shahabuddin A., Zainab M.Y. Development of Augmented Reality Pipeline Visualiser (ARPV) Application for Visualising Underground Water Pipeline. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2019. Vol. XLII-4/W16. P. 203–210. DOI: 10.5194/isprs-archives-XLII-4-W16-203-2019
2. Choi S., Park J.-S. Development of Augmented Reality System for Productivity Enhancement in Offshore Plant Construction. *Journal of Marine Science and Engineering*. 2021. Vol. 9. 209. DOI: 10.3390/jmse9020209

3. Chen B.-Q., Videiro P.M., Guedes Soares C. Opportunities and Challenges to Develop Digital Twins for Subsea Pipelines. *Journal of Marine Science and Engineering*. 2022. Vol. 10. 739. DOI: 10.3390/jmse10060739
4. Inoue K., Ogake S., Kobayashi K., Tomura T., Mitsui S., Satake T., Igo N. An A.R. Application for the Efficient Construction of Water Pipes Buried Underground. *Electronics*. 2023. Vol. 12. 2634. DOI: 10.3390/electronics12122634
5. Lea C., Vidal R., Reiter A., Hager G. Temporal Convolutional Networks: A Unified Approach to Action Segmentation. *Computer Vision – ECCV 2016 Workshops*. 2016. DOI: 10.1007/978-3-319-49409-8_7
6. Taiwo R., Zayed T., Adey B. A Novel Ensemble Learning Framework for Predicting the Causes of Water Pipe Failures. *Reliability Engineering & System Safety*. 2025. Vol. 264. 111320. DOI: 10.1016/j.res.2025.111320
7. Belay M., Rasheed A., Salvo Rossi P. Digital Twin-Based Federated Transfer Learning for Anomaly Detection in Industrial IoT. *IEEE International Conference on Industrial Electronics for Sustainable Energy Systems (CIES)*. 2025. DOI: 10.1109/CIES64955.2025.11007631
8. Ma C., Li X., Huang B., Li G., Li F. Personalized Client-Edge-Cloud Hierarchical Federated Learning in Mobile Edge Computing. *Journal of Cloud Computing*. 2024. Vol. 13. DOI: 10.1186/s13677-024-00721-w
9. Cole J., Macleod E., Mcleod K., Mackenzie A. Adaptive Thresholding in ML-Based Cloud Anomaly Detection Systems. *Research Gate: website*. URL: https://www.researchgate.net/publication/391449432_Adaptive_Thresholding_in_ML-Based_Cloud_Anomaly_Detection_Systems (дата звернення: 03.07.2025).
10. Chen H., Tian W., Wang P., Wang F., Xiong L., Li H. EPro-PnP: Generalized End-to-End Probabilistic Perspective-N-Points for Monocular Object Pose Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2024. DOI: 10.1109/TPAMI.2024.3354997
11. Xu Y., Lin K.-Y., Zhang G., Wang X., Li H. RNNPose: 6-DoF Object Pose Estimation Via Recurrent Correspondence Field Estimation and Pose Optimization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2024. DOI: 10.1109/TPAMI.2024.3360181
12. Sangenis E. Rafart, Shkel A. M. Fast-Alignment of AR Headset from Local to Geodetic Coordinate Frame for Navigation and Mixed Reality Applications. *IEEE Sensors Letters*. 2025. DOI: 10.1109/LSSENS.2025.3526597

REFERENCES:

1. Li, M. C., Shahabuddin, A., & Zainab, M. Y. (2019). Development of Augmented Reality Pipeline Visualiser (ARPV) Application for Visualising Underground Water Pipeline. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-4/W16, 203–210. <https://doi.org/10.5194/isprs-archives-XLII-4-W16-203-2019>
2. Choi, S., & Park, J.-S. (2021). Development of Augmented Reality System for Productivity Enhancement in Offshore Plant Construction. *Journal of Marine Science and Engineering*, 9, 209. <https://doi.org/10.3390/jmse9020209>
3. Chen, B.-Q., Videiro, P. M., & Guedes Soares, C. (2022). Opportunities and Challenges to Develop Digital Twins for Subsea Pipelines. *Journal of Marine Science and Engineering*, 10, 739. <https://doi.org/10.3390/jmse10060739>
4. Inoue, K., Ogake, S., Kobayashi, K., Tomura, T., Mitsui, S., Satake, T., & Igo, N. (2023). An A. R. Application for the Efficient Construction of Water Pipes Buried Underground. *Electronics*, 12, 2634. <https://doi.org/10.3390/electronics12122634>
5. Lea, C., Vidal, R., Reiter, A., & Hager, G. (2016). Temporal Convolutional Networks: A Unified Approach to Action Segmentation. *Computer Vision – ECCV 2016 Workshops*. https://doi.org/10.1007/978-3-319-49409-8_7 [In English].
6. Taiwo, R., Zayed, T., & Adey, B. (2025). A Novel Ensemble Learning Framework for Predicting the Causes of Water Pipe Failures. *Reliability Engineering & System Safety*, 264, 111320. <https://doi.org/10.1016/j.res.2025.111320>
7. Belay, M., Rasheed, A., & Salvo Rossi, P. (2025). Digital Twin-Based Federated Transfer Learning for Anomaly Detection in Industrial IoT. *IEEE International Conference on Industrial Electronics for Sustainable Energy Systems (CIES)*. <https://doi.org/10.1109/CIES64955.2025.11007631>
8. Ma, C., Li, X., Huang, B., Li, G., & Li, F. (2024). Personalized Client-Edge-Cloud Hierarchical Federated Learning in Mobile Edge Computing. *Journal of Cloud Computing*, 13. <https://doi.org/10.1186/s13677-024-00721-w>
9. Cole, J., Macleod, E., Mcleod, K., & Mackenzie, A. (2025). Adaptive Thresholding in ML-Based Cloud Anomaly Detection Systems. *Research Gate: website*. Retrieved from https://www.researchgate.net/publication/391449432_Adaptive_Thresholding_in_ML-Based_Cloud_Anomaly_Detection_Systems

10. Chen, H., Tian, W., Wang, P., Wang, F., Xiong, L., & Li, H. (2024). EPro-PnP: Generalized End-to-End Probabilistic Perspective-N-Points for Monocular Object Pose Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. <https://doi.org/10.1109/TPAMI.2024.3354997>
11. Xu, Y., Lin, K.-Y., Zhang, G., Wang, X., & Li, H. (2024). RNNPose: 6-DoF Object Pose Estimation Via Recurrent Correspondence Field Estimation and Pose Optimization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. <https://doi.org/10.1109/TPAMI.2024.3360181>
12. Sangenis E. Rafart, & Shkel, A.M. (2025). Fast-Alignment of AR Headset from Local to Geodetic Coordinate Frame for Navigation and Mixed Reality Applications. *IEEE Sensors Letters*. <https://doi.org/10.1109/LSENS.2025.3526597>

Стаття надійшла: 04.07.2025

Стаття прийнята: 28.07.2025

Опублікована: 10.11.2025

