

<https://doi.org/10.31891/2307-5732-2026-361-23>  
УДК 004.9:005.31:622.24(477)

ІВАНОТЧАК ОЛЕКСАНДР

Івано-Франківський національний технічний університет нафти і газу  
<https://orcid.org/0009-0001-5806-5726>  
e-mail: [oleksandr.ivanotchak-a12322@nung.edu.ua](mailto:oleksandr.ivanotchak-a12322@nung.edu.ua)

## НОВІТНІ КОНЦЕПТУАЛЬНІ ОСНОВИ РЕАЛІЗАЦІЇ МЕТОДОЛОГІЇ ТА СТРАТЕГІЇ ІНТЕЛЕКТУАЛЬНОЇ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ В ПРОЦЕСІ БУРІННЯ НАФТОГАЗОВИХ СВЕРДЛОВИН В УКРАЇНІ

У статті розглядається трансформація бурових операцій у контексті Індустрії 4.0 шляхом впровадження хмарних обчислювальних технологій, периферійних обчислень (edge computing) та інтелектуальних аналітичних рішень. Актуальність дослідження обумовлена потребою в оперативному прийнятті рішень під час буріння, яке характеризується складними технологічними умовами, великою кількістю параметрів телеметрії, нелінійними залежностями між ними та високим рівнем ризику. Показано, що традиційні SCADA/ICS-системи мають обмеження у здатності здійснювати глибокий аналіз у реальному часі та не підтримують адаптивних моделей прогнозування, необхідних для сучасних кіберфізичних систем керування бурінням.

У відповідь на ці виклики запропоновано концепцію Інтелектуальної системи підтримки прийняття рішень (ІСППР), яка поєднує хмарну архітектуру, інструменти машинного навчання та сучасні інтерфейси доступу до телеметрії. Основна увага приділена побудові середовища, яке забезпечує масштабованість, стійкість до аномальних ситуацій і гнучкість у розгортанні на edge- або cloud-платформах. Розроблена система орієнтована на інтеграцію периферійного та хмарного рівнів, що дає змогу реалізувати замкнений цикл «збирання даних – аналіз – рекомендація – вплив», характерний для інтелектуальних кіберфізичних систем.

У статті підкреслено роль контейнеризованих сервісів на базі FastAPI, OPC UA-конекторів та алгоритмів XGBoost у забезпеченні передбачуваної поведінки, високої продуктивності та адаптивності при роботі з великими потоками телеметрії. Такий підхід дозволяє формувати динамічні моделі прогнозування параметрів буріння, зокрема швидкості проходки, виявляти аномалії та оперативно генерувати рекомендації оператору.

Запропонована архітектура формує технологічне підґрунтя для переходу від реактивного до прогнозно-аналітичного управління процесом буріння. Вона забезпечує швидке реагування на зміни технологічних параметрів, гнучке масштабування обчислювальних ресурсів, підвищення енергоефективності та безпеки виробництва. Отримані результати свідчать, що ІСППР може стати основою для створення DSS-платформ нового покоління, орієнтованих на інтелектуальне, адаптивне та ефективне управління буровими процесами у добу Індустрії 4.0.

**Ключові слова:** індустрія 4.0; хмарні обчислення; буріння; системи підтримки прийняття рішень; машинне навчання; телеметрія

IVANOTCHAK OLEKSANDR

Ivano-Frankivsk National Technical University of Oil and Gas

## MODERN CONCEPTUAL FOUNDATIONS FOR THE IMPLEMENTATION OF THE METHODOLOGY AND STRATEGY OF INTELLIGENT DECISION SUPPORT IN THE DRILLING PROCESS OF OIL AND GAS WELLS IN UKRAINE

The article examines the transformation of drilling operations in the context of Industry 4.0 through the implementation of cloud computing, edge computing, and intelligent analytical solutions. The relevance of the study is determined by the need for rapid decision-making during drilling operations, which are characterized by complex technological conditions, a large number of telemetry parameters, nonlinear dependencies, and a high level of risk. It is shown that traditional SCADA/ICS systems are limited in their ability to perform in-depth real-time analysis and do not support adaptive predictive models required for modern cyber-physical drilling control systems.

In response to these challenges, the concept of an Intelligent Decision Support System (IDSS) is proposed, which integrates cloud architecture, machine learning tools, and modern telemetry access interfaces. The main focus is on creating an environment that ensures scalability, resilience to abnormal situations, and flexibility in deployment on edge or cloud platforms. The developed system integrates edge and cloud levels to implement a closed loop of "data collection – analysis – recommendation – control," which is a fundamental feature of intelligent cyber-physical systems.

The article emphasizes the role of containerized services based on FastAPI, OPC UA connectors, and XGBoost algorithms in ensuring predictable behavior, high performance, and adaptability when processing large volumes of telemetry data. This approach enables the creation of dynamic predictive models of drilling parameters, including rate of penetration, facilitates anomaly detection, and allows timely generation of recommendations for operators.

The proposed architecture forms the technological foundation for the transition from reactive to predictive-analytical drilling control. It ensures rapid response to changing process parameters, flexible scalability of computational resources, and improved energy efficiency and operational safety. The obtained results demonstrate that the IDSS can serve as a foundation for next-generation DSS platforms aimed at intelligent, adaptive, and efficient drilling management in the era of Industry 4.0.

**Keywords:** cloud computing, telemetry, drilling operations, machine learning, decision support systems, Industry 4.0

Стаття надійшла до редакції / Received 10.12.2025  
Прийнята до друку / Accepted 11.01.2026  
Опубліковано / Published 29.01.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Іванотчак Олександр

### Постановка задачі

Управління сучасними буровими процесами перебуває на етапі трансформації, що зумовлена як підвищенням складності експлуатаційних умов, так і технологічними зрушеннями, притаманними Четвертій

промисловій революції (Індустрії 4.0). Зростаючий обсяг телеметричних даних, необхідність їхньої оперативної обробки, вимоги до безпеки та зменшення ризиків при бурінні вимагають переходу від класичних систем моніторингу до інтелектуальних систем підтримки прийняття рішень. Традиційні SCADA/ICS-системи, хоч і забезпечують базову візуалізацію та контроль, здебільшого не здатні забезпечити ані глибокий аналіз, ані адаптивне реагування у реальному часі.

