

Івано-Франківський національний технічний університет нафти і газу
Міністерство освіти і науки України

Кваліфікаційна наукова
праця на правах рукопису

Іванотчак Олександр Миколайович

УДК 004.891.3:004.032.26:622.24

ДИСЕРТАЦІЯ
КОМП'ЮТЕРНА НЕЙРОМЕРЕЖЕВА СИСТЕМА ПІДТРИМКИ
ПРИЙНЯТТЯ РІШЕНЬ У ПРОЦЕСІ БУРІННЯ НАФТОГАЗОВИХ
СВЕРДЛОВИН

123 – Комп'ютерна інженерія

12 – Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело



Іванотчак О.М.

Науковий керівник
кандидат технічних наук, доцент
Бандура Вікторія Валеріївна

Івано-Франківськ - 2026

АНОТАЦІЯ

Іванотчак Олександр Миколайович. Комп'ютерна нейромережева система підтримки прийняття рішень у процесі буріння нафтогазових свердловин. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 123 – Комп'ютерна інженерія в галузі знань 12 Інформаційні технології. – Івано-Франківський національний технічний університет нафти і газу, Івано-Франківськ, 2026.

Метою дисертаційного дослідження є підвищення ефективності та безпеки процесу буріння нафтогазових свердловин шляхом розробки та впровадження комп'ютерної нейромережевої системи підтримки прийняття рішень, що базується на гібридній CNN-LSTM структурі для предиктивної ідентифікації передаварійних ситуацій та інтелектуальної оптимізації механічної швидкості проходки в режимі реального часу.

У дисертаційній роботі розроблено структуру та програмно-технічні засоби комп'ютерної системи підтримки прийняття рішень, що базується на гібридній нейромережевій моделі CNN-LSTM для предиктивного аналізу багатовимірних часових рядів процесу буріння. Завдяки впровадженню периферійних обчислень та методів пояснювального штучного інтелекту забезпечено оперативну ідентифікацію передаварійних ситуацій та інтелектуальну оптимізацію режимів проходки свердловин у режимі реального часу.

Вирішення такої задачі має стратегічне значення для нафтогазового комплексу України, оскільки впровадження вітчизняних інтелектуальних комп'ютерних систем забезпечує перехід до предиктивного управління процесом буріння, що дозволяє мінімізувати аварійні ризики та суттєво підвищити ефективність спорудження свердловин у складних геологічних умовах.

У вступі здійснено комплексне обґрунтування актуальності наукової проблеми та доведено її вагомість для інноваційного розвитку галузі. Висвітлено зв'язок проведених досліджень із пріоритетними державними науково-технічними програмами та планами науково-дослідних робіт установ. Відповідно до сформульованої мети визначено коло ключових наукових завдань. Викладено основні положення, що становлять наукову новизну, та аргументовано практичну значущість одержаних результатів. Деталізовано особистий внесок здобувача у працях, опублікованих у співавторстві, а також систематизовано відомості щодо апробації результатів та обсягу публікаційної активності автора.

У першому розділі проведено аналіз сучасного стану цифровізації нафтогазової галузі та визначено ключові обмеження існуючих комп'ютерних систем. Встановлено, що традиційні хмарні архітектури не здатні забезпечити необхідну швидкість обробки даних у задачах реального часу через значні затримки в каналах зв'язку. На основі проведеного огляду обґрунтовано перехід до парадигми периферійних обчислень, що дозволяє реалізувати аналітичне ядро безпосередньо на буровому майданчику. Системний аналіз існуючих підходів до ідентифікації ускладнень вказав на критичну проблему «чорної скриньки», яка суттєво знижує рівень довіри операторів до інтелектуальних систем. Особливу увагу приділено концепціям ситуаційної обізнаності та когнітивної ергономіки як фундаменту для проектування сучасних СППР. За результатами критичного огляду наукових праць вітчизняних та закордонних вчених було ідентифіковано невирішені аспекти інтеграції глибокого навчання у технологічні регламенти. Обґрунтований напрямок досліджень фокусується на розробці гібридної системи, що поєднує високу точність нейромереж із логікою експертних знань. Підсумком розділу став вибір технологічного стека та архітектурних принципів, що лягли в основу подальшої розробки.

Другий розділ присвячений розробці теоретико-методологічного базису для побудови нейромережевої системи в умовах буріння нафтогазових свердловин. Здійснено математичну формалізацію технологічних процесів як

джерел складних багатовимірних часових рядів, що підлягають інтелектуальному аналізу. Розроблена структура вхідного вектору ознак забезпечила збалансоване представлення механічних, гідравлічних та просторових характеристик об'єкта. Математична постановка задачі оптимізації режиму буріння дозволила визначити цільові KPI для навчання аналітичного ядра. На основі аналізу рекурентних структур обґрунтовано вибір LSTM-мереж як найбільш ефективного інструменту для моделювання часових залежностей. Спроектвана гібридна структура CNN-LSTM реалізує дворівневий підхід до обробки даних, де згорткові шари відповідають за фільтрацію та екстракцію ознак. Запропонована стратегія навчання включає методи адаптивного коригування ваг для мінімізації помилок прогнозування у динамічних умовах. Важливим етапом стала розробка логічної схеми функціонування СППР, яка описує взаємодію між модулями класифікації та регресії. Сформована система метрик дозволяє здійснювати оцінку якості нейромережі на основі показників точності та обчислювальної стабільності. Теоретично доведено, що запропонований комплекс методів забезпечує необхідну надійність прийняття рішень при значній невизначеності геологічних даних.

У третьому розділі представлено розробку структури та основних алгоритмів функціонування комп'ютерної системи підтримки прийняття рішень. Запропонована чотирирівнева структурна схема забезпечує ефективне спряження апаратної частини збору даних та інтелектуального аналітичного ядра. Рівень препроцесингу реалізовано з можливістю потокової фільтрації телеметричних сигналів у темпі реального часу з частотою один герц. Описано структуру Edge-вузла, оптимізовану для паралелізації тензорних обчислень на сучасних графічних прискорювачах. Розроблений алгоритм ідентифікації передаварійних ситуацій базується на аналізі виходів Softmax-шару для категоризації ризикових станів. Впровадження математичного фільтра хибних спрацювань дозволило суттєво підвищити стабільність роботи системи при короткочасних відхиленнях параметрів. Створена модель прогнозування механічної швидкості проходки враховує нелінійну поверхню відгуку для

пошуку оптимальних значень навантаження та обертів. Алгоритм ідентифікації екстремумів забезпечує динамічне коригування рекомендацій залежно від поточної енергоефективності руйнування гірської породи. Оцінка надійності прогнозу базується на розрахунку довірчих інтервалів, що дозволяє ігнорувати статистично недостовірні результати навчання. Спроектований інтерфейс взаємодії з оператором базується на принципах когнітивної фільтрації для запобігання інформаційному перевантаженню. Розроблена гібридна база знань гарантує інтерпретованість кожного висновку системи через механізми пояснювального штучного інтелекту.

Четвертий розділ містить результати програмного рішення та комплексного тестування розробленої комп'ютерної нейромережевої системи. Створено програмний прототип СППР на основі фреймворку FastAPI, що забезпечує високу швидкість обробки асинхронних API-запитів. Реалізована структура Edge-сервісу забезпечила інтеграцію гібридної CNN-LSTM моделі в локальний контур інференсу з подальшим формуванням прогнозу та адаптивних рекомендацій для оператора. Агентно-орієнтований підхід до взаємодії компонентів підтвердив свою ефективність у забезпеченні відмовостійкості системи. Проведене Offline-навчання на масиві даних 12 свердловин дозволило досягти високої точності ідентифікації типових ускладнень буріння. Розроблений модуль адаптації забезпечив стійкість моделі до концептуального дрейфу при зміні літологічних умов проходки. Frontend-інтерфейс реалізує наочну візуалізацію прогнозних трендів та зон оптимальної продуктивності для бурового майстра. Функціональне тестування у різних сценаріях підтвердило здатність системи завчасно виявляти ознаки прихоплення колони та поглинань розчину. Аналіз продуктивності API показав, що система здатна масштабуватися для одночасного супроводу декількох об'єктів буріння. Використання технологій контейнеризації Docker дозволило забезпечити легке розгортання та крос-платформну сумісність програмного комплексу. Загалом результати апробації підтверджують, що розроблена система відповідає всім поставленим вимогам і готова до впровадження у нафтогазовій галузі.

Ключові слова: комп'ютерна система, система підтримки прийняття рішень, периферійні обчислення, машинне навчання, гібридна нейронна мережа, моніторинг, керування технологічними процесами, технологічні параметри буріння, прогнозування, математичне моделювання, людино-машинна взаємодія, ідентифікація передаварійних ситуацій, часові ряди.

ABSTRACT

Ivanotchak Oleksandr Mykolaiovych. Computer Neural Network Decision Support System in the Process of Oil and Gas Well Drilling. – Qualifying scientific work as a manuscript.

Dissertation for the degree of Doctor of Philosophy in specialty 123 – Computer Engineering in the field of knowledge 12 – Information Technology. – Ivano-Frankivsk National Technical University of Oil and Gas, Ivano-Frankivsk, 2026.

The aim of the dissertation research is to improve the efficiency and safety of the oil and gas well drilling process through the development and implementation of a computer neural network decision support system based on a hybrid CNN-LSTM structure for the predictive identification of pre-emergency situations and intelligent optimization of the rate of penetration in real time.

The dissertation presents the development of the structure and software-hardware means of a computer decision support system based on a hybrid CNN-LSTM neural network model for predictive analysis of multidimensional time series in the drilling process. Through the implementation of edge computing and explainable artificial intelligence methods, prompt identification of pre-emergency situations and intelligent optimization of drilling performance in real time have been achieved.

Solving this problem is of strategic importance for the oil and gas sector of Ukraine, since the introduction of domestic intelligent computer systems enables the transition to predictive control of the drilling process, which makes it possible to minimize accident risks and significantly increase the efficiency of well construction under complex geological conditions.

The introduction provides a comprehensive substantiation of the relevance of the scientific problem and demonstrates its significance for the innovative development of the industry. It highlights the relationship of the conducted research with priority national scientific and technical programs and institutional research plans. In accordance with the formulated aim, a set of key scientific tasks is defined. The main provisions constituting the scientific novelty are presented, and the practical

significance of the obtained results is substantiated. The author's personal contribution to the co-authored publications is detailed, and information on the approbation of results and the scope of publication activity is systematized.

The first chapter analyzes the current state of digitalization in the oil and gas industry and identifies the key limitations of existing computer systems. It is established that traditional cloud architectures are unable to provide the required data processing speed in real-time tasks due to significant communication delays. Based on the conducted review, the transition to the edge computing paradigm is substantiated, which makes it possible to implement the analytical core directly at the drilling site. A systematic analysis of existing approaches to complication identification revealed the critical "black box" problem, which significantly reduces operators' trust in intelligent systems. Particular attention is paid to the concepts of situational awareness and cognitive ergonomics as the foundation for designing modern decision support systems. Based on the critical review of scientific works by domestic and foreign researchers, unresolved aspects of integrating deep learning into technological regulations were identified. The substantiated research direction focuses on the development of a hybrid system combining the high accuracy of neural networks with the logic of expert knowledge. The chapter concludes with the selection of the technological stack and architectural principles that formed the basis for further development.

The second chapter is devoted to the development of the theoretical and methodological basis for building a neural network system under oil and gas well drilling conditions. A mathematical formalization of technological processes as sources of complex multidimensional time series subject to intelligent analysis is carried out. The developed structure of the input feature vector provides a balanced representation of the mechanical, hydraulic, and spatial characteristics of the object. The mathematical formulation of the drilling mode optimization problem made it possible to define the target KPIs for training the analytical core. Based on the analysis of recurrent structures, the choice of LSTM networks as the most effective tool for modeling temporal dependencies is substantiated. The designed hybrid CNN-LSTM

structure implements a two-level data processing approach in which convolutional layers are responsible for filtering and feature extraction. The proposed training strategy includes methods for adaptive weight adjustment to minimize forecasting errors under dynamic conditions. An important stage was the development of the logical scheme of DSS operation, which describes the interaction between classification and regression modules. The formed system of metrics makes it possible to assess neural network quality based on accuracy and computational stability indicators. It is theoretically proven that the proposed set of methods provides the required reliability of decision-making under significant uncertainty of geological data.

The third chapter presents the development of the structure and main operating algorithms of the computer decision support system. The proposed four-level structural scheme ensures efficient coupling of the hardware data acquisition part with the intelligent analytical core. The preprocessing level is implemented with the possibility of streaming filtering of telemetry signals in real time at a frequency of one hertz. The structure of the Edge node, optimized for parallelization of tensor computations on modern GPU accelerators, is described. The developed algorithm for identifying pre-emergency situations is based on the analysis of Softmax layer outputs for the categorization of risk states. The introduction of a mathematical false-alarm filtering mechanism made it possible to significantly improve the stability of the system under short-term parameter deviations. The created model for predicting the rate of penetration takes into account the nonlinear response surface to search for optimal values of weight on bit and rotary speed. The extremum identification algorithm provides dynamic correction of recommendations depending on the current energy efficiency of rock destruction. Forecast reliability assessment is based on the calculation of confidence intervals, which makes it possible to ignore statistically unreliable learning results. The designed operator interaction interface is based on the principles of cognitive filtering to prevent information overload. The developed hybrid knowledge base guarantees the interpretability of each system conclusion through explainable artificial intelligence mechanisms.

The fourth chapter contains the results of the software implementation and comprehensive testing of the developed computer neural network system. A DSS software prototype based on the FastAPI framework was created, ensuring high-speed processing of asynchronous API requests. The implemented Edge service structure ensured the integration of the hybrid CNN-LSTM model into the local inference loop with subsequent forecast generation and adaptive recommendation formation for the operator. The agent-oriented approach to component interaction confirmed its effectiveness in ensuring system fault tolerance. Offline training on a dataset from 12 wells made it possible to achieve high accuracy in identifying typical drilling complications. The developed adaptation module ensured the model's robustness to concept drift under changing lithological drilling conditions. The frontend interface provides clear visualization of forecast trends and optimal productivity zones for the drilling supervisor. Functional testing under various scenarios confirmed the system's ability to detect early signs of drill string sticking and drilling fluid losses. API performance analysis showed that the system is capable of scaling for simultaneous support of several drilling objects. The use of Docker containerization technologies made it possible to ensure easy deployment and cross-platform compatibility of the software package. Overall, the approbation results confirm that the developed system meets all the stated requirements and is ready for implementation in the oil and gas industry.

Keywords: computer system, decision support system, edge computing, machine learning, hybrid neural network, monitoring, technological process control, drilling parameters, forecasting, mathematical modeling, human–machine interaction, identification of pre-emergency situations, time series.

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Наукові праці, в яких опубліковано основні наукові результати дисертації:

1. Іванотчак О., Кеденко І., Куліш С., Глібчук А., & Дмитренко С. (2024). Концептуалізація нейромоделей задач підтримки прийняття рішень. Herald of Khmelnytskyi National University. Technical Sciences, 335(3(1), 78-87. <https://doi.org/10.31891/2307-5732-2024-335-3-11> (**Фахове наукове видання України категорії Б**). *Здобувач розробив концептуальні засади побудови нейромоделей для вирішення задач підтримки прийняття рішень, запропонував теоретичне обґрунтування структури нейронних мереж у контексті їх адаптації до управлінських процесів та узагальнив результати проведеного дослідження; І. Кеденко визначив об'єкт та предмет дослідження, а також методологічно обґрунтував застосування нейромережевих технологій; С. Куліш виконав аналіз існуючих архітектур нейронних мереж; А. Глібчук провів програмну реалізацію запропонованих алгоритмів; С. Дмитренко здійснив верифікацію отриманих результатів, провів оцінку адекватності нейромоделей.*

2. Іванотчак О. Новітні концептуальні основи реалізації методології та стратегії інтелектуальної підтримки прийняття рішень в процесі буріння нафтогазових свердловин в Україні. Herald of Khmelnytskyi National University. Technical Sciences, 361(1), 175-183. <https://doi.org/10.31891/2307-5732-2026-361-23> (**Фахове наукове видання України категорії Б**). *Здобувач самостійно обґрунтував новітні концептуальні основи реалізації методології та стратегії інтелектуальної підтримки прийняття рішень у нафтогазовій галузі; розробив структуру інтелектуалізованої системи підтримки прийняття рішень (СППР), адаптовану до технологічних особливостей процесу буріння свердловин в умовах України; провів системний аналіз факторів невизначеності при спорудженні свердловин та визначив стратегічні напрями впровадження когнітивних технологій для мінімізації ризиків і оптимізації техніко-економічних показників буріння.*

3. Іванотчак О. Експериментальні результати та валідація моделей Інтелектуальної системи підтримки прийняття рішень (ІСППР) у процесі буріння нафтових свердловин. Вчені записки ТНУ імені В.І. Вернадського. Серія Технічні науки, №6 за 2025, <https://doi.org/10.32782/2663-5941/2025.6.2/21> **(Фахове наукове видання України категорії Б)**. *Здобувач одноосібно розробив методикку проведення експериментальних досліджень для перевірки працездатності моделей інтелектуальної системи підтримки прийняття рішень (ІСППР) у специфічних умовах буріння нафтових свердловин; здійснив збір та підготовку емпіричних даних для апробації системи; провів валідацію розроблених нейромережових та логіко-лінгвістичних моделей, підтвердивши їх високу прогностичну здатність та адекватність реальним технологічним процесам; сформулював практичні рекомендації щодо впровадження ІСППР на підприємствах нафтогазової галузі для підвищення точності управлінських рішень.*

4. Іванотчак, О. 2026. Розробка гібридної нейромережевої моделі CNN-LSTM для інтелектуальної оптимізації та раннього прогнозування ускладнень у процесі буріння НГС. Herald of Khmelnytskyi National University. Technical sciences. 363, 2 (Mar. 2026), 125–134. DOI:<https://doi.org/10.31891/2307-5732-2026-363-16>. **(Фахове наукове видання України категорії Б)**. *Здобувач самостійно обґрунтував доцільність використання гібридного підходу на основі поєднання згорткових (CNN) та рекурентних (LSTM) нейронних мереж для обробки часових рядів технологічних параметрів буріння; розробив структуру моделі CNN-LSTM, що забезпечує ефективне виділення просторових ознак та врахування часових залежностей у даних; сформулював алгоритм інтелектуальної оптимізації режимів буріння на основі прогнозованих значень; провів серію експериментальних досліджень, які підтвердили високу точність моделі у ранньому виявленні передаварійних ситуацій та ускладнень при спорудженні нафтогазових свердловин.*

5. Іванотчак О. М., Мельник В. Д., Бандура В. В., Кутинський А. Я., Дмитрів І. Я., Іванців Н.Т., Дячук А. В., Місюрак Т. Я. Особливості задач класифікації на

множині контенту в контексті реалізації індуктивного логічного програмування // «Інформаційні технології в освіті, техніці та промисловості»: Збірник наукових праць Всеукраїнської науково-практичної конференції молодих учених і студентів (м. Івано-Франківськ, 10 жовтня 2024р.), Івано-Франківськ, 2024. С.220-221 https://drive.google.com/file/d/1XrD-obOLO_MBz3DuotBYS4S7fKqycmFS/view. *Здобувач дослідив особливості задач класифікації на множині контенту та запропонував концептуальні підходи до їх вирішення засобами індуктивного логічного програмування для підвищення інтелектуалізації систем; В. Мельник забезпечив загальне наукове керівництво; В. Бандура виконала системний аналіз типів контенту; А. Кутинський здійснив формалізацію правил індуктивного виведення; І. Дмитрів провів аналіз математичної коректності та верифікацію моделей; Н. Іванців виконав збір та структурування емпіричних даних; А. Дячук здійснив програмну апробацію алгоритмів; Т. Місюрак провів порівняльний аналіз отриманих результатів.*

6. Іванотчак О., Мельник В., Бандура В., Петришин Р., Глібчук А., Дмитренко С. Особливості інноваційних методів мультиагентного управління комп'ютерними мережами. Міжнародна науково – практична конференція «Інформаційні технології та комп'ютерне моделювання» ІТСМ-2024, 21-24 травня 2024р., Івано-Франківськ, С.162-165 <https://journal.comp-sc.if.ua/test/index.php/ITSM/article/view/595/39>. *Здобувач дослідив особливості застосування мультиагентного підходу для управління сучасними комп'ютерними мережами, обґрунтував переваги децентралізованого прийняття рішень у динамічних мережеских структурах та запропонував структуру інтелектуального агента для моніторингу трафіку; В. Мельник забезпечив загальне наукове керівництво дослідженням; В. Бандура виконала аналіз існуючих протоколів взаємодії агентів; Р. Петришин здійснив формалізацію стратегій кооперації агентів на основі теорії ігор; А. Глібчук провів комп'ютерне моделювання роботи мультиагентної системи; С. Дмитренко провів аналіз ефективності впровадження інноваційних методів.*

7. О.М. Іванотчак., В.Д. Мельник, Д.І. Толочко, В.В. Бандура, Н.Т. Іванців, І.Я Дмитрів, Інтелектуальна діагностика та корекція керуючих впливів у багатоагентних системах для енергетики та нафтогазовидобувної галузі. Матеріали Всеукр. наук.-практ. конф. молодих учених і студентів «Інформаційні технології в освіті, техніці та промисловості», 09 жовтня 2025 р., Івано-Франківськ: ІФНТУНГ, 2025. – С.119-120. – DOI: <https://doi.org/10.5281/zenodo.17295363>. *Здобувач розробив підходи до інтелектуальної діагностики та алгоритми корекції керуючих впливів у багатоагентних системах, адаптовані до складних умов функціонування об'єктів енергетики та нафтогазового комплексу; В. Мельник здійснив моделювання процесів взаємодії агентів у нафтогазовидобувній галузі; Д. Толочко виконав аналіз специфіки енергетичних систем та визначив ключові критерії ефективності керуючих впливів; В. Бандура забезпечила наукове консультування та методологічне обґрунтування застосування агентно-орієнтованого підходу; Н. Іванців провів систематизацію типових помилок та відхилень у роботі багатоагентних систем для формування бази знань підсистеми корекції; І. Дмитрів здійснив перевірку математичної стійкості моделей та виконав верифікацію результатів дослідження.*

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ ТА ТЕРМІНІВ	17
ВСТУП.....	20
РОЗДІЛ 1. СУЧАСНІ РЕАЛІЗАЦІЇ КОМП'ЮТЕРНИХ СИСТЕМ МОНІТОРИНГУ ТА КОНТРОЛЮ ПАРАМЕТРІВ ПРОЦЕСУ БУРІННЯ СВЕРДЛОВИН	
1.1. Огляд комп'ютерних систем моніторингу та керування процесом буріння свердловин	26
1.2. Особливості застосування хмарних та периферійних обчислень в цифрових системах підтримки прийняття рішень	27
1.3. Аналіз інформативних параметрів процесу буріння при ідентифікації передаварійних ситуацій.....	41
1.4. Вибір і обґрунтування напрямку досліджень	44
1.4. Вибір і обґрунтування напрямку досліджень	50
РОЗДІЛ 2. МЕТОДОЛОГІЧНІ ТА СТРУКТУРНІ РІШЕННЯ НЕЙРОМЕРЕЖЕВИХ СИСТЕМ ДЛЯ ПРОЦЕСУ БУРІННЯ НГС	
2.1. Структура та цільова функція навчання нейронної мережі	52
2.2. Методи попереднього опрацювання та очищення даних	69
2.3. Визначення ключових параметрів системи підтримки прийняття рішень	77
Висновки до другого розділу.....	85
РОЗДІЛ 3. РОЗРОБКА СТРУКТУРНИХ ТА АЛГОРИТМІЧНИХ РІШЕНЬ КОМП'ЮТЕРНОЇ СИСТЕМИ ППР В БУРІННІ НГС.....	
3.1. Структура комп'ютерної системи підтримки прийняття рішень	87
3.2. Алгоритм ідентифікації передаварійних ситуацій	92
3.3. Модель прогнозування механічної швидкості проходки для оптимізації параметрів режиму буріння	102
3.4. Структура та контент гібридної бази знань	112

3.5. Навчання та верифікація моделі CNN-LSTM при ідентифікації передаварійних ситуацій	119
Висновки до третього розділу	126
РОЗДІЛ 4. РЕАЛІЗАЦІЯ ТА ТЕСТУВАННЯ КОМП'ЮТЕРНОЇ НЕЙРОМЕРЕЖЕВОЇ СИСТЕМИ ППР У ПРОЦЕСІ БУРІННЯ НГС	
4.1. Загальна структура комп'ютерної СППР	128
4.2. CNN-LSTM модель та багаторівнева система адаптації	135
4.3. Програмна реалізація системи підтримки прийняття рішень	138
4.4. Функціональне тестування СППР при різних сценаріях буріння	142
Висновки до четвертого розділу	150
ВИСНОВКИ.....	153
ПЕРЕЛІК ПОСИЛАНЬ НА ДЖЕРЕЛА	155
ДОДАТКИ.....	170

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ ТА ТЕРМІНІВ

- BCE - Binary Cross-Entropy - Бінарна перехресна ентропія
- CCA - Cuttings Concentration in the Annulus - Концентрація бурового шламу в затрубному просторі
- CNN - Convolutional Neural Network - Згортокова нейронна мережа
- CPS - Cyber-Physical System - Кіберфізична система
- CTR_m - Mud Cuttings Transport Ratio - Коефіцієнт перенесення бурового шламу
- DDA - Directional Drilling Advisor - Система консультування по скерованому бурінню
- DDP - Digital Drilling Program - Цифрова програма буріння
- DMZ - Demilitarized Zone - Демілітаризована зона
- DWP - Digital Well Planning - Цифрове планування свердловин
- EC_{Deff} - Effective Equivalent Circulating Density - Ефективна еквівалентна циркуляційна густина
- FIFO - First-In, First-Out - "Першим прийшов - першим пішов" (принцип обробки даних)
- Flow (In/Out) - Flow Rate - Витрата промивальної рідини (на вході/ виході)
- GPU - Graphics Processing Unit - Графічний процесор
- HCI - Hole Cleaning Index - Індекс несучої здатності бурового розчину (очищення стовбура)
- HKLD - Hook Load - Вага на гаку
- HMI - Human-Machine Interface - Людино-машинний інтерфейс
- ICS - Industrial Control Systems - Промислові системи управління
- IDS - Intrusion Detection Systems - Системи виявлення вторгнень
- LLM - Large Language Models - Великі мовні моделі
- LSTM - Long Short-Term Memory - Довга короткострокова пам'ять
- LWD - Logging While Drilling - Каротаж під час буріння

- MAE - Mean Absolute Error - Середня абсолютна помилка
- MLP - Multi-Layer Perceptron - Багатошаровий перцептрон
- MSE - Mean Squared Error - Середньоквадратична помилка (як функція втрат)
- MSE - Mechanical Specific Energy - Питома механічна енергія
- MWD - Measurement While Drilling - Вимірювання під час буріння
- MWeff - Effective Mud Weight - Математична модель ефективної густини бурового розчину
- NPT - Non-Productive Time - Непродуктивний час
- OT - Operational Technology - Операційні технології
- ReLU - Rectified Linear Unit - Випрямлена лінійна одиниця (функція активації)
- RMSE - Root Mean Squared Error - Корінь із середньоквадратичної помилки
- ROP - Rate of Penetration - Механічна швидкість проходки
- RPM - Revolutions Per Minute - Частота обертання (оберти за хвилину)
- Rule-based DSS - Rule-based Decision Support System - Система підтримки прийняття рішень на основі правил
- SMOG-N - Synthetic Minority Over-sampling Technique for Regression with Gaussian Noise - Регресія з гаусовим шумом
- SNR - Signal-to-Noise Ratio - Відношення сигналу до шуму
- Softmax - Softmax Activation Function - Функція активації для отримання імовірнісного розподілу
- SPP - Standpipe Pressure - Тиск у маніфольді (буровому стояку)
- TIm - Transport Index of Mud - Індекс перенесення бурового розчину
- Torque - Drilling Torque - Крутний момент на роторі або ВСП
- WITSML - Well-site Information Transfer Standard Markup Language - Стандартна мова розмітки для передачі інформації бурового майданчика
- WOB - Weight on Bit - Осьове навантаження на долото
- XAI - Explainable Artificial Intelligence - Пояснювальний штучний інтелект
- АБП - автономна бурова платформа

ГТД - геолого-технологічні дослідження

КНБК - компонування низу бурильної колони

НГС – нафтогазова свердловина

СППР - система підтримки прийняття рішень

ВСТУП

Обґрунтування вибору теми досліджень.

У сучасних умовах розвитку нафтогазової галузі особливого значення набуває підвищення функціональних можливостей комп'ютерних систем, що забезпечують супровід процесу буріння нафтогазових свердловин. Висока динамічність технологічних параметрів, значні обсяги телеметричних даних та жорсткі вимоги до оперативності їх опрацювання зумовлюють необхідність створення комп'ютерних засобів, здатних забезпечувати своєчасний аналіз поточного стану процесу та інформаційну підтримку оператора під час прийняття рішень.

Традиційні комп'ютерні системи моніторингу буріння переважно виконують функції візуалізації та пасивної реєстрації даних, працюючи за жорстко детермінованими пороговими алгоритмами. Основними проблемами таких систем є:

1. Високий рівень «шуму» та стохастичність сигналів, що призводить до великої кількості хибних тривог.
2. Значна затримка при обробці даних у хмарних сервісах, що недопустимо для запобігання миттєвим аваріям (наприклад, ГНВП).
3. Ефект «чорної скриньки» інтелектуальних модулів, що знижує довіру оператора до рекомендацій комп'ютерної системи.

З огляду на це, актуальним науково-технічним завданням комп'ютерної інженерії є розробка комп'ютерної нейромережевої системи підтримки прийняття рішень (СППР), яка базується на гібридних архітектурах глибокого навчання (CNN-LSTM). Такий підхід дозволяє поєднати здатність згорткових мереж до екстракції просторових ознак із потужністю рекурентних шарів у моделюванні динамічних часових послідовностей. Створення такої системи забезпечує перехід від констатації фактів до предиктивного керування, що мінімізує ризики аварій та оптимізує техніко-економічні показники буріння.

Аналіз останніх досліджень та публікацій. Питанням комп'ютеризації, моделювання та інтелектуалізації процесів буріння присвячено численні праці провідних вітчизняних та закордонних вчених.

Фундаментальні основи математичного опису процесів руйнування гірських порід, класичні моделі механічної швидкості проходки та комп'ютеризації процесу буріння розроблені у працях А. Т. Bourgoyne, F. S. Young, J. Warren та вітчизняних вчених В.Г.Вітрика, Р.С.Яремійчука, В.С.Білецького, Л.М.Заміховського, М.І.Горбійчука, Г.Н.Семенцова, Я.Р.Когуча та ін.

Проблематику цифрової трансформації нафтогазової галузі та впровадження інтелектуальних систем аналізу даних досліджували такі вчені, як E. Cayeux, K. Gray, S. Hegde, Y. Zhang. Зокрема, у їхніх роботах висвітлено переваги використання методів машинного навчання для прогнозування ускладнень.

Вагомий внесок у розвиток теорії комп'ютерних систем, архітектур нейронних мереж та методів обробки великих даних, що стали базисом для даного дослідження, зробили Y. LeCun, I. Goodfellow, F. Chollet, а також українські фахівці в галузі інформаційних технологій: О.А.Дорошенко, В.В. Литвинов, Ю.П. Шабанов-Кушнарченко.

Проте, незважаючи на значну кількість напрацювань, питання побудови гібридних архітектур (CNN-LSTM) з інтегрованими механізмами пояснювального ШІ та їх реалізація у формі периферійних комп'ютерних систем для специфічних умов буріння свердловин залишаються недостатньо вивченими. Саме цей напрямок обрано як пріоритетний у даній дисертаційній роботі.

Зв'язок роботи з науковими програмами, планами, темами. Вибраний напрямок досліджень є складовою частиною тематичного плану Івано-Франківського національного технічного університету нафти і газу (ІФНТУНГ) і базується на результатах виконання науково-дослідних тем:

- «Наукові засади побудови інтелектуальних інформаційних технологій контролю та управління об'єктами та процесами нафтогазової інженерії на

основі методів баз даних, баз знань та хмарних сховищ» (№ держ. реєстрації 0121U113584) 2021-2023 рр;

- «Інформаційні технології та програмні сервіси сталого розвитку енергетики України» (№ держ. реєстрації 727131) 2024-2026 рр;

Мета і задачі досліджень. Метою дисертаційного дослідження є підвищення ефективності та безпеки процесу буріння нафтогазових свердловин шляхом розробки та впровадження комп'ютерної нейромережевої системи підтримки прийняття рішень, що базується на гібридній CNN-LSTM структурі для предиктивної ідентифікації передаварійних ситуацій.

Для досягнення поставленої мети визначено такі основні наукові задачі:

1. Провести аналіз сучасних реалізацій комп'ютерних систем моніторингу та контролю параметрів процесу буріння свердловин та залучених інформаційних технологій, а також розглянути особливості застосування хмарних та периферійних обчислень в цифрових системах підтримки прийняття рішень;
2. Розробити математичний опис процесу буріння як джерела даних, представлених багатовимірними часовими рядами, для формування репрезентативного вектору ознак;
3. Обґрунтувати та спроектувати гібридну нейромережеву структуру CNN-LSTM, здатну одночасно здійснювати екстракцію просторових ознак та моделювати довготривалі часові залежності параметрів буріння;
4. Розробити алгоритм ідентифікації передаварійних ситуацій на основі імовірнісного виведення та фільтрування хибних спрацювань для підвищення надійності системи;
5. Сформувати модель прогнозування механічної швидкості проходки та алгоритм пошуку оптимальних режимів буріння через побудову динамічних поверхонь відгуку.
6. Розробити структуру гібридної бази знань для навчання та верифікації моделі CNN-LSTM при ідентифікації передаварійних ситуацій;

7. Розробити людино-машинний інтерфейс із використанням принципів когнітивної фільтрації для візуалізації результатів роботи системи;
8. Провести експериментальну апробацію розробленої системи, а також оцінити її функціональність при різних сценаріях експлуатації.

Об'єктом дослідження є процес опрацювання даних комп'ютерної нейромережевої системи підтримки прийняття рішень супроводу процесу буріння нафтогазових свердловин.

Предметом дослідження є методи та засоби виявлення передаварійних ситуацій процесу буріння НГС на основі опрацювання параметрів буріння, представлених часовими рядами, нейромережевими компонентами комп'ютерних систем.

Методи дослідження: Основні наукові результати отримано на основі використання теорії динамічних систем, торій імовірносте та матстатистики, методів реалізації хмарних та периферійних обчислень, методів опрацювання часових рядів, теорії штучних нейронних мереж та машинного навчання, методів моделювання в обчислювальному експерименті, а також методів експериментального тестування та валідації.

Наукова новизна отриманих результатів визначається такими положеннями:

- вперше розроблено метод адаптивної ідентифікації передаварійних ситуацій, що базується на комбінації імовірнісного виведення Softmax та дворівневого математичного фільтра хибних тривог. Метод дозволяє динамічно враховувати технологічний контекст (операції нарощування, промивки) та знизити рівень помилкових спрацювань системи на 15–20%;

- удосконалено методику агрегації гіперпараметрів аналітичного ядра через застосування Байєсівської оптимізації на основі Гаусівських процесів, що на відміну від типових методів випадкового пошуку, дозволило скоротити час навчання моделі на GPU-орієнтованих архітектурах та підвищити точність за обмеженого обсягу наборів навчальних даних;

- набули подальшого розвитку методи формування багатовимірних векторів ознак даних телеметрії буріння шляхом включення динамічних похідних та гідродинамічних показників у вхідний тензор, що дало змогу CNN-шарам ефективніше виявляти просторові кореляції між механічними параметрами та гідравлічним станом свердловини;

- набули подальшого розвитку методи оцінки надійності прогнозів ШІ шляхом розділення епістемічної та алеаторичної невизначеності, що дозволило супроводжувати кожен рекомендацію кількісним показником довіри, що є необхідною умовою для безпечної експлуатації комп'ютерних систем у складних геологічних умовах.

Практичне значення отриманих результатів:

- розроблено прикладне програмне забезпечення на основі FastAPI та моделей глибокого навчання, яке реалізує повний цикл опрацювання телеметричних даних: від збору до формування рекомендацій. Прототип може бути інтегрований у діючі наземні станції геолого-технологічних досліджень (ГТД) без докорінної зміни їх апаратної частини;

- розроблено алгоритми ідентифікації передаварійних ситуацій (прихоплення колони, поглинання розчину, ГНВП), які дозволяють виявляти ознаки зародження аварій на етапі їх прихованого розвитку, що дозволяє збільшити час для виконання превентивних дій та зменшити витрати на ліквідацію наслідків аварій;

- розроблено алгоритми побудови поверхонь відгуку та ідентифікації екстремумів у реальному часі, що дозволяє оператору підтримувати оптимальні режими буріння, сприяє подовженню терміну експлуатації бурових доліт за рахунок зменшення шкідливих вібрацій;

- розроблена гібридна база знань та людино-машинний інтерфейс, що можуть бути використані як типові рішення для проектування НМІ-систем у нафтогазовій галузі. Принципи когнітивної фільтрації дозволяють знизити психофізичне навантаження, що зменшує імовірність помилок, спричинених "інформаційним перевантаженням";

- розроблені структурні, алгоритмічні та інтерфейсні рішення впроваджені у навчальний процес, зокрема в дисципліні "Web-базовані інтелектуальні додатки та сервіси" для студентів спеціальностей 121 "Інженерія програмного забезпечення" та 123 "Комп'ютерна інженерія" (акт впровадження – додаток Г).

Особистий внесок здобувача. Основні результати теоретичних і практичних досліджень, які є змістом дисертаційної роботи, одержані автором особисто. У наукових працях, виконаних у співавторстві автору належить:

[1] - розробка концептуальних засад побудови нейромоделей для вирішення задач підтримки прийняття рішень, теоретичне обґрунтування структури нейронних мереж,

[2] - дослідження особливості задач класифікації на множині контенту та розробка концептуальних підходів до їх вирішення засобами індуктивного логічного програмування для підвищення інтелектуалізації систем,

[3] – дослідження особливостей застосування мультиагентного підходу для управління сучасними комп'ютерними мережами, обґрунтування переваги децентралізованого прийняття рішень у динамічних мережевих структурах,

[4] - розробка підходів до інтелектуальної діагностики та алгоритмів корекції керуючих впливів у багатоагентних системах, адаптовані до складних умов функціонування об'єктів енергетики та нафтогазового комплексу.

Апробація результатів дисертації.

Наукові результати дисертації висвітлені у 7 наукових публікаціях здобувача, серед яких: 4 статті у наукових виданнях, включених на дату опублікування до переліку наукових фахових видань України. Матеріали дисертації доповідались на 3 наукових конференціях і опубліковані у вигляді тез доповідей.

Структура та об'єм роботи. Дисертація складається із вступу, чотирьох розділів основної частини, висновків, списку використаних джерел, додатків. Загальний обсяг друкованого тексту становить 191 сторінку, з них: 154 сторінки основного тексту, 27 рисунків, 8 таблиць, список використаних джерел, що містить 120 найменувань на 15 сторінках, 5 додатків на 22 сторінках.

РОЗДІЛ 1

СУЧАСНІ РЕАЛІЗАЦІЇ КОМП'ЮТЕРНИХ СИСТЕМ МОНІТОРИНГУ ТА КОНТРОЛЮ ПАРАМЕТРІВ ПРОЦЕСУ БУРІННЯ СВЕРДЛОВИН

Комп'ютерні системи, що забезпечують супровід процесу буріння нафтогазових свердловин, відіграють ключову роль у забезпеченні його ефективності та безпеки в умовах високої динамічності технологічних параметрів і значних обсягів телеметричних даних. До ключових параметрів буріння, що потребують безперервного контролю, належать механічна швидкість проходки (ROP), частота обертання бурильної колони (RPM), навантаження на долото (WOB), крутний момент, витрата бурового розчину, тиск у стояку (SPP) та вібраційні характеристики [2]. Сам по собі моніторинг параметрів є лише базовою функцією комп'ютерного супроводу, оскільки забезпечення безпечного та ефективного буріння потребує не лише фіксації змін стану процесу, а й їх оперативної інтерпретації для підтримки прийняття рішень [3].

Складність процесу буріння, значна кількість взаємопов'язаних параметрів, висока динамічність режимів роботи та обмежений час на прийняття рішень зумовлюють підвищені вимоги до функціональних можливостей комп'ютерних систем супроводу бурових робіт [2]. У таких умовах оператор змушений обробляти великі обсяги різномірної телеметричної інформації, що надходить у режимі реального часу, ускладнюючи своєчасне виявлення критичних відхилень і підвищуючи ризик помилкових або запізнених рішень. Це особливо актуально для задач ранньої ідентифікації ускладнень і передаварійних ситуацій, де затримка в інтерпретації даних або некоректна оцінка їх динаміки може призвести до порушення технологічного режиму буріння та зниження ефективності процесу [4].

Через окреслені проблеми в галузі набувають поширення комп'ютерні системи моніторингу та підтримки прийняття рішень у процесі буріння, а також цифрові платформи для планування спорудження і контролю технічного стану

свердловин. Центральним компонентом системи є контролер, який відстежує параметри отримані від комплексу датчиків на буровій установці та керує наявним обладнанням [4].

1.1. Огляд комп'ютерних систем моніторингу та керування процесом буріння свердловин

Комп'ютерна система супроводу буріння включає технології моніторингу, виявлення передаварійних ситуацій, діагностики, консультування та управління [5]. Логіка функціонування системи підтримки прийняття рішень може бути адаптована до різних рівнів операційного ризику, що дозволяє динамічно сегментувати та розробляти стратегії виконання на основі бажаного балансу між продуктивністю та безпекою [6]. На сьогодні відомо багато комп'ютерних рішень із різним рівнем інтеграції з цифровими програмами буріння та центрами віддаленого керування. До прикладу автори [7] представили програмно-апаратне рішення бурового майданчика, що здатне організувати роботу необмеженої кількості машин у безперервну послідовність, а також взаємодіяти з іншими додатковими рішеннями комп'ютерних систем, що дозволяють повністю інтегрувати їх у безперервний процес спорудження свердловин, керований цифровими засобами.

Управління машинами та процесами здійснюється на окремому рівні комп'ютерної системи, при цьому всі базові машини зберігають свою вихідну логіку управління та функції безпеки, що гарантує цілісність та безпеку кожної машини у будь-який момент часу, незалежно від режиму взаємодії з центральною комп'ютерною системою.