У зв'язку з цим дедалі більшої актуальності набуває інтеграція хмарних обчислень, контейнеризованих сервісів, алгоритмів машинного навчання та телеметрії з польових сенсорів у єдине розподілене обчислювальне середовище. Такий підхід дозволяє реалізовувати концепції цифрових бурових майданчиків, де на основі потоків даних моделюється і прогнозується динаміка процесів, виявляються аномалії, формуються рекомендації для інженерного персоналу.

На цьому тлі формується потреба в Інтелектуальній системі підтримки прийняття рішень (ІСППР) — цифровому інтелектуальному модулі, здатному працювати як у хмарі, так і на рівні edge-інфраструктури, обробляти великі масиви даних, будувати прогнози швидкості механічного проникнення (*ROP*), здійснювати аналіз аномалій та автоматизувати частину операційної аналітики. Такі рішення мають забезпечувати гнучкість, масштабованість, модульність та простоту інтеграції з польовим обладнанням.

Постає необхідність теоретичного та практичного обґрунтування архітектурних підходів, вибору алгоритмів, інструментів обробки телеметрії та забезпечення високої надійності й швидкодії у реальному середовищі буріння. Водночас важливою є оцінка, наскільки такі системи готові до інтеграції з реальними виробничими кластерами та наскільки ефективно вони здатні реагувати на динамічні зміни умов буріння, включаючи критичні сценарії.

У даній статті окреслюється архітектура та принципи реалізації ІСППР — хмарної DSS-платформи нового покоління, яка відповідає викликам Індустрії 4.0 та відкриває нові горизонти для автоматизації, цифровізації й інтелектуалізації бурових операцій.

#### Аналіз попередніх досліджень

Проблематика цифрової трансформації бурових процесів у межах Індустрії 4.0 нині активно розробляється у міжнародних і національних дослідженнях. В українському науковому просторі, зокрема в Івано-Франківському національному технічному університеті нафти й газу, сформовано напрям, присвячений побудові інтелектуальних моделей прогнозування та оптимізації процесів буріння [1–2]. У цих роботах було закладено основи використання нейромережових алгоритмів та баз параметризованих кейсів для підвищення точності прогнозів і розроблення адаптивних стратегій керування технологічними параметрами. Такі підходи узгоджуються з глобальними тенденціями розвитку інтелектуальних систем підтримки прийняття рішень, орієнтованих на обробку великих потоків телеметричних даних у реальному часі. Основою цих систем виступає інтеграція хмарних обчислень, машинного навчання та інтернету речей (IoT), що забезпечує безперервну взаємодію між сенсорами, буровими установками й аналітичними модулями.

Розвиток хмарних сервісів для нафтогазової галузі показав, що перенесення аналітичних і обчислювальних навантажень у хмару підвищує ефективність і знижує витрати на інфраструктуру [3]. Відповідно до стандартів хмарних технологій [4] визначено принципи динамічного масштабування, автоматизованого управління ресурсами та спільного доступу, які стали ключовими при створенні промислових систем збору даних. Концепція Індустрії 4.0 [5] заклала методологічне підґрунтя, що забезпечило перехід до кіберфізичних систем, де фізичні об'єкти тісно пов'язані з їхніми цифровими моделями через хмарні сервіси, сенсори та мережеві інтерфейси.

Значний науковий інтерес викликає edge computing — обробка даних на периферії мережі, безпосередньо біля джерела їх формування [6]. Це дозволяє зменшити затримки, оптимізувати використання каналів зв'язку та підвищити надійність прийняття рішень у режимі реального часу, що є критично важливим для процесів буріння. Для забезпечення взаємодії між численними пристроями та системами управління застосовується індустриальний інтернет речей (IIoT) [7], який забезпечує стандартизований обмін даними та уніфікацію протоколів зв'язку. Важливу роль у цьому відіграє протокол OPC UA, який реалізує незалежну від платформи архітектуру, механізми безпечної комунікації та моделі даних, орієнтовані на промислові застосування [8–9]. Результати експериментів [10–11] підтверджують доцільність використання OPC UA у середовищах з високими вимогами до надійності та сумісності — зокрема як телеметричного шлюзу між буровими сенсорами та хмарними аналітичними сервісами.

Паралельно активно розвивається напрям цифрових двійників (Digital Twins), що забезпечують створення віртуальних відображень бурових процесів для аналізу й прогнозування поведінки системи [12–13]. Такі моделі дають змогу виявляти відхилення у технологічних параметрах, оцінювати ризики аварій і формувати рекомендації щодо корекції режимів буріння. Використання цифрових двійників стало одним із базових принципів створення систем типу ІСППР, де інтегруються дані телеметрії, машинне навчання та фізичні моделі свердловини.

Значну увагу науковці приділяють методам машинного навчання у прогнозуванні показників ефективності буріння, зокрема швидкості проходки (*ROP*) та крутного моменту. Ряд досліджень [14–18] демонструють переваги гібридних моделей, які поєднують емпіричні та фізично обґрунтовані залежності з алгоритмами глибокого навчання. Це дозволяє враховувати складну нелінійність процесів та підвищує точність прогнозів навіть у складних геологічних умовах. Значний інтерес викликають ансамблеві методи, серед яких XGBoost [19] посідає провідне місце завдяки здатності ефективно обробляти великі масиви телеметричних

даних і зменшувати похибки прогнозування. Його застосування у бурових системах дає можливість створювати адаптивні моделі, що навчаються в процесі експлуатації обладнання.

Сучасні роботи також наголошують на необхідності поєднання хмарних і периферійних (edge) компонентів у єдину архітектуру [4–5]. Такий підхід дає змогу поєднати високу швидкість локальної обробки з аналітичними можливостями хмари. Під час буріння це реалізується через багаторівневу взаємодію: на рівні установок відбувається первинна фільтрація й аналіз даних, тоді як у хмарі виконуються складні моделі машинного навчання та оптимізаційні алгоритми. Гібридна архітектура edge–cloud забезпечує не лише стійкість і масштабованість, але й підвищує енергоефективність та відмовостійкість систем у польових умовах.

Загалом, аналіз сучасних джерел дозволяє виділити кілька ключових тенденцій у розвитку інтелектуальної підтримки буріння:

- Формування хмарно-периферійних середовищ для інтеграції телеметрії, аналітики та управління процесом буріння.
- Розвиток моделей машинного навчання для прогнозування продуктивності, виявлення аномалій та підвищення безпеки операцій.
- Запровадження цифрових двійників і DSS-платформ, що забезпечують адаптивне управління на основі даних у реальному часі.

Синтез цих напрямів створює основу для формування нової генерації ІСППР, які відповідають вимогам Індустрії 4.0: вони забезпечують гнучкість, масштабованість, відмовостійкість і здатність до самонавчання. Така еволюція технологій відкриває можливості для підвищення ефективності бурових операцій, зменшення ризиків і впровадження сталих, енергоощадних рішень у нафтогазовій галузі.

#### Виклад основного матеріалу

Інтелектуальна система підтримки прийняття рішень (ІСППР) створена як середовище керування процесом буріння, що поєднує переваги хмарних і периферійних обчислень у межах концепції Індустрії 4.0. Її архітектура спрямована на інтеграцію потоків телеметрії, аналітичних моделей і систем візуалізації у єдиному інформаційному просторі, здатному працювати в реальному часі. Основна ідея полягає у тому, що кожен компонент – від сенсора до аналітичної моделі – є частиною взаємопов'язаної структури, де дані циркулюють без затримок і втрат контексту.

На нижньому рівні архітектури відбувається безперервне збирання телеметрії з бурових установок. Сенсори вимірюють ключові параметри процесу: вагу на долоті (*WOB*), швидкість обертання (*RPM*), крутний момент, тиск і температуру. Для передачі цих даних застосовується протокол OPC UA, який забезпечує стандартизовану модель інформаційної взаємодії та шифровані канали обміну. Первинна обробка сигналів виконується безпосередньо на периферії – edge-вузлі, де дані очищуються від шуму, усереднюються, нормалізуються й підготовляються до передавання у хмару. Такий підхід знижує навантаження на канали зв'язку та скорочує час реакції системи у разі зміни умов буріння.

Після попередньої обробки телеметрія передається через брокери повідомлень MQTT або модуль PubSub до хмарної аналітичної інфраструктури. Тут дані накопичуються у часових базах (TimeSeries DB) і потрапляють у модулі аналітики, реалізовані у вигляді контейнеризованих сервісів на базі FastAPI. Кожен сервіс виконує власну функцію: один відповідає за агрегацію даних, інший – за виявлення аномалій, третій – за короткостроковий прогноз параметрів буріння. Такий мікросервісний підхід забезпечує масштабованість і дає змогу розгорнути нові аналітичні модулі без зупинки системи.

Взаємодія між edge-та cloud-компонентами побудована за принципом замкнутого контуру керування. Хмарні моделі не лише аналізують дані, а й формують рекомендації щодо регулювання режимів буріння – наприклад, оптимізації *WOB* або *RPM*. Ці рекомендації повертаються на периферійний рівень і можуть застосовуватись автоматично чи після підтвердження оператором. Таким чином, система формує цикл «сенсор → аналітика → рішення → зворотний вплив», що є характерною ознакою інтелектуальних кіберфізичних систем.

Затримку в такому циклі можна представити рівнянням:

$$T_{\text{заг.затрим.}} = T_{\text{сенс.}} + T_{\text{зпе}} + T_{\text{еп}} + T_{\text{зх}} + T_{\text{хмар.}} + T_{\text{зв.пк}} + T_{\text{вик.мех.}}$$

$T_{\text{заг.затрим.}}$  — загальний час реакції системи ІСППР;

$T_{\text{сенс.}}$  — затримка збору даних (наприклад, період дискретизації датчика);

$T_{\text{зпе}}$  — затримка передачі даних від датчика до edge-серверу;

$T_{\text{еп}}$  — час аналізу на edge-пристрої (сервері),  $T_{\text{еп}} = \frac{C_e}{f_e}$ ;

$f_e$  — процесора потужність ( $\frac{\text{такти}}{c}$ );

$C_e$  — кількість тактів процесору для аналізу одного пакету;

$T_{\text{зх}}$  — затримка відправлення даних у хмару;

$T_{\text{хмар.}}$  — час обробки та аналітики у хмарі;

$T_{\text{зв.пк}}$  — затримка передачі команд із хмари на edge-вузол;

$T_{\text{вик.мех.}}$  — затримка виконання команд виконавчим механізмом.

Вся інформаційна взаємодія у системі стандартизована відповідно до моделі OPC UA, у якій кожен параметр описується набором атрибутів:

$$Parameter = \{Name, Unit, Range, UpdateRate\}$$

Ця модель узгоджується зі стандартом WITSML 2.1, що полегшує інтеграцію з геолого-геофізичними базами та SCADA-системами. Завдяки цьому різні потоки телеметрії – від сенсорів, лабораторних аналізаторів і польових реєстраторів – можуть бути об’єднані у спільне сховище даних (data lake), доступне як для машинного навчання, так і для аналітики у реальному часі.

З технічного погляду, кожен компонент системи реалізується як Docker-контейнер, керований засобами оркестрації Kubernetes. Це забезпечує автоматичне масштабування, відмовостійкість і незалежність від конкретного обладнання. У разі втрати зв’язку з хмарою edge-вузол переходить у автономний режим, продовжуючи роботу на локальних моделях до моменту відновлення синхронізації. Така схема підвищує надійність і дозволяє застосовувати систему навіть у віддалених районах із нестабільним каналом передачі даних.