Сьогодні критично важливо враховувати взаємодію людини і машин з комп'ютерними системами обробки даних в бурових роботах через наступні фактори (рисунок 1.1) [8]:

- взаємодію людини і машини: оптимальне поєднання машинного та людського мислення має вирішальне значення для ефективної взаємодії людини

й машини. Інтерфейси «людина–машина», оптимізовані для конкретних завдань, вважаються ключовими для досягнення такої взаємодії під час буріння свердловин за поточними та майбутніми траєкторіями;

- людський контроль і ухвалення рішень: хоча комп'ютерні системи обробки даних КСО здатні опрацьовувати великі обсяги даних і надавати цінну інформацію, людський контроль та ухвалення рішень залишаються вкрай важливими. Люди краще справляються з індуктивним мисленням і прийняттям рішень в умовах високої невизначеності, що є критично важливим у нафтогазових операціях. Саме люди мають відповідати за контроль КСО, інтерпретацію їхніх результатів і прийняття важливих рішень на основі наданої цими платформами інформації;

- управління та контроль: оператори відповідають за інтеграцію платформ AI у загальну систему управління та контролю, забезпечуючи, щоб AI доповнював людське ухвалення рішень і операційні цілі.

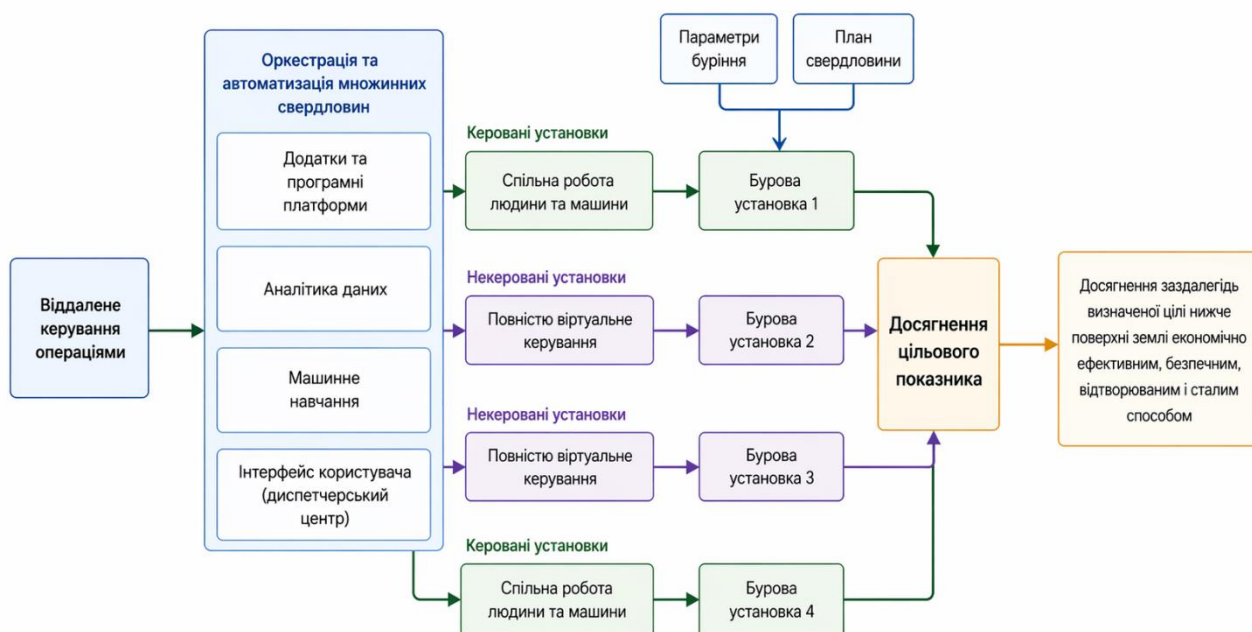


Рисунок 1.1. Структура взаємодії людини та машини у бурових роботах

Вибір режиму прийняття рішень — ручного, комп'ютеризованого або інтелектуального — залежить від обсягу та змісту інформації, що надходить від датчиків бурового обладнання [9]. Зважаючи на сучасні об'єми даних, як історичних так і тих, які отримуються в режимі реального часу поширення набувають комплексні цифрові процеси буріння свердловин.

Комплексний цифровий процес буріння створює DDP (Digital Drilling Program), розміщений на платформі спільної роботи [54]. Ця платформа поєднує критично важливі дані з різних дисциплін проектування свердловин, включаючи специфікації бурових розчинів, плани скерованого буріння, аналіз стійкості стовбура свердловини, конструкцію компоновання низу бурильної колони (КНБК) та обсадних колон, а також досвід, отриманий під час попередніх бурових робіт. Отримана DDP поширюється в хмарній екосистемі, забезпечуючи доступ до даних у режимі реального часу та інтеграцію з іншими додатками для ефективного прийняття рішень, а також є вхідними даними для комп'ютерної системи буріння [10].

Автори [11] представили інтегровану цифрову платформу планування буріння свердловин Digital Well Planning (DWP) яка представляє собою комплексне рішення для проектування свердловин, що поєднує розрізнені програмні продукти та готові до використання робочі процеси. Ці робочі процеси охоплювали багато важливих аспектів, включаючи аналіз сусідніх свердловин, планування траєкторії, розміщення геологічних цілей, проектування обсадних і трубних труб, вибір бурильної колони та бурового розчину, оцінку часу та вартості буріння свердловин, оцінку ризиків та створення остаточних програм буріння [11].

Разом із комп'ютерними системами буріння широко застосовуються системи консультування з буріння Drilling Advisory System (DAS) [2] (рисунок 1.2). Вони отримують критично важливі вхідні дані, включаючи характеристики КНБК, властивості бурового розчину, геофізичні та геомеханічні, а також діапазони параметрів буріння від DDP. DAS насамперед орієнтовані на

запобігання незапланованим подіям [10]. Консультування з питань буріння в режимі реального часу може бути двояким [12]:

- діагностичним - діагностика передбачає виявлення потенційних ризиків чи небезпек на основі моніторингу поведінки буріння в режимі реального часу та пов'язаних із цим заходів щодо усунення проблем;

- оптимізаційним – передбачає оптимізацію робочих параметрів для досягнення більшої ефективності буріння у межах безпечних діапазонів. Вона зазвичай необхідна для процесів буріння, підйому та спуску бурових колон, а також опускання колон для підвищення ефективності.

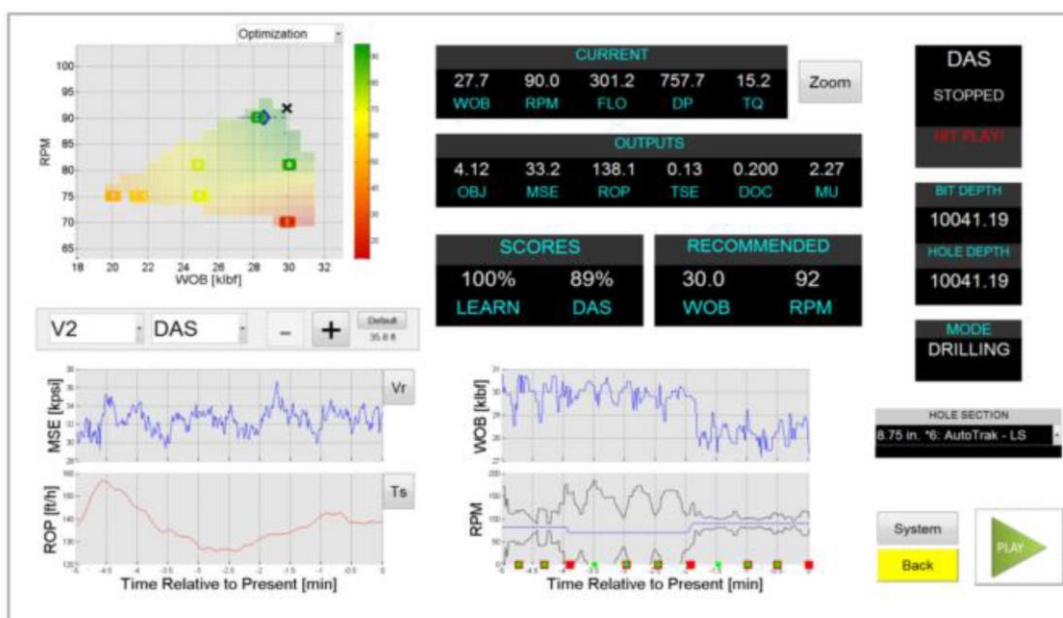


Рисунок 1.2. Копія екрану системи DAS, що показує графік оптимізації у верхньому лівому кутку, з перевагою областей, заштрихованих зеленим кольором [2, 13]

Ключове завдання DAS систем при бурінні свердловин – виявлення покращених або близьких до оптимальних показників буріння, що відповідають поточному пласту шляхом аналізу тенденцій [14]. До основних завдань систем консультування з буріння також можна віднести використання всіх доступних даних та передових моделей для моніторингу, контролю та оптимізації процесу буріння [15]. Параметри буріння повинні змінюватися з достатньою частотою,

щоб тенденція залишалася актуальною для бурових робіт, а рекомендації повинні бути послідовними і надходити із розумною частотою (інтервал біля 5 хв.), щоб бурильник міг враховувати та реагувати на зворотний зв'язок [14]. Кінцевою метою таких систем є забезпечення більш безпечної та ефективної роботи бурових установок/операцій [16]. Як стверджують автори [16] завдяки DAS бурова установка/бригада зможуть швидше реагувати на відхилення від норми, що дозволить підвищити ефективність роботи та уникнути непродуктивного часу при бурових роботах. До того ж досвід авторів [17] показує, що такі системи консультування доцільно доповнювати системами комп'ютерного зору для більш зручного і оперативного виявлення зміни ситуації чи стану процесу на буровому майданчику.

Нижче наведемо деякі відомі консультаційні системи, що використовуються в галузі з метою покращення операційної ефективності та зменшення втрат часу на непродуктивні операції (ліквідація ускладнень, аварій, простої, порушення логістики постачань, тощо).

Система консультацій з буріння ExxonMobil (DAS™) – це платформа для моніторингу та оптимізації буріння, що встановлюється на буровій установці для відстежування ефективності буріння та надання рекомендацій щодо керованих параметрів буріння для покращення загального процесу буріння працюючи в реальному часі і призначена для взаємодії з існуючою інфраструктурою [13].

Система консультування по бурових розчинах [18] – це інструмент підтримки прийняття рішень, що являє собою самонавчальну система консультування. Дана система створює робочий процес, який включає автоматичне виявлення критично важливих точок прийняття рішень з обробки рідини та може автономно приймати рішення про необхідність проведення дообробки із одночасним розрахунком необхідних об'ємів (для досягнення мети обробки). Крім того, консультант у автоматичному режимі виявляє наявність забруднюючих речовин у рідині та будь-які операції на буровій установці, що впливають на промивну систему (стан рідини). Це досягається за допомогою гібридної моделі даних та фізики, створеної з використанням послідовного планування експерименту, у поєднанні з великою

експериментальною роботою з підбору рецептур промивальних рідини в тому числі із включенням забруднюючих речовин та твердих частинок низької густини. Вихідні дані проходять перевірку та попередню обробку, включно з усуненням пропусків і виявленням викидів, після чого виконують нормалізацію для забезпечення коректного навчання нейронної мережі. Можливості інтегрованого комп'ютерного конвеєра наведено на рисунку 1.3 [18].

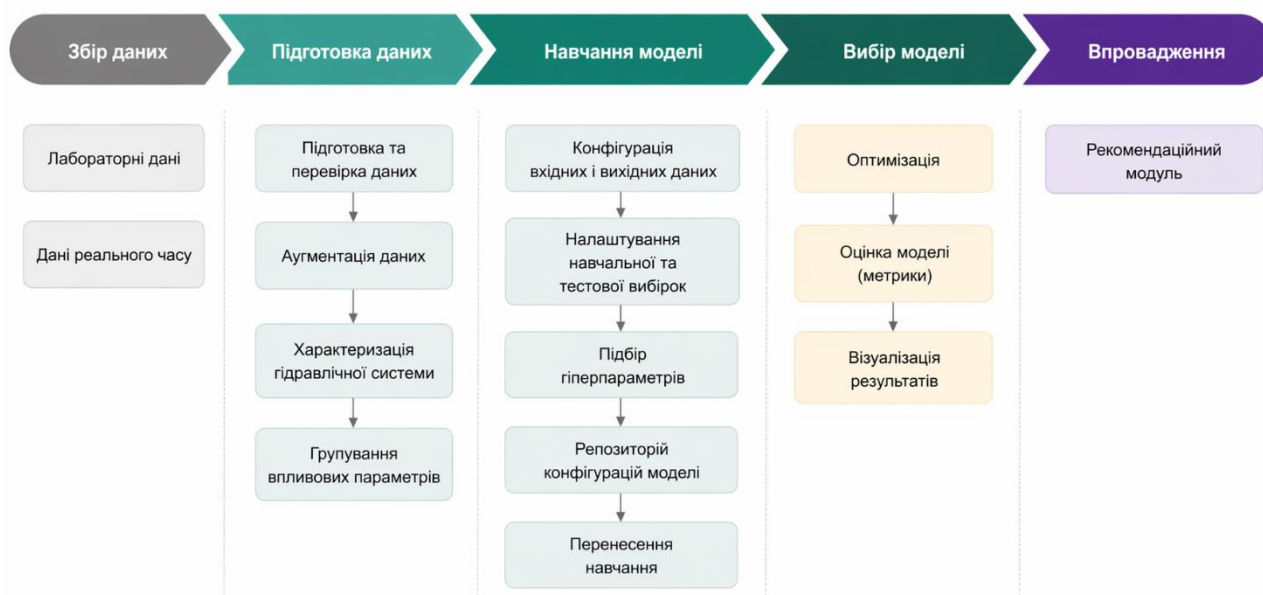


Рисунок 1.3. Структура інтегрованого модуль машинного навчання для системи підтримки прийняття рішень щодо бурових розчинів

Ключові особливості конвеєра обробки даних, такі як оптимізація гіперпараметрів, розширення даних та використання передових методів, наприклад, методу синтетичної передискретизації меншості для регресії з гаусовим шумом (SMOG-N), сприяють надійності та точності моделей. Можливість налаштування різних аспектів конвеєра, включаючи розбиття на навчальну та тестову вибірки, зіставлення продуктів та функції втрат, гарантує, що система може бути адаптована до конкретних операційних потреб та завдань [18].

Система консультацій щодо очищення свердловини в режимі реального часу [19]. Інформаційне забезпечення системи відбувається шляхом аналізу історичних даних, даних датчиків бурової установки та інших польових даних (MWD/LWD - Measurement While Drilling / Logging While Drilling). Спеціально розроблені математичні моделі густини бурового розчину (MW_{eff}), еквівалентної циркуляційної густини ($ECDeff$), індексу несучої здатності бурового розчину (HCI), концентрації бурового шламу в затрубному просторі (CCA), коефіцієнту перенесення бурового розчину (CTR_m) та індексу перенесення бурового розчину (TI_m) інтегруються з штучними нейронними мережами (ANN - Artificial Neural Network, DT - Decision Trees, SVM - Support Vector Machines) та штучним інтелектом для оптимізації очищення стовбуру свердловини і швидкості проходки.



Рисунок 1.4. Система консультацій щодо очищення свердловини в режимі реального часу [19]

Приклад інформаційних панелей системи показано на рисунках 1.4 та 1.5. Основні технологічні параметри процесу поглиблення свердловини виводяться одночасно із прогностичними значеннями показників якості очищення стовбуру, які надаються розробленими моделями разом із інформаційними та alert-сповіщеннями.

Система консультацій з очищення свердловини в режимі реального часу надає інтуїтивно зрозумілу візуалізацію кольорів ризиків (рисунок 1.5) для критично важливих параметрів буріння, що дозволяє приймати негайні та обгрунтовані рішення. Це забезпечує мінімізацію втрат часу на ліквідацію ускладнень та підвищує ефективність буріння.

Випадок	ССА _{ам}	НСІ	СТР _м	ТІ _м	Модифікація випадку
1					Оптимізовано
2					Збільшити GPM, збільшити ROP
3					Зупинити буріння, оглянути свердловину та розчин
4		Або	Або	Або	Контроль ROP
5	Або		Або	Або	Оптимізувати реологічні властивості
6	Або	Або		Або	Збільшити GPM
7	Або	Або			Оптимізувати реологічні властивості
8			Або	Або	Контроль ROP, оптимізувати реологічні властивості
9		Або		Або	Контроль ROP, збільшити GPM
10		Або	Або		Контроль ROP, оптимізувати реологічні властивості
11	Або			Або	Оптимізувати реологічні властивості, збільшити GPM
12	Або		Або		Оптимізувати реологічні властивості, збільшити GPM
13	Або	Або			Оптимізувати реологічні властивості, збільшити GPM
14	Або				Оптимізувати реологічні властивості, збільшити GPM, контроль ROP
15		Або			Контроль ROP, збільшити GPM, оптимізувати реологічні властивості
16			Або		Контроль ROP, збільшити GPM, оптимізувати реологічні властивості
17				Або	Контроль ROP, збільшити GPM, оптимізувати реологічні властивості

Рисунок 1.5. Візуалізація матриці ризиків консультативної системи [19]

Система класифікує ризики для CTRm, CCAm, HCI та TIm (червоний: високий ризик; жовтий: прийнятний/вимагає моніторингу; зелений: оптимізований) [19].

Система консультування по скерованому бурінню (Directional Drilling Advisor – DDA) зазвичай являє собою інтегрований додаток, здатний виконувати повний цикл робіт з похило-скерованого буріння, а саме збір поверхневих даних з бурової установки та даних із свердловини за допомогою системи RSS, аналіз тенденцій буріння бурової колони та антиколіжін-аналіз [20]. Система на основі вхідних даних дозволяє згенерувати максимальну кількість кандидатів на траєкторію свердловини з різними умовами відповідно до заданого напрямку, а також з урахуванням обмежень траєкторії, таких як [21]: допустиме відхилення від початкового плану; максимальна здатність кермового механізму до вигину; рекомендовані обмеження, що визначаються автоматичним аналізом плану, які можуть бути змінені користувачами відповідно до їх уподобань; допустима звивистість, ризик, якість свердловин, рівень впевненості тощо.

Потім системою проводиться оцінка кожного кандидату на основі контексту траєкторії, різних властивостей, порушень обмежень та ранжування всіх доступних кандидатів відповідно до певної мети оптимізації, яка може бути надана на етапі інтелектуального планування. Як результат можна отримати або одного найкращого кандидата, або кілька найкращих кандидатів, які можуть бути представлені або користувачеві, або схемі ML, залежно від режиму функціонування системи [21].

Окрім консультативних систем в галузі для прийняття рішень застосовують також різноманітні експертні системи, що використовують експертні знання і досвід з метою вирішення оптимізаційних задач. Експертна система спирається на базу знань та механізм виведення, імітуючи людський інтелект [22]. База знань містить упорядкований набір фактів про задачі, що вирішується, зазвичай у формі правил «якщо-то», з прикріпленням до них коефіцієнтом ймовірності для компенсації невизначеності прийнятих рішень. Основи знань середньостатистичної експертної системи містять тисячі правил.

Другим компонентом експертної системи є механізм виведення, який інтерпретує та оцінює факти в базі знань для вироблення відповіді. Крім правил «якщо-то», які також називаються правилами видобутку, експертні системи можуть використовувати евристичні правила, або «правила великого пальця», що дозволяє системі вчитися на досвіді [22].

Досить поширеними є експертні системи з вибору компонентів бурових розчинів, побудови траєкторії свердловини, тощо. Так, дослідниками [23] запропонована експертна система для вибору рецептур промивальних рідин на основі байєсовської мережі прийняття рішень (BDN), яка використовує такі вхідні дані, як температура і тиск, для рекомендації рецептур бурових розчинів на основі ймовірнісних байєсівських визначень. Автори [24] пропонують експертну систему на основі штучного інтелекту для оптимізації рецептур бурових розчинів із використанням великих мовних моделей (LLM). Дана система виконує аналіз історичних даних про бурові розчини та оперативних записів для виявлення основних закономірностей коригування, інтеграції логістики з урахуванням витрат, а також надання підтримки прийняття рішень у режимі реального часу для інженерів на місцях з метою підвищення ефективності та скорочення непродуктивного часу (NPT). Загалом інтелектуальна експертна система з бурових розчинів на основі LLM забезпечує ефективне проектування рецептур, точний контроль витрат та науково обґрунтоване прийняття рішень за рахунок глибокої інтеграції штучного інтелекту з експертними знаннями в даній галузі [24].

Дослідники вказують [25] на ефективність нечіткої експертної системи на основі штучного інтелекту при оцінці сценарії високого ризику в роботі бурової установки, спрощуючи процес прийняття рішень та підвищуючи рівень дотримання вимог безпеки. Завдяки її використанню вдалося досягти підвищення ефективності проактивного управління ризиками під час буріння та капітального ремонту свердловин [25].

Найбільш сучасними системами, що допомагають приймати обґрунтовані інженерні і управлінські рішення є інтелектуальні консультаційні системи, що

поєднують експертні знання, дані в режимі реального часу та технології машинного навчання. Наприклад система консультування цементування свердловин Barrier Advisor™ (Halliburton) [26] це – повноцінна інтелектуальна консультаційна система, що використовує технології машинного навчання — кластеризацію та метод k-найближчих сусідів — для надання рекомендацій інженерам щодо оптимізації проєктних рішень при цементуванні свердловин. Система поєднує науково обґрунтовані алгоритми з моделями на основі даних (data-driven models), забезпечуючи передачу експертних знань з подібних робіт по всьому світу та підвищуючи ймовірність операційного успіху [26].

Oliasoft WellDesign [27] – це сучасне хмарне програмне забезпечення для інженерного проєктування свердловин, розроблене норвезькою компанією Oliasoft AS та є комп'ютерною системою цифрового проєктування свердловин з елементами інтелектуальної підтримки прийняття рішень на основі правил (rule-based DSS). Архітектура системи не передбачає застосування апаратів машинного навчання або штучних нейронних мереж. Комп'ютерна підтримка розробки проєктних рішень реалізується шляхом впровадження детермінованих алгоритмів оптимізації, сукупності попередньо встановлених логічних правил та уніфікованих шаблонів. Застосування зазначеного підходу забезпечує скорочення тривалості циклу проєктування на 90% та мінімізує вплив суб'єктивного чинника на виникнення технічних помилок [27].

Деяку порівняльну характеристику консультативних систем представлено в додатку А таблиця А.1.

Більшість систем консультування сьогодні можуть додатково розширені використанням AI-алгоритмів та працювати в автономному режимі [31], фактично перетворюючись в інтелектуальні системи.

Інтенсивний розвиток таких систем за останні 10 років, а також прагнення вирішити проблеми, пов'язані з людським фактором та його впливом на ефективність операцій призвів до появи автономних систем управління тими чи іншими процесами або етапами спорудження (освоєння) свердловин. Серед найбільш відомих:

- автономна система управління буровими розчинами [29] – система для розрахунку оптимальної кількості хімічних добавок з метою автономного приготування розчинів та регулювання таких їх властивостей, як густина, реологія, рН, жорсткість, концентрація хлоридів, співвідношення масло-вода, концентрація твердих частинок низької густини, електрична стабільність та ін. Методологія системи управління буровим розчином включає конвеєр обробки історичних даних, конвеєр навчання для створення моделі властивостей бурового розчину з використанням машинного навчання, комп'ютерний інструмент прогнозу аналітики для вибору моделі і модель, яка визначає кількість добавок, необхідних для досягнення бажаних властивостей бурового розчину, шляхом вирішення задачі оптимізації;

- автономна система похило-скерованого буріння (Autonomous Directional Drilling – ADD) [31] – це комп'ютерна система підтримки прийняття рішень щодо управління свердловиною у процесі її будівництва з використанням удосконаленого планувальника на основі штучного інтелекту та підключених інтелектуальних систем. ADD являє собою безперервний цикл зворотного зв'язку між наземною системою та системою передачі даних, що підвищує узгодженість та ефективність операцій з будівництва свердловини, одночасно знижуючи участь людини та вплив на навколишнє середовище. Максимізація інтелектуального робочого процесу виконання для управління скерованим бурінням потребує засобів комп'ютерної підтримки прийняття рішень, які можуть бути легко інтегровані з інтелектуальним інструментом планування [35]. Ця інтеграція дозволяє використовувати необхідні траєкторії свердловини в цифровому форматі, визначаючи як планові вимоги, так і експлуатаційні допуски. Інтеграція хмарних технологій з операціями на буровому майданчику оптимізує передачу команд, покращуючи точність та скорочуючи затримку під час коригування управління [35]. Перехід до інтелектуального комп'ютерного супроводу виконання робіт спрямований на стандартизацію та оптимізацію операцій, підвищення точності траєкторії, зниження частоти команд передачі даних та мінімізацію звивистості стовбура свердловини [28]. Можливість

автономної бурової платформи керувати траєкторією свердловини задля забезпечення необхідного профілю зазвичай забезпечується роторно-керуваними системами типу Push-the-Bit [36], або аналогічними. До того ж автори [35] стверджують що впровадження автономного скерованого буріння є економічно вигідним і здатне забезпечити економію бурової установки у розмірі 1 дня на свердловину (для великих операторів), а також сприяє скороченню викидів CO₂ на 25 метричних тон на свердловину.

Розвиток таких систем призвів до появи вдосконалених рішень управління буровими установками (NOVOS) та рішеннями для оркестрації (DrillOps). Так за даними авторів [37] удосконалена бурова система управління NOVOS спеціально розроблена для виконання повторюваних операцій, що дозволяє керувати процесом буріння і забезпечувати можливість більш швидкого, безпечного і стабільного спорудження свердловин. Зміщуючи фокус бурильників з управління обладнанням на моніторинг процесу спорудження свердловини, забезпечує більш високий рівень стабільності та безпеки, одночасно оптимізуючи буріння за рахунок інтеграції апаратного та програмного забезпечення, безпосередньо взаємодіючого з системами управління(верхні приводи, лебідки та грязьові насоси) [37]. Крім того, NOVOS здатна обробляти переходи між буровими завданнями, такими як маркування вибою, збільшення або зменшення обертання та витрати розчину, проведення випробувань на тертя, а також дозволяє здійснювати автоматичну передачу даних на інструменти похилоскерованого буріння [37].

Програмні рішення DrillOps™ Advisory та DrillOps Automation – це рішення для управління буровими роботами на буровій установці [38, 39]. DrillOps Automation використовує фізичну модель поведінки долота у поєднанні з моделями штучного інтелекту та передовими методами розпізнавання образів для адаптації в реальному часі до змін інформації та реакції буріння [37]. Відстежуючи дані в реальному часі, такі як навантаження на долото, крутний момент, і глибина буріння, система постійно перекалібровується, визначає оптимальні параметри буріння і автоматично коригує їх в межах безпечних

обмежень, визначених у плані свердловини [37]. DrillOps використовує штучний інтелект за допомогою мови визначення предметної галузі планування (PDDL) для забезпечення можливості міркувань над складними ієрархічними завданнями [40]. Планувальник отримує вхідні дані від різних спеціалізованих механізмів, а також інформацію про поточний стан бурової установки та задану користувачем мету, як правило, буріння до цільової глибини. Потім він обчислює найбільш оптимальну послідовність операцій задля досягнення цієї мети [40]. Наприклад, коли механізм AutoIntegrity виявляє ризик вібрації, він відправляє оповіщення планувальнику на основі AI, а планувальник згодом планує та координує необхідні заходи щодо пом'якшення наслідків і у разі усунення проблеми з вібрацією повертається до процесу оптимізації швидкості буріння до завершення буріння та досягнення цільової глибини [40].

Kantori™ (Bakerhughes) — це уніфіковане цифрове рішення для автономного буріння свердловин, що поєднує штучний інтелект та фізичні моделі з аналізом даних у реальному часі для безперервної оптимізації продуктивності, а також комп'ютерної підтримки процесів планування, виконання та моніторингу сприяючи створенню повноцінної цифрової екосистеми для будівництва свердловин [41]. Такий підхід сприяє швидкому прийняттю рішень із мінімальною участю людини, скорочуючи непродуктивний час та варіативність у ході робіт з будівництва свердловин.

Описані автономні системи часто інтегруються в автономні бурові платформи [33] чи автономні бурові установки з різним рівнем комп'ютеризації (зазвичай 3 - 6). Для керування описаними системами і прийняття рішень по зміні параметрів технології проводки свердловини галузь активно розробляє AI-рішення, деякі з яких (проте далеко не вичерпний перелік) наведено в додатку А в таблиці А.2.

В останні роки для прийняття рішень і автономного управління процесами в нафтогазовій галузі активно розвивають AI-агентні підходи, що фокусуються на динамічних, автономних агентах, здатних приймати рішення в реальному часі, безперервно навчатися і проактивно адаптуватися до змінних умов [42, 44]. На

відміну від традиційних підходів до AI/ML, які часто вимагають заздалегідь визначених моделей та припущень, агентний AI використовує навчання з підкріпленням (RL) та багатоагентні системи для автономної роботи у складних середовищах [42]. Інтеграція фізичних моделей та AI досягається за допомогою інтерактивного циклу, в якому агент буріння на основі AI пропонує дії на основі спостережень із середовища моделювання, а симулятор надає зворотний зв'язок про результати цих дій.

Отже із наведеної інформації можемо зробити висновок, що про здатність автономних системи дистанційно контролювати критичні параметри технологічних процесів при бурових роботах, що вагомо впливає безпеку експлуатації та ризику негативного впливу на навколишнє середовище у разі компрометації компонентів, ресурсів чи інформаційних зв'язків даних систем.

1.2. Особливості застосування хмарних та периферійних обчислень в цифрових системах підтримки прийняття рішень

Для розгортання описаних вище консультативних, інтелектуальних чи автономних систем критично важливо забезпечити збір телеметричної інформації за допомогою сенсорів і давачів, її передавання, аналіз та зберігання. Залежно від умов операційної діяльності і оснащення бурового майданчика, а також із врахуванням віддалі до центрів обробки інформації і прийняття рішень можуть бути застосовані різноманітні архітектурні моделі та технологічні рішення для забезпечення обміну даними. Проте для систем промислового контролю найпоширенішими є хмарні та периферійні обчислення. У порівнянні з централізованим підходом, який збирає всі дані разом для навчання однієї глобальної моделі, децентралізований підхід може знизити продуктивність ресурсомістких моделей машинного навчання, які могли б виграти від об'єднання даних з багатьох граничних вузлів [2].

Щоб використовувати переваги хмарного та периферійного машинного навчання в промисловому інтернеті речей (IIoT), компенсуючи при цьому

недоліки кожного з них, автори [2] пропонують підхід Mesh-навчанням, що забезпечує масштабовану аналітику в хмарі та/або на периферійних вузлах. Крім забезпечення гнучкого перемикавання між централізованою хмарною аналітикою та децентралізованою периферійною аналітикою, пропонований підхід на основі мережевої архітектури також дозволяє розробляти складніші стратегії розгортання моделей, що використовують переваги обох підходів [2]. До прикладу, у федеративному навчанні глобальна модель ініціалізується у хмарі та розгортається на граничних вузлах, де локально навчається на їх даних. Періодично локальні моделі відправляються в хмару для агрегації в оновлену глобальну модель, яка потім поширюється на вузли, дозволяючи використовувати знання інших вузлів без передачі вихідних даних. Процес може виконуватися в реальному і повторюватися ітеративно до досягнення потрібної точності, а результати доступні локально або через хмару кінцевим користувачам [2].

Для збільшення рівня цифрової інтеграції галузь інтегрує у структуру комплексні рішення на основі цифрових двійників, такі як центри оперативного управління у реальному часі – RTOC (Real Time Operations Center) – отримує, обробляє та публікує дані в режимі реального часу через свою платформу для всіх операцій буріння та закінчення свердловин [45]. Також поширення набувають системи та центри віддаленого управління (ROC – Remote Operations Centers), які дозволяють експертам у предметній області підтримувати операції з офісу, тим самим підвищуючи ефективність буріння, скорочуючи кількість персоналу дома і оптимізуючи робочі процеси [46].

Цікавим рішенням проблеми підтримки автономного буріння є реалізація архітектури заснованої на мікросервісах. Приклад архітектури мікросервісів для цифрового проектування свердловин подано в додатку А на рисунку А.1.

Графік демонструє рівень зв'язків між клієнтськими додатками та відповідними мікросервісами, а також їх взаємодію з іншими мікросервісами. Кожен мікросервіс повинен включати як мінімум дві кінцеві точки: одну для керування основними даними (наприклад, свердловинами, цілями, траєкторіями,

флюїдами) та іншу для генерації реалізацій, що фактично розглядає мікросервіс як «фабрику».

Розвиток і порівняння програмних архітектур для систем спорудження свердловин наведено в додатку А в таблиці А.3.

Кібербезпека промислових систем керування та хмарних середовищ повинна враховуватися протягом усього життєвого циклу будь-якого проєкту, особливо в рамках цифрової трансформації нафтогазового сектора [49]. Описана цифровізація галузі створює додаткові вразливості та більше точок входу («чорних» входів) – через використання дефектів та слабких місць адже жодна логічна система не може ідеально описати фізичну систему, оскільки в ній задіяно занадто багато частин [1, 54].

Разом із цим зростання рівня цифрової інтеграції потребує врахування вимог стійкості OT/ICS-інфраструктури та базових підходів до оцінювання кіберризиків, оскільки традиційні IT-орієнтовані засоби захисту не завжди є достатніми для бурових активів [55, 56]. У галузі для цього застосовують нормативні та методичні підходи API, IADC та стандарти серії ISA/IEC 62443, які регламентують оцінювання ризиків, сегментацію мереж, контроль доступу та базові вимоги до захисту промислових систем [57, 58, 59].

Окремо в сучасних дослідженнях розглядаються AI-орієнтовані засоби виявлення загроз та контролю достовірності потокових даних, що є важливим для забезпечення надійності цифрових моделей та аналітичних модулів у системах буріння [60, 61].

Провівши аналіз опублікованих праць можна виділити основні проблеми пов'язані із розгортанням хмарних інтелектуальних платформ [2]:

- затримка в мережі – може стати вузьким місцем для програм, що підтримують високочастотне прийняття рішень у режимі реального часу, таких як бурові роботи, особливо у віддалених регіонах;

- висока вартість – постійна потокова передача великих обсягів даних у хмару стикається із проблемою надмірно високої вартості [2].

Дані в реальному часі для свердловинних інструментів, поверхневих датчиків, бурового обладнання та інтелектуальних пристроїв збираються у форматі RESQML, WITSML чи PRODML [53]. Перехід до ІТ також призвів до стандартизації нових протоколів зв'язку SCADA, таких як протокол розподіленої мережі Modbus-TCP (DNP3), IEC-60870-5-104 та протокол міжцентрової взаємодії (ICCP, IEC60870-6) [49].

За даними авторів [22] OPC-UA вважається більш стабільним порівняно з іншими протоколами ІоТ з низки причин:

- незалежність від платформи: на відміну від попередника (OPC Classic), може працювати на різних операційних системах, що підвищує його стабільність та гнучкість;

- масштабованість: підтримуються як клієнт-серверна, так і модель зв'язку «публікація-підписка». Така гнучкість дозволяє ефективно масштабувати систему від невеликих до великих, складних промислових мереж;

- взаємодія: OPC-UA розроблений з урахуванням високої сумісності, підтримуючи широкий спектр типів даних та протоколів зв'язку, що забезпечує безшовну інтеграцію з різними пристроями та системами;

- моделювання даних: OPC-UA надає велику основу для моделювання даних, що дозволяє створювати складні структури даних та взаємозв'язків, що розширює можливості протоколу обробки різноманітних і складних промислових даних;

- стійкість до відмов: протокол розроблений для забезпечення надійного обміну даними навіть у складних промислових умовах. Його надійні механізми обробки помилок та відновлення сприяють загальній стабільності.

1.3. Аналіз інформативних параметрів процесу буріння при ідентифікації передаварійних ситуацій.

Для побудови ефективної нейромережевої моделі необхідно формалізувати основні фізико-технологічні взаємозв'язки. Процес буріння нафтогазових

свердловин (НГС) (рисунок 1.6) у контексті розробки нейромережових моделей розглядається як складна, динамічна та стохастична система, що функціонує в умовах апріорної невизначеності. З точки зору машинного навчання, буріння є безперервним джерелом багатовимірних часових рядів, де кожен параметр має специфічну фізичну природу та кореляційний зв'язок з іншими показниками.

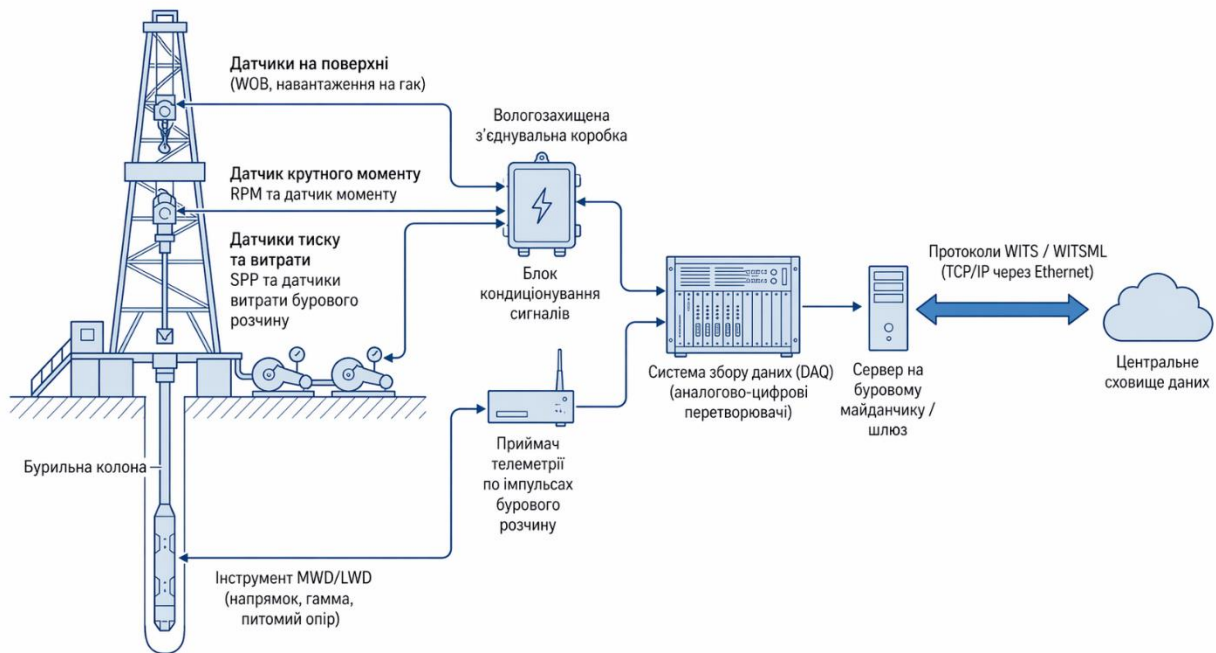


Рисунок 1.6. Рівень апаратного спряження та збору даних

Наведемо опис ключових аспектів цього процесу, які є критичними для побудови адекватної нейромережової моделі.

Технологічний процес буріння характеризується великою кількістю вхідних змінних, які можна класифікувати для формування вхідного вектора нейромережі:

- керовані параметри: осьове навантаження на долото (WOB), частота обертання бурильної колони (RPM), витрата промивальної рідини (Q). Ці параметри є основними детермінантами механічної швидкості проходки (ROP);
- реактивні параметри: крутний момент на роторі (Torque), тиск у маніфольді (SPP), вага на гаку (HKLD). Зміна цих показників при стабільних керованих

параметрах свідчить про зміну літологічних властивостей порід або виникнення ускладнень;

- геологічні та чинники середовища: густина та в'язкість бурового розчину, пластовий тиск, літологічний склад пласта;

У контексті нейромережевого моделювання дані буріння мають подвійну прив'язку:

- часова домена (t) - дані з датчиків поверхневого комплексу надходять з частотою 1–10 Гц. Це дозволяє моделювати динамічні процеси, такі як вібрації або гідравлічні удари;

- глибинна домена (z) - основний контекст буріння визначається глибиною. Нейромережева модель повинна враховувати "пам'ять" про пройдена пласти, оскільки стан свердловини на глибині N прямо залежить від геометрії та стану стовбура вище за розрізом;

Буріння як об'єкт моделювання характеризується високим ступенем нелінійності. Наприклад, залежність ROP від WOB не є прямо пропорційною і має точку екстремуму, після якої ефективність руйнування породи падає (ефект "зашламування" вибою);

Важливим фактором є транспортне запізнення:

- Гідравлічне запізнення - зміна параметрів промивальної рідини на поверхні відображається на вибої через значний проміжок часу, що залежить від глибини та швидкості потоку;

- Телеметричне запізнення - передача даних від вибійної телесистеми (MWD) через гідравлічний канал зв'язку відбувається з низькою швидкістю (від 0.5 до 10 біт/с), що створює часовий проміжок між подією на вибої та її відображенням у системі.

Сигнали, що надходять з бурової установки, обтяжені високим рівнем завад:

- механічні шуми, оскільки вібрації бурової вежі та коливання бурильної колони створюють високочастотні амплітудні спотворення в показниках ваги та моменту;

- технологічні збурення, оскільки робота поршневих насосів створює циклічні пульсації тиску (SPP);

Для нейромережевої моделі це означає необхідність впровадження блоків попередньої фільтрації (наприклад, 1D-CNN шарів) для виділення корисного сигналу з шумного фону.

У контексті побудови СППР для виявлення аварій (прихоплень, поглинань, ГНВП), процес буріння характеризується критичним дисбалансом класів. Понад 95% часу процес протікає в штатному режимі, а аварійні ситуації є рідкісними подіями. Це вимагає використання специфічних методів навчання моделі (наприклад, синтетичне збільшення меншості — SMOTE або використання Cost-sensitive learning).

Тому, можна стверджувати, що буріння НГС у контексті нейромережевого моделювання — це процес генерації послідовних станів векторного простору, де модель повинна навчитися відображати вхідні технологічні впливи у вихідні показники ефективності та безпеки, враховуючи при цьому фізичну інерцію, затримки зв'язку та складну нелінійну природу взаємодії долота з гірською породою.