Безпека комунікацій гарантується використанням шифрування TLS 1.3, автентифікації через OAuth 2.0 та контролю доступу на основі ролей (RBAC). Для запобігання несанкціонованим змінам моделей машинного навчання реалізовано окремий рівень прав доступу до аналітичного ядра. Усі події логуються в системі моніторингу, що дає змогу відстежувати стан обладнання, навантаження серверів та ефективність прогнозних моделей.

Таким чином, архітектура ІСППР являє собою інтегровану систему, у якій периферійна аналітика та хмарна обробка доповнюють одна одну. Вона забезпечує швидке реагування на зміни технологічних параметрів, гнучке масштабування обчислювальних ресурсів і високу стійкість до відмов. На основі цієї архітектури формується фундамент для побудови інтелектуальних систем буріння, що відповідають вимогам Індустрії 4.0, — адаптивних, самонавчальних і здатних до безперервного вдосконалення у процесі експлуатації.

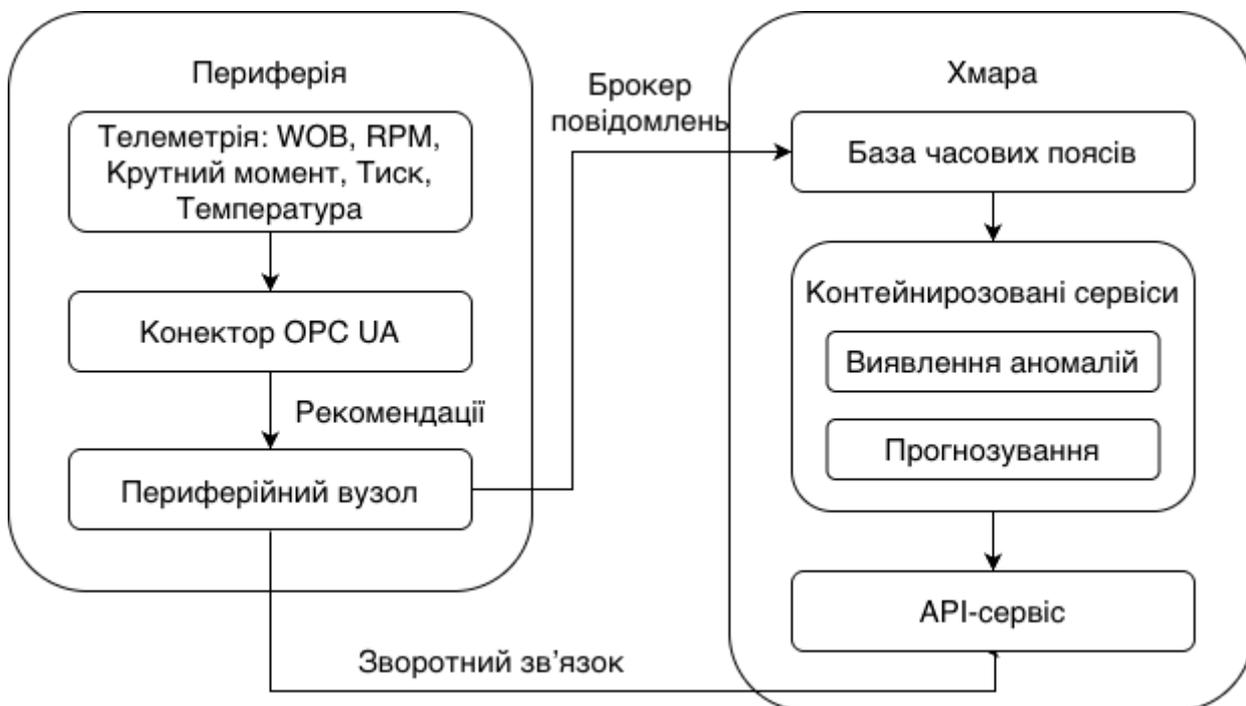


Рис.1. Концептуальна архітектура ІСППР (взаємодія edge–cloud компонентів).

Аналітичне ядро ІСППР виконує роль інтелектуального центру, у якому поєднуються фізико-математичні моделі бурового процесу та алгоритми машинного навчання. Його основна мета — здійснювати прогнозування показників ефективності буріння, виявлення відхилень і формування рекомендацій щодо керування режимами роботи установки.

Математичне ядро функціонує в межах гібридної архітектури edge–cloud, тому частина обчислень виконується локально, а частина — у хмарі, що дає змогу мінімізувати затримки й підтримувати безперервний цикл «дані → аналіз → рішення → зворотний вплив».

Стан бурового процесу описується множиною технологічних параметрів:

$$X = \{WOB, RPM, TQ, SPP, \Delta P, Q, T, \rho_m\}$$

*WOB* — навантаження на долото (Weight on Bit), кН;

*RPM* — швидкість обертання бурильної колони (*Revolutions per Minute*), об/хв;

*TQ* — крутний момент (*Torque*), Н·м;

*SPP* — тиск у нагнітальній лінії (*Standpipe Pressure*), МПа;

$\Delta P$  — перепад тиску між гирлом і вибоєм свердловини (Па),

*Q* — витрата бурового розчину (л/с),

*T* — температура у свердловині (°C),

$\rho_m$  — густина бурового розчину (кг/м<sup>3</sup>).

Цільовим параметром прогнозування є швидкість проходки долота ( $ROP$ ), що визначає ефективність процесу буріння:

$$ROP = \frac{dL}{dt},$$

де  $L$  — глибина свердловини, м  $t$  — час буріння, год.

Базова залежність між механічними параметрами буріння і швидкістю проходки може бути апроксимована емпіричним рівнянням типу Gomes-Teale:

$$ROP = k \cdot WOB^{\alpha_1} \cdot RPM^{\alpha_2} \cdot e^{-\beta TQ},$$

$k$  — коефіцієнт буримості породи;

$\alpha_1, \alpha_2, \beta$  — емпіричні параметри, що залежать від типу долота й гідродинамічних умов.