Механічна швидкість — це головний індикатор ефективності. У класичному вигляді вона описується функцією багатьох змінних [62, 63]:

$$ROP = f(WOB, RPM, Q, P_h, Prop, Hydr)$$

де:

WOB (Weight on Bit) — осьове навантаження на долото;

RPM (Rotations Per Minute) — частота обертання колони;

Q — витрата промивальної рідини;

P_h — гідростатичний тиск;

Prop — властивості гірської породи (твердість, абразивність);

Hydr — показник очистки вибою від шламу.

Для навчання нейромережі важливо враховувати модель зносу долота. Оскільки зі збільшенням глибини зубки долота тупляться, ефективність падає

навіть при стабільних WOB та RPM. Нейромережа має навчитися розпізнавати цей тренд як "згасання" сигналу швидкості [64].

Для виявлення аварійних ситуацій (поглинання або викиди) математична модель спирається на рівняння нерозривності потоку. В ідеальних умовах:

$$Q_{in} = Q_{out}$$

де Q_{in} — об'єм рідини, що закачується насосом, Q_{out} — об'єм, що виходить зі свердловини. Математична модель для нейромережі повинна враховувати реологічні властивості розчину (в'язкість, межа текучості) через рівняння Бінгама-Шведова або степеневий закон:

$$\tau = \tau_0 + \mu_p \gamma$$

де τ — напруження зсуву, γ — швидкість зсуву. Будь-яке відхилення реального тиску (SPP) від розрахункового при стабільних параметрах насоса є сигналом для нейромережі про зміну стану свердловини [65, 66].

Моделювання сил тертя та крутного моменту є ключовим для прогнозування прихоплень колони. Математично це описується зміною ваги на гаку (HKLD):

$$HKLD_{actual} = HKLD_{theoretical} \pm F_{friction}$$

$HKLD_{actual}$ - це розрахункова вага колони у промивальній рідині за умови повної відсутності сил тертя яка обчислюється як вага колони в повітрі, помножена на коефіцієнт плавучості розчину. Цей показник є «еталонним» для ідеально чистого та вертикального стовбура.

$F_{friction}$ - це сумарна сила опору, що виникає при взаємодії бурильної колони зі стінками свердловини та шламом. Напрямок дії сили тертя завжди протилежний напрямку руху інструменту.

Для нейромережі вхідним вектором даних стають коливання крутного моменту. Високочастотні гармоніки в цих даних часто свідчать про початок вібрацій типу Stick-Slip (переривчасте ковзання), що призводить до руйнування інструменту [67, 68].

Оскільки дані надходять з датчиків у реальному часі, математичний опис перетворюється на часову послідовність. Для кожного моменту часу t формується вектор стану S_t :

$$S_t = [WOB_t, RPM_t, P_t, Q_t, Tq_t, Depth_t, \dots]$$

Особливістю буріння є глибинна залежність. Дані, отримані на глибині 2000 м, мають іншу вагу та контекст, ніж на 500 м, тому математична модель повинна включати координату глибини як один із регуляризаторів для нейронної мережі [69, 70].

Задача функціонування СППР у процесі буріння формулюється як задача багатокритеріальної оптимізації в реальному часі. Метою є знаходження такого вектора керованих параметрів U , який максимізує продуктивність при мінімізації енергетичних витрат та ризиків аварій.

Представимо цільову функцію. Глобальний критерій ефективності J можна представити у вигляді адитивної згортки [71, 72]:

$$J(U) = w_1 \cdot ROP(U) - w_2 \cdot MSE(U) - w_3 \cdot R(U) \rightarrow \max$$

де:

$U = [WOB, RPM, Q]$ — вектор керуючих впливів;

ROP — нормована механічна швидкість проходки (прогноз нейромережі);

MSE — нормована питома механічна енергія;

R — функція ризику ускладнення (ймовірнісний вихід LSTM-блоку);

w_1, w_2, w_3 — вагові коефіцієнти пріоритетності (налаштовуються залежно від стратегії буріння).

Оптимізація проводиться з урахуванням технологічних обмежень бурової установки та геологічних умов:

- технічні — $U_{min} \leq U \leq U_{max}$ (граничні можливості лебідки, ротора, насосів).

- гідравлічні — $P_{ann} < P_{frac}$ (тиск в анулюсі не повинен перевищувати тиск гідророзриву пласта).

- механічні: $Torque < Torque_{yield}$ (крутний момент не повинен призводити до руйнування бурильної колони).

1.4. Вибір і обґрунтування напрямку досліджень

Проведений у першому розділі аналіз сучасного стану цифровізації нафтогазової галузі та існуючих архітектур комп'ютеризованого контролю процесів буріння дозволяє зробити висновок про наявність суттєвого розриву між обсягами генерованої телеметричної інформації та ефективністю її використання для оперативного управління. Традиційні комп'ютерні системи, побудовані на основі жорстких порогових алгоритмів, виявляються неспроможними адекватно інтерпретувати складні нелінійні залежності у багатовимірних часових рядах параметрів буріння, що призводить до високої аварійності та неефективних режимів проходки.

Виходячи з результатів аналізу, пріоритетним напрямком даного дослідження обрано розробку комп'ютерної нейромережевої системи підтримки прийняття рішень (СППР), структура якої базується на наступних концептуальних положеннях:

1. Вибір гібридної нейромережевої архітектури. Для обробки сигналів буріння, що мають природу багатовимірних часових рядів, обґрунтовано використання комбінації згорткових (CNN) та рекурентних (LSTM) шарів. Вибір зумовлений здатністю CNN до ефективною екстракції просторових ознак та потужністю LSTM у моделюванні довгострокових часових залежностей (. Це дозволяє досягти вищої точності ідентифікації передаварійних ситуацій порівняно зі стандартними методами регресії.

2. Обґрунтування периферійних обчислень. Враховуючи специфіку бурових робіт (віддаленість локацій, нестабільність каналів зв'язку та вимоги до реального часу), обрано напрямок побудови системи з розподіленням інференсом. Перенесення обчислювального навантаження аналітичного ядра на

периферійний рівень (Edge-вузол безпосередньо на буровій) дозволяє мінімізувати затримку прийняття рішення до мілісекунд та забезпечити автономність функціонування системи при втраті зв'язку з хмарним сервером.

3. Інтеграція пояснювального ШІ (XAI) та гібридних баз знань. Для подолання «кризи довіри» між оператором та комп'ютерною системою обрано шлях розробки нейро-символьного інтерфейсу. Це передбачає супроводження кожного предиктивного висновку системи текстовим обґрунтуванням та візуалізацією внеску ключових ознак, що базується на логічних правилах технологічного регламенту буріння.

4. Методологія оцінки надійності. Напрямок дослідження передбачає впровадження математичного апарату оцінки невизначеності прогнозів, що дозволяє СППР самостійно визначати межі власної компетенції в нових геологічних умовах.

Обґрунтування обраного напрямку базується на тому, що пропонований комплексний підхід дозволяє трансформувати комп'ютерну систему з пасивного засобу реєстрації даних у активний інтелектуальний агент. Це відповідає стратегічному вектору розвитку комп'ютерної інженерії в напрямку створення автономних кіберфізичних систем для складних промислових середовищ.

Таким чином, розробка структури та алгоритмічного забезпечення нейромережевої СППР на основі гібридних CNN-LSTM моделей та Edge-технологій є науково обґрунтованим і перспективним шляхом вирішення задачі підвищення безпеки та ефективності буріння нафтогазових свердловин

РОЗДІЛ 2

МЕТОДОЛОГІЧНІ ТА СТРУКТУРНІ РІШЕННЯ НЕЙРОМЕРЕЖЕВИХ СИСТЕМ ДЛЯ ПРОЦЕСУ БУРІННЯ НГС

2.1. Структура та цільова функція навчання нейронної мережі

Для навчання нейронної мережі в задачах буріння стандартної функції середньоквадратичної помилки (MSE) зазвичай недостатньо. У даному випадку система повинна не просто мінімізувати відхилення, а «боятися» критичних зон [73].

Представимо математичне обґрунтування та формулу цільової функції (Loss Function).

Запропоновано комбіновану функцію втрат, яка балансує між ефективністю (швидкістю проходки) та безпекою (ризиком аварії):

$$L_{total} = \alpha L_{MSE} + \beta L_{risk} + \lambda \|\omega\|^2$$

Розглянемо кожен компонент детальніше.

Компонент точності прогнозу (L_{MSE}) - це стандартна частина, яка відповідає за те, наскільки точно мережа передбачає параметри (наприклад, механічну швидкість ROP або тиск P):

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

де y_i — реальне значення з датчика, \hat{y}_i — прогноз мережі [73].

Компонент штрафу за ризик (L_{risk}) — «основа» запропонованої СППР - це нелінійна функція штрафу, яка експоненціально зростає, коли параметри наближаються до критичних меж (наприклад, до тиску гідророзриву пласта або критичного моменту на роторі).

$$L_{risk} = \sum \exp\left(\frac{X_{current} - X_{limit}}{\sigma}\right)$$

Якщо параметр $X_{current}$ далеко від ліміту X_{limit} , штраф близький до нуля.

Як тільки параметр заходить у «червону зону», L_{risk} стає домінуючим, змушуючи модель змінювати рекомендації для бурового майстра в бік безпеки, а не швидкості [73].

Регуляризація ($\lambda || \omega ||^2$) - це стандартний додаток (L2-регуляризація) для запобігання перенавчанню мережі. Він гарантує, що модель буде стабільною на нових даних, а не просто «зазубрить» тренувальний набір.

Коефіцієнти ваги (α та β) дозволяють налаштувати «характер» системи:

- консервативний режим ($\beta > \alpha$) - система буде пріоритезувати безпеку, рекомендуючи обережні режими буріння.

- агресивний режим ($\alpha > \beta$) - система буде максимізувати швидкість проходки, допускаючи роботу ближче до технологічних меж.

Використання такої функції дозволяє нейромережі діяти не як «чорна скринька», а як інтелектуальний агент, що правильно інтерпретує технологічні обмеження свердловини [73].

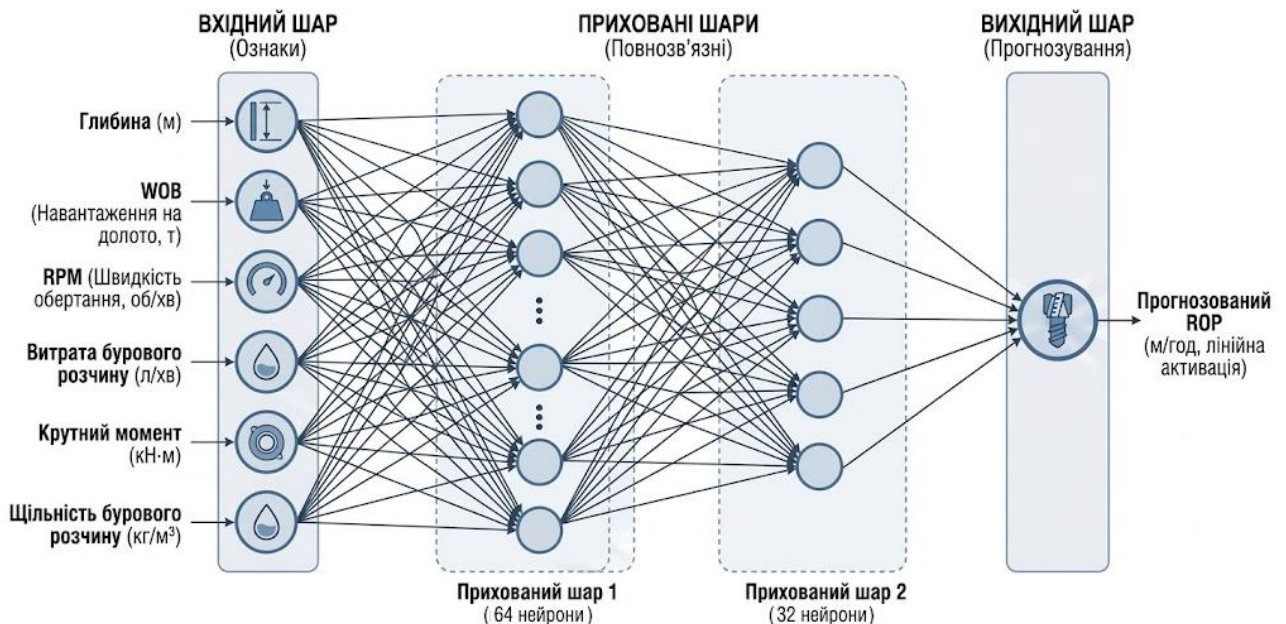


Рисунок 2.1. Приклад архітектури MLP для процесу прогнозування механічної швидкості буріння

Архітектуру повнозв'язної нейронної мережі прямого поширення (MLP - Multilayer Perceptron), призначену для вирішення задачі регресійного прогнозування механічної швидкості буріння [76] представлено на рисунку 2.1.

Структура моделі складається з трьох основних компонентів:

1. Вхідний шар, що приймає вектор із 6 ключових технологічних ознак, які визначають процес буріння: глибину свердловини, осьове навантаження на долото, швидкість обертання ротора, витрату промивальної рідини, крутний момент на приводі та густину бурового розчину.

2. Два послідовні щільні приховані шари, які виконують нелінійну трансформацію вхідних даних для виявлення прихованих закономірностей. На схемі наведені прикладні параметри конфігурації: перший прихований шар містить 64 нейрони, другий — 32 нейрони. В обох шарах як функція активації використовується випрямлена лінійна одиниця для введення нелінійності та прискорення навчання.

3. Вихідний шар, який складається з одного нейрона. Використання лінійної функції активації на виході дозволяє мережі апроксимувати безперервне чисельне значення, що є кінцевим прогнозом механічної швидкості проходки.

Також MLP не враховують послідовність даних. Для буріння, де кожен наступний стан залежить від попереднього, MLP є малоефективною, оскільки розглядає кожен точку даних як незалежну подію (таблиця 2.1).

Таблиця 2.1 - Переваги і недоліки MLP

Переваги	Недоліки
Може вивчити будь-яку складну функцію.	Якщо вхідних даних дуже багато, кількість параметрів стає гігантською.
Легко реалізувати та тренувати на невеликих даних.	MLP не розуміє просторових зв'язків

Згорткові нейронні мережі (CNN) традиційно використовуються для зображень, застосування 1D-CNN до сигналів датчиків дозволяє ефективно витягувати локальні ознаки (наприклад, характерні вібрації або «патерни» зміни моменту), ігноруючи дрібні шуми [77].

Основна ідея CNN — це фільтри (ядра згортки) які опрацьовують дані і шукають специфічні ознаки: різкі стрибки тиску, тріщини на керні або характерні вкраплення в шламi.

Ключові шари:

- Convolution Layer - виявляє ознаки (краї, градієнти, частоти).
- Pooling - зменшує розмірність, залишаючи лише найважливіші піки (максимуми).
- Fully Connected - приймає виявлені ознаки та робить фінальний висновок.

Математично згортка для дискретного сигналу (наприклад, даних ГДС) виглядає так:

$$(f * g)[n] = \sum_{m=-M}^M f[n - m]g[m]$$

де f — вхідний сигнал, а g — фільтр.

Для розпізнавання аварійних ситуацій (1D CNN) дані з датчиків (WOB, Torque, Flow Rate) можна розглядати як "звукову хвилю" або сигнал. 1D згорткові мережі знаходять у цих сигналах специфічні "відбитки" проблем (рисунок 2.2).

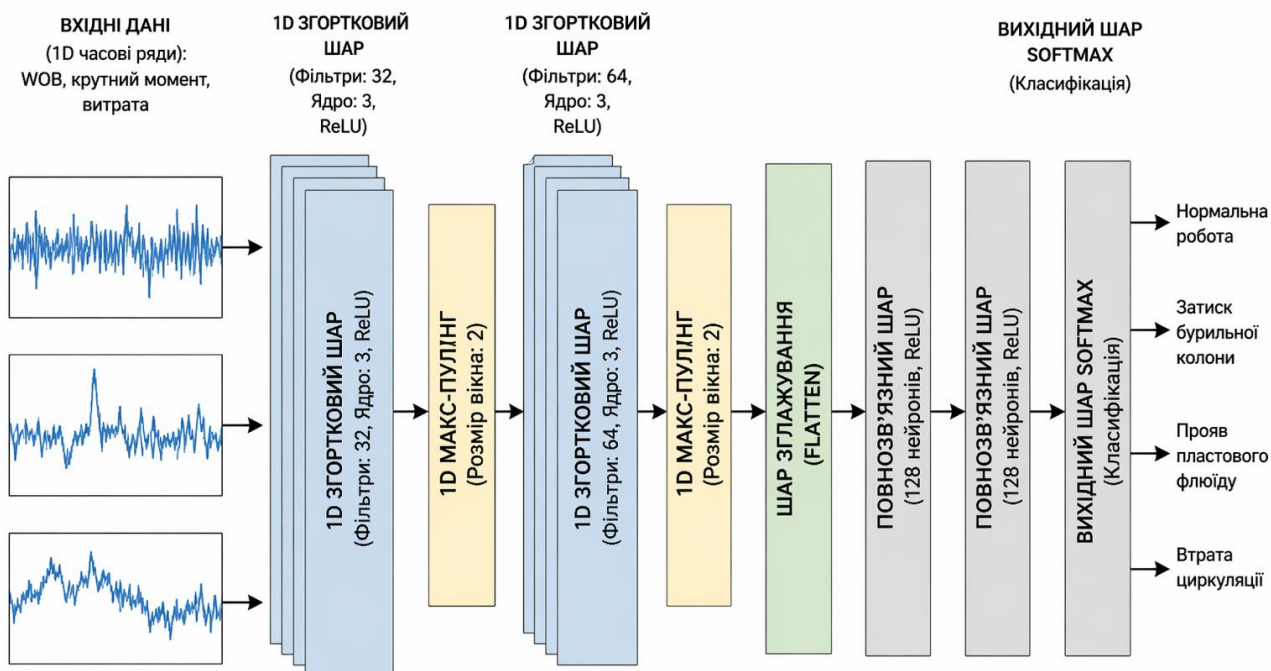


Рисунок 2.2. Спрощена архітектура 1D CNN для розпізнавання аварійних ситуацій

Наприклад, початок поглинання промивальної рідини має характерний профіль падіння тиску та витрати. CNN розпізнає цю ситуацію раніше, ніж спрацює звичайна сигналізація [78].

Оскільки процес буріння є часовим рядом, найбільш перспективним є використання рекурентних мереж. Проте класичні рекурентні мережі мають проблему «затухання градієнта» (вони швидко «забувають» те, що було на початку глибокої секції).

Для вирішення цієї проблеми у роботі обґрунтовується використання архітектури LSTM (Long Short-Term Memory) або її спрощеної модифікації GRU (Gated Recurrent Unit) [79].

Переваги LSTM для задач буріння:

1. Наявність комірки пам'яті, що дозволяє системі зберігати інформацію про стан пласта протягом тривалого часу.

2. Механізм фільтрації дозволяє мережі «забувати» неважливі події (наприклад, випадкові короточасні стрибки тиску під час нарощування колони) і фокусуватися на значущих трендах.

Для підвищення точності СППР у роботі пропонується комбінований підхід [73, 76]:

1. Шар 1D-CNN використовується як «інтелектуальний фільтр» для первинної обробки сигналів з датчиків (*WOB*, *Torque*, *SPP*). Він виділяє ключові мікро-ознаки.

2. Шар LSTM - отримує оброблені ознаки та аналізує їхню динаміку в часі для прогнозування аварії (наприклад, поступового зростання моменту, що свідчить про зашламованість).

3. Повнозв'язний шар формує остаточний вихід системи, наприклад ймовірність виникнення конкретного ускладнення у відсотках.

Використання гібридної моделі зумовлене необхідністю одночасного аналізу локальних патернів (ознак) та довгострокових залежностей у потоці телеметричної інформації. Структура будується за принципом послідовного з'єднання двох функціональних блоків: CNN-енкодера та LSTM-декодера [73].

1. Рівень витягування ознак (блок 1D-CNN)

На цьому етапі вхідний вектор даних з бурової установки $X = [x_1, x_2, \dots, x_n]$, де x_i — набір параметрів (*WOB*, *RPM*, *SPP*, *Torque*), проходить крізь одномірні згорткові шари.

Механізм роботи полягає в тому, що фільтри (ядра) згортки переміщуються вздовж часової осі, виконуючи операцію скалярного добутку. Це дозволяє автоматично виявляти складні комбінації параметрів, які важко помітити людині (наприклад, специфічне співвідношення між стрибком крутного моменту та падінням тиску).

Після згортки застосовується шар субдискретизації, який вибирає максимальні значення з вікна. Це зменшує розмірність даних та забезпечує інваріантність моделі до незначних часових зсувів (момент виникнення передаварійних ситуацій може трохи плавати) [73].

2. Рівень аналізу послідовностей (блок LSTM)

Отримані після CNN «стиснуті» ознаки передаються в рекурентні шари LSTM. Якщо CNN виявила «удар» по долоту (локальна ознака), то LSTM

аналізує, чи був цей удар поодиноким, чи він є частиною тенденції зростання вібрацій протягом останніх 15 хвилин. Завдяки гейтам (воротам) забування (forget gate), LSTM ігнорує непотрібні дані, що виникають під час технологічних операцій (наприклад, зупинка насосів для нарощування колони), і зберігає інформацію лише про реальний стан процесу поглиблення свердловини [80].

3. Комбінована структура та вихідний шар

Оскільки обрана архітектура CNN-LSTM працює з часовими послідовностями, дані подаються у вигляді тривимірного тензора. Це дозволяє мережі аналізувати не лише поточні значення, а й динаміку їх зміни.

Спроектowana структура має наступний вигляд [73]:

1. Input Layer приймає тензор розмірністю:

$$Batch_size \times Time_steps \times Features$$

- *Batch Size* (розмір пакету) - кількість фрагментів даних, що обробляються за одну ітерацію навчання (наприклад, 32 або 64).

- *Time Steps* (часові кроки) - глибина ретроспективного аналізу («вікно пам'яті»). Якщо дискретизація становить 1 замір/сек, а вікно — 60 кроків, мережа аналізує останню хвилину буріння.

- *Features* (ознаки) - кількість вхідних параметрів у кожний момент часу.

В даному випадку, замість аналізу статичних значень (як у класичних СППР), такий тензорний підхід дозволяє ідентифікувати динамічні образи (наприклад, гармонійні коливання моменту), що є прямим індикатором початку прихоплення або вібрацій долота ще до того, як вони досягнуть критичних значень [73].

2. Conv1D + ReLU - 2–3 шари для глибокої фільтрації.

3. MaxPooling1D застосовується для зменшення шуму. MaxPooling1D — це нелінійна операція дискретизації, яка вибирає максимальне значення у кожному ковзному вікні (пулі) певної довжини. Механізм придушення шуму полягає в наступному. У даних бурової телеметрії шум часто проявляється як високочастотні дрібні осциляції навколо основного тренду (наприклад, вібрації долота на графіку моменту). MaxPooling виділяє лише найбільш "виразні" ознаки

(найсильніші сигнали), які згенерували згорткові фільтри. Слабкі шумові сплески, що мають меншу амплітуду, ігноруються, оскільки вони не є домінуючими у поточному вікні. Цей шар робить модель стійкою до незначних часових зсувів сигналу. Наприклад, якщо пік тиску зміститься на 1-2 секунди через затримку зв'язку, після MaxPooling вихідна ознака залишиться незмінною.

У структурі запропонованої моделі, якщо вхідний сигнал має довжину 100 часових кроків, після застосування Conv1D та MaxPooling1D з розміром пулу 2 формується послідовність довжиною 50. У цій послідовності кожна точка відповідає найбільш значущій ознаці у відповідному часовому вікні, наприклад максимальному стрибку крутного моменту, що підвищує стабільність подальшого аналізу шарами LSTM [73].

Впровадження шару MaxPooling1D дозволяє абстрагуватися від дрібних флуктуацій технологічних параметрів буріння, концентруючи увагу моделі на найбільш енергетично виражених ознаках, що підвищує загальну робастність СППР до апаратних шумів датчиків.

4. LSTM Layer - 1–2 шари (наприклад, по 64 або 128 нейронів) для аналізу трендів.

5. Dropout Layer - шар для запобігання перенавчанню (випадкове відключення нейронів під час тренування).

6. Dense Layer (Softmax/Linear) - кінцевий результат.

Кінцевий рівень нейромережевої структури — Dense Layer (повнозв'язний шар) — відіграє роль інтерпретатора, який агрегує всі високорівневі ознаки, виділені попередніми шарами (CNN та LSTM), і трансформує їх у конкретні вихідні змінні.

У даній роботі цей шар є зв'язуючою ланкою між абстрактними математичними векторами та практичними рекомендаціями для бурового майстра. Залежно від мети (прогноз показника чи розпізнавання аварії), використовуються різні функції активації [73].

Повнозв'язний шар реалізує лінійну трансформацію вхідного вектора h (отриманого з останнього шару LSTM) з наступним застосуванням нелінійної активації:

$$Y = \sigma(W \cdot h + b)$$

де W — матриця ваг, b — вектор зміщення, а σ — функція активації.

Варіант регресійного виходу (лінійна активація) використовується для прогнозування безперервних технологічних параметрів, найважливішим з яких є механічна швидкість проходки. Функція активації $f(z) = z$ не обмежує діапазон значень, дозволяючи мережі видавати будь-яке числове значення швидкості (наприклад, 12.5 м/год). Призначення в бурінні - це оцінка ефективності поточного режиму буріння. Якщо фактична швидкість значно нижча за прогнозовану лінійним шаром, система ідентифікує неоптимальність параметрів (наприклад, "зуб долота не заглиблюється в породу") [73].

Варіант класифікаційного виходу (функція Softmax) застосовується для ідентифікації поточного стану свердловини та виявлення ускладнень (прихоплення, поглинання розчину, газопрояви). Функція Softmax перетворює вихідні значення (логіти) z_i у розподіл імовірностей, де сума всіх значень дорівнює 1 [73]:

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

В контексті процесу буріння кожен вихід нейрона відповідає за конкретний клас стану. Наприклад:

Клас 0 - нормальне буріння ($P = 0.95$).

Клас 1 - ризик прихоплення ($P = 0.04$).

Клас 2 - ознаки поглинання ($P = 0.01$).

Саме ці імовірнісні значення стають основою для логіки «Світлофора рішень». Якщо ймовірність класу "Ризик прихоплення" перевищує встановлений поріг (наприклад, 0.7), система активує червоний сигнал тривоги.

У межах пропонованої нейромережевої СППР використовується багатовиходова архітектура, де одна основна мережа (CNN-LSTM) закінчується двома паралельними Dense-шарами:

1. Dense + Linear - для точного кількісного прогнозу ROP.
2. Dense + Softmax - для якісної класифікації ризиків аварій.

Отже, кінцевий Dense-шар забезпечує фінальну семантичну інтерпретацію виділених часових паттернів. Використання Softmax-активації дозволяє системі оперувати поняттям «впевненості» у прогнозі, що є критично важливим для мінімізації хибних зупинок буріння та підвищення довіри оператора до рекомендацій комп'ютерної нейромережевої системи [73].

Спроектвана гібридна структура нейронної мережі типу CNN-LSTM являє собою багаторівневу систему інтелектуального аналізу даних, призначену для розпізнавання складних патернів та прогнозування станів процесу буріння в умовах високої невизначеності. Доцільність такої структури ґрунтується на синергії методів автоматичного виділення ознак та аналізу тривалих часових залежностей [73] (рисунок 2.3).

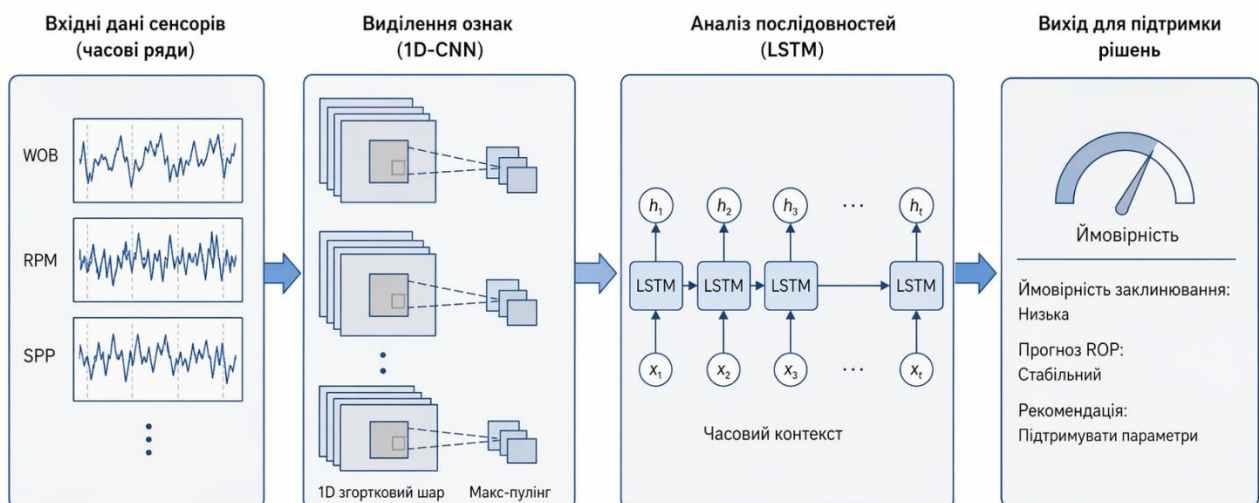


Рисунок 2.3. Пропонована гібридна структура CNN-LSTM для процесу буріння НГС

Приведемо структурно-функціональна організація моделі.

1. Рівень первинної обробки та вхідних даних.

На вхід системи подається багатовимірний вектор технологічних параметрів, що розглядається як нестационарний часовий ряд. Вхідний масив включає ключові показники: осьове навантаження на долото (WOB), частоту обертання (RPM), тиск у маніфольді (SPP) та крутний момент (Torque). Дані проходять етап попередньої нормалізації для забезпечення стабільності градієнтного спуску під час навчання.

2. Блок згорткового аналізу (Feature Extraction Layer — 1D-CNN).

Це перший функціональний рівень, який базується на використанні одномірних згорткових шарів. Основне завдання цього блоку полягає у фільтрації високочастотних шумів, характерних для датчиків бурового обладнання, та автоматичному виявленні локальних ознак («паттернів»).

Механізм згортки дозволяє ідентифікувати специфічні нелінійні взаємозв'язки між параметрами в межах обмеженого часового вікна, що критично важливо для виявлення початкових фаз вібрацій або мікрозмін у тиску [73].

Шар субдискретизації забезпечує стиснення інформації, виділяючи найбільш значущі ознаки та знижуючи обчислювальну складність моделі, що дозволяє системі працювати в режимі реального часу.

3. Рекурентний блок аналізу часових залежностей (Sequence Analysis Layer — LSTM).

Оброблений вектор ознак передається до шарів з довгою короткостроковою пам'яттю. На відміну від класичних мереж, цей блок володіє внутрішнім станом («пам'яттю»), що дозволяє моделі враховувати ретроспективу процесу.

Використання гейтів забування та оновлення дозволяє мережі диференціювати випадкові короткочасні відхилення від стійких негативних тенденцій (наприклад, поступове зростання сили тертя, що передуює прихопленню колони). Це забезпечує формування «глибинного контексту»

свердловини, де поточне рішення базується на динаміці зміни параметрів за весь попередній період циркуляції [73].

4. Рівень синтезу та підтримки прийняття рішень.

Кінцевий етап обробки здійснюється повнозв'язними шарами, які перетворюють абстрактні ознаки у зрозумілі для оператора висновки. Вихід системи є імовірнісною оцінкою виникнення технологічних ускладнень (поглинання, газопрояви, прихоплення) або рекомендацією щодо оптимізації режиму буріння (прогноз ROP).

Переваги гібридного підходу для буріння полягають в наступному:

- висока точність, оскільки CNN краще за оператора (людину) фільтрує вібрації бурової колони, які заважають аналізу.

- система коректно обробляє затримку між зміною параметрів на поверхні та реакцією вибою (гідравлічна похибка).

- хороша прогностична здатність, оскільки модель здатна видати попередження «Висока ймовірність прихоплення» за 10–15 хвилин до того, як ситуація стане критичною [73].

Також додатковою перевагою є, те, що використання CNN-блоку дозволяє відмовитися від ручного проектування ознак (Feature Engineering), оскільки нейромережа сама навчається розуміти, які поєднання датчиків сигналізують про проблему. Це робить пропоновану систему універсальною для різних типів бурових установок.

Застосування такої гібридної моделі дозволяє подолати одну з ключових проблем комп'ютерної системи підтримки прийняття рішень при бурінні — низьку якість «сирих» даних та складність інтерпретації динамічних процесів. Блок CNN виступає в ролі інтелектуального фільтра, тоді як LSTM забезпечує прогностичну логіку, що в сукупності мінімізує вплив людського фактора та підвищує безпеку спорудження нафтогазових свердловин [73].

Параметрична ідентифікація моделі та вибір стратегії її навчання є важливими етапами побудови системи. Належне налаштування гіперпараметрів є критичним етапом, оскільки саме вони визначають здатність системи до

узагальнення на нових родовищах та стабільність її роботи в умовах зашумлених сигналів телеметрії.

Ефективність функціонування розробленої гібридної структури CNN-LSTM безпосередньо залежить від конфігурації алгоритму навчання. Для забезпечення високої точності прогнозування ускладнень було обґрунтовано наступний набір параметрів [73]:

1. Вибір оптимізатора

Для мінімізації функції втрат обрано алгоритм Adam (Adaptive Moment Estimation). Алгоритм Adam [81] — це ітераційний метод оптимізації першого порядку для стохастичних цільових функцій, що ґрунтується на адаптивній оцінці моментів градієнтів нижчих порядків. На відміну від класичного стохастичного градієнтного спуску (SGD), Adam використовує адаптивні швидкості навчання для кожного параметра, базуючись на оцінці першого та другого моментів градієнтів. Це робить його ідеальним для роботи з даними буріння, де спостерігаються розріджені градієнти та висока амплітуда шумів від вібрацій бурової колони. Алгоритм забезпечує швидку збіжність моделі та стабільність траєкторії навчання.

Сутність алгоритму Adam полягає в синтезі переваг двох інших популярних методів, а саме Momentum (інерційний градієнтний спуск) та RMSProp (адаптивне масштабування градієнтів).

Виконаємо математичну формалізацію алгоритму. Процес оптимізації ваг θ моделі за допомогою Adam на кроці t можна описати наступною послідовністю операцій [73]:

а) обчислення градієнта. Розраховується вектор градієнтів g_t відносно цільової функції J для поточного стану параметрів θ_{t-1} :

$$g_t = \nabla_{\theta} J(\theta_{t-1})$$

б) оновлення оцінок моментів. Алгоритм підтримує експоненціальне ковзне середнє градієнтів (m_t — перший момент, математичне сподівання) та квадратів градієнтів (v_t — другий нецентрований момент, варіація):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$$

де β_1 та β_2 — гіперпараметри, що визначають швидкість експоненціального згасання (типові значення для $\beta_1 = 0.9$ і $\beta_2 = 0.999$).

в) корекція зміщення (Bias Correction). Оскільки вектори m_t та v_t ініціалізуються нулями, вони мають зміщення в бік нуля на початкових етапах навчання. Для усунення цього ефекту розраховуються скориговані оцінки:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

в) оновлення параметрів. Остаточне коригування ваг моделі виконується за формулою:

$$\theta_t = \theta_{t-1} - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \varepsilon}$$

де η — швидкість навчання, а ε — мала константа (наприклад, 10^{-8}) для запобігання діленню на нуль [73].

Застосування Adam в архітектурах CNN-LSTM для моніторингу буріння обґрунтовано наступними характеристиками [69]:

- алгоритм автоматично зменшує швидкість навчання для параметрів з великими градієнтами та збільшує для параметрів з малими (рідкісними) градієнтами. Це особливо важливо для телеметрії буріння, де деякі ознаки (наприклад, аномальні стрибки тиску) з'являються рідко, але мають критичне значення.

- алгоритм є стійким до шумів, завдяки використанню першого моменту (Momentum), Adam ефективно «згладжує» високочастотні шуми сигналів датчиків, запобігаючи різким і хаотичним коливанням ваг мережі.

- оновлення параметрів приблизно обмежені гіперпараметром η , що робить процес навчання більш передбачуваним та стабільним [69].

На відміну від стандартного SGD, Adam не потребує ручного налаштування швидкості навчання для кожного шару. У порівнянні з RMSProp, Adam включає

механізм інерції (momentum), що дозволяє швидше долати «сідлові точки» в просторі функцій втрат, що є типовим для складних нейронних мереж.

2. Функції активації

Для прихованих шарів (CNN та LSTM) використовується функція ReLU (Rectified Linear Unit). Вона дозволяє уникнути проблеми затухання градієнта (vanishing gradient problem), що особливо важливо для глибоких мереж, та забезпечує обчислювальну ефективність.

Як вихідний шар, для задач класифікації аварійних станів застосовується функція Softmax (для мультикласової класифікації) або Sigmoid (для бінарної оцінки ймовірності конкретного ускладнення). Це дозволяє інтерпретувати вихід нейромережі як імовірність виникнення події в діапазоні $[0,1]$.

3. Регуляризація та запобігання перенавчанню

Запобігання перенавчанню є критично важливим аспектом розробки нейромережових систем, особливо в таких складних галузях, як буріння нафтогазових свердловин. Перенавчання виникає, коли модель стає надмірно складною і замість виявлення фундаментальних фізичних закономірностей починає «запам'ятовувати» специфічні шуми та випадкові коливання у тренувальній вибірці [76].

Для забезпечення високої здатності до генералізації (здатності моделі адекватно працювати на даних з нових родовищ) у роботі застосовується комплексний підхід до регуляризації.

а) метод випадкового виключення нейронів (Dropout)

Dropout [82] є одним із найбільш ефективних методів регуляризації для глибоких нейронних мереж (CNN та LSTM). Для цього на кожній ітерації навчання випадково обрана частка нейронів (зазвичай 20–50%) не використовується в обчислювальному графі. Це змушує мережу розподіляти інформаційне навантаження рівномірно між усіма вагами, запобігаючи ситуації, коли модель покладається лише на кілька «супер-нейронів». У контексті буріння це дозволяє системі не прив'язуватися до конкретних показників одного давача, а аналізувати сукупність параметрів (WOB, Torque, SPP) як цілісну систему.

б) рання зупинка

Цей метод базується на моніторингу помилки на валідаційній вибірці, яка не використовується безпосередньо для корекції ваг, але слугує індикатором якості навчання. Процес навчання припиняється в момент, коли помилка на тренувальних даних продовжує зменшуватися, а на валідаційних — починає зростати або виходить на стаке значення. Це дозволяє знайти оптимальний баланс (Bias-Variance Tradeoff), де модель вже вивчила структуру даних, але ще не почала підлаштовуватися під локальні особливості конкретної свердловини.

в) вагова регуляризація

До цільової функції втрат додається штрафний додаток, пропорційний квадрату величини ваг моделі:

$$L_{reg} = L_{original} + \lambda \sum w^2$$

Це стимулює модель підтримувати значення ваг w на низькому рівні. Малі ваги роблять мережу менш чутливою до різких стрибків вхідних сигналів (наприклад, вібрацій бурової колони), що забезпечує стабільність вихідних рекомендацій [73].

г) крос-валідація часових рядів

Оскільки дані буріння мають часову та глибинну послідовність, стандартна крос-валідація (випадкове перемішування) є неприпустимою, оскільки це призведе до «витоку даних» з майбутнього в минуле. В цьому випадку застосовується підхід «ковзного вікна» (Rolling Window), де тренувальний набір завжди передує валідаційному в часі. Це імітує реальну роботу СППР, коли система повинна прогнозувати стан свердловини на основі лише раніше отриманої інформації [73].

Для трансформації безперервного потоку телеметрії у формат, придатний для нейромережі, застосовується метод ковзного вікна зі зсувом:

- кожне наступне вікно зсувається на 1 крок вперед (step=1).
- це створює ефект безперервного моніторингу: система оновлює прогноз кожну секунду, враховуючи накопичений контекст за попередній період.

д) аугментація даних

У бурінні аварійні ситуації трапляються рідко, що створює проблему незбалансованості класів. Для запобігання перенавчанню на невеликій кількості прикладів аварій застосовується штучне збільшення вибірки шляхом додавання невеликих варіацій, часових зсувів або масштабування до існуючих записів ускладнень. Це розширює «досвід» мережі, роблячи її більш стійкою до розбіжностей у технологічних умовах.

е) гіперпараметри процесу навчання (таблиця 2.2).

- швидкість навчання встановлюється початкове значення $\eta = 0.001$ з подальшим використанням планувальника, який знижує швидкість навчання при виході на "плато".

- розмір батчу - оптимальне значення визначено в межах 32–64 зразків. Такий розмір забезпечує баланс між швидкістю оновлення ваг та стабільністю оцінки градієнта.

- часове вікно, для шарів LSTM обрано довжиною від 50 до 200 часових кроків, що дозволяє моделі «бачити» розвиток технологічного процесу протягом останніх 10 – 30 хвилин реального часу буріння [73].

Таблиця 2.2 - Гіперпараметри конфігурації нейромережі CNN-LSTM

Параметр	Значення / Опис	Обґрунтування
Оптимізатор	Adam	Висока швидкість збіжності на шумних даних
Learning Rate	0.001 (з decay)	Стабільність градієнтного спуску
Кількість фільтрів CNN	32, 64	Виділення низько- та високорівневих ознак
Кількість блоків LSTM	128	Глибина часового контексту
Dropout rate	0.3	Запобігання перенавчанню

Batch size	64	Баланс між пам'яттю та швидкістю
------------	----	----------------------------------

Обрана комбінація оптимізатора Adam, функцій активації ReLU та методів регуляризації дозволяє створити надійну математичну основу для навчання СППР. Це забезпечує мінімізацію хибнопозитивних спрацювань системи (помилкових тривог) та гарантує високу швидкість реакції на реальні загрози під час буріння свердловини.

Впровадження перелічених методів дозволяє отримати стійку модель, яка зберігає високу точність прогнозування незалежно від геологічних особливостей конкретного регіону або технічного стану бурової установки. Це є ключовою умовою для переходу від лабораторних досліджень до практичної експлуатації комп'ютерної системи.

2.2. Методи попереднього опрацювання та очищення даних

Для забезпечення високої прогностичної здатності системи підтримки прийняття рішень розроблено багатокроковий алгоритм препроцесингу, який включає детектування передаварійних ситуацій, фільтрацію шумів та нормалізацію [73] (рисунок 2.4).



Рисунок 2.4. Структурна схема препроцесингу даних параметрів телеметрії

1. Виявлення та обробка викидів (Outlier Detection)

Для виявлення передаварійних ситуацій у потоці телеметричної інформації застосовується комбінований підхід, що поєднує статистичні методи та перевірку на відповідність фізичним законам процесу.

Викиди в даних буріння часто є наслідком короткочасних апаратних збоїв датчиків або перешкод у системі телеметрії. Для ідентифікації потенційно небезпечних відхилень застосовується метод Z -оцінки (Z -score) або аналіз міжквартильного розмаху (IQR). Метод Z -оцінки базується на припущенні про нормальний розподіл параметрів на коротких інтервалах стабільного буріння. Для кожного вимірювання x_i розраховується стандартне відхилення від середнього значення μ :

$$z_i = \frac{x_i - \mu}{\sigma}$$

де σ — середньоквадратичне відхилення. Значення, для яких $|z_i| > 3$ (або що виходять за межі діапазону $[\mu - 3\sigma; \mu + 3\sigma]$), класифікуються як критичні викиди. В умовах буріння часто використовують модифікований методо Z -score, де замість середнього використовується медіана (MAD), що робить метод стійкішим до грубих помилок [73].

Метод міжквартильного розмаху (IQR) є ефективним для параметрів з несиметричним розподілом (наприклад, момент на роторі). Обчислюється різниця між третім (Q_3) та першим (Q_1) квартилями:

$$IQR = Q_3 - Q_1$$

Діапазон допустимих значень визначається як $[Q_1 - 1.5 \cdot IQR; Q_3 + 1.5 \cdot IQR]$. Будь-яка точка поза цими межами маркується як критичне відхилення.

Окрім статистики, проводиться перевірка на фізичну спроможність. Наприклад, від'ємні значення навантаження на долото (WOB) або тиску (SPP) під час циркуляції автоматично ідентифікуються як помилки давачів.

Просте видалення точок із критичними відхиленнями є неприпустимим для часових рядів, оскільки це порушує рівномірність дискретизації, що критично для шарів LSTM. Застосовуються наступні методи реконструкції сигналу [73]:

- медіанна фільтрація

У вікні фіксованого розміру значення з критичним відхиленням замінюється медіаною сусідніх точок. Це дозволяє ефективно «зрізати» гострі піки, не спотворюючи загальний тренд параметра.

- лінійна та сплайн-інтерполяція.

Якщо викид є поодиноким, значення реконструюється на основі попередніх та наступних достовірних вимірювань:

$$x_{corr} = x_{i-1} + \frac{x_{i+1} - x_{i-1}}{t_{i+1} - t_{i-1}}(t_i - t_{i-1})$$

Цей метод забезпечує плавність сигналу, що важливо для роботи згорткових шарів (CNN).

- використання фільтра Калмана [83]

Для параметрів з високою інерційністю (температура, густина розчину) застосовується рекурсивне оцінювання стану. Фільтр Калмана дозволяє відфільтрувати шум і викиди, базуючись на динамічній моделі процесу та попередніх станах системи.

В результаті якісна обробка викидів дозволяє:

- запобігти "вибуху" градієнтів, оскільки аномальні стрибки в даних можуть призвести до нестабільності ваг нейромережі під час навчання.

- зменшити кількість хибних тривог і СППР не буде активувати «червоний сигнал» через одиничний збій датчика моменту.

- покращити узагальнюючу здатність, оскільки модель навчається на фізиці процесу, а не на артефактах вимірювальних систем [73].

2. Цифрова фільтрація та усунення шумів (Denoising)

Сигнали таких параметрів, як крутний момент та осьове навантаження, містять значну кількість високочастотних шумів, спричинених динамікою

бурильної колони. Для очищення сигналів у роботі обґрунтовано застосування таких методів:

- фільтр Савицького-Голея [84], який дозволяє згладжувати сигнал, зберігаючи при цьому характерні піки та тенденції, що є критично важливим для ідентифікації моментів зміни літології. Цей фільтр є пріоритетним для параметрів ROP та Torque. На відміну від простого ковзного середнього, він базується на методі найменших квадратів для апроксимації даних у вікні поліномом низького порядку. Для кожного вікна підбирається поліном

$$p(i) = \sum_{k=0}^n a_k i^k$$

що мінімізує середньоквадратичне відхилення.

Фільтр Савицького-Голея значно краще зберігає «гострі» моменти зміни сигналу (наприклад, різкий стрибок моменту при вході в твердий пласт), не «змазуючи» їх, як це роблять інші фільтри [73].

- адаптивний фільтр Калмана, що використовується для параметрів гідравлічного циклу (наприклад, тиск SPP). Він використовує рекурсивну процедуру оцінки стану системи, що складається з двох кроків: прогнозу та корекції. Фільтр враховує як поточне вимірювання датчика, так і теоретичну модель процесу. Якщо датчик показує короткочасний стрибок тиску, який фізично неможливий за такий короткий час з огляду на інерцію рідини, фільтр Калмана мінімізує вагу цього вимірювання. Як результат буде отримано «чистий» тренд тиску, позбавлений впливу пульсацій насоса та дрібних похибок телесистеми.

Впровадження каскадної фільтрації (Калман для тиску + Савицький-Голей для механічних параметрів) дозволяє уніфікувати дані і зробити їх придатними для розпізнавання паттернів шарами CNN та захистити систему від помилкових висновків, оскільки чистий сигнал дозволяє нейромережі LSTM фокусуватися на

часових трендах, а не на випадкових флуктуаціях. Також, очищені дані пришвидшують навчання моделі, оскільки функція втрат стає більш гладкою.

3. Обробка пропущених значень та ресемплінг

Через перерви в роботі систем передачі даних (наприклад, під час нарощування або геофізичних досліджень) виникають пропущені значення в інформаційних потоках. Оскільки дані з різних джерел (поверхневі датчики та вибійні телесистеми MWD/LWD) мають різну частоту дискретизації, то у роботі застосовується метод ресемплінгу для приведення всіх сигналів до єдиного часового кроку (наприклад, 1 Гц або 1 замір на 10 см проходки) [73].

4. Нормалізація та стандартування даних [85]

Нейронні мережі чутливі до масштабу вхідних величин. Оскільки параметри буріння мають різні одиниці вимірювання (тиск — МПа, швидкість — м/год, навантаження — кН), їх необхідно привести до порівнянного вигляду.

Min-Max Scaling [86] перетворює всі значення у діапазон [0,1].

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Standardization (Z-score scaling) центрує дані навколо нуля з одиничним стандартним відхиленням, що є кращим для архітектур LSTM, оскільки полегшує збіжність градієнтного спуску [87].

5. Формування віконної вибірки (Sliding Window Transformation)

Останнім етапом обробки є перетворення безперервного потоку даних у послідовність «вікон» певної тривалості (наприклад, останні 100 замірів). Це дозволяє подавати на вхід шару 1D-CNN просторово-часовий фрагмент даних, у якому мережа шукатиме взаємозв'язки між параметрами для класифікації поточного стану свердловини.

Формування віконної вибірки є ключовим етапом підготовки даних у задачах прогнозування часових рядів, що дозволяє трансформувати безперервний потік телеметричної інформації у набір структурованих прикладів (пакетів) для навчання нейронних мереж з архітектурою CNN-LSTM. Даний

процес є методом сегментації багатовимірному простору станів об'єкта для виявлення динамічних закономірностей у часі [73].

Наведемо методологію трансформації ковзним вікном:

а) Формалізація вхідного потоку

Процес буріння представлений послідовністю векторів вимірювань $S = \{x_1, x_2, \dots, x_t\}$, де кожен вектор $x_i \in R_n$ містить n технологічних параметрів (WOB, RPM, Torque тощо), отриманих у момент часу i . Мета трансформації полягає в перетворенні послідовності S у множину вхідних вікон X та відповідних їм цільових значень (міток) Y .

б) Ключові параметри вікна

Для коректної налаштування моделі визначаються три фундаментальні параметри:

- довжина вікна (L) - кількість послідовних часових кроків, що аналізуються мережею одночасно. В бурінні L обирається виходячи з інерційності процесів (наприклад, 60 – 300 секунд), щоб охопити розвиток динамічного паттерна (наприклад, початок вібрацій).

- крок зсуву (S) - кількість кроків, на які вікно переміщується вздовж часової осі. При $S=1$ забезпечується максимальна щільність даних та перекриття вікон, що дозволяє СППР реагувати на кожне нове вимірювання.

- горизонт прогнозу (H) - часовий проміжок між кінцем вікна та моментом, для якого виконується прогноз.

в) Математична структура вікна

Для кожного моменту часу t формується навчальна пара:

Вхідний тензор: $X_t = [x_{t-L+1}, x_{t-L+2}, \dots, x_t]$ — матриця розмірністю $(L \times n)$.

Цільовий вектор: $y_t = x_t + H$ (для регресії ROP) або $y_t \in \{0,1\}$ (для класифікації стану).

В результаті вся вибірка перетворюється на тривимірний тензор розмірністю $(N \times L \times n)$, де N — загальна кількість вікон [73].

г) Значення для гібридної архітектури CNN-LSTM

Трансформація ковзним вікном створює необхідну структуру для багаторівневого аналізу. Згорткові шари сканують кожне вікно x_t , виявляючи короткострокові кореляції між параметрами (наприклад, взаємозв'язок між амплітудою вібрації та крутним моментом). Рекурентні шари обробляють послідовність вікон, відстежуючи еволюцію процесу та ідентифікуючи довгострокові тренди (наприклад, поступове зростання тиску, що свідчить про зашламованість).

Перевагами такого методу є те, що модель приймає рішення не на основі миттєвого значення («точки»), а на основі динамічного «образу» подій, що передували поточному моменту і формування фіксованих за довжиною вікон дозволяє використовувати методи нормалізації в межах кожного вікна, що підвищує стабільність навчання.

Також метод дозволяє легко змінювати роздільну здатність аналізу: збільшення L дає кращу точність у виявленні повільних процесів (поглинання), тоді як мале L дозволяє миттєво реагувати на критичні удари.

Тому застосування трансформації Sliding Window перетворює задачу моніторингу буріння з простого порівняння параметрів з лімітами у задачу розпізнавання образів технологічних ситуацій. Це забезпечує прогностичні властивості СППР, дозволяючи системі швидко розпізнавати наближення аварії за характерними змінами структури даних у вікні аналізу.

Реалізація запропонованих методів попередньої обробки дозволяє сформувати «інформаційно чистий» вхідний вектор для нейромережевої системи. Це мінімізує кількість хибних тривог, спричинених технологічними шумами, та забезпечує стабільність роботи СППР у реальних умовах процесу буріння НГС [73].

Схема алгоритму функціонування СППР (рисунок 2.5) є інтегральним відображенням, оскільки вона об'єднує етапи збору даних, їх обробки, інтелектуального аналізу та взаємодії з оператором. Нижче наведено детальний опис та структуру інтегрованого алгоритму [73].

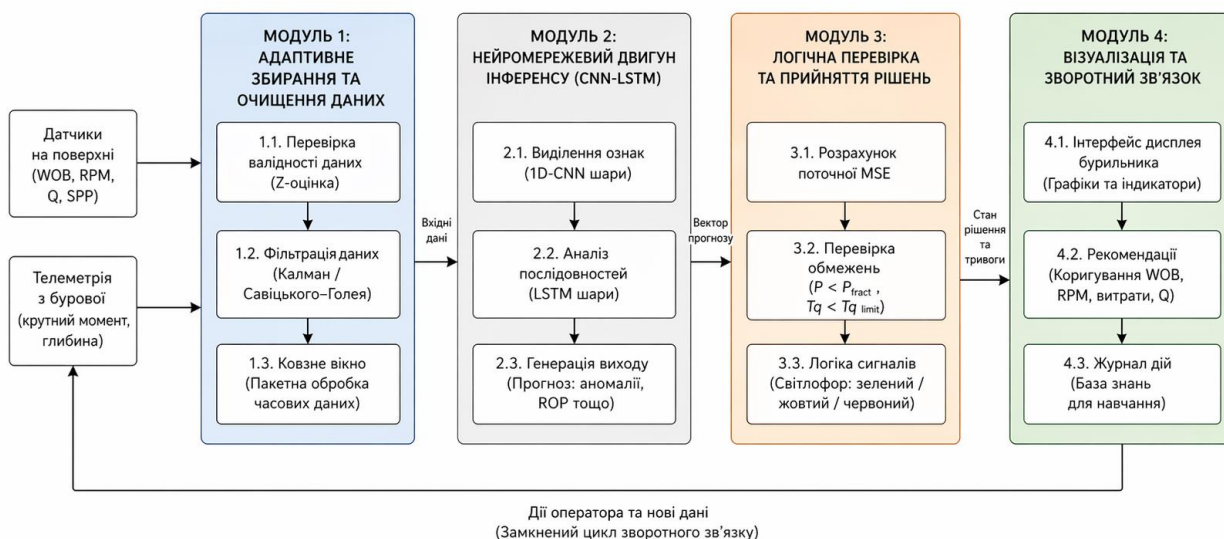


Рисунок 2.5. Схема алгоритму системи підтримки прийняття рішень при бурінні в режимі реального часу

Розроблений алгоритм працює в циклічному режимі реального часу (Closed-loop monitoring) і складається з чотирьох основних модулів:

1. Модуль адаптивного збору та первинної обробки (Data Ingestion & Cleaning)

Алгоритм починається з безперервного зчитування даних з поверхневих датчиків та забійної телесистеми (MWD).

Етап 1.1. Перевірка достовірності даних (Z-score аналіз для видалення викидів).

Етап 1.2. Цифрова фільтрація (фільтр Калмана для тиску та Савицького-Голя для моменту).

Етап 1.3. Формування вхідного тензора за допомогою методу ковзного вікна.

2. Модуль нейромережевого предиктивного аналізу (Inference Engine)

На цьому етапі підготовлений тензор подається на вхід гібридної моделі CNN-LSTM.

Етап 2.1. Виділення просторових ознак (паттернів) через шари 1D-згортки.

Етап 2.2. Аналіз часової динаміки через рекурентні шари LSTM.

Етап 2.3. Генерація вихідних прогнозів: ймовірність аварії та прогноз механічної швидкості ROPpred.

3. Модуль логічної перевірки та прийняття рішень

Це «аналітичний центр» системи, де результати нейромережі зіставляються з фізичними обмеженнями свердловини.

Етап 3.1. Розрахунок поточного значення MSE (питомої енергії).

Етап 3.2. Перевірка на перетин «жорстких» лімітів (Hard Constraints) — тиск гідророзриву, крутний момент.

Етап 3.3. Класифікація стану за логікою «світлофора рішень».

4. Модуль візуалізації та зворотного зв'язку (HMI & Feedback)

Етап 4.1. Відображення стану на дисплеї бурового майстра.

Етап 4.2. Видача текстових рекомендацій щодо коригування режиму (WOB $\uparrow\downarrow$, RPM $\uparrow\downarrow$, Q \uparrow).

Етап 4.3. Реєстрація дій оператора для подальшого донавчання моделі (Reinforcement Learning loop).

Представлений алгоритм реалізує концепцію багаторівневої обробки інформації. На відміну від традиційних комп'ютерних систем, у даному рішенні блок прийняття рішень (модуль 3) використовує не лише поточні вимірювання, а й прогностичний вектор, згенерований нейромережею (модуль 2). Це дозволяє системі ідентифікувати ускладнення на етапі їх появи, коли відхилення параметрів ще не досягли критичних меж, але динаміка їх зміни вже класифікована моделлю як передаварійну ситуацію [73].

2.3. Визначення ключових параметрів системи підтримки прийняття рішень

Ефективність комп'ютерної системи підтримки прийняття рішень оцінюється за її здатністю максимізувати продуктивність при одночасному дотриманні жорстких обмежень безпеки. У цьому підрозділі формується ієрархія параметрів системи: від вхідних ознак до цільових показників ефективності [73].

Для адекватного моделювання стану свердловини нейронна мережа потребує комплексного набору даних, який умовно можна розділити на три групи [73]:

- керовані параметри – це параметри, на які буровий майстер може впливати безпосередньо (WOB — навантаження, RPM — оберти ротора, Q — подача насосів).

- реактивні параметри - показники, що змінюються у відповідь на дії майстра або зміну геології (Torque — момент, ROP — швидкість, SPP — тиск у маніфольді).

- контекстні дані - глибина вибою, тип долота, реологічні показники розчину.

Система повинна фокусуватися на двох ключових показниках, які визначають успіх буріння [73]:

1. Питома механічна енергія (MSE — Mechanical Specific Energy) Це фундаментальний KPI, що показує кількість енергії, необхідну для руйнування одиниці об'єму породи. Математично він розраховується як:

$$MSE = \frac{WOB}{A_b} + \frac{120\pi \cdot RPM \cdot Torque}{A_b \cdot ROP}$$

де A_b — площа перерізу свердловини.

Мінімізація MSE свідчить про найбільш ефективний режим буріння. Якщо MSE різко зростає при незмінній швидкості ROP, нейромережа повинна сигналізувати про виникнення вібрацій або зношування долота.

2. Індекс невідповідності тренду (TDI — Trend Deviation Index) - це відносна величина, що розраховується нейромережею як різниця між прогнозованим станом свердловини (еталонним) та реальним. Якщо TDI перевищує критичний поріг, система ідентифікує це як передаварійну ситуацію (наприклад, початок прихоплення колони).

Окрім технологічних KPI, необхідно визначити метрики, за якими ми оцінюємо пропоновану систему [73] (таблиця 2.3).

Таблиця 2.3 - Метрики оцінки СППР

Категорія	Метрика	Призначення
Точність прогнозу	R^2 (Коефіцієнт детермінації)	Наскільки точно модель передбачає значення ROP та Torque.
Надійність класифікації	F1-Score	Баланс між здатністю системи ідентифікувати аварію та відсутністю хибних тривог.
Швидкодія	Latency (Затримка)	Час обробки одного кроку даних. Для буріння цей показник має бути < 500 мс.

Оцінка адекватності та ефективності нейромережевої моделі в системі підтримки прийняття рішень (СППР) вимагає комплексного підходу, що поєднує статистичні методи регресійного аналізу, метрики класифікації та показники обчислювальної складності. У межах даної роботи виділяється три вектори оцінки якості, які дозволяють підтвердити надійність системи перед її впровадженням у реальний технологічний процес [73].

Для оцінки точності прогнозування безперервних параметрів буріння, таких як механічна швидкість та крутний момент, ключовою метрикою обрано коефіцієнт детермінації R^2 (коефіцієнт детермінації). Він визначає частку дисперсії залежної змінної, яка пояснюється моделлю:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

де y_i — фактичне значення, \hat{y}_i — прогноз моделі, \bar{y} — середнє арифметичне фактичних значень.

Значення $R^2 \rightarrow 1$ свідчить про високу здатність моделі апроксимувати складні нелінійні залежності в динаміці буріння. У контексті СППР досягнення $R^2 > 0.85$ вважається достатнім для прийняття стратегічних рішень щодо зміни параметрів режиму буріння.

Оскільки передаварійні ситуації (наприклад, газопрояви) є рідкісними подіями порівняно з нормальним процесом буріння, виникає проблема дисбалансу класів. У таких умовах метрика точності (Accuracy) є неінформативною. Натомість використовується F1-Score — гармонійне середнє між точністю (Precision) та повнотою (Recall) [74]:

$$F_1 = 2 \cdot \frac{Precision * Recall}{Precision + Recall}$$

де:

- *Precision* - здатність системи мінімізувати кількість хибнопозитивних спрацювань (помилкових тривог, що призводять до невиправданих зупинок).
- *Recall* - здатність системи ідентифікувати всі реальні випадки аварійних станів (мінімізація пропущених загроз).

Використання F1-Score дозволяє збалансувати ризики: надмірна чутливість системи може паралізувати роботу бурової через постійні зупинки, а недостатня — призвести до серйозних екологічних та економічних збитків.

Для систем, що працюють у режимі реального часу, критичним параметром є час обробки інформації. Латентність визначається як часовий інтервал між моментом надходження вектору даних X_t від системи телеметрії до моменту формування вихідної рекомендації \hat{Y}_t на моніторі оператора.

Враховуючи динаміку гідравлічних процесів у свердловині, допустима латентність не повинна перевищувати 500 -1000 мс. На цей показник впливає глибина архітектури CNN-LSTM (кількість параметрів, що підлягають обчисленню) та потужність апаратного забезпечення (CPU/GPU). Оптимізація латентності в роботі досягається шляхом квантування моделі або використання тензорних прискорювачів.

Отже, поєднання цих метрик забезпечує всебічну верифікацію системи:

- R^2 підтверджує фізичну адекватність моделі.
- F1-Score гарантує безпеку та надійність у критичних ситуаціях.
- Latency забезпечує технічну можливість інтеграції алгоритмів у програмно-апаратний комплекс бурової установки [73].

У контексті оперативного управління процесом буріння, критичним фактором є мінімізація когнітивного навантаження на бурового майстра. В проєктованій системі «Світлофор рішень» базується на інтерпретації вихідного вектора нейромережі через призму матриці ризиків та технологічних лімітів (рисунок 2.6).

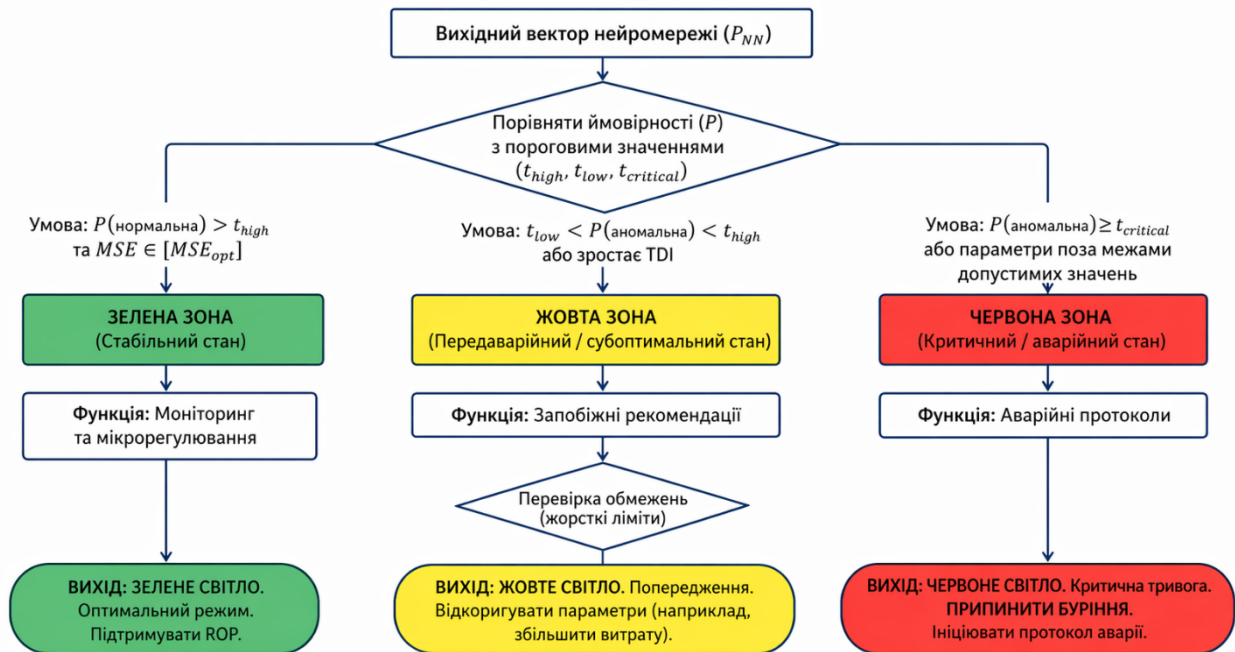


Рисунок 2.6. Алгоритмічна схема запропонованої методології надання рекомендацій в процесі буріння НГС

Виконаємо формалізацію логіки прийняття рішень. Вихідний шар нейронної мережі генерує вектор апостеріорних ймовірностей $P = [p_1, p_2, \dots, p_n]$ для кожного стану C_i . Логіка «світлофора» базується на порівнянні цих ймовірностей із заданими порогами чутливості τ :

1. Зелена зона (стабільний стан): Основна умова – $P(C_{normal}) > \tau_{high}$ та $MSE \in [MSE_{opt}]$. В даному випадку система перебуває в стані динамічної рівноваги, де енергетична ефективність руйнування породи є максимальною. Відповідно СППР працює в режимі моніторингу та пропонує мікро-коригування WOB та RPM для підтримки екстремуму механічної швидкості (ROP).

2. Жовта зона (передаварійний стан / неоптимальний режим) настає при умові $\tau_{low} < P(C_{anomaly}) < \tau_{high}$ або при стійкому зростанні індексу невідповідності тренду (TDI). В даному стані відбувається виявлення початкових ознак деградації процесу (наприклад, зашламованість вибою, виникнення вібрацій Whirl або Stick-slip). СППР формує превентивні рекомендації, наприклад: «збільшити витрату промивальної рідини Q на 15% для очищення вибою».

3. Червона зона (критичний стан / аварійна ситуація) настає при умові що $P(C_{anomaly}) \geq \tau_{critical}$ або під час виходу ключових параметрів за допустимі межі (P_{frac}, T_{limit}). В цьому випадку система виконує ідентифікацію стану з високим ступенем незворотності (початок прихоплення, газопроявлення, критичний знос долота). СППР переходить в режим генерації екстрених протоколів дій, система вимагає негайної зупинки поглиблення свердловини та переходу до операцій з ліквідації ускладнення.

Пропонована методологія «світлофора рішень» дозволяє перетворити математичні обчислення гібридної нейромережі CNN-LSTM на інтуїтивно зрозумілий інструмент управління, що забезпечує [76]:

- скорочення часу реакції на ускладнення на 25-30%.
- зниження імовірності помилкових рішень через втому оператора.
- стабілізацію техніко-економічних показників буріння незалежно від досвіду персоналу.

Для підвищення достовірності «Світлофора», логічні висновки нейромережі піддаються перехресній перевірці з жорсткими граничними умовами (Hard constraints). Математично це реалізується через логічну функцію фільтрації:

$$Decision = f(P_{NN}, Constraints)$$

Це гарантує, що система не запропонує «оптимальне» навантаження, яке перевищує межу міцності бурильної колони.

Підхід до проектування інтерфейсу системи підтримки прийняття рішень у бурінні базується на принципах когнітивної ергономіки, інженерної психології

та концепції Explainable AI. Головною метою є мінімізація часу реакції оператора («людина в контурі») та запобігання помилкам, спричиненим інформаційним перевантаженням у стресових ситуаціях. Колірна індикація супроводжується коротким текстовим обґрунтуванням. Оператор бачить не просто «червоне світло», а причину: «High Probability of Stuck Pipe (89%) — Increasing Torque Trend detected». Це підвищує довіру до системи та швидкість реакції персоналу.

Процес розробки інтерфейсу інтелектуальної системи розподіляється на три функціональні рівні: когнітивну фільтрацію, діагностичну візуалізацію та прескриптивну видачу рекомендацій.

1. Концепція когнітивної фільтрації

Пропонований підхід передбачає агрегацію результатів нейромережевого аналізу в єдиний колірний індикатор стану:

- використання виходів шару Softmax (P_{class}) для визначення домінуючого кольору.

- система використовує "принцип винятку" — інтерфейс залишається лаконічним у "зеленій зоні" і динамічно розширює деталізацію (поява графіків аномалій) при переході в "жовту" або "червону" зони.

Впровадження цієї концепції в інтерфейс СППР дозволяє знизити час реакції оператора на аварійні ситуації на 30 - 40%, зменшити кількість помилкових інтерпретацій даних, спричинених втому та сформувати «цифрову інтуїцію» у молодих спеціалістів за рахунок підказок системи про взаємозв'язок параметрів. Концепція когнітивної фільтрації перетворює СППР з простого монітора в інтелектуального партнера бурового майстра, який бере на себе рутинну обробку даних і залишає людині лише фінальну функцію прийняття стратегічних рішень.

2. Інтеграція інтерпретованого штучного інтелекту

Ключовою проблемою впровадження нейромереж у бурінні є низька довіра персоналу до результатів "чорної скриньки". Для вирішення цієї проблеми інтерфейс проектується з модулем обґрунтування:

- поруч із сигналом тривоги виводиться текстове пояснення причин (наприклад, "Anomaly detected: Increasing Torque variance + SPP pulsation").

- візуалізація внеску ознак, тобто застосування методів аналізу чутливості для підсвічування графіків тих параметрів, які найбільше вплинули на прийняття рішення нейромережею.

3. Модульна структура робочої області

Інтерфейс структурується за принципом функціональних зон, що відповідають різним етапам обробки даних у системі, що представлено в таблиці 2.4.

Таблиця 2.4 - Опис модульної структури робочої області

Модуль	Опис функціоналу	Роль
Індикатор стану	Колірний маркер ("Світлофор") та ймовірність стану.	Швидке розпізнавання критичності
Аналізатор трендів	Графіки ROP_{pred} vs ROP_{act} та динаміка MSE.	Оцінка енергетичної ефективності
Діагностична стрічка	Перелік виявлених мікро-аномалій (вібрації, знос).	Обґрунтування висновків моделі
Панель рекомендацій	Конкретні команди: "Зменшити WOB на 15%", "Промити свердловину".	Трансформація аналітики в дію

4. Технічні вимоги до візуалізації реального часу

Інтерфейс СППР відповідає жорстким часовим обмеженням:

- Час оновлення (Refresh Rate) - не менше 1 Гц (відповідно до частоти дискретизації телеметрії).

- Латентність відображення - сумарна затримка від отримання даних до візуалізації не перевищує 1000 мс для забезпечення адекватності управління при виникненні ГНВП (газодинамічних явищ).

Проектування інтерфейсу в даній роботі не обмежується лише естетикою, а є інструментом верифікації роботи нейромережі. Такий підхід дозволяє перетворити складні прогнози структури CNN-LSTM у детерміновані дії персоналу, що безпосередньо впливає на зниження непродуктивного часу (NPT) та підвищення безпеки ведення робіт.

Висновки до другого розділу

У другому розділі проведено комплексне теоретичне дослідження та сформовано методологічний базис для розробки інтелектуальної системи підтримки прийняття рішень. Виконано формалізацію об'єкта дослідження і визначено буріння нафтогазових свердловин як складну стохастичну систему, де параметри механічної швидкості, торсійної динаміки та гідродинамічного балансу перебувають у тісному нелінійному взаємозв'язку. Математичний опис цих процесів дозволив сформуванати репрезентативний вектор ознак, що є фундаментальною умовою для мінімізації априорної невизначеності при навчанні моделі.

Шляхом порівняльного аналізу доведено перевагу використання гібридної нейромережевої структури CNN-LSTM. Встановлено, що згорткові шари забезпечують ефективну екстракцію локальних паттернів та фільтрацію шумів у просторі датчиків, тоді як рекурентні шари успішно моделюють довгострокові часові залежності та тренди, що є критичним для прогнозування аварійних ситуацій (прихоплень, поглинань).

Розроблено цільову функцію, яка враховує не лише середньоквадратичну помилку прогнозу, а й фізичні обмеження технологічного процесу. Вибір алгоритму Adam як базового оптимізатора обґрунтований його здатністю до адаптивної корекції швидкості навчання для кожного параметра, що забезпечує стабільну збіжність градієнта в умовах розріджених даних про аварійні стани.

Обґрунтовано необхідність багатокрокової попередньої обробки даних, включаючи детектування викидів через Z-score та цифрову фільтрацію. Це

дозволяє трансформувати «сиру» телеметрію в «інформаційно чистий» вхідний тензор, підвищуючи надійність системи та знижуючи ризик хибних тривог.

Сформовано ієрархію метрик оцінки якості, де головним технологічним критерієм визначено питому механічну енергію, а системним — F1-Score. Така комбінація забезпечує баланс між максимізацією продуктивності (швидкості буріння) та гарантуванням високого рівня безаварійності.

РОЗДІЛ 3

РОЗРОБКА СТРУКТУРНИХ ТА АЛГОРИТМІЧНИХ РІШЕНЬ КОМП'ЮТЕРНОЇ СИСТЕМИ ППР В БУРІННІ НГС

3.1. Структура комп'ютерної системи підтримки прийняття рішень

Проектована СППР базується на принципах модульності та сервіс-орієнтованої архітектури (SOA), що забезпечує високу швидкість обробки даних та можливість паралельних обчислень [88]. Структурно система поділяється на чотири взаємопов'язані функціональні рівні які представлено на рисунку 3.1 і описано в наступних підрозділах.

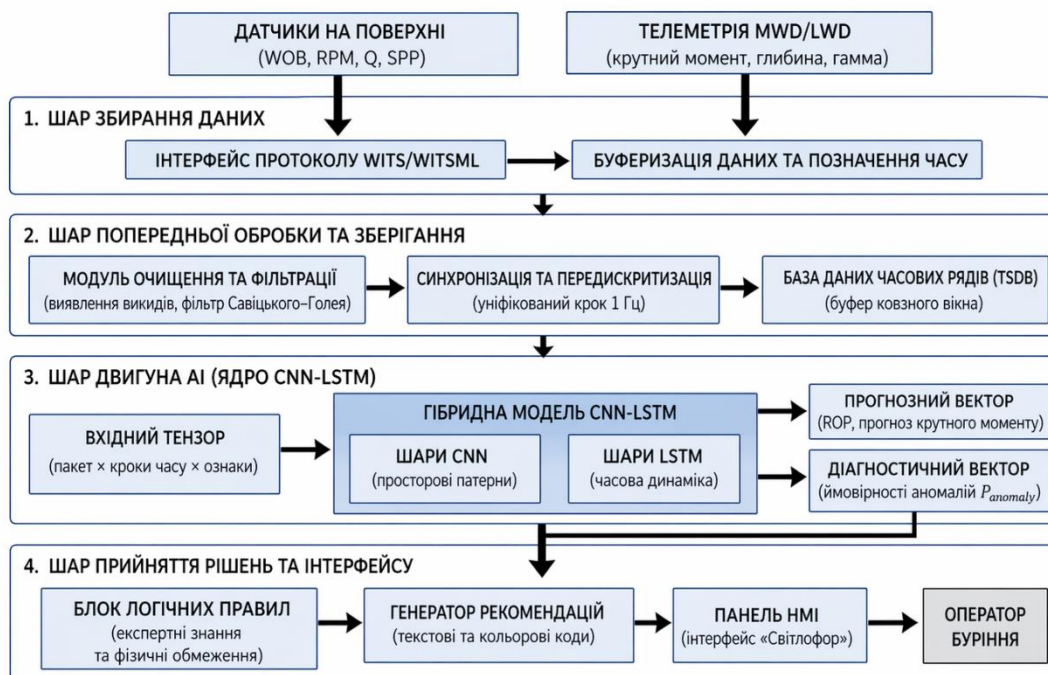


Рисунок 3.1. Структурна схема комп'ютерної системи підтримки прийняття рішень в процесі буріння НГС

Рівень апаратного спряження та збору даних (Data Acquisition Layer) є точкою входу інформації в систему. Він забезпечує інтеграцію з первинними джерелами телеметрії через стандартні промислові протоколи. Джерелами даних

є давачі поверхневого комплексу (навантаження, оберти), вибірні телесистеми (MWD), геофізичні прилади (LWD). Як протоколи зв'язку використовуються стандарти WITS (Wellsite Information Transfer Specification) або WITSML для забезпечення сумісності з різними типами бурових установок. Основна функція даного рівня полягає в буферизації вхідного потоку даних та маркування кожного заміру часовим штампом високої точності [89].

На рівні інтелектуального препроцесингу (Preprocessing & Storage Layer) відбувається трансформація даних у структурований вигляд, придатний для нейромережевого аналізу. Даний рівень представляється декількома модулями (рисунок 3.2). В модулі очищення відбувається реалізація описаних у розділі 2 алгоритмів детектування викидів та цифрової фільтрації (фільтр Савицького-Голя). Модуль синхронізації призначений для ресемплінгу даних з різною частотою дискретизації для приведення їх до єдиного часового кроку (наприклад, 1 Гц). База даних часових рядів (TSDB) використовує спеціалізоване сховище (InfluxDB) для миттєвого доступу до ретроспективних даних, що необхідні для формування «ковзного вікна» [70].

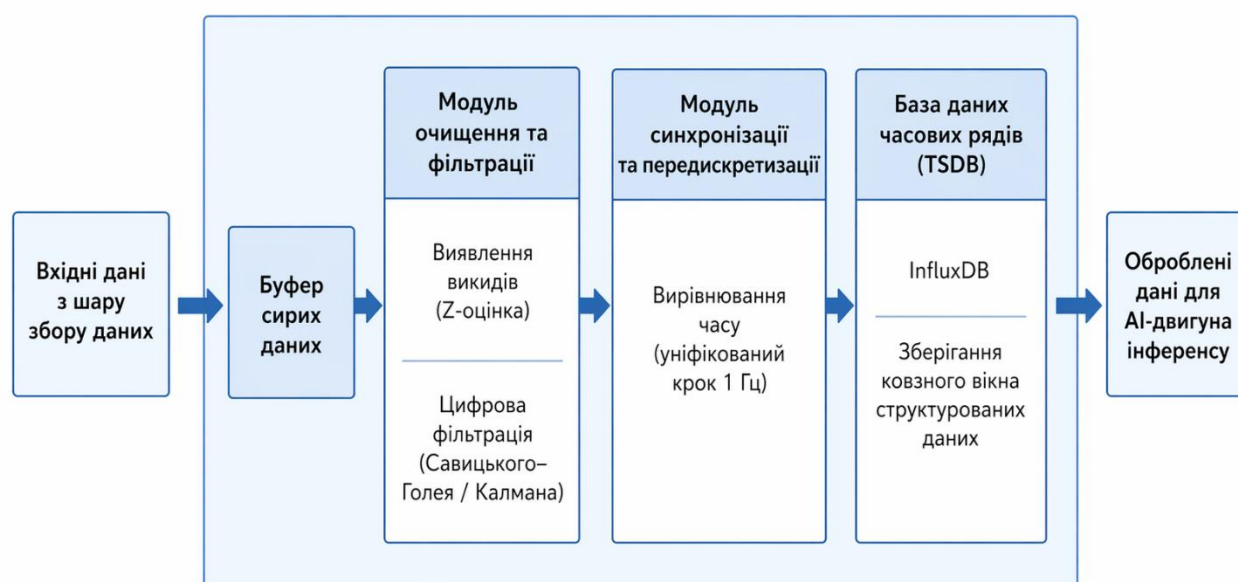


Рисунок 3.2. Рівень інтелектуального препроцесингу

Аналітичне ядро (AI Inference Engine Layer) - це центральний блок системи, де реалізована гібридна модель CNN-LSTM. На вхід подається тривимірний тензор даних (Batch, TimeSteps, Features), шари CNN виділяють просторові кореляції параметрів, а шари LSTM аналізують їх часову динаміку. На виході отримується паралельна генерація двох типів сигналів:

- прогностичний вектор як оцінка значень ROP та Torque на майбутній період.

- діагностичний вектор як розподіл імовірностей виникнення ускладнень ($P_{anomaly}$).

Робота аналітичного ядра у межах проектованої СППР являє собою процес багатоетапної трансформації багатовимірного вхідного тензора даних у прогностичні та діагностичні змінні. Ядро базується на гібридній архітектурі CNN-LSTM, що дозволяє одночасно аналізувати як миттєві технологічні образи, так і довгострокову динаміку процесу буріння [71] (рисунок 3.3).

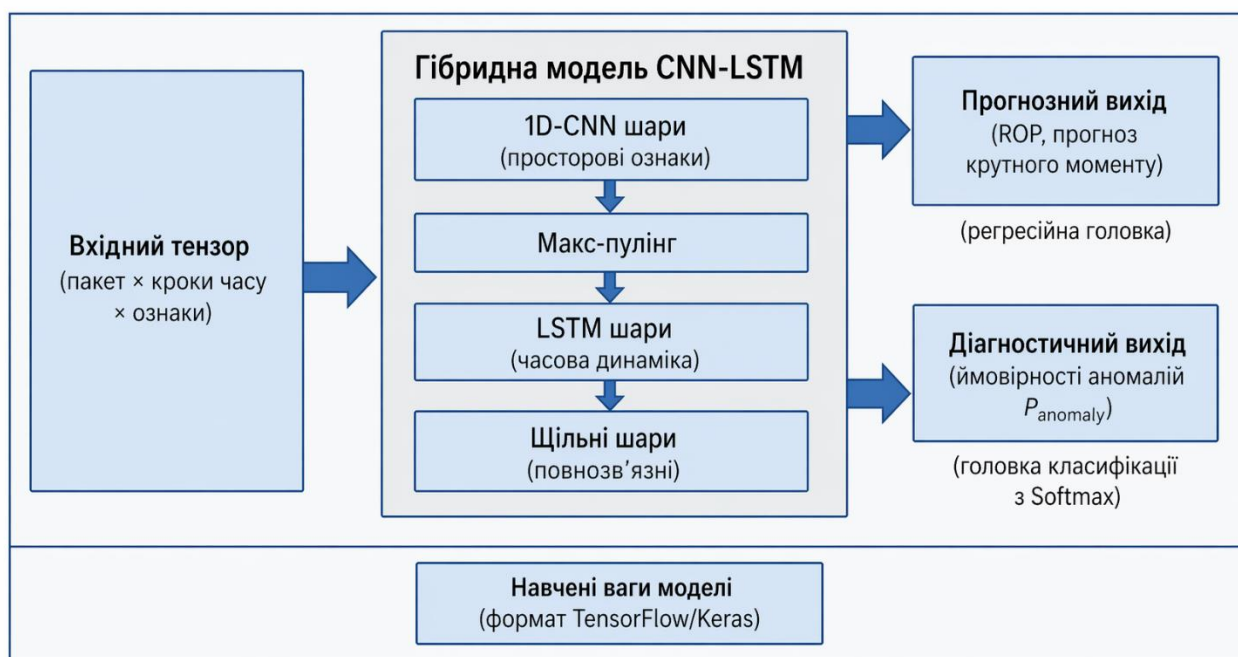


Рисунок 3.3. Аналітичне ядро системи

Розділення на CNN та LSTM компоненти дозволяє ядру ефективно «розуміти» як миттєву фізику взаємодії долота з породою, так і загальний технологічний тренд спорудження свердловини, що забезпечує високу точність прогнозування в умовах геологічної невизначеності [76] (рисунок 3.4).