Або якщо врахувати механічні параметри буріння, властивості бурового розчину і параметри гідравліки (Mohammed M Al-Rubaii):

$$ROP = 0.00012 \frac{RPM \cdot \mu \cdot \mu^{0.85} \cdot SPP^{0.85} \cdot GPM^{0.01} \cdot HSI^{0.001}}{10 \cdot \left(\frac{PV}{YP}\right)^{0.5} \cdot \frac{MW^{0.1}}{MF^2}}$$

$\mu$  — коефіцієнт агресивності долота;

GPM — (Gallons Per Minute) – витрата розчину в галонах/хв;

HSI — (Hydraulic Horsepower per Square Inch) гідравлічна потужність бурового долота (л.с./дюйм);

PV — пластична в'язкість бурового розчину (CP);

YP — межа текучості для бурового розчину (CP);

MW — густина бурового розчину в фунт/фут<sup>3</sup>;

MF — в'язкість бурового розчину(с).

Ці моделі добре описують загальні тенденції, однак не враховує нелінійні ефекти, впливи гідравлічних коливань і зміну властивостей бурового розчину. Для підвищення точності використовується гібридна комбінація фізичної та машинної моделей.

Гібридна модель поєднує аналітичну складову з коригувальним членом, що обчислюється алгоритмом машинного навчання (XGBoost). Її загальний вигляд має форму:

$$L = \frac{1}{n} \sum_{i=1}^n (ROP_{pred,i} - ROP_{actual,i})^2 + \lambda \sum_{j=1}^m w_j^2,$$

$\lambda$  — регуляризаційний параметр,

$w_j$  — вагові коефіцієнти дерева рішень,

$n$  — кількість спостережень.

Таким чином забезпечується компроміс між точністю та узагальнюючою здатністю моделі.

У реалізації ІСППР алгоритм XGBoost працює у потоковому режимі, де кожна нова порція даних оновлює ваги ансамблю без повного перенавчання. Основна ідея — послідовне побудування дерев рішень, що мінімізують залишкову похибку попередніх моделей:

$$f_t(x) = f_{t-1}(x) + \eta \cdot h_t(x),$$

$h_t(x)$  — нове дерево рішень, побудоване на залишкових похибках,

$\eta$  — коефіцієнт навчання (learning rate).

Загальна модель після  $T$  ітерацій має вигляд:

$$f_{ML}(x) = \sum_{t=1}^T \eta h_t(x).$$

Гібридна модель ІСППР дозволяє поєднати знання інженера-технолога та статистичну силу машинного навчання. Фізична частина гарантує інтерпретованість результатів, тоді як ML-компонент компенсує впливи, не враховані у класичних рівняннях.

Наприклад, збільшення навантаження  $WOB$  підвищує швидкість проходки лише до певного оптимуму, після якого виникає надмірний знос долота — цей ефект добре уловлює нелінійна функція  $f_{ML}(x)$ .

Отримані результати прогнозування надходять до рівня DSS, де формуються рекомендації оператору у вигляді оптимальних значень режимів буріння. Так формується замкнений контур управління, у якому аналітичне ядро виступає центральним елементом прийняття рішень.

Функціонування ІСППР базується на послідовному проходженні даних через низку взаємопов'язаних модулів, які забезпечують повний цикл — від збору телеметричної інформації до формування рекомендацій для оператора. Кожен модуль виконує специфічну функцію в загальній структурі системи та забезпечує узгодженість фізичних вимірювань, математичного моделювання і підтримки прийняття рішень.

У найнижчому рівні архітектури здійснюється збір і первинна обробка телеметричних даних. Сюди надходять сигнали з датчиків, що фіксують основні технологічні параметри буріння: навантаження на долото ( $WOB$ ), швидкість обертання бурильної колони ( $RPM$ ), крутний момент ( $TQ$ ), перепад тиску ( $\Delta P$ ), температуру та витрату бурового розчину ( $Q$ ). Зібрані дані проходять попереднє фільтрування — усуваються сплески шуму,

аномальні значення та короточасні розриви сигналу. Після цього вони нормалізуються та синхронізуються за часом, що дозволяє використовувати їх у подальшій аналітичній обробці.

Наступним етапом є підготовка аналітичних ознак, тобто створення нових параметрів на основі комбінації первинних вимірів. Наприклад, визначаються відносні показники (співвідношення  $WOB/RPM$ ), енергетичні коефіцієнти або ковзні середні значення. Такий підхід дозволяє врахувати не лише миттєвий стан системи, а й динаміку зміни параметрів у часі, що особливо важливо для бурових процесів, де інерційність системи суттєво впливає на кінцевий результат.

Підготовлені дані надходять до аналітичного модуля машинного навчання, який реалізує побудову прогнозних моделей. Основним завданням цього модуля є оцінювання майбутньої швидкості проходки ( $ROP$ ) та визначення оптимальних режимів роботи бурової установки. Для цього використовуються гібридні моделі, що поєднують емпіричні фізичні залежності з елементами статистичного навчання. Такий підхід дає змогу зберегти інтерпретованість результатів (завдяки фізичним рівнянням) і водночас врахувати нелінійні впливи, які важко формалізувати аналітично.

Залежно від поставленої задачі, система може виконувати прогнозування, виявлення аномалій або оцінку відхилення від оптимального режиму. Наприклад, прогноз швидкості проходки ґрунтується на зв'язку між навантаженням на долото, швидкістю обертання та характеристиками бурового розчину. Якщо фактична швидкість значно відрізняється від очікуваної, система визначає це як аномалію та подає сигнал про можливе відхилення технологічного процесу.