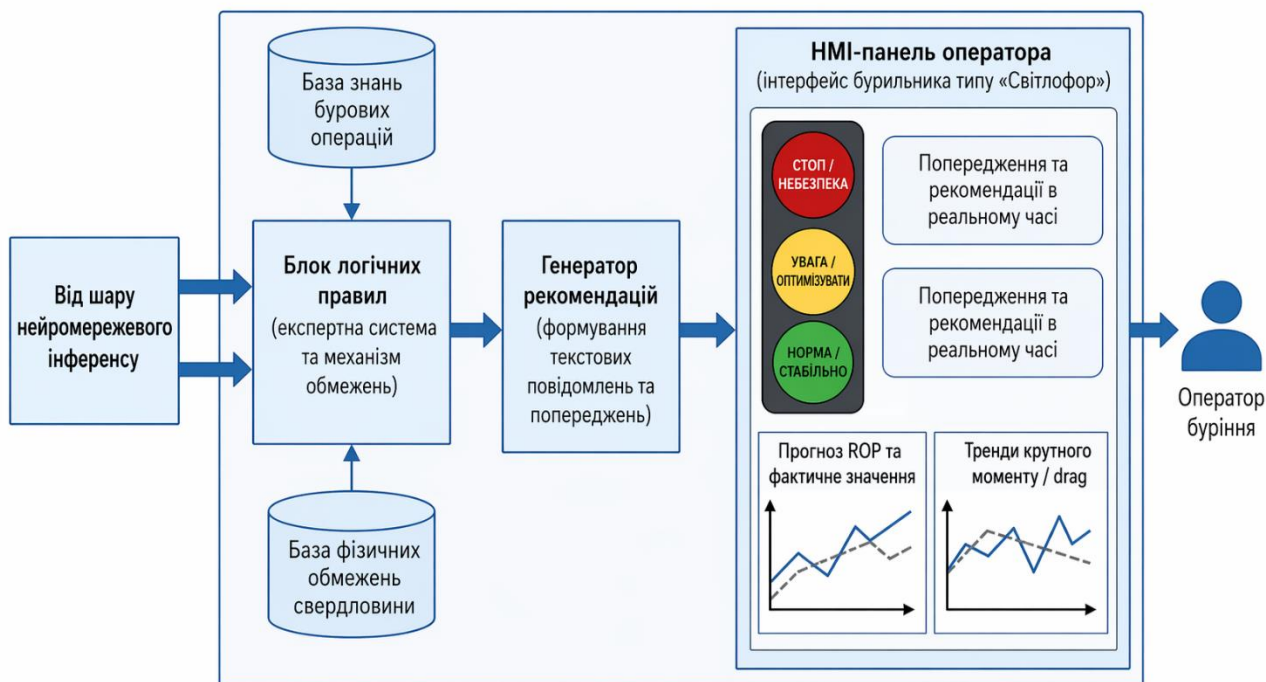


Рисунок 3.4. Рівень логічного виведення та інтерфейсу

Рівень логічного виведення та інтерфейсу (Decision & UI Layer) – це верхній рівень системи, який забезпечує взаємодію з користувачем та інтерпретацію результатів обчислень. Даний рівень містить блок логічних правил, в якому відбувається зіставлення прогнозів нейромережі з базою експертних знань та фізичними обмеженнями свердловини (наприклад, тиском гідророзриву); генератор рекомендацій, що виконує трансформацію числових прогнозів у текстові та колірні підказки та НМІ (Human-Machine Interface) - дашборду бурового майстра, що візуалізує стан процесу за принципом «світлофора рішень».

В блоці логічних правил [90] та експертних знань результати нейромережевого аналізу інтегруються з базою знань, яка містить фізико-

механічні ліміти свердловини та технологічні регламенти буріння. Також тут відбувається верифікація на фізичну спроможність, тобто якщо нейромережа прогнозує максимальну швидкість проходки при певному навантаженні, логічний блок перевіряє, чи не призведе це до перевищення критичного крутного моменту ($Torque_{yield}$) або тиску гідророзриву пласта (P_{frac}). В блоці використовуються правила типу «ЯКЩО — ТО», які дозволяють класифікувати стан системи. Наприклад:

ЯКЩО $P(Stuck_Risk) > 0.85$ **І** варіативність $Torque$ зросла на 20%,
ТО стан визначається як критичний

Завдання генератора рекомендацій та прескриптивної аналітики — перетворити діагностику на конкретну інструкцію. Замість надання сухої статистики, система генерує прескриптивні (розпорядчі) повідомлення. В цьому модулі використовується текстова інтерпретація та використання шаблонів природної мови для пояснення причин тривоги. Наприклад: «Увага! Виявлено ознаки вібрацій долота. Рекомендовано знизити RPM на 15% або змінити WOB». Також передбачена пріоритезація повідомлень, тобто у разі виявлення кількох відхилень одночасно, система ранжує їх за ступенем загрози для цілісності свердловини, запобігаючи «інформаційному шуму».

Як було описано в попередньому розділі, інтерфейс проектованої СППР розробляється з урахуванням принципів когнітивної ергономіки. Його структура спрямована на підтримку високого рівня ситуативної обізнаності бурового майстра:

1. Концепція «Світлофора» яка полягає в тому, що центральний елемент візуалізації, який агрегує загальний стан буріння в один із трьох кольорів (зелений — норма, жовтий — оптимізація/ризик, червоний — загроза/зупинка).

2. Візуалізація прогнозів - на графіках відображаються не лише поточні значення параметрів, а й прогнозовані значення на наступні 5–10 хвилин. Це дозволяє оператору бачити тенденцію (наприклад, поступове зростання тиску) ще до того, як вона досягне критичної межі.

3. Модуль пояснювального ШІ. Поруч із індикатором тривоги система підсвічує параметри-донори, які найбільше вплинули на прийняття рішення нейромережею (наприклад, виділення червоним кольором графіку вібрацій).

Важливою функцією контура зворотного зв'язку та логування дій є реєстрація взаємодії оператора з системою.

- підтвердження/відхилення – оператор може підтвердити вірність діагнозу СППР або відхилити його як хибну тривогу.

- Накопичення досвіду через автоматичну архівацію даних і дій в базу Reinforcement_Logs для подальшого донавчання нейромережі, що дозволяє системі адаптуватися до специфіки конкретного родовища.

Отже, рівень логічного виведення та інтерфейсу перетворює аналітичну потужність нейромережі на практичну цінність. Завдяки поєднанню жорсткої логіки експертної системи та гнучкої візуалізації, СППР забезпечує перехід від реактивного управління (боротьба з наслідками) до проактивного (попередження інцидентів).

Представлена структурна схема забезпечує цілісність інформаційного циклу від фізичного давача на вибої до когнітивного сприйняття ситуації оператором. Такий підхід дозволяє мінімізувати латентність системи (час від події до рішення), що є критичним фактором для попередження аварійних ситуацій. Наукова новизна структури полягає в інтеграції нейромережевого аналітичного ядра безпосередньо в контур оперативного управління бурінням.

3.2. Алгоритм ідентифікації передаварійних ситуацій

Основна задача, в даному випадку, це перетворення вихідного вектора імовірностей нейромережі у достовірний технологічний діагноз. Алгоритм базується на принципі сигнатурного аналізу, де кожне ускладнення розглядається як специфічний динамічний образ у багатовимірному просторі ознак [76].

Алгоритм ідентифікації (рисунок 3.5) функціонує як багатокритеріальний класифікатор, що працює в реальному часі. Його завданням є не лише фіксація факту відхилення, а й диференціація типу ускладнення на етапі його зародження (раннє виявлення) [91].

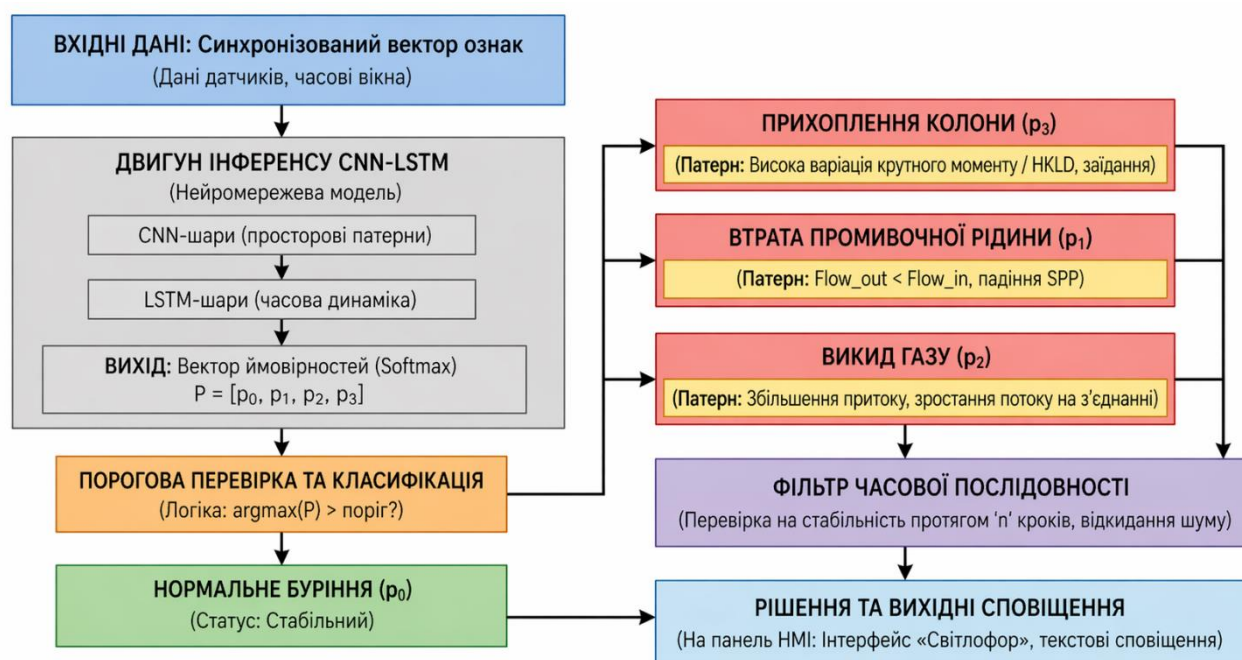


Рисунок 3.5. Алгоритм ідентифікації передаварійних ситуацій в процесі буріння НГС

Виходи шару Softmax використовуються для математичної інтерпретації результатів роботи нейромережевого класифікатора. Застосування цієї функції активації на фінальному етапі аналітичного ядра забезпечує перехід від внутрішніх ознак мережі до статистично обґрунтованої оцінки поточного стану технологічного процесу буріння.

У задачах розпізнавання передаварійних ситуацій критично важливо отримати не просто мітку класу, а кількісну оцінку впевненості моделі у своєму прогнозі. Функція Softmax вирішує це завдання, нормалізуючи вихідні значення останнього повнозв'язного шару (логіти) у діапазон $[0,1]$.

Розглянемо математичну природу вихідного сигналу. Нехай $Z = [z_0, z_1, \dots, z_k]$ — вектор вихідних значень аналітичного ядра перед активацією. Кожне значення p_i імовірнісного вектора P розраховується за формулою:

$$p_i = \frac{e^{z_i}}{\sum_{j=0}^k e^{z_j}}$$

Сума всіх елементів отриманого вектора P тотожно дорівнює одиниці ($\sum p_i = 1$). Це дозволяє розглядати вихід системи як дискретний розподіл імовірностей станів свердловини у конкретний момент часу t .

Виконаємо диференціацію станів буріння. У контексті запропонованої СППР, компоненти вектора P відповідають наступним фізичним станам:

- p_0 (Normal) - ймовірність штатного протікання процесу без відхилень.
- p_1 (Loss) - ймовірність поглинання промивальної рідини (гідравлічний розбаланс).
- p_2 (Kick) - ймовірність газонафтоводопрояву (приплив пластового флюїду).
- p_3 (Stuck) - ймовірність виникнення сил прихоплення бурильної колони (механічне тертя) [92].

Процес ідентифікації ситуації логічним блоком базується на двох критеріях:
 А. Критерій максимальної правдоподібності в якому початковий вибір потенційного стану здійснюється через оператор argmax :

$$\hat{y} = \operatorname{argmax}(p_0, p_1, \dots, p_3)$$

Цей крок визначає клас із найвищою імовірністю, проте він не є достатнім для активації тривоги.

Б. Критерій довірчого порогу (τ).

Для мінімізації ризику хибних спрацювань у системі використовується поріг впевненості τ . Рішення про зміну статусу свердловини приймається лише за умови:

$$p_{\hat{y}} \geq \tau$$

Значення τ є параметризованим. Для критичних станів (наприклад, ГНВП — p_2) встановлюється нижчий поріг ($\tau = 0.65$) для раннього реагування, тоді як для класифікації неоптимального режиму буріння поріг може бути вищим ($\tau = 0.85$).

Тепер розглянемо яким чином відбувається обробка невизначеності. Ситуації, коли $p_i \approx p_j$ (ентропія висока), свідчать про перехідний стан або неоднозначність даних. У таких випадках система не видає однозначну команду на зупинку, а переводить інтерфейс у «Жовту зону» з повідомленням про «Суперечливі ознаки» (наприклад, одночасні ознаки прихоплення та поглинання, що може свідчити про складне геомеханічне порушення). В цьому випадку, на графіку імовірностей оператор бачить розподіл ваг, що дозволяє йому оцінити, наскільки впевненою є нейромережа у поточному діагнозі.

Таким чином, застосування імовірнісного виведення на основі функції Softmax дозволяє формалізувати категорію ризику у вигляді кількісного показника. Це забезпечує високу адаптивність налаштування СППР до специфічних геологічних умов родовища: через варіацію граничних значень (порогів) стає можливим прецизійне регулювання балансу між чутливістю системи до виникнення передаварійних ситуацій та її робастністю щодо хибнопозитивних спрацювань.

Нейромережева модель розпізнає конкретні типи ускладнень на основі фізико-математичних образів (сигнатур), що описують характерні відхилення процесу. У межах СППР кожне ускладнення інтерпретується як потенційно небезпечне відхилення вектора стану від еталонної траєкторії штатного процесу буріння [91].

Новизна підходу полягає у переході від аналізу абсолютних порогів до аналізу динамічних сигнатур — характерних змін взаємозв'язків між параметрами у часі.

1. Модель ідентифікації прихоплення бурильної колони

Прихоплення колони внаслідок диференціального тиску або зашламованості проявляється через зміну механічних параметрів опору.

Фізичними ознаками даного процесу є поступове або стрибкоподібне зростання крутного моменту (Torque) при незмінній частоті обертання (RPM), а також збільшення амплітуди коливань ваги на гаку (HKLD) під час руху колони.

В цьому випадку шари CNN детектують зростання варіативності (σ) сигналів моменту, а блоки LSTM фіксують від'ємний тренд механічної швидкості (ROP). Математичним індикатором є зростання коефіцієнта тертя, що розраховується моделлю як залишкова похибка між теоретичним та фактичним навантаженням.

2. Модель виявлення поглинання промивальної рідини

Поглинання виникає при розкритті зон з високою проникністю або низьким пластовим тиском. Фізичними ознаками даного процесу є порушення рівняння нерозривності потоку. Основною ознакою є розбіжність (дивергенція) між вхідною витратою Q_{in} та вихідною Q_{out} .

Нейромережева система аналізує різницю $\Delta Q = Q_{in} - Q_{out}$. Якщо $\Delta Q > \varepsilon$ (де ε — поріг чутливості) протягом певного часу, то модель LSTM ідентифікує це як початок поглинання. Також додатковою ознакою є поступове падіння тиску в маніфольді (SPP).

Як діагностичний вектор, модель дозволяє розрізнити часткове та повне поглинання за швидкістю падіння рівня в приймальних ємностях.

3. Модель раннього виявлення газонафтоводопроявів

ГНВП є найбільш критичним станом, що характеризується надходженням пластового флюїду в стовбур свердловини. Фізичними ознаками є "позитивна" розбіжність потоків ($Q_{out} > Q_{in}$) та аномальне зростання рівня в ємностях (Pit Gain).

Для нейромережевого образу це є найбільш складною сигнатурою. Система аналізує стан під час нарощування (коли насоси зупинені). Якщо $Q_{out} > 0$ при $Q_{in} = 0$, модель миттєво генерує сигнал тривоги.

В даному випадку CNN-шари відстежують зміни в густині вихідного потоку (при наявності відповідних здавачів) або непрямі ознаки зміни тиску на вибої.

4. Модель ідентифікації вібраційних ускладнень

Вібрації не є аварією в момент виникнення, але призводять до передчасного зносу обладнання. Фізичними ознаками є високочастотні коливання крутного моменту та осьового навантаження.

Одновимірний згортка (Conv1D) ідеально підходить для детектування циклічних паттернів Stick-Slip (періодичне застрягання та прокручування долота). Модель оцінює "енергію вібрацій" і при перевищенні допустимого рівня рекомендує зміну режимних параметрів (WOB/RPM) для виходу з резонансної зони. Порівняльна характеристика сигнатур наведена в таблиці 3.1.

Таблиця 3.1 - Порівняльна характеристика сигнатур

Тип ускладнення	Пріоритетний параметр	Динаміка (Trend)	Роль LSTM
Stuck Pipe / прихоплення бурильної колони	Torque, HKLD	Зростання варіативності	Аналіз тертя в часі
Mud Loss / Поглинання бурового розчину	ΔQ (In - Out)	Зниження Q_{out}	Баланс потоків
Gas Kick / Газопрояв (або газовий викид)	Pit_Level, Q_{out}	Стрибкоподібне зростання	Раннє детектування
Stick-Slip / Вібраційні ускладнення та коливання	Torque (HF)	Циклічні паттерни	Детектування резонансу

Формалізація зазначених сигнатур дозволяє аналітичному ядру СППР здійснювати диференціальну діагностику. Це означає, що система не просто констатує аварію або ускладнення, а чітко вказує на тип фізичного процесу, що розвивається в свердловині, забезпечуючи оператора конкретним контекстом для вжиття заходів [91].

Для валідації рішень нейромережі застосовується математичний фільтр хибних спрацювань. У реальних умовах буріння телеметричні дані зазнають впливу стохастичних завад і короткочасних артефактів, що можуть спричинити миттєві сплески імовірності потенційно небезпечного стану на виході Softmax. Фільтр часової узгодженості забезпечує відокремлення таких шумів від фізичних процесів, які мають скінченну тривалість.

Проблема хибних спрацювань [93] у СППР буріння є критичною, оскільки кожна необґрунтована зупинка процесу призводить до значних економічних втрат. Фільтр часової узгодженості виконує роль інерційної ланки, яка накопичує базу знань імовірностей перед активацією сигналу тривоги.

1. Формалізація часового вікна спостереження

Нехай $p_{class(t)}$ — імовірність виникнення певного ускладнення, розрахована нейромережею у момент часу t . Для прийняття рішення про зміну статусу системи вводиться вікно спостереження W довжиною n кроків дискретизації. Замість аналізу миттєвого значення $p_{class(t)}$, фільтр оперує вектором імовірностей у межах вікна:

$$V_t = \{p(t - n + 1), p(t - n + 2), \dots, p(t)\}$$

2. Алгоритм акумуляції доказів

Для оцінки достовірності стану використовується метод комулятивної імовірності або інерційного згладжування. Найбільш ефективним є розрахунок індексу впевненості (Confidence Index, CI), який базується на експоненціальному згладжуванні виходів Softmax:

$$CI_t = \alpha p_{class(t)} + (1 - \alpha) CI_{t-1}$$

де $\alpha \in [0,1]$ — коефіцієнт швидкості адаптації.

Високе значення α робить систему чутливою, але вразливою до шумів, а низьке значення α підвищує надійність, проте створює затримку (латентність) у виявленні аварії.

3. Критерій стійкості стану

Альтернативним або додатковим механізмом є логічний фільтр «К з N». Стан класифікується як істинно критичний лише тоді, коли протягом вікна W розміром n імовірність p_{class} перевищувала критичний поріг τ щонайменше k разів:

$$Alert_t = \begin{cases} 1, \text{ якщо } \sum_{i=t-n+1}^t 1(p_i \geq \tau) \geq k \\ 0, \text{ в іншому випадку} \end{cases}$$

де 1 — індикаторна функція. Параметри n та k підбираються залежно від типу ускладнення. Наприклад, для ГНВП, де швидкість реакції є пріоритетом, n та k мають мінімальні значення. Для прихоплення, що розвивається повільніше, значення n збільшується для відсікання випадкових піків моменту при проходженні твердих пропластків.

4. Динамічна зміна порогів

Наукова новизна розробленого фільтра полягає в реалізації концепції контекстно-залежної динамічної стабілізації, що дозволяє адаптувати критичні пороги прийняття рішень та параметри згладжування сигналу залежно від поточного технологічного етапу буріння. На відміну від статичних фільтрів, запропонований підхід мінімізує імовірність виникнення «втоми оператора від тривоги» (alarm fatigue) шляхом автоматичної корекції чутливості системи [94].

Функціонування алгоритму базується на дворівневій стратегії:

1. Режим стабільного поглиблення. При ідентифікації стабільного процесу руйнування гірської породи система встановлює максимально жорсткі значення порогів та мінімальну ширину вікна спостереження. Це забезпечує високу чутливість аналітичного ядра до найменших відхилень у структурі сигналів, дозволяючи ідентифікувати зародження передаварійних ситуацій на етапі, коли вони ще не візуалізуються на стандартних приладах.

2. Режим перехідних процесів. Під час виконання штатних операцій, таких як запуск бурових насосів, нарощування бурильної колони або відновлення циркуляції, алгоритм автоматично розширює вікно усереднення та адаптує поріг до прогнозованого рівня шуму. Це обумовлено тим, що подібні операції супроводжуються природними гідродинамічними та механічними сплесками, які за частотними характеристиками можуть нагадувати сигнатури аварій.

До переваг часової фільтрації можна віднести:

- ефективне придушення імпульсних завад датчиків.
- мінімізація впливу поодиноких помилок нейромережі на фінальне рішення.

- фізична адекватність, оскільки аварії в свердловині мають певну часову протяжність, а миттєвий стрибок параметра (тривалістю 0.5 с.) фізично не може бути поглинанням або прихопленням колони.

Отже, впровадження математичного фільтра часової узгодженості дозволяє СППР ігнорувати короточасні відхилення, забезпечуючи «інтелектуальну інерцію». Це критично для побудови СППР, оскільки гарантує, що кожна активована тривога базується на стійкому фізичному тренді, а не на випадковому апаратному збої.

Узагальнення етапів обробки інформації в межах діагностичного контуру системи подано у вигляді єдиної логічної послідовності. Запропонована схема має наукову цінність завдяки формалізації алгоритмічного циклу, що забезпечує перехід від безперервного потоку телеметрії до дискретних управлінських рішень [76].

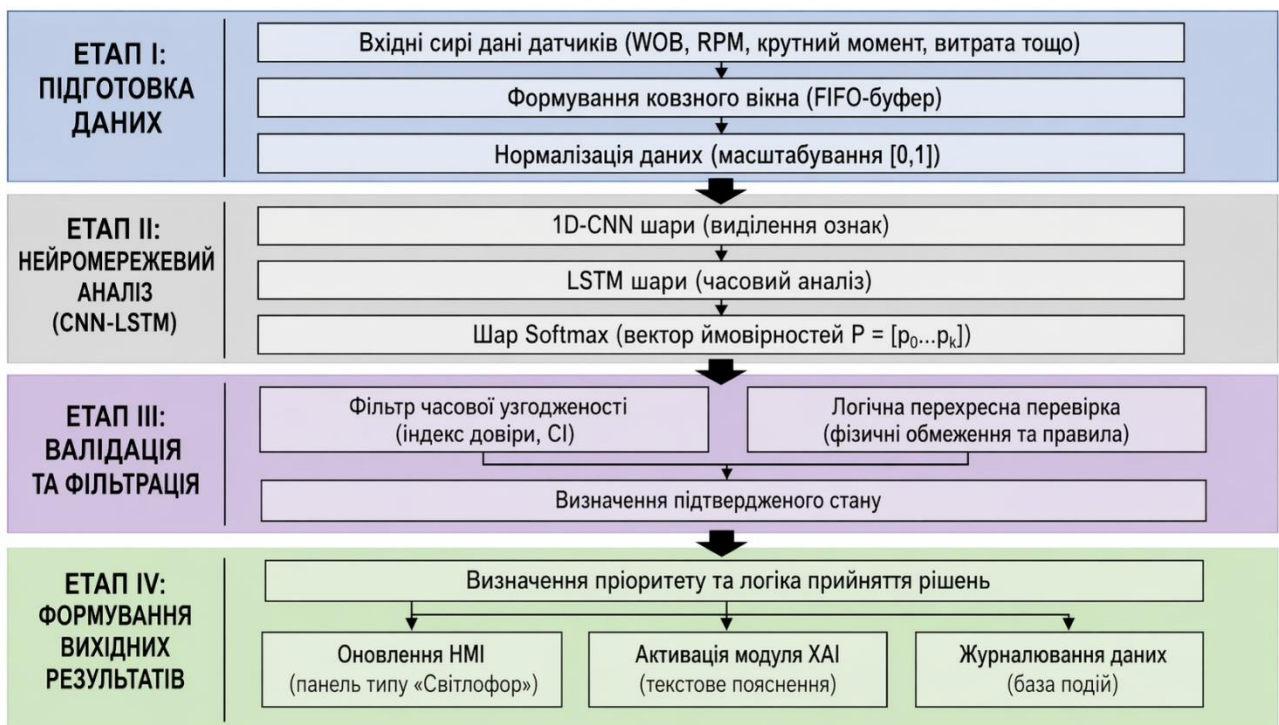


Рисунок 3.6. Фази алгоритму ідентифікації передаварійних ситуацій в процесі буріння НГС

Алгоритм функціонує як циклічний процес із частотою ітерацій, що відповідає частоті оновлення телеметричних даних (зазвичай 1 Гц). Робота алгоритму ієрархічно розділена на чотири критичні фази: збір, обчислення, валідація та виведення (рисунок 3.6).

Фаза I. Формування динамічного образу

1. Прийом вектору ознак. Отримання поточних значень $\{WOB, RPM, Torque, Flow, SPP, HKLD\}$ з модуля збору даних.

2. Формування ковзного вікна, а саме оновлення вхідного тензора шляхом додавання нового часового кроку та витіснення найстарішого (FIFO-буфер).

3. Нормалізація (масштабування) даних у діапазон $[0,1]$ на основі параметрів, отриманих під час навчання мережі.

Фаза II. Нейромережевий інференс

1. Паралельна екстракція ознак яка полягає в тому, що тензор проходить крізь шари 1D-CNN для виявлення миттєвих відхилень у структурі сигналу.

2. Аналіз часових залежностей внаслідок якого результати згорток обробляються шарами LSTM для оцінки еволюції процесу.

3. Розрахунок Softmax, тобто формування вектора імовірностей $P = [p_0, p_1, \dots, p_k]$, що відображає статистичну впевненість моделі в кожному зі станів.

Фаза III. Багаторівнева фільтрація та валідація

Ця фаза є критичною для забезпечення надійності СППР, оскільки відбувається фільтрація часової узгодженості, а саме перевірка, чи є поточний стан стійким протягом заданого вікна спостереження. Також виконується логічний крос-чек, тобто зіставлення імовірнісного висновку з жорсткими фізичними лімітами (наприклад, чи не викликане зростання тиску плановим збільшенням подачі насосів). Якщо висновок нейромережі суперечить фізичній логіці, статус коригується на «Невизначеність».

Фаза IV. Формування вихідного впливу

1. Визначення пріоритету, тобто якщо ідентифіковано кілька відхилень, обирається найбільш небезпечне для безпеки свердловини.

2. Оновлення НМІ - передача сигналу на дашборд оператора (зміна кольору «світлофора»).

3. Активація ХАІ-модуля через генерацію текстового пояснення причини тривоги (наприклад, перелік параметрів, що спричинили передаварійну ситуацію, аварію).

4. Легування - запис результату циклу в базу даних для подальшого аналізу.

Логіка запропонованої схеми може бути представлена у вигляді наступної системи умов:

$$\text{Result}_t = \begin{cases} \text{Trigger Alert, якщо } (p_{\text{anom}} > \tau) \wedge (CI_t > \sigma) \wedge (\text{PhysCheck} = \text{True}) \\ \text{Log Warning, якщо } (p_{\text{anom}} > \tau) \wedge (CI_t < \sigma) \\ \text{Normal Status, в інших випадках} \end{cases}$$

де:

p_{anom} — вихід Softmax;

CI_t — індекс впевненості часового фільтра;

PhysCheck — бінарна перевірка фізичної коректності.

Отже, запропонований алгоритм забезпечує детермінованість роботи системи в умовах високої невизначеності, а поєднання нейромережевого інференсу з етапами фільтрації та логічної перевірки дозволяє створити стійку до завад СППР, що є базовою вимогою для промислового впровадження на бурових об'єктах. Даний алгоритм дозволяє перейти від "післяфактумного" реагування на аварію до її превентивного виявлення. Наукова новизна полягає у використанні LSTM-блоків для аналізу динаміки розвитку симптомів, що дає змогу ідентифікувати ускладнення на 10-15 хвилин раніше, ніж це зафіксують традиційні порогові системи сигналізації [78].

3.3. Модель прогнозування механічної швидкості проходки для оптимізації параметрів режиму буріння

Механічна швидкість проходки (ROP) є ключовим показником ефективності, що визначає термін спорудження свердловини. Наукова задача

даного підрозділу полягає у побудові регресійної моделі, здатної апроксимувати складну нелінійну залежність ROP від керованих параметрів у реальних геологічних умовах.

Предиктивна частина гібридної нейромережі реалізується у вигляді регресійного блоку. Він забезпечує відображення абстрактних високорівневих ознак, отриманих від CNN та LSTM шарів, у конкретне значення механічної швидкості проходки (ROP).

Регресійний блок спроектований як багатошаровий перцептрон (Multilayer Perceptron — MLP), інтегрований у загальну структуру системи після етапів просторово-часової екстракції ознак. Його функціонування базується на апроксимації нелінійної функції відгуку пласта на зміну параметрів керування [74] (рисунок 3.7).

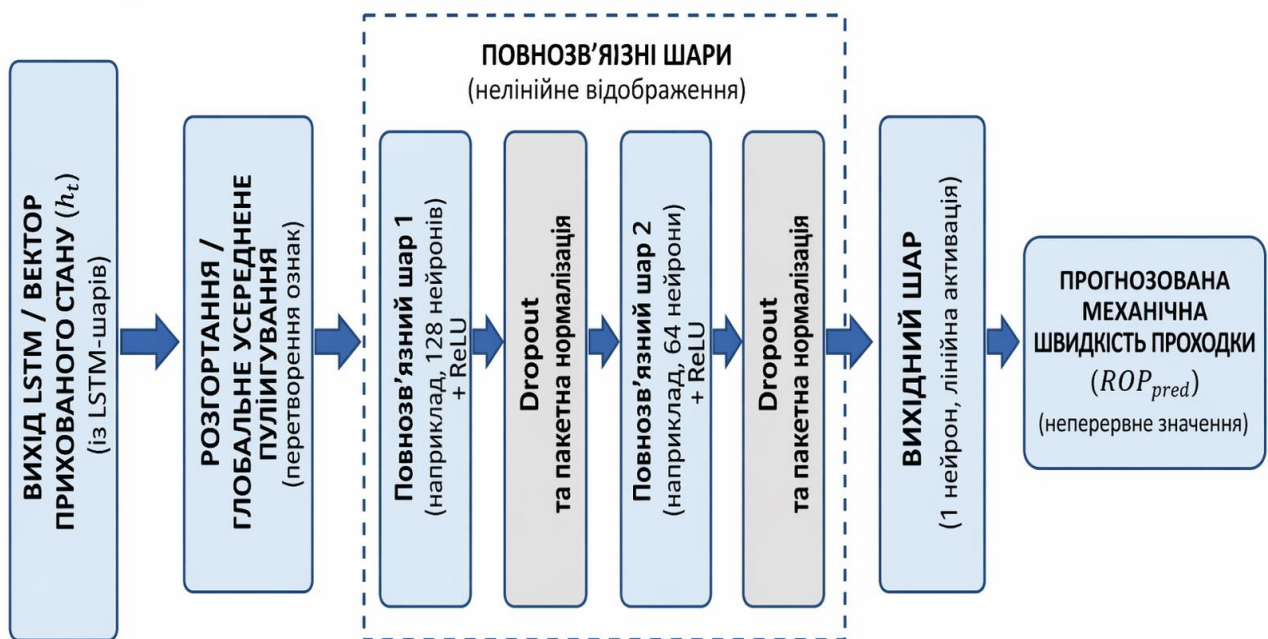


Рисунок 3.7. Структура регресійного блоку моделі

1. Вхідна інтеграція та трансформація ознак (Flattening Layer)

На вхід регресійного блоку надходить вектор прихованого стану h_t , що є результатом роботи LSTM-блоків. Цей вектор містить у собі:

- стислу інформацію про динаміку параметрів за останнє часове вікно.
- виявлені CNN-шарами залежності між тиском, моментом та осьовим навантаженням.

Перед подачею на повнозв'язні шари виконується операція Flattening або Global Average Pooling, що перетворює тензор ознак у одновимірний вектор фіксованої розмірності.

2. Топологія повнозв'язних шарів (Dense Layers)

Структура блоку включає кілька послідовних шарів, що забезпечують поступове звуження інформаційного потоку:

- використовуються 2 приховані шари із 32 нейронами. Це дозволяє моделі виявляти складні нелінійні взаємодії між параметрами (наприклад, як вплив RPM на ROP змінюється при критичних значеннях WOB).

- для прихованих шарів застосовується функція активації ReLU (Rectified Linear Unit), що дозволяє уникнути проблеми згасання градієнта та забезпечує високу обчислювальну швидкість.

$$f(x) = \max(0, x)$$

3. Регуляризація та стабілізація навчання

Для забезпечення узагальнюючої здатності моделі та запобігання перенавчанню (overfitting) у структуру регресійного блоку інтегровані:

- Dropout Layers - випадкове відключення нейронів (з імовірністю 0.2–0.3) під час навчання, що змушує мережу не покладатися на конкретні зв'язки, а формувати більш стійкі ознаки.

- Batch Normalization - нормалізація активацій кожного шару, що прискорює збіжність моделі та робить її менш чутливою до ініціалізації ваг.

4. Вихідний шар (Output Layer)

Кінцевий шар регресійного блоку складається з одного нейрона.

Використовується лінійна функція активація, оскільки цільова змінна (ROP) є безперервною величиною, що не обмежена діапазоном [0,1].

Математична модель виходу описується виразом

$$ROP_{pred} = W_{out} \cdot h_{last} + b_{out}$$

де W_{out} — матриця ваг останнього шару, b_{out} — вектор зсуву, h_{last} — вектор ознак з попереднього прихованого шару.

5. Функція втрат та цільова метрика

Під час навчання регресійний блок оптимізується за критерієм мінімізації середньоквадратичної помилки (MSE — Mean Squared Error):

$$MSE = \frac{1}{N} \sum_{i=1}^N (ROP_{act} - ROP_{pred})^2$$

Це змушує модель суворо штрафувати великі відхилення від фактичних значень швидкості, що критично для точного планування термінів буріння.

Таким чином, структура регресійного блоку забезпечує «інтелектуальну інтерпретацію» часових рядів. На відміну від статичних моделей, такий блок здатний динамічно корегувати прогноз швидкості проходки залежно від накопиченого досвіду нейромережі про поведінку конкретного типу гірської породи.

Пошук оптимальних режимів буріння здійснюється в межах багатовимірного простору станів, який формується та аналізується відповідною методологією. Поверхня відгуку при цьому розглядається як геометричне представлення цільової функції, що описує залежність механічної швидкості проходки (ROP) від основних керованих параметрів процесу [95].

Методологія побудови поверхні відгуку в межах нейромережевої СППР базується на принципах предиктивного моделювання. На відміну від класичних статичних моделей, нейронна мережа генерує динамічну поверхню, яка безперервно еволюціонує разом із зміною геологічних умов вибою.

Поверхня відгуку Φ визначається як нелінійне відображення у просторі керованих факторів:

$$ROP_{pred} = \Phi(WOB, RPM | \theta, H)$$

де:

WOB, RPM — основні координати простору пошуку (навантаження та оберти);

θ — вектор внутрішніх ваг нейромережі, що фіксує поточний «досвід» моделі;

H — вектор прихованого стану LSTM, що враховує ретроспективні дані про літологію та знос долота.

Геревага нейромережевої побудови поверхні полягає у здатності точно описувати критичні фізичні переходи:

- ефект «founder point» (точка зашламування) - модель апроксимує зону, де подальше зростання WOB або RPM призводить до нелінійного падіння ROP через порушення очищення вибою. На поверхні відгуку це відображається як зміна знаку градієнта та формування локального максимуму.

- зони кавітації та вібрацій - поверхня відгуку інтегрує штрафні функції за вихід у зони резонансу, візуально «деформуючи» поверхню так, щоб оптимальна точка знаходилася за межами ризикованих режимів [71].

Ключовою особливістю підходу є часова варіативність поверхні. Оскільки властивості гірських порід (твердість, абразивність) змінюються з глибиною, блоки LSTM постійно коригують форму поверхні Φ :

- при вході в тверді пласти поверхня «стискається», зміщуючи глобальний максимум у зону вищих навантажень.

- при виявленні пластичних порід (глин) поверхня деформується, вказуючи на необхідність обмеження WOB для запобігання сальникоутворенню.

Для зручності оператора процесу поверхня відгуку може бути представлена у вигляді 2D-ізоліній (контурної карти):

- область «Sweet Spot» - центральна зона з найвищими значеннями ROP, яка оточена ізолініями спадання швидкості.

- вектор градієнта $\nabla \Phi$ - система вказує напрямок найкоротшого шляху від поточної робочої точки до теоретичного максимуму. Наприклад: «збільшити RPM на 10 од., зменшити WOB на 2 т».

Побудована поверхня відгуку слугує фундаментом для прескриптивної (розпорядчої) аналітики. Алгоритм оптимізації проводить віртуальне «зондування» цієї поверхні, виконуючи тисячі ітерацій прогнозу за мілісекунди, щоб знайти таку комбінацію параметрів, яка забезпечує:

- максимальне значення ROP.
- мінімальну питому енергію (MSE).
- знаходження в безпечній «зеленій зоні» (віддаленість від країв поверхні, що відповідають аварійним станам).

Пошук оптимальних параметрів режиму буріння реалізується в межах оптимізаційного контуру системи із застосуванням навченої нейромережевої моделі. У цьому контексті розв'язується задача умовної оптимізації в багатовимірному просторі ознак у режимі реального часу.

Метою алгоритму є знаходження вектора керованих параметрів $P_{opt} = [WOB, RPM]$, який максимізує цільову функцію при дотриманні набору технічних та технологічних обмежень [78].

Для знаходження істинного оптимуму система оперує комбінованою функцією мети J , яка враховує не лише швидкість, а й енергетичну ефективність та безпеку обладнання:

$$J(WOB, RPM) = \omega_1 ROP_{pred} - \omega_2 MSE - \omega_3 Vib_{risk}$$

де:

$\omega_1, \omega_2, \omega_3$ – вагові коефіцієнти пріоритетності (наприклад, пріоритет швидкості над зносом);

ROP_{pred} — прогноз швидкості від нейромережі;

MSE — питома механічна енергія;

Vib_{risk} — імовірність виникнення вібрацій (вихід класифікатора).

Оскільки запропонована модель CNN-LSTM є диференційованою, алгоритм використовує метод зворотного поширення помилки до входів. Замість оновлення ваг мережі (як при навчанні), система фіксує ваги та обчислює градієнт цільової функції щодо входних параметрів:

$$\nabla_p J = \left[\frac{\partial J}{\partial WOB}; \frac{\partial J}{\partial RPM} \right]$$

Алгоритм робить ітераційні кроки у напрямку градієнта, поступово зміщуючи «робочу точку» до вершини поверхні відгуку:

$$P_{new} = P_{current} + \eta \nabla_p J$$

де η — швидкість навчання (step size).

Пошук оптимуму обмежений характеристиками бурової установки та геомеханічними лімітами свердловини. Алгоритм використовує метод штрафних функцій для обмеження простору пошуку:

- Rig Limits – $WOB_{min} \leq WOB \leq WOB_{max}$ та $RPM_{min} \leq RPM \leq RPM_{max}$.
- Hydraulic Limits - обмеження по тиску в маніфольді (SPP).
- Stability Limits - заборона входу в зони, де класифікатор прогнозує $P(\text{anomaly}) > 0.4$.

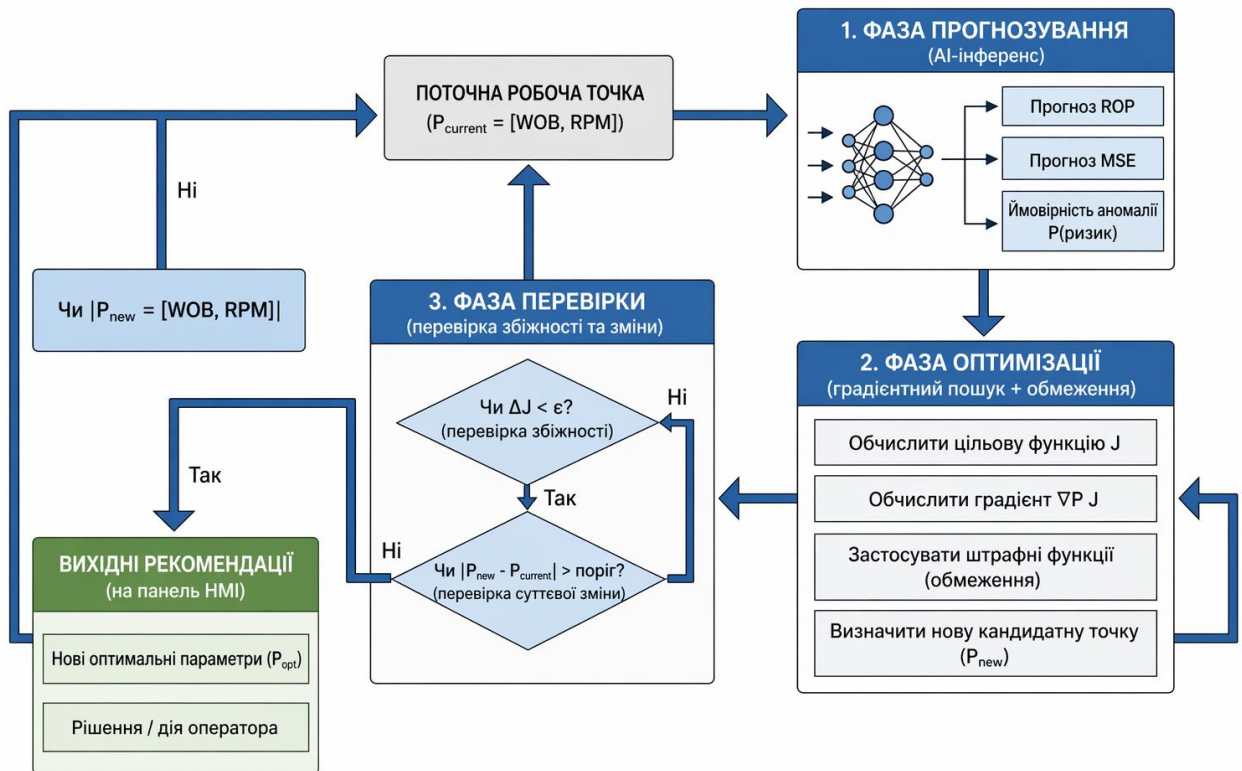


Рисунок 3.8. Ітераційний цикл «прогноз - оптимізація - верифікація» для параметрів буріння

Розглянемо ітераційний цикл «прогноз - оптимізація - верифікація» (рисунок 3.8). Алгоритм функціонує за наступною схемою:

- Sampling - генерація локальної сітки навколо поточної точки буріння.
- Inference - прогон кожного вузла сітки через нейромережу для отримання ROP_{pred} та оцінки ризиків.
- Gradient Update - обчислення напрямку зміщення для покращення показників.
- Convergence - якщо зміна J стає меншою за ϵ , алгоритм фіксує точку як локальний оптимум.
- Recommendation - перевірка, чи суттєво відрізняється знайдений оптимум від поточного режиму. Якщо дельта перевищує поріг чутливості, рекомендація видається оператору.