Аналітичні результати надходять до модуля формування рекомендацій, який здійснює узагальнення прогнозів і видає оператору зрозумілі підказки — наприклад, необхідність зменшити навантаження або змінити швидкість обертання. У разі інтеграції з автоматизованою системою керування ( $SCADA$ ) ці рекомендації можуть бути реалізовані у вигляді автоматичного регулювання параметрів. Таким чином, система утворює замкнений цикл керування, де рішення приймаються на основі аналізу поточного стану і прогнозу майбутніх тенденцій.

Особливістю ІСППР є можливість постійного самонавчання. У процесі експлуатації бурової установки накопичується нова інформація, яка використовується для корекції параметрів моделей. Це забезпечує адаптивність системи до змін геологічних умов, властивостей порід і складу бурового розчину. Завдяки такому механізму аналітичне ядро поступово підвищує точність своїх прогнозів і рекомендацій, не потребуючи повного переналаштування.

На рівні представлення результатів передбачено інформаційно-аналітичну панель, яка візуалізує поточні параметри процесу, тренди зміни та прогнози. Оператор має змогу відстежувати основні показники у реальному часі, оцінювати стан системи за кольоровими індикаторами та переглядати короткі текстові повідомлення з рекомендаціями. Це спрощує сприйняття інформації та підвищує швидкість реакції на можливі відхилення.

Узагальнена структура взаємодії модулів системи ілюструється на рисунку 2. Потік даних рухається від сенсорів і телеметричних приладів до рівня обробки, далі — до модуля аналітики та прогнозування, після чого результати повертаються у вигляді рекомендацій або керівних впливів.



Рис.2. Узагальнена структура модулів обробки та машинного навчання в ІСППР

Таким чином, ІСППР взаємопов'язані та забезпечують перетворення великих обсягів телеметрії у практичну інженерну інформацію. Такий підхід створює підґрунтя переходу від реактивного управління до прогнозно-аналітичного, що є ключовим елементом цифрової трансформації бурових операцій у контексті Індустрії 4.0.

Ефективність роботи ІСППР визначається не лише точністю моделей, а й побудовою надійної обчислювальної інфраструктури, здатної підтримувати постійний обмін великими обсягами даних між польовими вузлами, хмарними сервісами та користувацькими інтерфейсами. Архітектура системи спроектована за принципом гібридного обчислювального континууму ( $edge-cloud$  continuum), у якому обчислювальні ресурси динамічно розподіляються між рівнями залежно від пріоритетності завдань.

На периферійному рівні ( $edge$  layer) функціонують сервіси збору, буферизації та попередньої обробки телеметрії. Вони реалізовані у вигляді контейнеризованих застосунків, що запускаються на мікрокомп'ютерах

або промислових контролерах, підключених безпосередньо до систем вимірювання. Основні процеси, що виконуються на цьому рівні:

- нормалізація параметрів у реальному часі;
- фільтрація шумів і видалення хибних зчитувань;
- обчислення ковзних середніх та похідних;
- пакетування даних для передавання в хмару.

Передача даних здійснюється через стандартизовані протоколи OPC UA або MQTT, що забезпечують безпечну та уніфіковану взаємодію з обладнанням різних виробників. У випадку розриву з'єднання edge-сервіс тимчасово зберігає дані у локальному буфері, а після відновлення зв'язку автоматично синхронізує їх із хмарним сховищем.

Хмарний рівень (cloud layer) виконує функції централізованого аналізу, прогнозування та управління. Його інфраструктура базується на віртуалізованих контейнерах, керованих системою оркестрації на кшталт Kubernetes. Кожен аналітичний модуль — фільтрація, прогнозування, виявлення аномалій, оцінка ризиків — функціонує як окремий сервіс із власним API. Це дозволяє масштабувати окремі компоненти незалежно від інших: наприклад, збільшити кількість екземплярів сервісу прогнозування у період високої активності сенсорів.

Усі обчислювальні вузли пов'язані через центральну шину даних, яка передає потоки телеметрії у сховище часових рядів. Для цього застосовується оптимізоване сховище типу TimeSeries DB, орієнтоване на швидкі вставки й запити за часовими мітками. Обробка даних відбувається у вигляді конвеєрів (pipelines), що поєднують етапи очищення, агрегації, формування ознак і запуску моделей.

Завдяки модульній структурі, ІСППР підтримує розгортання аналітичних мікросервісів, які спілкуються між собою через внутрішню мережу REST- або gRPC-запитів. Наприклад:

- сервіс Data Preprocessor отримує дані від польових вузлів, перевіряє їх на повноту та передає у сховище;
- сервіс Predictor запитує агреговані дані й повертає прогноз швидкості проходки;
- сервіс Advisor трансформує прогноз у текстову рекомендацію для оператора.

Взаємодія між сервісами відбувається асинхронно, що мінімізує затримки та запобігає блокуванню при великій кількості запитів. Для керування чергами повідомлень може використовуватися брокер на зразок RabbitMQ або Kafka.

Усі канали обміну даними між рівнями системи захищено шифруванням за протоколом TLS 1.3. Доступ користувачів і сервісів контролюється за допомогою рольової моделі автентифікації (Role-Based Access Control, RBAC), яка визначає права на читання, запис і модифікацію даних.

Для запобігання втраті інформації використовується реплікація критичних баз даних і регулярне створення резервних копій. У разі збою система автоматично перемикається на резервний вузол, що гарантує безперервність роботи навіть у разі відмови частини компонентів.

Стан усіх сервісів відстежується через панель моніторингу, де у реальному часі виводяться показники продуктивності — середній час відповіді, обсяг оброблених даних, температура процесорів edge-вузлів, статуси контейнерів. Такий моніторинг дозволяє швидко реагувати на перевантаження або відмови й оптимізувати розподіл ресурсів.

Враховуючи, що моделі машинного навчання постійно вдосконалюються, у системі реалізовано механізм версіонування моделей. Кожна нова версія проходить етап валідації, під час якого порівнюються ключові метрики (MAE, RMSE, R<sup>2</sup>) із попередньою. Якщо нова модель демонструє покращення, вона автоматично розгортається у продуктивному середовищі.