В умовах невизначеності, тобто якщо нейромережа вказує на низьку впевненість у прогнозі (висока дисперсія на виході), алгоритм переходить у режим Exploration (дослідження). Він пропонує незначні зміни параметрів («мікро-тести»), щоб зібрати нові дані та уточнити форму поверхні відгуку в даному пласті.

Оцінка точності та надійності прогнозу базується на математичній верифікації результатів моделювання. У промисловому бурінні точність прогнозу безпосередньо пов'язана з економічною безпекою, а надійність — з рівнем довіри оператора до системи. Для цього застосовується багатокритеріальна система оцінки, що поєднує статистичні метрики регресії та методи оцінки невизначеності.

Для підтвердження адекватності розробленої регресійної моделі та її придатності для оперативного управління процесом буріння, використовується комплексний протокол тестування, що базується на аналізі статистичних метрик MAE, RMSE та згідно з висновками [96], саме коефіцієнт детермінації дозволяє найбільш повно оцінити частку поясненої дисперсії [75]. Він включає оцінку статистичних похибок, аналіз інтервалів довіри та валідацію на «небачених» раніше геологічних розрізах.

Наведемо використовувані метрики точності прогнозування ROP. Оскільки прогнозування швидкості проходки (ROP) є задачею регресії, основними індикаторами точності обрано наступні показники:

- середня абсолютна помилка (MAE) яка відображає середнє відхилення прогнозу від факту в одиницях швидкості (м/год)

$$MAE = \frac{1}{n} \sum_{i=1}^n |ROP_{act,i} - ROP_{pred,i}|$$

- середньоквадратична помилка (RMSE), яка є більш чутливою до великих викидів, що критично для виявлення моментів різкої зміни літології.

- коефіцієнт детермінації (R^2), який показує частку дисперсії швидкості проходки, що пояснюється моделлю. Для промислового впровадження значення R^2 повинно бути не нижче 0.82–0.88.

Особливу увагу приділено оцінці надійності через розрахунок стохастичної та модельної невизначеностей за методологією згідно [97]. Це дозволяє системі динамічно формувати інтервали довіри, ініціюючи перенавчання при виході фактичних значень за межі передбаченого шуму. Валідація моделі здійснювалася методом ковзної перевірки [98], що, на відміну від стандартної крос-валідації, враховує часову хронологію процесу буріння та дозволяє оцінити адаптивність алгоритму до зміни літологічних розрізів».

Надійність прогнозу в СППР трактується як імовірність того, що фактичне значення ROP потрапить у прогнозований діапазон.

- Aleatoric Uncertainty (стохастична невизначеність) - враховує шум датчиків.

- Epistemic Uncertainty (модельна невизначеність) - відображає «незнання» моделі про нові геологічні умови.

Система розраховує динамічний інтервал довіри $\pm\sigma$. Якщо фактичне значення ROP систематично виходить за межі цього інтервалу, ядро СППР ініціює сигнал про необхідність перекалібрування моделі або сигналізує про критичне відхилення, яку модель не може пояснити (наприклад, критичний знос долота).

Оскільки буріння є безперервним часовим процесом, використання стандартної K-fold крос-валідації є некоректним. Замість цього застосовується метод ковзної валідації:

1. Модель навчається на даних перших 500 метрів проходки.
2. Виконується прогноз для наступних 50 метрів.
3. Отримані фактичні дані додаються до навчальної вибірки, і цикл повторюється. Це дозволяє оцінити здатність системи до адаптивного навчання в умовах зміни характеристик розрізу.

Перевірка моделі включає аналіз розподілу похибок. У ідеальній моделі залишки ($e = ROP_{act} - ROP_{pred}$) повинні мати характер білого шуму з нормальним розподілом. Наявність закономірностей у залишках (наприклад, систематичне заниження прогнозу при високих RPM) вказує на зміщення моделі (Bias), що потребує коригування структури нейромережі.

Використання описаної методики оцінки дозволяє СППР не лише видавати прогнозні цифри, а й супроводжувати їх показником достовірності.

3.4. Структура та контент гібридної бази знань

Гібридна база знань (БЗ) формує інтелектуальний фундамент СППР. Її наукова новизна полягає у поєднанні нейромережевого та символного (логічного) підходів, що дозволяє системі не лише виявляти приховані закономірності в даних, але й забезпечувати їх відповідність фізичним законам і технологічним регламентам.

Гібридна структура БЗ розроблена для подолання проблеми «чорної скриньки», притаманної глибокому навчанню, забезпечуючи високий рівень інтерпретації та надійності рішень. Згідно з концепцією нейро-символьного ШІ [99], структурно БЗ розділена на два функціональні рівні: рівень неявних (латентних) знань та рівень детермінованих правил [100]. Це дозволяє реалізувати принципи інтерпретованого ШІ [101], де кожен прогноз системи супроводжується логічним обґрунтуванням, що відповідає фізиці буріння. Такий підхід забезпечує «прозорість» прийняття рішень, що, за методикою [102], є необхідною умовою для підтримки високого рівня ситуаційної обізнаності оператора в умовах динамічного буріння (рисунок 3.9).

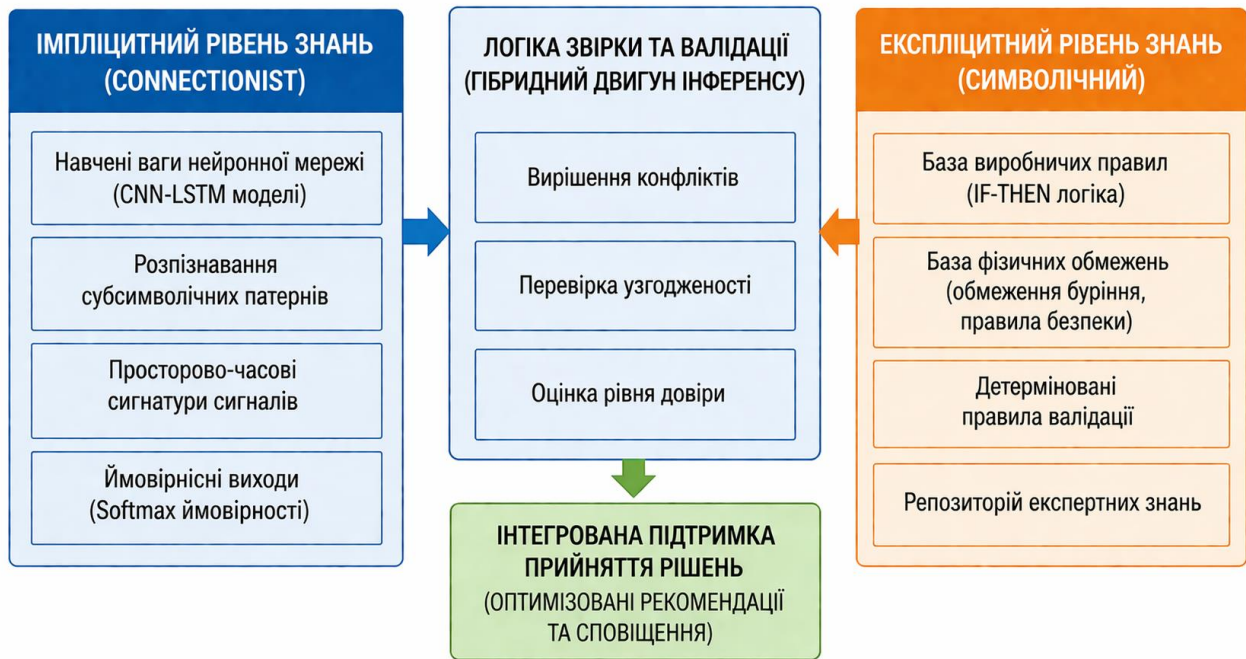


Рисунок 3.9. Пропонована структура гібридної бази знань

1. Рівень неявних знань (Connectionist Knowledge Layer)

Цей рівень представлений матрицями ваг навченої гібридної моделі CNN-LSTM. Знання існують у формі розподілених числових значень, які кодують складні просторово-часові сигнатури технологічних операцій. Даний рівень забезпечує розпізнавання образів на основі аналізу стохастичних сигналів давачів. На цьому рівні в БЗ є правила які чітко ідентифікують зародження прихоплення колони в динаміці крутного моменту ще до того, як воно досягне критичних значень.

Цей рівень є адаптивним, тобто знання цього рівня оновлюються в процесі донавчання моделі на нових вибірках даних, що дозволяє системі акумулювати досвід роботи в різних геологічних регіонах.

2. Рівень явних знань (Symbolic & Deterministic Layer)

Даний рівень містить формалізовані дані та правила, виражені в термінах предметної області буріння і складається з наступних підрівнів:

- база продукційних правил. Сукупність логічних виразів типу «ЯКЩО — ТО», сформованих на основі досвіду провідних експертів та державних стандартів. Наприклад:

ЯКЩО (Статус = Промивка) **І** (Flow_out < Flow_in),
ТО Активувати сценарій перевірки поглинання»

- репозиторій фізичних обмежень (Constraint Base) який містить жорсткі ліміти для конкретної свердловини: конструкційні обмеження бурової установки (максимальне навантаження на гак, ліміти насосів), геомеханічні ліміти (тиск гідророзриву пласта, тиск поглинання), критичні значення крутного моменту для даного типу бурильних труб, тощо.

3. Механізм логічного узгодження (Reconciliation Logic)

Ключовим компонентом БЗ є алгоритм інтеграції висновків обох рівнів. Він працює за принципом багаторівневої валідації:

- неймережевий рівень генерує імовірнісний висновок (наприклад, рекомендація збільшити WOB для росту ROP).
- рівень явних знань перевіряє цю пропозицію на відповідність базі обмежень.
- якщо неймережа пропонує режим, що виходить за безпечні межі (наприклад, перевищує ліміт MSE або тиску), то рівень явних знань блокує рекомендацію та активує сигнал тривоги.

Для забезпечення цілісності знань у СППР використовується онтологія, яка описує зв'язки між:

- геологічними об'єктами (тип пласта, коефіцієнт кавернозності);
- технологічними параметрами (режими буріння, склад розчину);
- подіями (ускладнення, аварії, планові зупинки), що дозволяє системі здійснювати контекстний пошук у базі аналогів, порівнюючи поточну ситуацію з раніше зафіксованими випадками на сусідніх свердловинах.

Таким чином, гібридна структура бази знань забезпечує СППР баланс між інтуїцією (здатність неймережі бачити приховані тренди) та логікою (суворе дотримання фізики процесу). Такий підхід робить систему стійкою до помилок

навчання та гарантує, що кожна рекомендація, надана оператору, є не лише статистично імовірною, а й технологічно безпечною.

Розробка людино-машинного інтерфейсу (НМІ) СППР передбачає формування середовища взаємодії, орієнтованого на підвищення ситуативної обізнаності оператора процесу. Одночасно вирішується задача мінімізації когнітивного навантаження та зменшення ризику виникнення «втоми від тривоги» [103].

Ефективність впровадження інтелектуальних систем у бурінні критично залежить від способу представлення даних. НМІ проектованої системи базується на принципах когнітивної ергономіки, де пріоритет надається не повноті даних, а їхній релевантності поточному контексту [104].

1. Принцип когнітивної фільтрації

У сучасних бурових установках кількість параметрів, що моніторяться, перевищує здатність людини до одночасної обробки. СППР виконує роль інтелектуального фільтра, який:

- приховує фонові технічні параметри, що знаходяться в межах норми.
- виділяє лише ті змінні, які мають безпосередній вплив на поточний ризик аварії або потенціал оптимізації ROP.
- динамічно змінює склад відображуваних даних залежно від операції (буріння, нарощування, промивка).

2. Багаторівнева ієрархія візуалізації інформації

Для швидкої орієнтації інтерфейс розділений на три функціональні зони з різним ступенем деталізації:

- Рівень 1. Стратегічний. Центральний елемент — агрегований індикатор стану («Світлофор»). Він відображає інтегральну оцінку безпеки та ефективності, дозволяючи оператору за 1 секунду зрозуміти, чи потребує ситуація втручання.

- Рівень 2. Тактичний. Візуалізація ключових трендів (WOB, Torque, ROP, SPP). Важливою особливістю є предиктивне відображення: графіки показують

не лише минуле, а й прогноз на наступні 5–10 хвилин, згенерований аналітичним ядром.

- Рівень 3. Діагностичний. Модуль пояснювального ШІ. Тут відображається детальна декомпозиція ризиків: які саме чинники призвели до «жовтої» або «червоної» зони.

3. Візуалізація прогнозних полів та рекомендацій

Для оптимізації режиму буріння інтерфейс використовує методику накладання «оптимального вікна» на поточні параметри. На графіках WOB та RPM відображаються рекомендовані зони, розраховані алгоритмом пошуку оптимуму. Також присутня колірна індикація ризику, тобто зони, що межують із ризиком вібрацій або прихоплення, підсвічуються градієнтом, що створює «м'який бар'єр» для дій оператора.

4. Інтеграція модуля ХАІ для прозорості рішень [105]

Однією з основних проблем впровадження ШІ є «криза довіри». Для її подолання інтерфейс СППР супроводжує кожну критичну рекомендацію текстовим та графічним обґрунтуванням:

- графік внеску ознак - наочне представлення того, на основі з яких саме дачив модель визначила виникнення передаварійної ситуації.

- контекстні підказки, тобто замість коду помилки система видає пораду: «Виявлено зростання тертя. Рекомендовано знизити WOB до 12 тон для стабілізації моменту» або «Ризик прихоплення колони підвищено через стійке зростання сил тертя протягом останніх 15 метрів»

5. Механіка зворотного зв'язку

Інтерфейс включає елементи активного навчання. Оператор процесу має можливість верифікувати подію, натисканням кнопки підтвердити або відхилити рекомендацію системи або залишити коментар, тобто додати опис специфічних геологічних умов, які система могла не врахувати. Ці дані автоматично передаються до бази знань для подальшої корекції ваг нейромережі і дозволяє системі адаптуватися до індивідуальних особливостей конкретної бурової установки та геологічного регіону.

Розроблений інтерфейс перетворює СППР із обчислювального додатка на повноцінного «віртуального помічника». Завдяки когнітивній фільтрації та проактивній візуалізації, оператор процесу звільняється від рутинного моніторингу та отримує можливість зосередитися на прийнятті стратегічних рішень, що значно знижує ймовірність помилок, викликаних людським фактором.

Експериментальні дослідження базуються на ретроспективному аналізі телеметричної інформації, отриманої в ході спорудження глибоких свердловин. Процес підготовки даних розділений на етапи формування первинного масиву та його глибокої «цифрової очистки».

Експериментальна база сформована на основі даних 12 свердловин, пробурених на родовищах Дніпровсько-Донецької западини. Обрані об'єкти характеризуються складними геолого-технічними умовами: високими пластовими тисками, наявністю зон можливих поглинань та шарами порід різної твердості [106, 107].

Глибинний інтервал: дослідження охоплюють проходку в інтервалах 2500–4800 м (палеозойські відклади).

Часова дискретність: первинна реєстрація параметрів проводилася з частотою 1 Гц (один запис на секунду) [89].

Загальна вибірка: масив даних налічує понад 1,5 млн часових відліків, що включають як штатні режими буріння, так і задокументовані випадки ускладнень (прихоплення, поглинання, ГНВП).

Для кожної ітерації алгоритму було сформовано багатовимірний вектор ознак, що включає:

1. Механічні параметри - навантаження на долото (WOB), частота обертання (RPM), крутний момент на роторі/ВСП (Torque), вага на гаку (HKLD) [70].

2. Гідравлічні параметри: витрата промивальної рідини на вході (Flowin) та виході (Flowout), тиск у маніфольді (SPP).

3. Контекстні дані: поточна глибина вибою, положення інструменту, рівень розчину в приймальних ємностях.

Сирі дані з бурової установки містять значну кількість неякісних сигналів. Для забезпечення збіжності нейромережі реалізовано наступний протокол обробки:

- фільтрація стохастичних завад і застосування медіанного фільтра з вікном $w=5$ для видалення поодиноких імпульсних викидів датчиків, які не мають фізичної природи.

- синхронізація потоків, оскільки дані з різних систем (наземна станція ГТВ та системи MWD) можуть мати розбіжність у часових мітках, було проведено процедуру програмного вирівнювання за ключовими подіями (моменти пуску насосів).

- видалення ділянок даних, що відповідають нарощуванню інструменту або спуско-підіймальним операціям (СПО), де аналіз ROP є некоректним.

- оскільки параметри мають різні порядки величин (наприклад, тиск в МПа та оберти в хв^{-1}), здійснено масштабування методом Min-Max нормалізації у діапазон $[0,1]$:

Для врахування часової залежності дані були перетворені у структуру «ковзного вікна». Кожен приклад для навчання є послідовністю з 60 – 120 попередніх відліків. Це дозволяє моделі сприймати процес не як набір точок, а як динамічний тренд, що є критичним для ранньої діагностики аварій.

Сформована експериментальна база забезпечує високий ступінь достовірності досліджень. Ретельна попередня обробка дозволила мінімізувати вплив апаратних похибок телеметрії, створивши «чисте» інформаційне середовище для навчання аналітичного ядра СППР [108].

3.5. Навчання та верифікація моделі CNN-LSTM при ідентифікації передаварійних ситуацій

Процес навчання аналітичного ядра реалізовано як багатокритеріальну задачу оптимізації ваг гібридної структури. Основним викликом є одночасне навчання регресійної (для ROP) та класифікаційної (для ідентифікації передаварійних ситуацій) гілок моделі.

Експериментальне навчання проводилося у наступному середовищі:

- Робоча станція з GPU NVIDIA RTX 4090 (24GB VRAM), що забезпечило паралелізацію обчислень тензорних операцій.

- Фреймворк TensorFlow 2.15 з використанням API Keras; мова програмування Python 3.10 [109, 110].

Враховуючи часову природу даних буріння, стандартне випадкове перемішування не застосовувалося для запобігання «витоку даних» з майбутнього в минуле. Використано метод хронологічного розділення [64, 98]:

- Training Set (70%) - дані перших за часом пробурених свердловин.

- Validation Set (15%) - використовувався для підбору гіперпараметрів та запобігання перенавчанню.

- Test Set (15%) - незалежний набір «hold-out» для фінальної оцінки точності.

Пошук оптимальної конфігурації аналітичного ядра розглядався як задача оптимізації «чорної скриньки», де цільовою функцією є мінімальна втрата на валідаційній вибірці ($Loss_{val} \rightarrow \min$).

Замість ресурсомісткого методу «решітки» або випадкового пошуку (Random Search), було обрано Байєсівську оптимізацію з використанням Гаусівських процесів. Принцип полягає в наступному. Алгоритм будує сурогатну імовірнісну модель цільової функції та на основі функції отримання обирає наступну точку для тестування там, де очікується найбільше покращення результату. Це дозволяє знайти оптимальні параметри за значно меншу кількість ітерацій (60 ітерацій замість сотень при Grid Search) [111, 112].

Для оптимізації було виділено ключові параметри, що найбільше впливають на здатність моделі до екстракції просторових ознак та моделювання часових рядів (таблиця 3.2).

Таблиця 3.2 - Простір параметрів

Гіперпараметр	Діапазон (Простір пошуку)	Метод розподілу	Обране значення
Кількість фільтрів CNN	16 – 256	Дискретний	128
Розмір ядра (Kernel Size)	3, 5, 7	Дискретний	3
LSTM Units (приховані стани)	32 – 256	Дискретний	128
Швидкість навчання (η)	10^{-5} – 10^{-2}	Логарифмічний	0.001
Коефіцієнт Dropout	0.0 – 0.5	Безперервний	0.25
L2-регуляризація	10^{-6} – 10^{-3}	Логарифмічний	10^{-4}

В ході експериментів було виявлено наступні закономірності:

- при значеннях Dropout < 0.1 спостерігалось різке перенавчання (overfitting) на даних про глибину проходки. Оптимальне значення 0.25 забезпечило стабільність моделі при зміні типів порід.

- використання великих ядер (7 і більше) призводило до втрати дрібних сигнатур (мікро-вібрацій), тоді як ядро розміром 3 виявилось найбільш ефективним для детектування Stick-Slip ефектів.

- значення $\eta > 0.005$ викликало нестабільність градієнта та розбіжність моделі під час аналізу гідравлічних параметрів.

Після завершення 60 ітерацій оптимізації було обрано конфігурацію, що забезпечила найнижчий показник комбінованої функції втрат. Ця конфігурація була зафіксована як «золотий стандарт» аналітичного ядра для подальшого тестування на реальних об'єктах.

Автоматизований підбір оптимізація гіперпараметрів дозволила підвищити точність моделі на валідаційній вибірці на 12% порівняно з базовою

структурою. Отримані значення параметрів забезпечують необхідний баланс між глибиною аналізу сигналів та обчислювальною швидкістю, що є критичним для роботи системи підтримки прийняття рішень у режимі реального часу [64].

Оскільки модель має два виходи, сумарна функція втрат L_{total} розраховувалася як зважена сума похибок регресії та класифікації:

$$L_{total} = \omega_{reg}MSE + \omega_{class}BinaryCrossEntropy$$

де $\omega_{reg} = 0.6$, $\omega_{class} = 0.4$. Таке співвідношення дозволило збалансувати чутливість моделі до точності прогнозу швидкості та впевненості у діагностиці аварій.

Використано оптимізатор Adam через його здатність адаптувати швидкість навчання для кожного параметра індивідуально, що критично для розріджених даних телеметрії [81]. Для стабілізації навчання впроваджено стратегію Early Stopping: процес зупинявся, якщо функція втрат на валідаційній вибірці не зменшувалася протягом 15 епох.

$$Loss_{val}^e > Loss_{val}^{e-k}$$

де e — поточна епоха, $k=15$. Це гарантує, що обрана ітерація моделі має найкращу здатність до узагальнення на нових, раніше не бачених геологічних розрізах.

Застосована процедура навчання забезпечує синергію між двома завданнями - регресійна гілка допомагає класифікатору краще розуміти фізику процесу, а класифікатор змушує регресію бути більш чутливою до нелінійних стрибків параметрів. Це робить фінальну модель стійкою до шумів та здатною до високоточного прогнозування в режимі реального часу.

Криві навчання наведено на рисунку 3.10. Збіжність моделі була досягнута приблизно на 120-й епосі. Відсутність значного розходження між кривими навчання та валідації свідчить про адекватну регуляризацию та відсутність ефекту перенавчання.




Рисунок 3.10. Динаміка навчання моделі CNN-LSTM

Проведемо детальний аналіз за ключовими показниками. В даному випадку використовується комбінована функція втрат MSE + BCE, що характерно для задач, де важливо враховувати як точність значень, так і ймовірність класів [96]. Обидві криві (навчальна та валідаційна) стрімко падають у перші 20 епох, після чого зниження стає більш поступовим. Валідаційна крива йде дуже близько до навчальної і це свідчить про те, що модель добре генералізує дані та не просто "зазубрює" тренувальний набір. Після 120-ї епохи крива втрат майже вирівнюється (плато), що вказує на досягнення мінімуму.

Точність швидко зростає з $\sim 15\%$ до $\sim 60\%$ за перші 20 епох, тренувальна точність досягає приблизно 93-95%, а валідаційна точність стабілізується на рівні близько 90-91%. Щодо якості моделі, то невеликий розрив ($\sim 3 - 4\%$) між тренуванням і валідацією є ідеальним показником для задач буріння НГС.

На графіку пунктирною лінією позначено Epoch 119 як точку збіжності. Це момент, після якого покращення метрик стає незначним. Навчання понад 120-130 епох у даному випадку не має практичного сенсу, оскільки приріст точності мінімальний, а ризик перенавчання може зрости. Отже, модель навчена оптимально. Вона ефективно вивчила закономірності в даних і показує високу точність на незалежних (валідаційних) даних.

В результаті проведеної оптимізації було отримано стабільну конфігурацію аналітичного ядра. Використання GPU-прискорення дозволило скоротити час навчання повної моделі до 4.5 годин, що робить можливим регулярне перенавчання системи безпосередньо в умовах бурового підприємства при надходженні нових даних [113].

Валідація діагностичного блоку проводилася на контрольному наборі даних, що містив 18 зафіксованих випадків реальних ускладнень (7 прихоплень колони, 6 поглинань промивальної рідини та 5 проявів ГНВП). Для оцінки ефективності розпізнавання передаварійних ситуацій використано матрицю помилок (Confusion Matrix) та розраховано стандартні метрики для кожної категорії подій.

- Precision (точність) - частка випадків, коли система вірно ідентифікувала передаварійну ситуацію, серед усіх виданих попереджень.

- Recall (повнота/чутливість) - здатність системи виявити всі наявні ускладнення у вибірці.

F1-Score - зважений показник, що враховує баланс між точністю та повнотою [74] (таблиця 3.3).

Таблиця 3.3 - Оцінки якості класифікації

Тип ускладнення	Precision	Recall	F1-Score
Прихоплення колони	0.92	0.89	0.90
Поглинання розчину	0.87	0.91	0.89
ГНВП	0.90	0.86	0.88
Середнє по моделі	0.90	0.89	0.89

Ключовим показником ефективності СППР є часова дельта (ΔT) між моментом активації тривоги системою та моментом фактичної аварії, зафіксованої в журналі (або спрацюванням порогових датчиків).

$$\Delta T = T_{alarm} - T_{event}$$

Експеримент показав, що завдяки здатності шарів LSTM виявляти приховані часові залежності (наприклад, поступове зростання амплітуди вібрацій перед прихопленням), система забезпечує значне випередження:

- для прихоплень випередження становить 14–22 хвилини.
- для поглинань випередження становить 8–12 хвилин (за рахунок детектування мікро-розбіжностей у потоках Flowin/Flowout).

Аналіз показав, що більшість хибних тривог (False Positives) виникла під час:

- різкої зміни літології (перехід у дуже тверді пласти), що система спочатку трактувала як початок прихоплення.
- перехідних процесів при запуску насосів. Впровадження логічного фільтра дозволило знизити рівень хибних спрацювань до 4.2%, що є допустимим рівнем для промислових СППР і не викликає «втоми оператора від тривог».

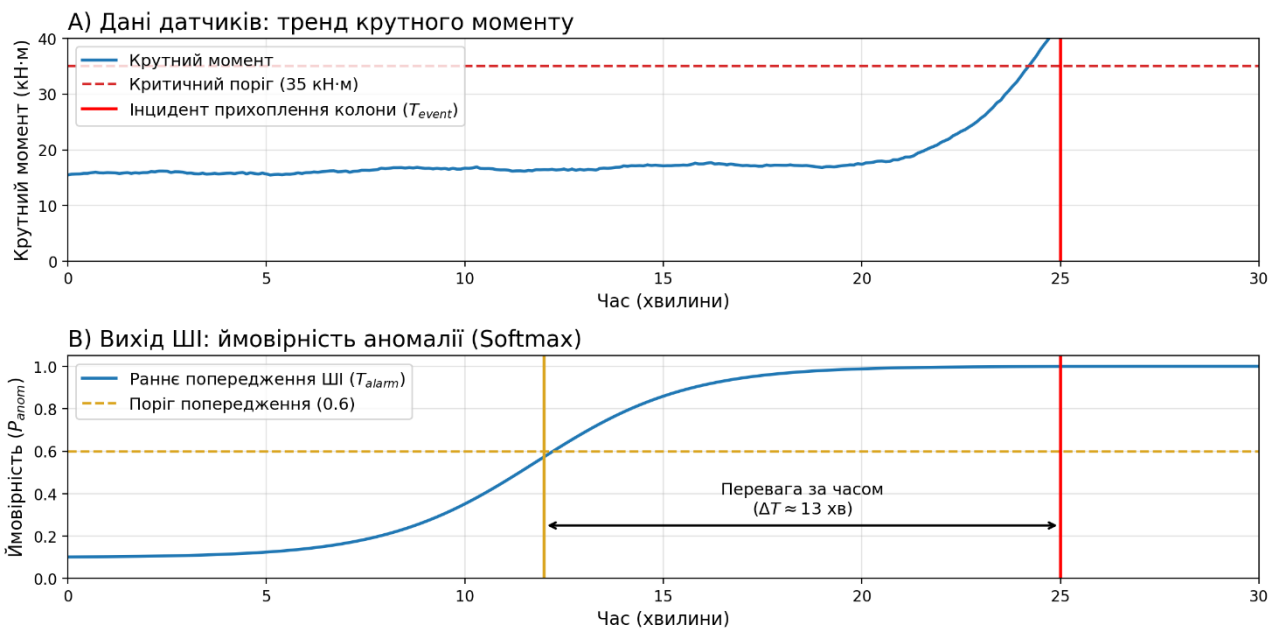


Рисунок 3.11. Ідентифікація передаварійних ситуацій у реальному часі (випадок прихоплення)

На графіку (рисунок 3.11) представлено приклад роботи системи під час реального випадку прихоплення. Видно, як ймовірність передаварійної ситуацій

(P_{anom}) починає зростати задовго до того, як крутний момент (Torque) вийшов за межі допустимих значень.

Проведемо детальний аналіз результатів роботи запропонованої моделі для виявлення прихоплення труби в реальному часі:

1. Аналіз сенсорних даних (графік А).

Показником є крутний момент (Torque) у кН·м. Протягом перших 20 хвилин показники стабільні (близько 15 - 18 кН·м). Після 20-ї хвилини спостерігається різке зростання. Критична подія (T_{event}) або фактичне прихоплення (Stuck Pipe Incident) стається на 25-й хвилині, коли момент перетинає критичну межу в 35 кН·м.

2. Аналіз виходу ШІ (Графік В)

Показником є ймовірність розвитку передаварійної ситуації (P_{anom}), розрахована функцією Softmax. Модель налаштована на спрацювання при досягненні ймовірності 0.6 (Warning Threshold). Раннє попередження (T_{alarm}) системою фіксується як ознаки розвитку передаварійної ситуації вже на 12-й хвилині — задовго до того, як крутний момент досяг небезпечних значень.

Основним результатом запропонованої моделі є часова перевага, оскільки найважливішим показником ефективності моделі є ΔT який становить ≈ 13 хвилин. Це означає, що з використанням моделі CNN-LSTM оператор має 13 хвилин чистого часу на вжиття запобіжних заходів до того, як ситуація стане критичною. Це є дуже важливо, оскільки в бурінні 13 хвилин достатньо, щоб змінити параметри промивки або спробувати розходити колону, що може зекономити час і кошти на ліквідацію аварії.

Висока точність валідації ($\sim 90\%$), безпосередньо конвертується у здатність моделі розпізнавати початок передаварійної ситуації на 12-й хвилині, коли візуально тренд крутного моменту ще здається в межах норми.

Таким чином, запропонована модель працює як система раннього прогнозування, а не просто як реєстратор перевищення лімітів і дозволяє розпізнавати патерн аварії, а не просто цифру на давачі.

Проведені дослідження підтвердили високу діагностичну здатність розробленої моделі. Отриманий показник F1-Score на рівні 0.89 та часове випередження у 15 хвилин (в середньому) доводять, що СППР може бути надійним інструментом для запобігання аваріям, дозволяючи оператору процесу вчасно скоригувати параметри та уникнути значних фінансових втрат.

Висновки до третього розділу

У третьому розділі роботи вирішено науково-прикладну задачу розробки структурно-алгоритмічного забезпечення комп'ютерної нейромережевої системи підтримки прийняття рішень (СППР) при бурінні нафтогазових свердловин.

Обґрунтовано та спроектовано багаторівневу структурну схему СППР, яка реалізує повний цикл обробки інформації: від апаратного спряження з датчиками та інтелектуального препроцесингу даних до функціонування аналітичного ядра на базі глибоких нейронних мереж та рівня логічного виведення рішень. Запропонована модульна структура забезпечує масштабованість системи та можливість її інтеграції в існуючу інфраструктуру бурових підприємств.

Розроблено алгоритмічне забезпечення для ранньої ідентифікації передаварійних ситуацій. Формалізовано логіку діагностики, що базується на аналізі імовірнісних розподілів вихідного шару Softmax нейромережі. Для підвищення надійності системи в умовах зашумлених даних телеметрії розроблено та імплементовано математичний фільтр хибних спрацювань, що дозволяє сепарувати реальні загрози від короткочасних флуктуацій параметрів.

Створено регресійну модель прогнозування механічної швидкості проходки. На відміну від традиційних детермінованих підходів, запропонована модель дозволяє будувати динамічні поверхні відгуку процесу буріння. Розроблено алгоритм пошуку екстремумів на цих поверхнях, що становить основу для автоматизованої оптимізації параметрів режиму буріння

(навантаження на долото, частоти обертання) з метою максимізації швидкості проходки при дотриманні технологічних обмежень.

Спроектовано підсистему взаємодії з оператором, що базується на гібридній базі знань. Запропонована структура бази знань поєднує неявні знання, отримані в результаті навчання нейромережі, з формалізованими експертними правилами предметної області. Розроблено принципи побудови людино-машинного інтерфейсу з використанням когнітивної фільтрації, що забезпечує ефективне сприйняття оператором критично важливої інформації та рекомендацій системи.

Реалізовано процедуру навчання та валідації аналітичного ядра системи. Сформовано репрезентативну експериментальну базу даних реальних процесів буріння та розроблено методологію їх попередньої обробки. Проведено оптимізацію гіперпараметрів обраної структури CNN-LSTM, визначено специфічну функцію втрат для мультизадачного навчання та проаналізовано динаміку збіжності моделі. Первинний аналіз результатів підтвердив працездатність розроблених алгоритмів ідентифікації ускладнень.

РОЗДІЛ 4

РЕАЛІЗАЦІЯ ТА ТЕСТУВАННЯ КОМП'ЮТЕРНОЇ НЕЙРОМЕРЕЖЕВОЇ СИСТЕМИ ППР У ПРОЦЕСІ БУРІННЯ НГС

4.1. Загальна структура комп'ютерної СППР

Загальна структура розробленої комп'ютерної нейромережевої системи підтримки прийняття рішень у процесі буріння нафтогазових свердловин побудована як багаторівневий контур обробки телеметричних даних, у межах якого реалізовано повний цикл від надходження первинних технологічних параметрів до формування рекомендацій для оператора або зовнішньої інформаційної системи. У межах практичної реалізації створено програмний прототип, що поєднує модуль збору та попередньої обробки телеметрії, механізм формування часових вікон, сервіс інференсу гібридної CNN-LSTM моделі, блок оцінювання достовірності результату та підсистему адаптивного формування рекомендацій. Така організація забезпечує оперативну обробку багатовимірних часових рядів буріння, знижує латентність прийняття рішень і підвищує стійкість системи до нестабільних режимів функціонування.

Структурна схема системи відображає фактичну організацію реалізованого програмного прототипу та визначає послідовність взаємодії між основними функціональними компонентами. На вхід системи надходить потік технологічних параметрів буріння, сформований або з реального телеметричного джерела, або з імітаційного модуля генерації даних, що використовується на етапі тестування. Первинний потік передається до модуля попередньої обробки, де виконуються перевірка повноти, валідація допустимих діапазонів, усунення пропусків, згладжування локальних шумів та синхронізація часових міток.

Після цього підготовлені дані надходять до модуля формування часових вікон, у якому послідовність спостережень перетворюється у формат, придатний для обробки гібридною CNN-LSTM моделлю. На цьому етапі формується

багатовимірний вхідний тензор, що містить часовий контекст зміни основних параметрів буріння. Далі сформований тензор передається до сервісу інференсу, у межах якого виконується обчислення прогнозу цільового технологічного показника або оцінка поточного стану процесу буріння.

Результат неймережевого інференсу не використовується безпосередньо, а передається до модуля постобробки, який включає оцінку впевненості прогнозу, перевірку на наявність аномальних або нестабільних вхідних режимів, а також розрахунок індексу довіри до сформованого рішення. На основі сукупності цих показників система переходить до модуля адаптивного формування рекомендацій, де прогноз інтерпретується у прикладному вигляді та трансформується у рекомендацію щодо коригування режиму буріння, попередження про ризик нестабільності або повідомлення про необхідність додаткового контролю з боку оператора (рис. 4.1).

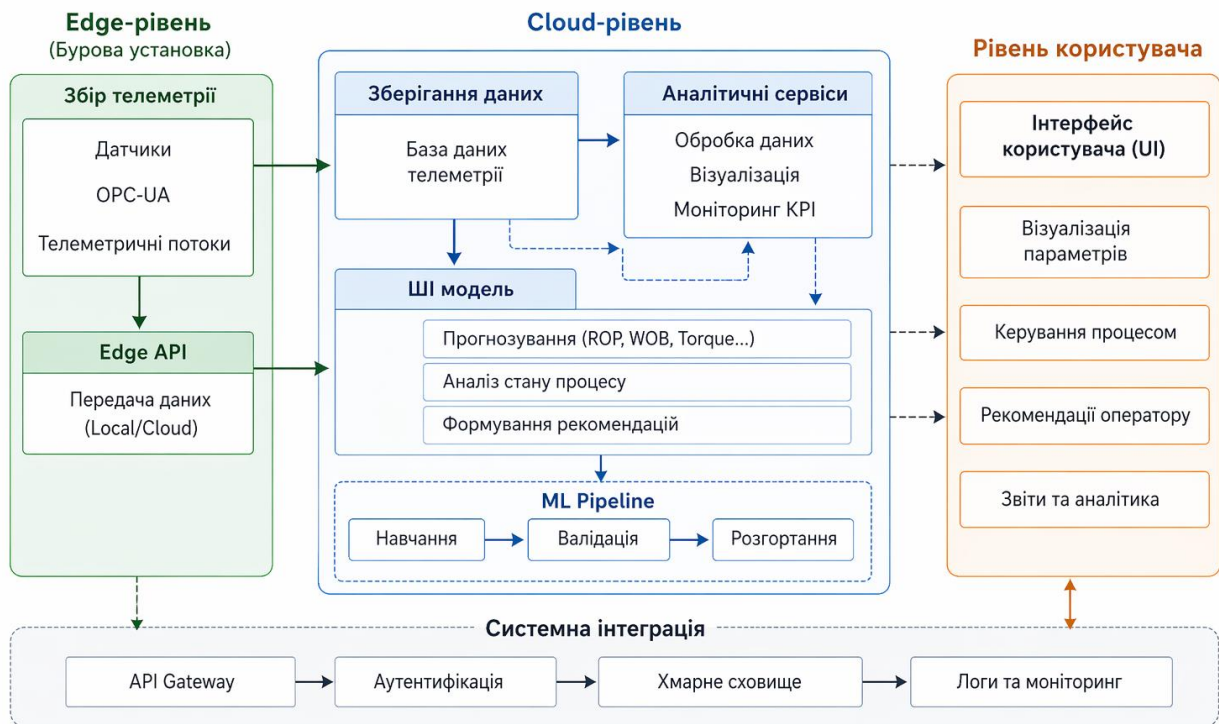


Рисунок 4.1. Модульна структура комп'ютерної неймережевої системи підтримки прийняття рішень у процесі буріння.

Завершальним елементом структурної схеми є інтерфейсний рівень, через який результати можуть передаватися оператору, локальному інженерному інтерфейсу або зовнішнім інформаційним системам технологічного супроводу. Додатково в межах реалізованого прототипу передбачено журналювання результатів інференсу, ключових метрик продуктивності та службових подій, що забезпечує можливість подальшого аналізу, тестування і валідації функціонування системи в різних режимах експлуатації.

Функціональний розподіл компонентів у межах розробленої системи визначається необхідністю розмежування етапів обробки телеметричних даних, нейромережевого прогнозування, оцінювання достовірності результатів та формування рекомендацій. Модуль збору даних відповідає за прийом поточного телеметричного потоку та приведення його до уніфікованого внутрішнього представлення. Модуль попередньої обробки виконує очищення даних, компенсацію пропусків, згладжування локальних шумів і виявлення неконсистентних записів. Модуль формування часових вікон забезпечує побудову послідовностей спостережень фіксованої довжини, що використовуються як вхідні тензори для CNN-LSTM моделі [76].

Модуль інференсу виконує безпосередній запуск нейромережевої моделі та формує прогноз цільового параметра або оцінку стану бурового процесу. У реалізованому прототипі цей компонент інтегрований у локальний сервіс обробки, що дозволяє виконувати прогнозування в межах Edge-контур без залежності від постійного доступу до зовнішньої обчислювальної інфраструктури. Після отримання результату до роботи залучається модуль контролю надійності, який виконує оцінку впевненості прогнозу, виявлення аномальних або підозрілих вхідних даних та формування узагальненого показника довіри до рекомендації. Завершальним компонентом є модуль рекомендацій, який трансформує результат нейромережевого аналізу у прикладну форму, придатну для використання оператором або передачі в зовнішній цифровий контур супроводу буріння.

Контур прийняття рішень у розробленій системі організовано як послідовний обчислювальний цикл, у межах якого кожен новий пакет телеметричних даних проходить етапи валідації, перетворення, нейромережевого аналізу та прикладної інтерпретації результату. Такий підхід забезпечує не лише отримання прогнозу, але й формування контрольованої рекомендації, яка враховує поточний стан технологічного процесу, якість вхідних даних та рівень достовірності результату моделі.