Метадані про всі версії зберігаються у централізованому репозиторії — із зазначенням дати навчання, обсягу даних, використаних гіперпараметрів і досягнутої точності. Це забезпечує повну відтворюваність результатів і контроль якості.

Для взаємодії з іншими системами (наприклад, SCADA чи корпоративними базами даних) ІСППР надає відкриті інтерфейси REST API. Через них можна отримати:

- прогноз швидкості проходки (ROP);
- оцінку стану обладнання;
- сигнали про виявлені аномалії;
- аналітичні звіти за певний часовий проміжок.

Використання уніфікованих форматів обміну (JSON, CSV, Parquet) забезпечує простоту інтеграції з існуючими інформаційними системами та інструментами візуалізації.

### Висновки

Проведене дослідження показало, що інтеграція хмарних обчислювальних технологій та інтелектуальних аналітичних моделей у процес буріння є ключовим етапом переходу галузі до принципів Індустрії 4.0. Запропонована концепція Інтелектуальної системи підтримки прийняття рішень (ІСППР) демонструє, що поєднання периферійних (edge) і хмарних (cloud) обчислень в єдиній архітектурі дозволяє створити адаптивне цифрове середовище підтримки прийняття рішень у реальному часі.

Архітектура системи, побудована за принципом обчислювального континууму, забезпечує безперервність потоку даних — від сенсорів бурової установки до аналітичного ядра та операторського інтерфейсу. Такий підхід усуває часові затримки, характерні для класичних SCADA/ICS систем, і створює

можливість реалізації замкненого циклу керування: сенсор → аналітика → рекомендація → дія. Завдяки цьому система переходить від реактивного реагування до проактивного управління процесом буріння.

Розроблена математична модель аналітичного ядра базується на гібридному поєднанні фізичних рівнянь і алгоритмів машинного навчання. Такий підхід забезпечує баланс між інтерпретованістю результатів і точністю прогнозування. Фізична частина описує основні закономірності механічної взаємодії бурового інструмента з породою, тоді як ML-компонент уточнює їх на основі історичних даних і дозволяє враховувати нелінійні впливи, зміни реологічних властивостей бурового розчину та стохастичні коливання параметрів. У результаті система здатна формувати точні прогнози швидкості проходки, виявляти аномалії та пропонувати рекомендації з оптимізації режимів буріння.

Запропонована модульна структура ІСППР охоплює всі етапи життєвого циклу даних: збір, очищення, формування ознак, аналіз, прогнозування, інтерпретацію результатів і передачу рекомендацій. Кожен модуль може розвиватися незалежно, що забезпечує гнучкість і масштабованість системи. Такий підхід не лише підвищує надійність, але й спрощує впровадження нових алгоритмів без зупинки процесу.

Інфраструктура обчислень реалізована у вигляді контейнеризованих сервісів, що функціонують у середовищі Kubernetes. Це забезпечує автономність, автоматичне масштабування та високу відмовостійкість. Завдяки використанню протоколів OPC UA та MQTT досягається уніфікація інформаційних потоків, а механізми TLS 1.3, OAuth 2.0 та RBAC гарантують безпеку комунікацій і контроль доступу. У сукупності це створює надійне цифрове середовище, придатне для використання навіть у віддалених бурових регіонах із обмеженим каналом зв'язку.

Важливим результатом дослідження є підтвердження того, що хмарна аналітична модель може ефективно співіснувати з периферійною аналітикою, створюючи інтелектуальну екосистему буріння. Завдяки принципу самонавчання система здатна адаптуватися до нових геологічних умов і вдосконалювати свої прогнози з кожним новим циклом буріння. Це відкриває перспективи для формування цифрових двійників бурових установок і подальшого переходу до Smart Drilling Systems.

З наукового погляду, ІСППР є прикладом застосування концепції кіберфізичних систем у промисловому бурінні. Вона демонструє, як інтеграція моделей машинного навчання, стандартів промислового інтернету речей і сервісно-орієнтованої архітектури здатна створити інтелектуальний рівень управління технологічним процесом. З практичного погляду — це інструмент для підвищення продуктивності, зниження витрат енергії та мінімізації аварійних ризиків під час буріння.

Підсумовуючи, можна стверджувати, що реалізація системи ІСППР підтверджує ефективність поєднання хмарних обчислень, машинного навчання та стандартів промислової взаємодії для створення цифрових рішень нового покоління. Отримані результати можуть бути використані як основа для розроблення інтелектуальних DSS-платформ у суміжних галузях — геологорозвідці, добуванні, транспорті або енергетиці.

Подальші дослідження мають бути спрямовані на розширення можливостей аналітичного ядра за рахунок застосування глибоких нейронних мереж, розроблення механізмів пояснюваності прогнозів (XAI) та інтеграцію з цифровими двійниками бурових підприємств.

## Література

1. Процюк В. В. Нейромережева система автоматизації прогнозування динаміки контрольованих параметрів процесу буріння нафтогазових свердловин. Дисертація. Івано-Франківський національний технічний університет нафти і газу, 2024.
2. Потеряйло Л. О. Інтелектуальні моделі оптимізації характеристик буріння на основі баз параметризованих кейсів. Дисертація. Івано-Франківський національний технічний університет нафти і газу, 2023.
3. Perrons, R. K., & Hems, A. (2013). Cloud computing in the upstream oil & gas industry: A proposed way forward. *Energy Policy*, 56, 732–737.
4. Mell, P., & Grance, T. (2011). The NIST Definition of Cloud Computing. NIST Special Publication 800-145.
5. Kagermann, H., Wahlster, W., & Helbig, J. (2013). Recommendations for Implementing the Strategic Initiative INDUSTRIE 4.0. acatech — National Academy of Science and Engineering (Final Report).
6. Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646.
7. Boyes, H., Hallaq, B., Cunningham, J., & Watson, T. (2018). The industrial internet of things (IIoT): An analysis framework. *Computers in Industry*, 101, 1–12.
8. Pfrommer, J., Ebner, A., Schleipen, M., & Beyerer, J. (2018). Open Source OPC UA PubSub over TSN for realtime industrial communication. 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA), 1087–1090.
9. IEC. (2015). IEC 62541-7:2015 — OPC Unified Architecture – Part 7: Profiles. International Electrotechnical Commission.
10. Ladegourdie, M., & Kua, J. (2022). Performance analysis of OPC UA for industrial interoperability towards Industry 4.0. *IoT*, 3(4), 507–525.
11. Busboom, A. (2024). Automated generation of OPC UA information models — A review and outlook. *Journal of Industrial Information Integration*, 39, 100602.

12. Meza, E. B. M., de Souza, D. G. B., Copetti, A., Sobral, A. P. B., Silva, G. V., Tammela, I., & Cardoso, R. (2024). Tools, technologies and frameworks for digital twins in the oil and gas industry: An in-depth analysis. *Sensors*, 24(19), 6457.
13. Azmi, P. A. R., Azmi, M. A. R., & Al-Bazi, A. (2024). A review of predictive analytics models in the oil and gas industry. *Sensors*, 24(12), 4013.
14. Jiao, S., Li, W., Li, Z., Gai, J., Zou, L., & Su, Y. (2024). Hybrid physics–machine learning models for predicting rate of penetration in the Halahatang oil field, Tarim Basin. *Scientific Reports*, 14, 5957.
15. Gurina, E., Klyuchnikov, N., Antipova, K., & Koroteev, D. (2022). Forecasting the abnormal events at well drilling with machine learning.
16. Soares, C., & Gray, K. (2019). Real-time predictive capabilities of analytical and machine learning rate of penetration (ROP) models. *Journal of Petroleum Science and Engineering*, 172, 934–959.
17. Hegde, C., Daigle, H., Millwater, H., & Gray, K. (2017). Analysis of rate of penetration (ROP) prediction in drilling using physics-based and data-driven models. *Journal of Petroleum Science and Engineering*, 159, 295–306.
18. Barbosa, L. F. F. M., Nascimento, A., Mathias, M. H., & de Carvalho, J. A. (2019). Machine learning methods applied to drilling rate of penetration prediction and optimization: A review. *Journal of Petroleum Science and Engineering*, 183, 106332.
19. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794.

### References

1. Protsiuk V. V. Neiromerezheva systema avtomatyzatsii prohnozuvannia dynamiky kontrolovanykh parametriv protsesu burinnia naftohazovykh sverdlorovyn. Dysertatsiia. Ivano-Frankivskiy natsionalnyi tekhnichnyi universytet nafty i hazu, 2024
2. Poteriailo L. O. Intelktualni modeli optymizatsii kharakterystyk burinnia na osnovi baz parametryzovanykh keisiv. Dysertatsiia. Ivano-Frankivskiy natsionalnyi tekhnichnyi universytet nafty i hazu, 2023.
3. Perrons, R. K., & Hems, A. (2013). Cloud computing in the upstream oil & gas industry: A proposed way forward. *Energy Policy*, 56, 732–737.
4. Mell, P., & Grance, T. (2011). The NIST Definition of Cloud Computing. NIST Special Publication 800-145.
5. Kagermann, H., Wahlster, W., & Helbig, J. (2013). Recommendations for Implementing the Strategic Initiative INDUSTRIE 4.0. acatech — National Academy of Science and Engineering (Final Report).
6. Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646.
7. Boyes, H., Hallaq, B., Cunningham, J., & Watson, T. (2018). The industrial internet of things (IIoT): An analysis framework. *Computers in Industry*, 101, 1–12.
8. Pfrommer, J., Ebner, A., Schleipen, M., & Beyerer, J. (2018). Open Source OPC UA PubSub over TSN for realtime industrial communication. 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA), 1087–1090.
9. IEC. (2015). IEC 62541-7:2015 — OPC Unified Architecture – Part 7: Profiles. International Electrotechnical Commission.
10. Ladegourdie, M., & Kua, J. (2022). Performance analysis of OPC UA for industrial interoperability towards Industry 4.0. *IoT*, 3(4), 507–525.
11. Busboom, A. (2024). Automated generation of OPC UA information models — A review and outlook. *Journal of Industrial Information Integration*, 39, 100602.
12. Meza, E. B. M., de Souza, D. G. B., Copetti, A., Sobral, A. P. B., Silva, G. V., Tammela, I., & Cardoso, R. (2024). Tools, technologies and frameworks for digital twins in the oil and gas industry: An in-depth analysis. *Sensors*, 24(19), 6457.
13. Azmi, P. A. R., Azmi, M. A. R., & Al-Bazi, A. (2024). A review of predictive analytics models in the oil and gas industry. *Sensors*, 24(12), 4013.
14. Jiao, S., Li, W., Li, Z., Gai, J., Zou, L., & Su, Y. (2024). Hybrid physics–machine learning models for predicting rate of penetration in the Halahatang oil field, Tarim Basin. *Scientific Reports*, 14, 5957.
15. Gurina, E., Klyuchnikov, N., Antipova, K., & Koroteev, D. (2022). Forecasting the abnormal events at well drilling with machine learning.
16. Soares, C., & Gray, K. (2019). Real-time predictive capabilities of analytical and machine learning rate of penetration (ROP) models. *Journal of Petroleum Science and Engineering*, 172, 934–959.
17. Hegde, C., Daigle, H., Millwater, H., & Gray, K. (2017). Analysis of rate of penetration (ROP) prediction in drilling using physics-based and data-driven models. *Journal of Petroleum Science and Engineering*, 159, 295–306.
18. Barbosa, L. F. F. M., Nascimento, A., Mathias, M. H., & de Carvalho, J. A. (2019). Machine learning methods applied to drilling rate of penetration prediction and optimization: A review. *Journal of Petroleum Science and Engineering*, 183, 106332.
19. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794