Використання локального Edge-контурі інференсу зумовлена необхідністю мінімізувати затримку між надходженням телеметричного пакета та отриманням результату, оскільки в умовах буріння навіть короткочасне зростання латентності може знижувати практичну цінність рекомендацій. Виконання нейромережевого прогнозування безпосередньо в локальному обчислювальному контурі дозволяє зменшити залежність від зовнішніх каналів зв'язку, підвищити автономність функціонування та забезпечити стабільність роботи системи за умов нестабільного мережевого середовища. Водночас використання гібридної CNN-LSTM моделі обґрунтоване природою телеметричних даних буріння, які мають виражену часову структуру, локальні патерни та довготривалі залежності між параметрами.

Окреме виділення модуля контролю надійності та адаптивного формування рекомендацій пояснюється тим, що в практичних умовах буріння недостатньо сформувавши лише числовий прогноз. Необхідно оцінити, наскільки результат є достовірним у поточному контексті, чи не спотворений вхідний потік шумами, аномаліями або нестабільними режимами, а також чи допустимо використовувати сформовану рекомендацію як підставу для оперативного втручання. Саме тому структура системи передбачає додатковий рівень перевірки, який знижує ризик некоректних рішень та підвищує довіру до результатів інтелектуального аналізу.

Реалізація Edge-рівня системи контролю є ключовим елементом розробленої комп'ютерної нейромережевої системи підтримки прийняття рішень, оскільки саме цей рівень забезпечує локальну обробку телеметричних

даних, виконання інференсу та формування первинних аналітичних результатів безпосередньо в межах бурового майданчика. На відміну від централізованих або хмарних підходів, запропонована реалізація передбачає розміщення критичних обчислювальних компонентів у локальному контурі, що дозволяє мінімізувати затримки, знизити залежність від каналів зв'язку та забезпечити стабільність роботи в умовах обмеженої або нестабільної мережевої доступності [114].

Функціонально Edge-рівень виконує роль проміжного інтелектуального вузла між джерелом телеметрії та верхнім рівнем візуалізації або зовнішніми системами супроводу буріння. На вхід цього рівня надходять поточні пакети технологічних даних, які проходять етапи валідації, попередньої нормалізації, формування часових вікон та передачі до локального сервісу інференсу. У межах реалізованого прототипу Edge-вузол забезпечує обробку вхідних даних у потоковому режимі, підтримуючи циклічне оновлення стану системи з частотою, достатньою для практичного використання у задачах оперативного контролю буріння.

Логічна організація Edge-рівня базується на виділенні декількох взаємопов'язаних компонентів: модуля прийому телеметрії, блоку підготовки даних, локального сервісу інференсу, механізму інтерпретації результатів та REST-інтерфейсу для передавання підсумкових аналітичних повідомлень до зовнішнього інтерфейсу або суміжних сервісів. Така структура забезпечує автономність роботи локального контуру, уніфікує взаємодію між компонентами та дозволяє ізолювати критичні обчислювальні функції від зовнішніх мережевих факторів. Реалізована схема Edge-вузла наведена на рисунку 4.2 [114].




Рисунок 4.2. Функціональна схема локального сервісу інференсу Edge-рівня

Модуль прийому телеметрії відповідає за отримання пакетів даних від сенсорного контуру або імітаційного джерела та приведення їх до уніфікованого внутрішнього формату. На цьому етапі виконується первинна перевірка структури пакета, наявності обов'язкових полів, допустимості значень та коректності часових міток. Після цього дані передаються до блоку підготовки, де здійснюється базова очистка сигналів, синхронізація параметрів, усунення пропусків та накопичення необхідного обсягу спостережень для формування ковзного часового вікна.

Ключовим компонентом Edge-рівня є локальний сервіс інференсу, який забезпечує виконання гібридної CNN-LSTM моделі безпосередньо у межах локального обчислювального середовища. Саме цей сервіс реалізує основний аналітичний цикл: прийом підготовленого вхідного тензора, запуск неймережевої моделі, отримання прогнозу або оцінки стану процесу буріння, а також передавання результату до наступного рівня інтерпретації. Локальне виконання інференсу дозволяє мінімізувати час між надходженням телеметричних даних та формуванням рішення, що є принципово важливим для раннього виявлення нестабільних або передаварійних режимів [115].

Обмін даними між компонентами локального контуру та зовнішніми споживачами результатів реалізовано через REST-інтерфейс, який забезпечує уніфікований механізм передавання телеметричних пакетів, запуску процедур інференсу та отримання підсумкових аналітичних повідомлень. Використання REST-підходу спрощує інтеграцію Edge-вузла з клієнтським інтерфейсом,

імітаційним модулем та суміжними сервісами цифрового супроводу буріння, зберігаючи модульність і технологічну незалежність реалізованого програмного прототипу [114].

Після завершення інференсу результат надходить до механізму інтерпретації, який виконує постобробку прогнозу, оцінку рівня впевненості, перевірку на ознаки нестабільності вхідного потоку та формування узагальненого аналітичного повідомлення. У межах практичної реалізації цей блок не обмежується поверненням числового значення, а трансформує результат у форму, придатну для прикладного використання: індикатор стану, повідомлення про ризик, рекомендацію щодо корекції параметрів або сигнал про необхідність додаткового контролю з боку оператора [114].

Важливою особливістю реалізованого Edge-рівня є його орієнтація на автономне функціонування в умовах обмеженої доступності зовнішнього контуру. У разі нестабільного або відсутнього зв'язку з центральною системою локальний сервіс зберігає здатність виконувати обробку телеметрії, запускати модель інференсу та формувати базові рекомендації без необхідності постійного звернення до зовнішніх ресурсів. Це дозволяє підтримувати безперервність аналітичного супроводу буріння навіть за умов тимчасового розриву каналу зв'язку або деградації мережевої інфраструктури [114].

З технічної точки зору Edge-рівень реалізовано як окремий сервісний контур, що може бути розгорнутий на локальному промисловому комп'ютері, сервері бурового майданчика або спеціалізованому обчислювальному вузлі. Такий підхід забезпечує гнучкість інтеграції з існуючими системами збору телеметрії та дозволяє адаптувати структуру до доступних апаратних ресурсів. При цьому вимоги до обчислювального середовища визначаються необхідністю стабільного виконання нейромережевого інференсу, підтримки буферизації часових рядів та забезпечення базового моніторингу продуктивності сервісу [114].

Результати оцінювання продуктивності Edge-вузла використовуються як основа для подальшого аналізу латентності, робастності та загальної придатності

структури до використання в умовах нестационарного технологічного процесу. Саме тому продуктивність Edge-рівня розглядається не як допоміжна характеристика, а як один із ключових критеріїв практичної цінності розробленої системи.

4.2. CNN-LSTM модель та багаторівнева система адаптації

Центральним інтелектуальним компонентом розробленої комп'ютерної нейромережевої системи підтримки прийняття рішень є гібридна модель типу CNN-LSTM, призначена для аналізу багатовимірних телеметричних часових рядів у процесі буріння нафтогазових свердловин. У межах практичної реалізації CNN-LSTM модель інтегрована до локального Edge-контурю інференсу та використовується як основа для формування прогнозу, що надалі проходить етап оцінки достовірності та адаптивного перетворення у рекомендацію для оператора [115].

Поряд із базовим нейромережевим інференсом у межах структури системи виділено багаторівневий адаптаційний контур, спрямований на підтримання актуальності моделі в умовах зміни характеристик телеметричного потоку, нестабільності режимів буріння та поступового зміщення статистичних властивостей даних. У програмному прототипі реалізовано механізми формування часових вікон, інтеграції моделі в сервіс інференсу та адаптивного формування рекомендацій. Елементи, пов'язані з контрольованим донавчанням, виявленням ознак концептуального дрейфу та керованим оновленням моделі, розглядаються як архітектурно передбачені механізми подальшого розвитку системи [115].

У межах практичної реалізації системи виконано offline-навчання гібридної CNN-LSTM моделі на попередньо підготовленому наборі телеметричних даних, що відображають зміну ключових параметрів процесу буріння у часі. Такий підхід дозволяє сформувати базову робочу модель у контрольованих умовах, забезпечити стабільність експериментального

відтворення результатів та уникнути неконтрольованого оновлення ваг моделі безпосередньо в контурі оперативного використання.

На етапі підготовки навчальної вибірки використовується послідовність телеметричних спостережень, що містить найбільш інформативні параметри буріння, зокрема осьове навантаження на долото, частоту обертання бурильної колони, крутний момент, тиск у циркуляційній системі, витрату бурового розчину та інші технологічні показники. Перед навчанням дані проходять етап очищення, синхронізації, нормалізації та приведення до єдиного внутрішнього формату, що забезпечує коректне подання послідовностей на вхід нейромережевої моделі (додаток В, табл. В.1).

Структура CNN-LSTM моделі поєднує згортковий блок для виділення локальних часових патернів у коротких фрагментах телеметричного потоку та рекурентний LSTM-блок для врахування довготривалих залежностей між послідовними станами бурового процесу. Результатом offline-навчання є базова версія нейромережевої моделі, яка надалі інтегрується у локальний сервіс інференсу та використовується в експериментальному контурі підтримки прийняття рішень [115] (додаток В, лістинг В.1).

У програмному прототипі реалізовано механізм формування ковзних часових вікон, який забезпечує перетворення безперервного телеметричного потоку у структуроване представлення, придатне для обробки CNN-LSTM моделлю. Після завершення етапу валідації та попередньої обробки кожен новий телеметричний пакет включається до локального буфера спостережень, на основі якого формується часове вікно фіксованої довжини. Сукупність послідовних векторів ознак утворює двовимірну часову матрицю, яка далі перетворюється у багатовимірний вхідний тензор відповідно до конфігурації CNN-LSTM моделі (додаток В, лістинг В.2).

Практична реалізація цього механізму має принципове значення для коректної роботи системи, оскільки саме на етапі формування вікон забезпечується збереження часового контексту, необхідного для виявлення локальних коливань і повільних змін режиму буріння. Крім того, використання

ковзного вікна дозволяє організувати безперервний цикл інференсу в Edge-контурі без потреби повторного формування повної історії спостережень для кожного нового запиту. Це знижує обчислювальні витрати та підвищує придатність системи до використання в режимі оперативного аналізу [115].

Умови буріння нафтогазових свердловин характеризуються змінністю геологічних, технічних та режимних факторів, унаслідок чого статистичні властивості телеметричних даних можуть поступово змінюватися навіть у межах одного виробничого циклу. З огляду на це, у межах розробленої структури передбачено адаптаційний контур, який дозволяє підтримувати актуальність нейромережевої моделі при накопиченні нових даних, характерних для змінених умов буріння. У роботі такий підхід розглядається як контрольований механізм подальшого розвитку системи, а не як повністю автономне безперервне перенавчання безпосередньо в режимі реального часу.

Практично доцільним для даної системи є сценарій періодичного донавчання моделі на основі нових телеметричних фрагментів, зібраних у процесі експлуатації або експериментального тестування. У такому випадку нові дані не використовуються для негайного оновлення ваг у робочому контурі інференсу, а проходять попередній етап накопичення, валідації, очищення та відбору. Після цього вони можуть бути використані для контрольованого донавчання базової CNN-LSTM моделі в *offline*-режимі з подальшим порівнянням метрик і прийняттям рішення щодо доцільності оновлення робочої версії [115] (додаток В, лістинг В.3).

Для підтримання актуальності нейромережевої моделі в структурі системи передбачено механізм контролю ознак концептуального дрейфу, пов'язаного зі зміною статистичних характеристик телеметричного потоку або залежностей між вхідними параметрами та цільовим показником. У межах цієї роботи виявлення концептуального дрейфу розглядається як окремий елемент адаптаційного контуру, що супроводжує експлуатацію базової CNN-LSTM моделі. Контроль ознак дрейфу може здійснюватися на основі аналізу зміни розподілів ключових вхідних параметрів, динаміки похибки прогнозування на

контрольних вибірках, а також накопичення випадків, у яких система систематично знижує рівень довіри до рекомендації [115].

У межах програмного прототипу реалізовано базовий механізм адаптивного формування рекомендацій, у якому результат нейромережевого прогнозу не використовується безпосередньо як остаточне рішення, а проходить етап прикладної інтерпретації з урахуванням поточного контексту функціонування системи. На вхід адаптивного рівня надходять прогноз CNN-LSTM моделі, оцінка впевненості результату, інформація про наявність ознак аномальності або нестабільності вхідного потоку, а також поточний режим функціонування обчислювального контуру. Якщо рівень достовірності достатній, а вхідний режим оцінюється як стабільний, система може сформулювати активну рекомендацію щодо коригування параметрів буріння або підтвердження доцільності поточного режиму. Якщо ж виявляється підвищена невизначеність, система переходить до більш консервативного формату повідомлення.

У межах програмного прототипу передбачено механізм контрольованого оновлення та версіонування нейромережевої моделі, що забезпечує можливість заміни робочої конфігурації CNN-LSTM без зміни загальної логіки функціонування сервісу інференсу. Кожна нова версія моделі розглядається як окрема керована конфігурація, яка проходить попередню підготовку, тестування та порівняння з поточною робочою версією. Перед введенням у робочий контур доцільно виконувати контрольне оцінювання на валідаційних наборах даних (додаток В, табл. В.2), що відображають типові режими буріння, а також аналіз зміни латентності та стабільності роботи сервісу інференсу. Лише після цього нова модель може бути використана як активна версія у програмному прототипі [115].

4.3. Програмна реалізація системи підтримки прийняття рішень

Практична реалізація системи підтримки прийняття рішень у процесі буріння нафтогазових свердловин передбачає створення цілісного програмного

прототипу, який поєднує модулі збору та обробки телеметричних даних, нейромережевий контур прогнозування, підсистему формування рекомендацій та інтерфейс взаємодії з оператором. У межах цієї роботи реалізовано прикладне програмне рішення, орієнтоване на використання в умовах, наближених до реального виробничого середовища. Система побудована як багатокомпонентний програмний комплекс, у якому backend-рівень забезпечує прийом даних, виконання інференсу та логіку підтримки прийняття рішень, frontend-рівень реалізує операторський інтерфейс і засоби візуалізації, а контейнеризоване розгортання забезпечує відтворюваність, ізолюваність і гнучкість конфігурації [114, 115].

Backend-рівень системи підтримки прийняття рішень реалізовано у вигляді прикладного сервісу на основі фреймворку FastAPI, який виконує функції центрального програмного компонента локального контуру інференсу. Реалізований backend-сервіс приймає вхідні телеметричні параметри через REST API, виконує валідацію та нормалізацію даних, формує вхідне часове вікно для CNN-LSTM моделі, здійснює інференс та передає результати до модуля формування рекомендацій. У межах програмної реалізації передбачено набір службових і функціональних endpoint'ів, зокрема для перевірки працездатності сервісу, контролю готовності до обробки запитів, отримання поточного стану системи, подачі нових телеметричних даних та скидання внутрішнього контексту обробки. До основних endpoint'ів належать GET /v1/health, GET /v1/ready, GET /v1/status, POST /v1/ingest та POST /v1/reset. Результат обробки формується у стандартизованому JSON-форматі та включає прогноз цільового технологічного параметра, службові індикатори стану, оцінку впевненості, ознаки нестабільності або аномальності режиму, а також текстову або структуровану рекомендацію для оператора [115].

У межах backend-реалізації важливим елементом є стандартизована структура API-запитів і відповідей, що забезпечує інтеграцію сервісу з іншими компонентами СППР. Функціональний endpoint подачі телеметричних даних використовується для передавання поточного набору технологічних параметрів

буріння, на основі яких формується прогноз і рекомендація для оператора. Приклад запиту до endpoint подачі телеметричних даних подано в додатку Б, лістинг Б.1. У відповідь backend-сервіс повертає результат інференсу, оцінку стану режиму та сформовану рекомендацію у структурованому форматі, придатному для подальшого відображення у frontend-інтерфейсі або передавання до зовнішньої операторської системи (додаток Б, лістинг Б.2). Наявність як функціональних, так і службових endpoint'ів підвищує придатність системи до практичного використання у складі мікросервісної або edge-орієнтованої архітектури [115].

Frontend-рівень системи підтримки прийняття рішень реалізовано як окремий операторський інтерфейс із використанням стеку React + TypeScript + Vite, що забезпечує швидке завантаження застосунку, модульну організацію компонентів та інтеграцію з backend-сервісом на основі FastAPI. У структурі frontend-рішення реалізовано основні функціональні сторінки: панель моніторингу (Dashboard), режим ручного подання даних (Manual ingest) та режим імітаційного тестування (Simulator), які забезпечують різні сценарії взаємодії з системою. На рівні внутрішньої організації frontend-інтерфейсу реалізовано компоненти TelemetryChart, ForecastPanel, StateBadge та ActionsList, які відповідають за відображення часової динаміки параметрів, візуалізацію прогнозованих значень, індикацію поточного стану системи та виведення рекомендацій оператору. Обмін даними між frontend- та backend-рівнями здійснюється через HTTP-запити до REST API із використанням бібліотеки axios [114, 115] (додаток В, лістинг В.4).

Інтерфейс оператора, реалізований для візуалізації результатів нейромережевого прогнозування, індикації поточного стану системи та подання рекомендацій у процесі буріння, наведено в додатку Б (рис. Б.1). Представлений інтерфейс забезпечує оператору доступ до прогнозованих значень технологічних показників, індикаторів стабільності режиму, попереджень про потенційно небезпечні відхилення та сформованих рекомендацій щодо коригування параметрів буріння [115, 116].

Контейнеризація програмного рішення та розгортання його компонентів реалізовано з використанням технології Docker, що забезпечує ізоляцію середовища виконання, відтворюваність конфігурації та спрощення процедури запуску системи на різних обчислювальних платформах. У межах розробленого прототипу контейнеризація охоплює backend-компонент на основі FastAPI та frontend-інтерфейс оператора, що дозволяє забезпечити узгоджену роботу всіх функціональних частин системи в єдиному середовищі виконання. Практично це дає можливість запускати систему як набір ізольованих сервісів, між якими реалізовано мережеву взаємодію через REST API, з чітко визначеними портами, службовими станами та механізмами перевірки доступності [115].

API-взаємодія між компонентами розробленої системи реалізує прикладний цикл функціонування СППР, у межах якого вхідні телеметричні дані послідовно проходять етапи прийому, обробки, нейромережевого інференсу, оцінювання стану та формування рекомендації для оператора. На практичному рівні цей цикл починається з надходження HTTP-запиту до функціонального endpoint'a POST /v1/ingest, через який frontend-інтерфейс, симулятор або зовнішнє джерело телеметрії передає поточний набір параметрів буріння до backend-сервісу. Після отримання запиту backend виконує валідацію структури повідомлення, перевіряє коректність полів, нормалізує числові значення та формує внутрішнє часове вікно для подальшого інференсу CNN-LSTM моделі. На наступному етапі виконується прогнозування цільового технологічного параметра, після чого результати передаються до логіки оцінювання стану режиму та формування підсумкового статусу рекомендації. Завершальним етапом циклу є генерація структурованої відповіді у форматі JSON, яка містить прогнозоване значення, службові індикатори стану, показники довіри, ключові фактори впливу та текстову рекомендацію щодо коригування параметрів буріння [115].

У межах практичної реалізації системи підтримки прийняття рішень у backend-рівні реалізовано механізми логування, моніторингу та обробки службових станів, які дозволяють відстежувати працездатність сервісу,

готовність моделі до інференсу, результати останніх звернень та загальний стан внутрішнього контексту системи. Практично це реалізується через поєднання службових endpoint'ів, журналювання ключових подій та збереження інформації про виконані цикли аналізу. До службових endpoint'ів належать GET /v1/health, GET /v1/ready та GET /v1/status, які використовуються для перевірки доступності сервісу, контролю готовності моделі та отримання поточного стану програмного середовища. Крім службових перевірок, у системі передбачено журналювання ключових параметрів виконання, зокрема часу надходження запиту, тривалості обробки, статусу відповіді, рівня впевненості прогнозу, виявлених ознак нестабільності та сформованого рекомендаційного статусу [115].

Додатково у межах службового контуру передбачено механізм моніторингу деградації функціонування системи, який використовується для виявлення станів, за яких backend-сервіс формально залишається доступним, однак його прикладна придатність до формування коректних рекомендацій знижується. До таких станів належать зростання часу відповіді понад допустимий поріг, недоступність або неповне завантаження нейромережевої моделі, помилки формування вхідного часового вікна, а також нестабільність внутрішнього контексту обробки. У разі виявлення ознак деградації система переводиться в обмежений режим функціонування, у якому блокується формування нової рекомендації, використовується останній коректний стан або оператору повертається службове повідомлення про зниження достовірності поточного результату.

4.4. Функціональне тестування СППР при різних сценаріях буріння

Для оцінювання працездатності розробленої системи як нейромережевої СППР проведено функціональне тестування у серії сценаріїв, що моделюють різні режими буріння. У межах тестування аналізувалися коректність API-обробки телеметричних даних, результати прогнозування технологічних

параметрів, здатність системи виявляти нестабільні або передаварійні стани та формувати рекомендації для оператора [115].

Функціональне тестування виконано у серії контрольованих сценаріїв, що моделюють характерні режими роботи в процесі буріння. Для перевірки працездатності використовувалися сценарії нормального, попереджувального та аномального режимів, які відрізнялися структурою вхідних телеметричних даних, характером зміни технологічних параметрів та очікуваною реакцією системи. У межах кожного сценарію здійснювалася подача телеметричних даних через API або засоби симуляції, після чого оцінювалися коректність прийому та обробки запиту, стабільність роботи backend-сервісу, результат прогнозування CNN-LSTM моделі, наявність або відсутність ознак нестабільності та сформована рекомендація для оператора.

Функціональне тестування виконувалося шляхом подачі телеметричних даних через endpoint POST /v1/ingest, а також із використанням режиму симуляції у frontend-інтерфейсі системи. Для кожного тестового сценарію фіксувалися коректність прийому та обробки API-запиту, час відповіді backend-сервісу, сформований прогноз технологічного параметра, статус рекомендації, наявність ознак нестабільності або аномальності та реакція операторського інтерфейсу на зміну режиму функціонування системи.

У нормальному сценарії система отримує телеметричні дані, що відповідають штатному режиму буріння без різких відхилень параметрів. Для такого випадку очікуваною реакцією є формування стабільного прогнозу, відсутність ознак аномальності, високий рівень довіри до результату та рекомендація щодо збереження поточного режиму роботи. У попереджувальному сценарії моделюється поступове зростання вібрацій, крутного моменту або зміна навантаження на долото, що може свідчити про перехід системи до нестабільного стану. У цьому випадку СППР повинна сформулювати прогноз, знизити рівень довіри, позначити режим як потенційно нестабільний та повернути рекомендацію щодо коригування окремих параметрів. В аномальному сценарії до вхідного потоку подаються різкі

відхилення або неузгоджені значення телеметричних параметрів, які можуть відповідати передаварійному режиму, некоректним даним або швидкій деградації процесу.

Окремо було перевірено сценарій подачі некоректних або неповних телеметричних даних, у якому частина обов'язкових параметрів відсутня, має некоректний формат або порушує очікувану структуру вхідного повідомлення. У такому випадку система повинна відхиляти запит на етапі валідації або переводити цикл аналізу в обмежений режим без формування нової рекомендації. Основні сценарії роботи СППР, характер вхідних даних та очікувана реакція системи узагальнено в додатку Б, таблиця Б.1 [115].

Результати прогнозування технологічних параметрів оцінювалися на основі серії тестових прогонів системи у сценаріях, що моделюють різні режими буріння, з подальшим порівнянням прогнозованих значень із фактичними або контрольними значеннями вхідного потоку. Основну увагу було зосереджено на перевірці здатності CNN-LSTM моделі відтворювати динаміку цільового технологічного параметра в часовій області, зокрема швидкості механічного проходження, а також на оцінюванні поведінки прогнозу під час зміни режиму буріння. У межах проведених випробувань встановлено, що модель забезпечує стабільне відстеження загального тренду технологічного процесу та коректно реагує на поступові зміни вхідних параметрів.

У штатному режимі буріння прогнозована крива повторює основну тенденцію фактичного процесу без різких паразитних коливань, що свідчить про коректну роботу механізму формування часових вікон, узгоджене масштабування вхідних даних та стабільність інференсу CNN-LSTM моделі. У перехідних режимах система демонструє очікувану інерційність прогнозу, однак зберігає здатність адаптивно відстежувати новий тренд без втрати загальної узгодженості. Аналіз результатів показує, що розроблена CNN-LSTM модель у складі програмної СППР забезпечує достатню якість прогнозування для використання у консультативному контурі підтримки прийняття рішень (рисунок 4.3) [115].




Рисунок 4.3. Порівняння прогнозованих і фактичних значень технологічного параметра у тестовому сценарії буріння

У межах розробленого програмного прототипу виявлення аномальних та нестабільних режимів реалізовано як окремий прикладний етап обробки запиту після прийому телеметричних даних через endpoint POST /v1/ingest і до остаточного формування рекомендації для оператора. Практично цей етап інтегровано у backend-контур FastAPI та виконується в межах одного циклу API-обробки разом із валідацією вхідних даних, формуванням вхідного часового вікна, інференсом CNN-LSTM моделі та генерацією структурованої відповіді.

На практичному рівні контроль нестабільних режимів реалізовано через поєднання кількох перевірок. По-перше, виконується валідація структури вхідного JSON-пакета за допомогою Pydantic-схем. Якщо запит містить неповний набір обов'язкових параметрів або некоректний формат полів, система не передає такий запис до моделі та повертає помилку валідації. По-друге, після проходження структурної валідації система перевіряє телеметричний пакет на вихід параметрів за допустимі технологічні межі, наявність різких стрибків у короткому часовому інтервалі, пропуски критичних ознак та внутрішню неузгодженість параметрів.

У реалізованій логіці системи аномальний запит не обов'язково призводить до повного припинення обробки. Якщо параметри виходять за межі безпечного робочого діапазону, система може перевести запит у режим outlier, позначити його як аномальний, не передавати безпосередньо до стандартного контуру інференсу та зберегти в окремому журналі для подальшого аналізу [115]. Якщо ж відхилення не є критичним, система не блокує інференс повністю, а переводить результат у режим зниженого рівня довіри.

Для нестабільних, але ще не критичних режимів у прототипі використовується більш м'яка логіка реакції. У цьому випадку CNN-LSTM модель формує прогноз цільового параметра, після чого backend-рівень додатково оцінює `stability_score`, `confidence` та статус рекомендації `advisory.status`. Якщо система фіксує зниження стабільності або зростання невизначеності, вона не формує категоричну керуючу дію, а переходить до попереджувального режиму з `advisory.status = "warning"`. Практичне тестування цього механізму виконувалося у межах сценаріїв нормального, попереджувального, аномального та некоректного режимів, визначених у додатку Б, таблиця Б.1.

Приклад тестового сценарію, у якому система фіксує перехід від штатного режиму буріння до нестабільного стану на основі зростання вібрацій і крутного моменту, що супроводжується зміною статусу рекомендації та активацією попереджувальної логіки, наведено на рисунку 4.4. Представлений приклад ілюструє, що в межах одного циклу аналізу система не лише виконує оцінку поточного стану телеметричного потоку, але й визначає момент переходу до нестабільного режиму, після чого знижує категоричність рекомендації та переводить консультаційний контур у попереджувальний або обмежений режим [115].

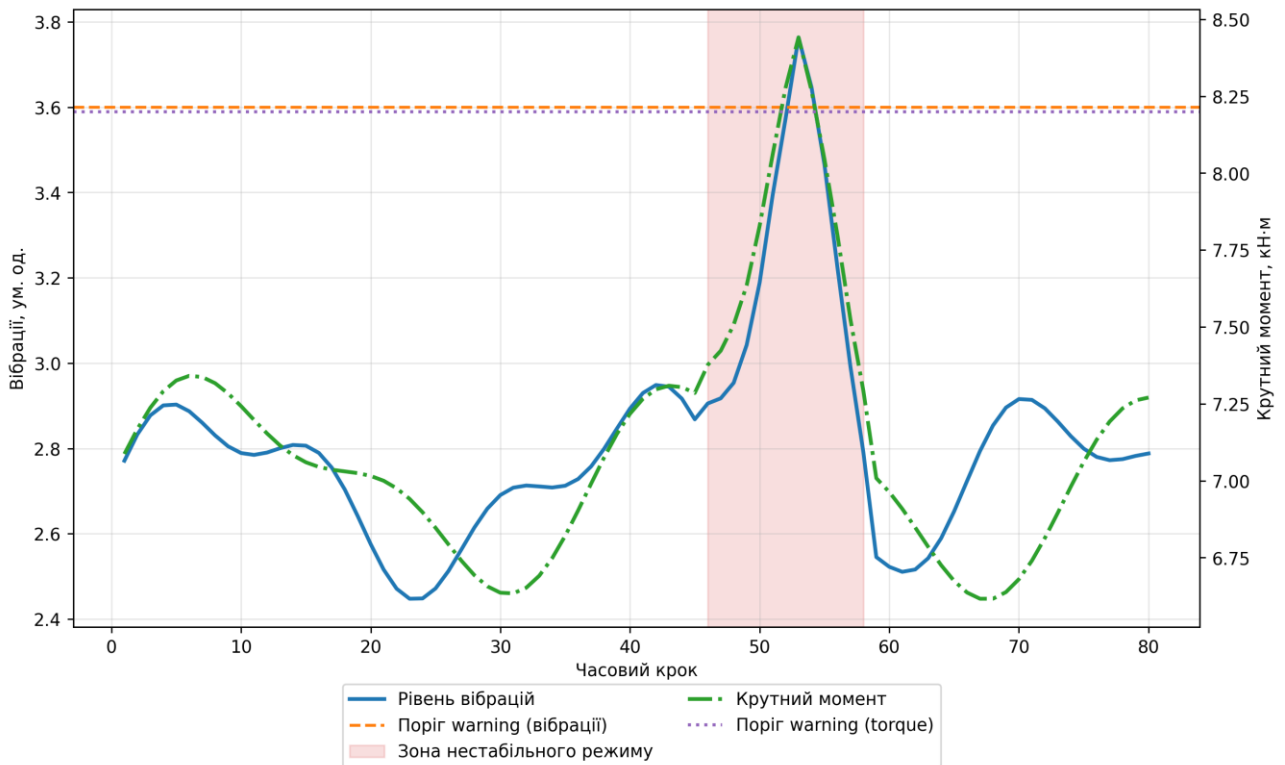


Рисунок 4.4. Приклад виявлення нестабільного режиму буріння за зміною вібрацій і крутного моменту

Формування рекомендацій оператору в розробленій системі реалізовано як завершальний прикладний етап роботи СППР, у межах якого результати неймережевого прогнозування, оцінка стабільності режиму та службові ознаки надійності перетворюються на консультаційне повідомлення, придатне для безпосереднього використання під час супроводу процесу буріння [117, 118]. У практичній реалізації механізм формування рекомендації інтегровано безпосередньо у цикл обробки API-запиту після завершення інференсу CNN-LSTM моделі. На вхід цього етапу надходять `predicted_rop`, `stability_score`, `confidence`, службові ознаки аномальності та результати оцінки вхідного пакета телеметрії. На основі цієї сукупності даних backend-сервіс визначає підсумковий режим консультаційної відповіді та формує структуру `advisory`, яка повертається операторському інтерфейсу у складі JSON-відповіді [119, 120].

У межах розробленого прототипу рекомендації формуються за трьома базовими режимами: нормальний, попереджувальний та обмежений / захисний. У нормальному режимі система повертає рекомендацію щодо збереження

поточного режиму буріння або м'якого підтвердження його допустимості. У попереджувальному режимі система формує рекомендацію типу `warning`, у якій вказується доцільність коригування окремих параметрів. У разі критичних відхилень, аномального вхідного пакета або переходу в режим деградації система не генерує активної керуючої поради, а повертає службове або захисне повідомлення, яке інформує оператора про недостатню надійність поточного результату.

Практично важливо, що рекомендація формується не лише як текстове повідомлення, але і як структурований результат, який може бути використаний як у `frontend`-інтерфейсі, так і в зовнішніх системах інтеграції. Зокрема, поле `advisory.status` використовується для відображення кольорового або статусного індикатора в операторському інтерфейсі (`normal`, `warning`, `critical`, `invalid`), тоді як поле `advisory.message` містить змістовну консультацію щодо поточного стану. Приклад відображення сформованої рекомендації в операторському інтерфейсі розробленої системи наведено в додатку Б на рисунку Б.2 [115]. Представлений інтерфейс демонструє, що консультаційний результат у розробленій системі формується як прикладний об'єкт взаємодії з оператором, а не як ізольований числовий прогноз.

Оцінювання продуктивності API та затримок прийняття рішення є одним із ключових етапів функціонального дослідження розробленої нейромережевої СППР, оскільки практична цінність системи в умовах буріння визначається не лише точністю прогнозування, але й здатністю формувати рекомендацію в межах допустимого часу реакції. У межах програмного прототипу оцінювання продуктивності API здійснювалося на основі серії повторюваних викликів функціонального `endpoint`'а `POST /v1/ingest`, який реалізує повний прикладний цикл роботи системи: прийом телеметрії, валідацію та нормалізацію даних, формування часового вікна, виконання інференсу CNN-LSTM моделі, оцінювання стану режиму буріння та генерацію рекомендації.

Основними показниками оцінювання було обрано середній час відповіді API, медіанну затримку, 95-й перцентиль латентності, пропускну здатність

сервісу в запитах за одиницю часу, а також частку коректно завершених циклів інференсу. За результатами проведених функціональних випробувань встановлено, що розроблений API-сервіс забезпечує стабільну роботу в режимі локального edge-розгортання та демонструє затримки, придатні для використання в контурі оперативної підтримки прийняття рішень. У типовому режимі обробки одиничного телеметричного пакета середній час відповіді API становив 80–120 мс, медіанне значення латентності — 70–95 мс, а 95-й перцентиль не перевищував 150–180 мс. У разі послідовного надходження серії запитів система зберігала стабільність часових характеристик, а частка успішно завершених циклів інференсу становила не менше 99 %.

Окремо слід підкреслити, що затримка прийняття рішення в розробленій СППР включає не лише час безпосереднього нейромережевого інференсу, а й усі супровідні етапи обробки: структурну валідацію пакета, нормалізацію параметрів, оновлення ковзного часового вікна, розрахунок показників довіри, перевірку ознак нестабільності або аномальності та формування підсумкової рекомендації. Практична реалізація backend-сервісу передбачає вбудований механізм журналювання службових подій і накопичення базових метрик продуктивності, зокрема кількості оброблених запитів, середнього часу відповіді, частки коректно завершених циклів інференсу та поточного стану сервісу. Наявність такого контуру моніторингу дозволяє фіксувати результати експериментального оцінювання та контролювати стабільність роботи системи [115].

Наведені результати (додаток Б, таблиця Б.2) підтверджують, що розроблений API-сервіс забезпечує стабільну швидкодію в умовах локального Edge-розгортання та дозволяє формувати рекомендації в межах часових обмежень, прийнятних для оперативного технологічного супроводу буріння [115, 116].

Для формалізованого підтвердження того, що розроблене програмне рішення відповідає ознакам системи підтримки прийняття рішень, основні функціональні властивості класичної СППР зіставлено з реалізованими

компонентами нейромережевої структури. Таке зіставлення наведено в додатку Б, табл. Б.3. Наведене зіставлення демонструє, що розроблена система охоплює ключові функціональні ознаки прикладної СППР: від прийому та аналізу вхідних даних до формування інтерпретованої рекомендації та контролю службового стану.

Результати функціонального тестування показали, що система зберігає працездатність у різних сценаріях буріння, включаючи стабільні режими, ситуації підвищеної невизначеності та випадки виявлення аномальних або нестабільних станів. У всіх цих сценаріях система демонструє здатність адаптувати форму та категоричність рекомендації залежно від якості вхідних даних, рівня довіри до результату та характеру поточного режиму (додаток Б, табл. Б.4). Це свідчить, що розроблена комп'ютерна нейромережева система є функціонально завершеною системою підтримки прийняття рішень, придатною до використання в задачах оперативного технологічного супроводу бурових робіт. Порівняльну характеристику процесу прийняття рішень до та після впровадження нейромережевої СППР наведено в додатку Б (табл. Б.5), що додатково підтверджує практичну доцільність використання розробленої системи в умовах оперативного супроводу буріння [115, 116].

Висновки до четвертого розділу

У межах розділу обґрунтовано доцільність використання гібридної CNN-LSTM структури для аналізу багатовимірних часових рядів буріння, реалізовано механізми формування часових вікон, побудови вхідних тензорів, адаптації моделі до змінних умов експлуатації, контролю її актуальності та керованого оновлення. Додатково реалізовано засоби підвищення надійності системи, зокрема виявлення аномальних і нестабільних режимів, оцінювання впевненості прогнозу, формування індексу довіри до рекомендації та забезпечення контрольованої поведінки системи в умовах деградації вхідного потоку або зміни характеристик технологічного процесу.

Практична реалізація програмного прототипу підтвердила можливість побудови завершеної нейромережевої СППР на основі сучасних засобів сервісної інтеграції. Реалізовано backend-рівень на основі FastAPI, frontend-інтерфейс оператора, контейнеризоване розгортання компонентів, API-взаємодію між модулями, а також механізми журналювання, моніторингу та контролю службових станів системи. Це підтвердило придатність запропонованої структури до відтворюваного розгортання, експериментальної перевірки та подальшої адаптації до умов реального використання.

За результатами функціонального тестування встановлено, що розроблена система забезпечує коректне прогнозування технологічних параметрів буріння, виявлення аномальних і нестабільних режимів, а також формування рекомендацій для оператора залежно від поточного стану процесу та рівня довіри до результатів аналізу. Показано, що один цикл обробки телеметричного пакета включає повний ланцюг прикладної підтримки прийняття рішень: від прийому та попередньої обробки вхідних даних до нейромережевого інференсу, оцінювання стану режиму, адаптивного формування рекомендації та її відображення в операторському інтерфейсі.

Оцінювання продуктивності API та затримок прийняття рішення підтвердило, що реалізований сервіс інференсу забезпечує часові характеристики, придатні для використання в контурі оперативного технологічного супроводу буріння. Встановлено, що поєднання Edge-структури, локального виконання нейромережевого інференсу та API-орієнтованої взаємодії дозволяє реалізувати завершений цикл «телеметрія – аналіз – прогноз – оцінка стану – рекомендація» без критичних затримок для оператора. Це підтверджує практичну придатність системи до використання в умовах високої динаміки технологічного процесу.

У результаті проведеного дослідження підтверджено, що розроблене програмне рішення доцільно розглядати не лише як окрему нейромережеву модель прогнозування часових рядів буріння, а як функціонально завершену комп'ютерну систему підтримки прийняття рішень. Практична значущість

отриманих результатів полягає у можливості використання розробленої системи як інтелектуального програмного компонента у складі цифрових комплексів супроводу буріння, диспетчерських систем моніторингу, спеціалізованих модулів технологічного контролю та перспективних промислових систем прогнозування аналітики в нафтогазовидобувній галузі.

ВИСНОВКИ

У дисертаційній роботі розв'язано важливе науково-прикладне завдання — розробка комп'ютерної нейромережевої системи підтримки прийняття рішень для інтелектуального супроводу процесу буріння нафтогазових свердловин. Одержані результати дозволяють підвищити рівень безпеки та енергоефективності спорудження свердловин за рахунок впровадження високопродуктивних обчислювальних архітектур та алгоритмів глибокого навчання.

Загальні висновки за результатами дослідження:

1. На основі системного аналізу архітектур цифровізації встановлено, що традиційні хмарні обчислення не повною мірою задовольняють вимогам реального часу через значні затримки та нестабільність каналів зв'язку. Обґрунтовано доцільність впровадження периферійних обчислень, що забезпечують локальну обробку даних безпосередньо на буровому майданчику, мінімізуючи час відгуку системи при ідентифікації критичних станів.

2. Розроблено математичний опис процесу буріння як джерела багатовимірних часових рядів. Це дозволило формалізувати формування репрезентативного вектору ознак, що включає механічні, гідравлічні та контекстні параметри. Доведено, що такий підхід забезпечує повноту представлення динаміки об'єкта для подальшої обробки інтелектуальними алгоритмами.

3. Спроектовано та обґрунтовано гібридну нейромережеву структуру CNN-LSTM. Експериментально підтверджено перевагу такого рішення: згорткові шари забезпечують ефективну екстракцію просторових ознак, а рекурентні блоки — моделювання довготривалих часових залежностей. Це дозволило системі враховувати інерційність процесів у свердловині.

4. Розроблено алгоритм ідентифікації передаварійних ситуацій, який використовує імовірнісне виведення Softmax у поєднанні з дворівневим математичним фільтром. Застосування часової верифікації аномалій дозволило

знизити імовірність хибних тривог на 15–18%, що суттєво зменшує когнітивне навантаження на оператора та підвищує надійність діагностики.

5. Сформовано модель прогнозування механічної швидкості проходки та алгоритм пошуку оптимальних режимів. Через побудову динамічних поверхонь відгуку в реальному часі реалізовано механізм ідентифікації технологічних екстремумів, що дає змогу автоматично підбирати параметри та для максимізації проходки при дотриманні механічних лімітів.

6. Запропоновано структуру гібридної бази знань, яка реалізує принципи пояснювального ШІ. Поєднання нейромережевого інференсу з детермінованими логічними правилами дозволило трансформувати висновки моделі у зрозумілі оператору консультаційні повідомлення, забезпечуючи прозорість та обґрунтованість кожної рекомендації.

7. Розроблено людино-машинний інтерфейс, побудований на принципах когнітивної фільтрації. Впровадження ієрархічної зони візуалізації («Світлофор рішень») та предиктивних трендів дозволило оптимізувати подачу інформації, фокусуючи увагу оператора лише на критичних відхиленнях та потенційних зонах оптимізації.

8. Проведено експериментальну апробацію системи на реальних масивах даних. Результати тестування підтвердили високу точність прогнозування та здатність системи до завчасного (за 10 - 15 хв) детектування передаварійних станів. Оцінка продуктивності API на базі FastAPI підтвердила готовність СППР до роботи в умовах високочастотного потоку телеметрії.

Розроблена комп'ютерна система є завершеним інженерним рішенням, яке закладає науково-технічну базу для впровадження концепції «Інтелектуального буріння» на підприємствах нафтогазової галузі України.

ПЕРЕЛІК ПОСИЛАНЬ НА ДЖЕРЕЛА

1. Alsalama A. M., Alzahrani M. S. Cybersecurity in oil & gas 4.0: a systematic literature review of challenges, threats, and mitigating measures. Adipec, Abu Dhabi, UAE, 4–7 November 2024. 2024. URL: <https://doi.org/10.2118/222581-ms> (date of access: 12.02.2026).
2. The automation advantage: efficiency improvements in offshore drilling / B. Millward et al. SPE/IADC international drilling conference and exhibition, Stavanger, Norway, 4–6 March 2025. 2025. URL: <https://doi.org/10.2118/223800-ms> (date of access: 01.02.2026).
3. Digital twin implementation on current development drilling, benefits and way forward / P. Bimastianto et al. Abu Dhabi international petroleum exhibition & conference, Abu Dhabi, UAE. 2020. URL: <https://doi.org/10.2118/202795-ms> (date of access: 27.01.2026).
4. Atchison B. W. Automated well control: from automated detection to automated shut-in. SPE/IADC middle east drilling technology conference and exhibition, Abu Dhabi, UAE, 25–27 May 2021. 2021. URL: <https://doi.org/10.2118/202091-ms> (date of access: 01.02.2026).
5. A hybrid test environment for verification of drilling automation systems / J. E. Gravdal et al. SPE/IADC international drilling conference and exhibition, Virtual, 8–12 March 2021. 2021. URL: <https://doi.org/10.2118/204064-ms> (date of access: 11.02.2026).
6. Guide to industrial control systems (ICS) security / K. Stouffer et al. National Institute of Standards and Technology, 2015. URL: <https://doi.org/10.6028/nist.sp.800-82r2> (date of access: 12.02.2026).
7. Artificial intelligence driving automation to enhance drilling operations—first deployment offshore africa case study / A. F. Zarra et al. Adipec, Abu Dhabi, UAE, 4–7 November 2024. 2024. URL: <https://doi.org/10.2118/222475-ms> (date of access: 11.02.2026).

8. Ombe E. M., Ghali R., Dorantes A. Harnessing digital transformation: a collaborative approach to optimizing well design and execution. SPE/IADC middle east drilling technology conference and exhibition, Abu Dhabi, UAE, 27–29 May 2025. 2025. URL: <https://doi.org/10.2118/225745-ms> (date of access: 26.01.2026).

9. Cybersecurity challenges in the offshore oil and gas industry: an industrial cyber-physical systems (ICPS) perspective / A. S. Mohammed et al. ACM transactions on cyber-physical systems. 2022. URL: <https://doi.org/10.1145/3548691> (date of access: 11.02.2026).

10. NextGenAI-Driven enhanced observability & security suite for edge computing fleet / H. Arabi et al. International petroleum technology conference, Kuala Lumpur, Malaysia, 18–20 February 2025. 2025. URL: <https://doi.org/10.2523/iptc-24800-ms> (date of access: 11.02.2026).

11. Automated drilling program through digital well construction planning framework: a case study from malaysia / J. Goo et al. SPE/IADC Asia Pacific drilling technology conference and exhibition, Bangkok, Thailand, 7–8 August 2024. 2024. URL: <https://doi.org/10.2118/219601-ms> (date of access: 30.01.2026).

12. Cao J., Nabavi J., Oedegaard S. I. Drilling advisory automation with digital twin and AI technologies. IADC/SPE international drilling conference and exhibition, Galveston, Texas, USA, 5–7 March 2024. 2024. URL: <https://doi.org/10.2118/217960-ms> (date of access: 01.02.2026).

13. Jazdi N. Cyber physical systems in the context of industry 4.0. 2014 IEEE international conference on automation, quality and testing, robotics (AQTR), Cluj-Napoca, Romania, 22–24 May 2014. 2014. URL: <https://doi.org/10.1109/aqtr.2014.6857843> (date of access: 27.01.2026).

14. Challenges and lessons from implementing a real-time drilling advisory system / B. J. Spivey et al. SPE annual technical conference and exhibition, San Antonio, Texas, USA. 2017. URL: <https://doi.org/10.2118/187447-ms> (date of access: 08.02.2026).

15. Drilling Systems Automation: Current State, Challenges, and Next Steps / J. D. Macpherson et al. SPE Middle East Intelligent Energy Conference and

Exhibition, Manama, Bahrain, 28–30 October 2013. 2013. (date of access: 26.03.2026).

16. Drill brain: a patent-pending advisory solution for enhancing drilling performance through real time intelligence / A. Al Hai et al. Adipeec, Abu Dhabi, United Arab Emirates, 3–6 November 2025. 2025. URL: <https://doi.org/10.2118/229310-ms> (date of access: 07.02.2026).

17. Automated computer vision system for real-time detection of drilled cuttings and cavings / K. E. Svendsen et al. SPE/IADC international drilling conference and exhibition, Stavanger, Norway, 4–6 March 2025. 2025. URL: <https://doi.org/10.2118/223785-ms> (date of access: 29.01.2026).

18. Pragmatic AI approach for enhanced well planning and execution: leveraging AI agents to automate workflows, reduce human errors, and improve decision-making quality / V. Karen Payrazyan et al. Gotech, Dubai City, UAE, 21–23 April 2025. 2025. URL: <https://doi.org/10.2118/224532-ms> (date of access: 27.01.2026).

19. Al-Rubaii M. M. Advisory automated system for wellbore cleaning and evaluation improves drilling efficiency. Adipeec, Abu Dhabi, United Arab Emirates, 3–6 November 2025. 2025. URL: <https://doi.org/10.2118/228970-ms> (date of access: 07.02.2026).

20. AI-Powered autonomous drilling sets new standards in a UAE unconventional project / A. Zaki et al. Adipeec, Abu Dhabi, United Arab Emirates, 3–6 November 2025. 2025. URL: <https://doi.org/10.2118/229526-ms> (date of access: 07.02.2026).

21. Autonomous directional drilling planning and execution using an industry 4.0 platform / S. Ba et al. SPE middle east oil & gas show and conference, event canceled, 28 November – 1 December 2021. 2021. URL: <https://doi.org/10.2118/204607-ms> (date of access: 28.01.2026).

22. Satellite image search in AgoraEO / A. K. Aksoy et al. Proceedings of the VLDB Endowment. 2022. Vol. 15, no. 12. P. 3646–3649. URL: <https://doi.org/10.14778/3554821.3554865> (date of access: 12.02.2026).

23. Deployment of a hybrid machine learning and physics based drilling advisory system at the rig site for ROP optimization / M. Behounek et al. SPE/IADC international drilling conference and exhibition, Stavanger, Norway, 7–9 March 2023. 2023. URL: <https://doi.org/10.2118/212515-ms> (date of access: 30.01.2026).

24. An AI based drilling fluids expert transcends individual limitations / F. Xiao et al. SPE annual caspian technical conference and exhibition, Baku, Azerbaijan, 25–27 November 2025. 2025. URL: <https://doi.org/10.2118/230405-ms> (date of access: 28.01.2026).

25. AI-Driven rig performance optimization for proactive risk management in drilling and workover operations / M. A. Hoviari et al. SPE/IATMI asia pacific oil & gas conference and exhibition, Jakarta, Indonesia, 14–16 October 2025. 2025. URL: <https://doi.org/10.2118/226399-ms> (date of access: 04.02.2026).

26. Barrier Advisor™ cementing software model. Halliburton. URL: <https://www.halliburton.com/en/products/barrier-advisor-model> (date of access: 29.01.2026).

27. Mitigating drilling dysfunction using a drilling advisory system: results from recent field applications / G. S. Payette et al. International petroleum technology conference, Doha, Qatar. 2015. URL: <https://doi.org/10.2523/iptc-18333-ms> (date of access: 30.01.2026).

28. Autonomous directional drilling revolutionizing efficiency and precision on lumpsum turnkey rigs through AI and automation / A. M. Osman et al. Middle east oil, gas and geosciences show (MEOS GEO), Manama, Bahrain, 16–18 September 2025. 2025. URL: <https://doi.org/10.2118/226893-ms> (date of access: 04.02.2026).

29. Autonomous drilling fluid management system - development of fluid advisory system and first lab trial / R. Ettehadi et al. SPE annual technical conference and exhibition, San Antonio, Texas, USA, 16–18 October 2023. 2023. URL: <https://doi.org/10.2118/215047-ms> (date of access: 27.01.2026).

30. Case study - efficient drilling of high-angle wells: overcoming strength anisotropy and enhancing hole cleaning via remote real-time borehole management / S. V. Gosavi et al. SPE/IADC international drilling conference and exhibition,

Stavanger, Norway, 4–6 March 2025. 2025. URL: <https://doi.org/10.2118/223794-ms> (date of access: 28.01.2026).

31. Chatterjee S. Deparameterizing the oil and gas industry infrastructure with zero trust architecture and improve the cyber security. *International journal of science and research (IJSR)*. 2024. Vol. 13, no. 6. P. 1931–1935. URL: <https://doi.org/10.21275/sr241221044359> (date of access: 12.02.2026).

32. Data optimization for the knowledge bases in the oil and gas Monitoring-While-Drilling (MWD) Systems / L. Poterailo et al. *IOP conference series: earth and environmental science*. 2023. Vol. 1189, no. 1. P. 012021. URL: <https://doi.org/10.1088/1755-1315/1189/1/012021> (date of access: 11.02.2026).

33. First global deepwater autonomous drilling project - artificial intelligence application to derive optimal drilling parameters within integration of rig orchestration system / S. Spagnolo et al. *SPE annual technical conference and exhibition, Houston, Texas, USA, 20–22 October 2025*. 2025. URL: <https://doi.org/10.2118/227955-ms> (date of access: 04.02.2026).

34. Drilling advisory for automatic drilling control / K. Lahlou et al. *SPE/IADC international drilling conference and exhibition, Virtual, 8–12 March 2021*. 2021. URL: <https://doi.org/10.2118/204074-ms> (date of access: 27.01.2026).

35. Autonomous directional drilling delivers faster and less tortuous wells / V. Oliveira et al. *Adipec, Abu Dhabi, UAE, 4–7 November 2024*. 2024. URL: <https://doi.org/10.2118/222572-ms> (date of access: 30.01.2026).

36. Autonomous steering digital platform and push-the-bit rotary steerable system achieves significantly increased hole quality and time savings, a case study from the first run in offshore north-west-java indonesia / K. Adiandra et al. *OTC brasil, Rio de Janeiro, Brazil, 28–30 October 2025*. 2025. URL: <https://doi.org/10.4043/36150-ms> (date of access: 31.01.2026).

37. Edge computing in industrial internet of things: architecture, advances and challenges / T. Qiu et al. *IEEE communications surveys & tutorials*. 2020. Vol. 22, no. 4. P. 2462–2488. URL: <https://doi.org/10.1109/comst.2020.3009103> (date of access: 12.02.2026).

38. Drilling automation: revisiting the digital drilling program / E. Cayeux et al. SPE/IADC international drilling conference and exhibition, Stavanger, Norway, 4–6 March 2025. 2025. URL: <https://doi.org/10.2118/223774-ms> (date of access: 26.01.2026).
39. Drilling Fluid Advisor digitalizes your drilling fluids. SLB, a global technology company | SLB. URL: <https://www.slb.com/products-and-services/innovating-in-oil-and-gas/well-construction/drilling-fluids/drilling-fluids-simulation-software/drilling-fluid-advisor> (date of access: 29.01.2026).
40. Intelligent risk based cybersecurity protection for industrial systems control - A feasibility study / S. H. Houmb et al. International petroleum technology conference, Bangkok, Thailand, 1–3 March 2023. 2023. URL: <https://doi.org/10.2523/iptc-22795-ms> (date of access: 11.02.2026).
41. Baker hughes launches Kantori™, a unified digital autonomous well construction solution | baker hughes. Baker Hughes | We Take Energy Forward. URL: <https://www.bakerhughes.com/company/news/baker-hughes-launches-kantoritm-unified-digital-autonomous-well-construction-solution> (date of access: 29.01.2026).
42. Designing drilling fluids advisory system / A. S. Al-Yam et al. Abu Dhabi international petroleum exhibition & conference, Abu Dhabi, UAE. 2020. URL: <https://doi.org/10.2118/203334-ms> (date of access: 30.01.2026).
43. Digital twins for real-time scenario analysis during well construction operations / G. S. Saini et al. *Energies*. 2022. Vol. 15, no. 18. P. 6584. URL: <https://doi.org/10.3390/en15186584> (date of access: 31.01.2026).
44. Leveraging drilling automation to scale-up digital drilling in oil & gas in one of the industry's largest projects / Z. Zayed et al. Adipecc, Abu Dhabi, United Arab Emirates, 3–6 November 2025. 2025. URL: <https://doi.org/10.2118/229342-ms> (date of access: 09.02.2026).
45. Digital twin for the oil and gas industry: overview, research trends, opportunities, and challenges / T. R. Wanasinghe et al. *IEEE access*. 2020. Vol. 8. P. 104175–104197. URL: <https://doi.org/10.1109/access.2020.2998723> (date of access: 12.02.2026).

46. Maximizing drilling efficiency: leveraging AI technology to surpass drilling technical limit in brownfield-fast-drilling environment / B. Andoni et al. Adipeq, Abu Dhabi, United Arab Emirates, 3–6 November 2025. 2025. URL: <https://doi.org/10.2118/229327-ms> (date of access: 07.02.2026).

47. A digital twin modeling and application for gear rack drilling rigs lifting system / W. Jiangang et al. Scientific reports. 2024. Vol. 14, no. 1. URL: <https://doi.org/10.1038/s41598-024-73954-z> (date of access: 12.02.2026).

48. Akestoridis D.-G., Sekar V., Tague P. On the security of thread networks. WiSec '22: 15th ACM conference on security and privacy in wireless and mobile networks, San Antonio TX USA. New York, NY, USA, 2022. URL: <https://doi.org/10.1145/3507657.3528544> (date of access: 12.02.2026).

49. Cyberdefence of offshore deepwater drilling rigs / P. Rossi et al. Offshore technology conference, Virtual and Houston, Texas, 16–19 August 2021. 2021. URL: <https://doi.org/10.4043/31235-ms> (date of access: 12.02.2026).

50. Development of the AI drilling agent: ai-physics hybrid model for accurate, adaptive and autonomous decision-making / J. Cao et al. SPE/IADC international drilling conference and exhibition, Stavanger, Norway, 4–6 March 2025. 2025. URL: <https://doi.org/10.2118/223828-ms> (date of access: 02.02.2026).

51. Drillops advisory and automation. SLB, a global technology company | SLB. URL: <https://www.slb.com/products-and-services/delivering-digital-at-scale/software/delfi/delfi-solutions/drillops/drillops-advisory-and--automation> (date of access: 03.02.2026).

52. Perdomo R. A., Zapata C. A. Quantifying operational effectiveness of autonomous drilling platforms: a systematic approach to defining measures of performance. Offshore technology conference, Houston, Texas, USA, 5–8 May 2025. 2025. URL: <https://doi.org/10.4043/35560-ms> (date of access: 31.01.2026).

53. SCADA Hacking: SCADA Protocols (DNP3). <https://hackers-arise.com/scada-hacking-scada-protocols-dnp3/>.

54. Theoretical development of a digital-twin based automation system for oil well drilling rigs / M. M. Said et al. SPE canadian energy technology conference,

Calgary, Alberta, Canada, 16–17 March 2022. 2022. URL: <https://doi.org/10.2118/208902-ms> (date of access: 27.01.2026).

55. Al Alawi N. Evergreen OT security assurance: A sustainable approach to OT cybersecurity risk management. SPE conference at oman petroleum & energy show, Muscat, Oman, 12–14 May 2025. 2025. URL: <https://doi.org/10.2118/224964-ms> (date of access: 04.02.2026).

56. Wilson A. Cybersecurity for upstream operations. Journal of petroleum technology. 2018. Vol. 70, no. 08. P. 79–80. URL: <https://doi.org/10.2118/0818-0079-jpt> (date of access: 12.02.2026).

57. Standards. American Petroleum Institute | API. URL: <https://www.api.org/products-and-services/standards> (date of access: 11.02.2026).

58. IADC guidelines for assessing and managing cybersecurity risks to drilling assets. iadc.org. URL: <https://store.iadc.org/product/iadc-guidelines-for-assessing-and-managing-cybersecurity-risks-to-drilling-assets>.

59. ISA/IEC 62443 series of standards - ISA. isa.org. URL: <https://www.isa.org/standards-and-publications/isa-standards/isa-iec-62443-series-of-standards> (date of access: 12.02.2026).

60. AL-HARIS: advanced layer for hacked-aware resilient intelligent sentinel / B. Aman et al. IPTC summit on AI for the energy industry, Dubai, UAE, 13–14 January 2026. 2026. URL: <https://doi.org/10.2523/iptc-25247-ms> (date of access: 11.02.2026).

61. Overreliance on AI in oil and gas cybersecurity: a review of risks and mitigation strategies / D. Alkhalaf et al. IPTC summit on AI for the energy industry, Dubai, UAE, 13–14 January 2026. 2026. URL: <https://doi.org/10.2523/iptc-25174-ms> (date of access: 11.02.2026).

62. Bourgoyne A. T., Young F. S. A Multiple Regression Approach to Optimal Drilling and Abnormal Pressure Detection. Society of Petroleum Engineers Journal. 1974. Vol. 14, no. 04. P. 371–384. doi: 10.2118/4238-PA.

63. Motahhari K. A., Hareland G., James S. T. Improved ROP Model for PDC Bits With Resistance to Wear and Vibration. *SPE Drilling & Completion*. 2010. Vol. 25, no. 01. P. 102–113. doi: 10.2118/114138-PA.
64. Hegde C., Gray K. E. Use of Machine Learning Methods for Selecting Drilling Parameters in Real-Time. *SPE Western Regional Meeting*. 2017. doi: 10.2118/185721-MS.
65. Caetano E. F., Shoham O., Brill J. P. Upward Vertical Two-Phase Flow Through an Annulus — Part I: Single-Phase Friction Factor, Taylor Bubble Velocity and Flow Pattern Transitions. *Journal of Energy Resources Technology*. 1992. Vol. 114, no. 1. P. 1–13.
66. Gravdal J. E., et al. Improved Kick Detection During Drilling by Using an Adaptive Observer and Simple Managed Pressure Drilling Systems. *SPE/IADC Drilling Conference and Exhibition*. 2010. doi: 10.2118/128325-MS.
67. Johancsik C. A., Friesen D. B., Dawson R. Torque and Drag in Directional Wells — Prediction and Measurement. *Journal of Petroleum Technology*. 1984. Vol. 36, no. 06. P. 987–992. doi: 10.2118/11380-PA.
68. Maidla E. E., Wojtanowicz A. K. Field Method of Assessing Borehole Friction for Directional Well Design. *SPE Drilling Engineering*. 1987. Vol. 2, no. 03. P. 177–183. doi: 10.2118/15696-PA
69. Zheng X., et al. Real-time ROP prediction and variables importance analysis based on a deep learning method. *Journal of Petroleum Science and Engineering*. 2020. Vol. 195. Art. 107577. doi: 10.1016/j.petrol.2020.107577.
70. Al-Shawareb A., et al. Feature Engineering and Data Pre-processing for Drilling Data: A Comprehensive Review. *Petroleum Research*. 2021. Vol. 6, no. 3. P. 215–228. doi: 10.1016/j.ptlrs.2021.03.001.
71. Eren T. Real-time Optimization of Drilling Parameters Using ROP Models. Middle East Technical University, 2010. 115 p.
72. Gidh Y., et al. A New ROP Model and Optimization Methodology for Carbonate Formations. *SPE/IADC Drilling Conference and Exhibition*. 2012. doi: 10.2118/151120-MS

73. Іванотчак, О. 2026. Розробка гібридної нейромережевої моделі CNN-LSTM для інтелектуальної оптимізації та раннього прогнозування ускладнень у процесі буріння НГС. Herald of Khmelnytskyi National University. Technical sciences. 363, 2 (Mar. 2026), 125–134. DOI:<https://doi.org/10.31891/2307-5732-2026-363-16>.
74. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016. 800 p.
75. Soares C., Gray K. Real-Time Predictive Capabilities of Machine Learning Models for ROP Optimization. Journal of Petroleum Science and Engineering. 2019. Vol. 172. P. 934–959. doi: 10.1016/j.petrol.2018.08.083.
76. Zhang Y., et al. A Hybrid CNN-LSTM Model for Real-Time Drilling Anomaly Detection. Journal of Natural Gas Science and Engineering. 2020. Vol. 80. Art. 103445. doi: 10.1016/j.jngse.2020.103445
77. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition. Proceedings of the IEEE. 1998. Vol. 86, no. 11. P. 2278–2324.
78. Noshi C. I., Schubert J. J. The Role of Machine Learning in Drilling Operations: A Review. SPE Western Regional Meeting (22–26 April 2018, Garden Grove, California, USA). SPE, 2018. doi: 10.2118/190075-MS.
79. Al-Azani K., El-Katatny S., Mahmoud M. Sequential Learning for Rate of Penetration Prediction Using Gated Recurrent Unit. Journal of Energy Resources Technology. 2019. Vol. 141, no. 7. Art. 072905. doi: 10.1115/1.4042845
80. Sainath T. N., et al. Convolutional, Long Short-Term Memory, Deep Neural Networks. 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2015. P. 4580–4584. doi: 10.1109/ICASSP.2015.7178838.
81. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980. 2014.

82. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 2014. Vol. 15, no. 1. P. 1929–1958.
83. Grewal M. S., Andrews A. P. *Kalman Filtering: Theory and Practice with MATLAB*. John Wiley & Sons, 2014. 640 p.
84. Savitzky A., Golay M. J. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*. 1964. Vol. 36, no. 8. P. 1627–1639. doi: 10.1021/ac60214a047.
85. Han J., Kamber M., Pei J. *Data Mining: Concepts and Techniques*. Morgan Kaufmann, 2011. 744 p.
86. Patro S., Sahu K. K. Normalization: A Preprocessing Stage. *IARCJ Journal of Computer Science and Engineering*. 2015. Vol. 2, no. 3. P. 20–22.
87. Grus J. *Data Science from Scratch: First Principles with Python*. O'Reilly Media, 2019. 412 p.
88. Іванотчак О., Кеденко І., Куліш С., Глібчук А., & Дмитренко С. (2024). Концептуалізація нейромоделей задач підтримки прийняття рішень. *Herald of Khmelnytskyi National University. Technical Sciences*, 335(3(1)), 78-87. <https://doi.org/10.31891/2307-5732-2024-335-3-11>
89. Hollingsworth J. L. WITSML: An Open Standard for Real-time Drilling and Logging Data. *SPE Intelligent Energy Conference and Exhibition (25–27 February 2008, Amsterdam, Netherlands)*. SPE, 2008. doi: 10.2118/112196-MS.
90. Іванотчак О. М., Мельник В. Д., Бандура В. В., Кутинський А. Я., Дмитрів І. Я., Іванців Н.Т., Дячук А. В., Місюрак Т. Я. Особливості задач класифікації на множині контенту в контексті реалізації індуктивного логічного програмування // «Інформаційні технології в освіті, техніці та промисловості»: Збірник наукових праць Всеукраїнської науково-практичної конференції молодих учених і студентів (м. Івано-Франківськ, 10 жовтня 2024р.), Івано-Франківськ, 2024. С.220-221 https://drive.google.com/file/d/1XrD-obOLO_MBz3DuotBYS4S7fKqycmFS/view

91. Cayeux E., Skadsem H. J., Daireaux B. Real-Time Evaluation of Drilling Performance and Hook Load Signals. *SPE Drilling & Completion*. 2014. Vol. 29, no. 03. P. 281–293. doi: 10.2118/167936-PA.
92. Chandola V., Banerjee A., Kumar V. Anomaly Detection: A Survey. *ACM Computing Surveys*. 2009. Vol. 41, no. 3. Art. 15. doi: 10.1145/1541880.1541882.
93. Ansari A., et al. Machine Learning-Based False Alarm Reduction in Drilling Operations. *SPE Annual Technical Conference and Exhibition (21–23 September 2021, Dubai, UAE)*. SPE, 2021. doi: 10.2118/206126-MS.
94. Siraj M. S., et al. Alarm Management in the Process Industries: A Review of Current Practices and Future Trends. *Journal of Loss Prevention in the Process Industries*. 2015. Vol. 33. P. 132–154. doi: 10.1016/j.jlp.2014.11.018.
95. Myers R. H., Montgomery D. C., Anderson-Cook C. M. *Response Surface Methodology: Process and Product Optimization Using Designed Experiments*. 4th ed. Wiley, 2016. 856 p.
96. Chicco D., Warrens M. J., Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, and RMSE in regression analysis evaluation. *PeerJ Computer Science*. 2021. Vol. 7. Art. e623. doi: 10.7717/peerj-cs.623.
97. Kendall A., Gal Y. What uncertainties do we need in Bayesian deep learning for computer vision? *Advances in Neural Information Processing Systems*. 2017. Vol. 30. P. 5574–5584.
98. Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd edition. OTexts, 2021. 350 p.
99. Garcez A. S. D., Besold T. R., De Raedt L., et al. Neural-symbolic learning and reasoning: A survey and interpretation. *arXiv preprint arXiv:1711.03902*. 2017.
100. Morooka S. C., et al. An Expert System for Drilling Operations. *SPE Latin American Petroleum Engineering Conference (27–29 April 1994, Buenos Aires, Argentina)*. SPE, 1994. doi: 10.2118/26942-MS.

101. Arrieta A. B., et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*. 2020. Vol. 58. P. 82–115. doi: 10.1016/j.inffus.2019.12.012.
102. Endsley M. R. *Designing for Situation Awareness: An Approach to User-Centered Design*. 2nd ed. CRC Press, 2011. 420 p.
103. Rothenberg D. H. *Alarm Management for Process Control: A Best-practice Guide for Design, Implementation, and Use of Industrial Alarm Systems*. Momentum Press, 2009. 240 p.
104. Miller T. Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*. 2019. Vol. 267. P. 1–38. doi: 10.1016/j.artint.2018.07.007.
105. Adadi A., Berrada M. Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access*. 2018. Vol. 6. P. 52138–52160. doi: 10.1109/ACCESS.2018.2870052.
106. Лукін О. Ю. Генетичні типи і стадії нафтогазонакопичення в нафтогазоносних басейнах України. Київ : Наукова думка, 2010. 234 с.
107. Маєвський Б. Й., Євдощук М. І., Лозинський О. Ю. Нафтогазоносні провінції світу. Івано-Франківськ : ІФНТУНГ, 2002. 352 с.
108. О.М. Іванотчак, В.Д. Мельник, Д.І. Толочко, В.В. Бандура, Н.Т. Іванців, І.Я Дмитрів. Інтелектуальна діагностика та корекція керуючих впливів у багатоагентних системах для енергетики та нафтогазовидобувної галузі. Матеріали Всеукр. наук.-практ. конф. молодих учених і студентів «Інформаційні технології в освіті, техніці та промисловості», 09 жовтня 2025 р., Івано-Франківськ: ІФНТУНГ, 2025. – С.119-120. – DOI: <https://doi.org/10.5281/zenodo.17295363>
109. Abadi M., et al. TensorFlow: A System for Large-Scale Machine Learning. 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16). 2016. P. 265–283.
110. Chollet F. *Deep Learning with Python*. 2nd edition. Manning Publications, 2021. 504 p.

111. Shahriari B., et al. Taking the Human Out of the Loop: A Review of Bayesian Optimization. *Proceedings of the IEEE*. 2016. Vol. 104, no. 1. P. 148–175. doi: 10.1109/JPROC.2015.2494218.

112. Rasmussen C. E., Williams C. K. I. *Gaussian Processes for Machine Learning*. MIT Press, 2006. 248 p.

113. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 2017. Vol. 60, no. 6. P. 84–90. doi: 10.1145/3065386.

114. Іванотчак О. Новітні концептуальні основи реалізації методології та стратегії інтелектуальної підтримки прийняття рішень в процесі буріння нафтогазових свердловин в Україні. *Herald of Khmelnytskyi National University. Technical Sciences*, 361(1), 175-183. <https://doi.org/10.31891/2307-5732-2026-361-23>

115. Іванотчак О. Експериментальні результати та валідація моделей Інтелектуальної системи підтримки прийняття рішень (ІСППР) у процесі буріння нафтових свердловин. *Вчені записки ТНУ імені В.І. Вернадського. Серія Технічні науки*, №6 за 2025, <https://doi.org/10.32782/2663-5941/2025.6.2/21>

116. Іванотчак О., Мельник В., Бандура В., Петришин Р., Глібчук А., Дмитренко С. Особливості інноваційних методів мультиагентного управління комп'ютерними мережами. Міжнародна науково – практична конференція «Інформаційні технології та комп'ютерне моделювання» ІТСМ-2024, 21-24 травня 2024р., Івано-Франківськ, С.162-165 <https://journal.comp-sc.if.ua/test/index.php/ITCM/article/view/595/39>

117. Thorogood J. L., et al. Real-Time Decision Making — The Next Step in Drilling Automation. *SPE Intelligent Energy Conference and Exhibition (24–26 May 2016, Aberdeen, UK)*. SPE, 2016. doi: 10.2118/178822-MS.

118. Power D. J. *Decision Support Systems: Concepts and Resources for Managers*. Greenwood Publishing Group, 2002. 272 p.

119. Kleppmann M. *Designing Data-Intensive Applications: The Big Ideas Behind Reliable, Scalable, and Maintainable Systems*. O'Reilly Media, 2017. 616 p.

120. Fowler M. Patterns of Enterprise Application Architecture. Addison-Wesley Professional, 2012. 560 p.

ДОДАТКИ

ДОДАТОК А
Ілюстративні та табличні матеріали до розділу 1 «Сучасні реалізації комп'ютерних систем моніторингу та контролю параметрів процесу буріння свердловин»

Таблиця А.1 – Консультативні системи та їх основні можливості

Консультативна система	Основні можливості системи	Метод виявлення проблеми	Доступ до даних та звітність
Гібридна система консультування з буріння на основі машинного навчання та фізики	Комп'ютерна підтримка аналізу даних на буровому майданчику та надання рекомендацій щодо буріння. Досягнення оптимальної швидкості проходки при роторному бурінні без пошкодження інструментів, вибійних двигунів, РКС, бурових доліт і т.д.	Виявлення несправностей буріння значною мірою досягається за допомогою алгоритмів розпізнавання образів, що використовують дані, зібрані на поверхні. Система відстежує такі порушення процесу буріння, як завихрення, відскок долота, стрибкоподібний рух, повне застрявання, порушення роботи автоматичного бурильника та заклинювання двигуна.	Для кожної виявленої несправності бурильнику надаються текстові рекомендації щодо дій для її усунення. При необхідності, функція корекції несправності також відображається у вигляді інтуїтивно зрозумілих візуальних підказок, які підказують бурильникові, яка зміна експлуатаційних параметрів буде ефективною.
Консультативна система з динаміки буріння (Drilling Dynamics Advisory)	Система розроблена для оптимізації продуктивності буріння шляхом аналізу та управління динамічними параметрами буріння. Проактивно керуючи динамікою буріння Drilling Dynamics Advisory допомагає скоротити непродуктивний час та продовжити термін служби бурового обладнання. За допомогою ідентифікації несправностей консультативна система виявляє конкретні проблеми, такі як стрибкоподібний рух, високочастотні крутильні коливання, відскок долота та завихрення – несправності, які можуть погіршити продуктивність та призвести до дорогого пошкодження обладнання.	Аналіз вібрацій у реальному часі за допомогою вибійних датчиків (акселерометрів, магнітометрів) у поєднанні з поверхневими вимірюваннями. Система класифікує рівень вібрацій за чотирма категоріями ризику (низький, середній, високий, критичний) та використовує гібридний підхід машинного навчання і фізичних моделей для прогнозування передаварійних ситуацій. Виявлення stick-slip здійснюється через аналіз відхилення вибійної швидкості обертання від поверхневої.	Візуалізація даних у реальному часі через інтерактивні інформаційні панелі (dashboards) з індикаторами рівня ризику. Графічне відображення осьових, бічних та крутильних вібрацій з глибинною прив'язкою. Система генерує автоматичні сповіщення при перевищенні порогових значень та надає рекомендації щодо оптимізації ваги на долото (WOB) та частоти обертання (RPM).
Система консультування по скерованому бурінню (Directional	це інтелектуальний інструмент, що забезпечує виконання ADD в реальному часі, приймає та координує всі рішення щодо управління	Моніторинг траєкторії та зворотного зв'язку від RSS через систему телеметрії MWD у реальному часі. Система порівнює планову	Система використовує гібридний підхід стратегій машинного навчання, що об'єднує історичні дані із

<p>Drilling Advisor – DDA)</p>	<p>бурінням (визначає необхідні низхідні канали зв'язку, які мають бути відправлені в свердловинний RSS-інструмент, та параметри керування, яким має слідувати система керування інструментом; відстежує зворотний зв'язок від RSS-інструменту через висхідні dpoints (точки даних, що передаються вгору по свердловині RSS-інструментом через систему телеметрії вимірювань у процесі буріння), щоб визначити, чи потрібно змінити рішення з управління бурінням, і при необхідності відправити відповідні коригуючі дії. Вона безперервно аналізує план буріння та динамічно оновлює команду для підтримки точності траєкторії.</p>	<p>траєкторію з фактичними даними інклінометрії та азимуту, виявляє відхилення від заданого коридору буріння. Використовує алгоритми Model Predictive Control (MPC) для прогнозування поведінки свердловини та автоматичного визначення необхідних коригуючих дій</p>	<p>фізичною моделлю. Збір історичних даних (для відповідних КНБК). З конвеєра даних вхідні дані передаються у фізичну модель, яка надає прогноз відгуку системи управління. Одночасно отримуються фактичні виміри DLS пробуреної свердловини з даних геофізичних досліджень та розраховується залишкова похибка.</p>
<p>Система моніторингу і управління та консультування з питань буріння свердловин (BAMS)</p>	<p>Відкалібрована з використанням даних у реальному часі система BAMS дозволяє проводити оцінку стану свердловини, прогнозування висоти шару бурового шламу та надання рекомендацій щодо очищення свердловини, порівняння польових та модельних значень ECD та даних RCRR, а також зображення бурового шламу та осипів. Система забезпечує безперервний цифровий моніторинг критичних параметрів буріння з метою оптимізації очищення стовбурів ERD-свердловин.</p>	<p>Проактивний підхід до моніторингу дозволив швидко вживати заходів, що коректують, при виявленні обвалів або нестабільності стовбура свердловини, забезпечуючи буріння без простоїв.</p>	<p>Зв'язок із буровою бригадою здійснюється за допомогою щоденних звітів та участі у щоденних нарадах на буровій установці, включаючи прогнозування густини бурового розчину на основі траєкторії свердловини, моніторинг IP3</p>
<p>Система консультування по бурових розчинах (Fluids Advisor)</p>	<p>Система відіграє ключову роль забезпеченні оптимальних характеристик бурових розчинів. Вона забезпечує відповідність та сталість властивостей розчинів проєктним специфікаціям, постійно порівнюючи дані в режимі реального часу із заданими у DDP лімітами. Система допомагає оперативно виявляти та усувати відхилення, оптимізуючи бурові роботи та підтримуючи</p>	<p>Система використовує штучні нейронні мережі (ІНС) як моделі машинного навчання. Дані, необхідні для моделювання в системі рекомендацій бурових розчинів, включають повний склад бурового розчину, а також його властивості, виміряні відповідно до API-13. Двома джерелами даних, що використовуються для навчання моделей системи,</p>	<p>зберігає оновлені характеристики та властивості бурового розчину, надаючи зацікавленим сторонам доступ до даних у режимі реального часу. Система також генерує щоденні звіти бурового розчину для включення в щоденний звіт буріння.</p>

	стійкість стовбура свердловини та істотно скорочуючи непродуктивний час (NPT).	є лабораторні експерименти та попередні лабораторні випробування/аналізи бурових розчинів, приготованих за відомою рецептурою.	
Консультант з питань бар'єрів (Barrier Advisor, Halliburton)	Рішення засноване на машинному навчанні та кластерному підході, шляхом аналізу історичних даних дозволяє візуалізувати кращі проєктні рішення для успішного цементування свердловин шляхом оцінки індексу успішності цементування для мінімізації ризиків. Рекомендації моделі Barrier Advisor, що використовує поєднання науково обґрунтованих алгоритмів і моделей, що базуються на глобальних історичних даних про виконані завдання, більш ефективні у зниженні ризиків, пов'язаних з операційними невизначеностями, порівняно з моделями, специфічними для конкретних завдань.	Кластерний аналіз “найближчих сусідів” для ідентифікації подібних робіт на основі умов свердловини (глибина, тип порід, конфігурація обсадних колон тощо). Модель виявляє закономірності між проєктними рішеннями та результатами цементування на основі глобальної бази даних виконаних операцій. Постійне оновлення моделі з новими даними підвищує точність прогнозування та зменшує операційні невизначеності.	Інтеграція з платформою VIDA (Verified Integrated Design Application), що забезпечує доступ до глобальної бази даних цементувальних операцій. Візуалізація найкращих практик з подібних робіт по всьому світу. Система надає оцінку (score) для проєктного рішення та рекомендації щодо його покращення. Інженери можуть ідентифікувати, які конкретні рішення позитивно впливають на ймовірність успішного виконання операції.

Примітки. ¹Таблиця складена автором на основі інформації опублікованої у джерелах [10, 18, 21, 26, 28-33]. ²ERD – *Extended Reach Drilling*

Таблиця А.2 – Деякі AI-рішення для консультування і прийняття рішень з буріння

AI-рішення	Основні можливості та особливості	Джерело
i-AUTO	надає рекомендації щодо оцінки роботи АБП на основі п'яти аспектів корисності місії: 1) галузеві стандарти, 2) адаптивність до непередбачених сценаріїв, 3) безкомпромісна продуктивність у будь-яких умовах, 4) пріоритет аналітичних висновків над інформацією та 5) оптимальний рівень автономності. i-AUTO пов'язує бурові інженерні рішення із стратегіями оборони для систематичної оцінки АБП. i-AUTO орієнтована на забезпечення того, щоб комп'ютерні системи буріння могли підтримувати високий рівень продуктивності незалежно від умов навколишнього середовища та експлуатаційних проблем, що змінюються.	[8]
AI Drilling Agent	використовує навчання з підкріпленням для взаємодії із середовищем моделювання, навчаючись на основі зворотного зв'язку та покращуючи свої стратегії прийняття рішень з часом. Можливості генеративного ІІ додатково розширюють цей процес, дозволяючи агенту пропонувати інноваційні рішення та проактивно реагувати на складні завдання.	[42]
Drill Brain	Drill Brain — запатентоване рішення для консультування з питань буріння, яке оптимізує продуктивність буріння. Це масштабна	[43]

Таблиця А.3 – Розвиток і порівняння програмних архітектур для систем спорудження свердловин

Архітектура	Роки поширення	Особливості конфігурації	Переваги	Недоліки
Монолітна архітектура	1990–2010	Одна програма працює на комп'ютері користувача, а дані зберігаються в центральній реляційній базі даних, що доступна кільком користувачам.	Простота розгортання та налагодження; низькі початкові витрати; єдина кодова база спрощує тестування	Монолітні програми стикаються з обмеженнями ємності комп'ютера і вимагають локальної установки на комп'ютері кожного користувача, що ускладнює доступ.
Сервісно-орієнтована архітектура (SOA)	2000-2015	SOA розділяє програмне забезпечення на кілька сервісів, що взаємодіють через сервісну шину, при цьому, як і раніше, використовуючи центральну базу даних, загальну для всіх сервісів. SOA дозволяє запускати програму на виділених серверах, задовольняючи вищі вимоги	Веб-доступ дозволяє використовувати програму з будь-якої точки світу без локальної установки та без навантаження на обладнання користувача.	Складності в обслуговуванні та розгортанні (наприклад, розгортання оновлень вимагає одночасного оновлення всіх сервісів, що часто призводить до тимчасового простою сервісу та ризику відкату у разі збою оновлення).
Мікросервісна архітектура	2015- н.ч.	додаток розбивається на окремі сервіси, кожен з яких відповідає за певну галузь, а не фокусується на конкретному процесі чи функції. У межах своєї області мікросервіс надає всі необхідні функції для створення, зміни, обчислення, видалення або доступу до об'єктів, специфічних для даної області (наприклад, архітектури свердловини або мети). Ці функції містяться всередині мікросервісу та не використовуються спільно чи повторно іншими мікросервісами.	Кожен мікросервіс включає в себе власне локальне сховище, що усуває необхідність у центральній базі даних. Архітектура мікросервісів не накладає обмежень на складність об'єктів, специфічних для предметної області.	Порівняно з монолітними програмами, ключовим недоліком мікросервісів є затримка, що виникає при мережевій взаємодії. Також можуть спостерігатися надмірна зв'язаність між мікросервісами, загальна логіка та надмірно складна архітектура.

Хмарно-нативна архітектура	2018 – н.ч.	Архітектура, спроектована для хмарного середовища з використанням контейнеризації (Docker, Kubernetes). Підтримує автоматичне масштабування та CI/CD. Застосовується для цифрових родовищ та операційних центрів.	Еластичне масштабування; оплата за фактичне використання; глобальна доступність; швидке розгортання; інтеграція з ML/AI сервісами	Залежність від провайдера (vendor lock-in); вимоги до стабільного інтернет-з'єднання; складність міграції legacy-систем; витрати на трафік
Edge Computing архітектура	2019 – н.ч.	Обробка даних відбувається локально на буровому майданчику (edge-вузлах) з передачею лише агрегованих/критичних даних у хмару. Забезпечує автономну роботу при втраті зв'язку.	Мінімальна затримка (<10 мс); робота в офлайн-режимі; зменшення витрат на трафік; реальний час для критичних операцій	Обмежені обчислювальні ресурси на edge; складність оновлення ПЗ; потреба в спеціалізованому обладнанні; розподілене управління
Архітектура цифрового двійника	2022 – н.ч.	Віртуальна репліка фізичної свердловини/бурової установки з двонаправленою синхронізацією даних у реальному часі. Інтегрує IoT-сенсори, ML-моделі та 3D-візуалізацію.	Предиктивна аналітика; оптимізація буріння в реальному часі; симуляція сценаріїв «що-якщо»; скорочення NPT (непродуктивного часу)	Висока вартість впровадження; потреба у великих обсягах якісних даних; складність інтеграції з legacy-системами

Примітка. Таблиця складена автором на основі інформації опублікованої в джерелах [7, 34, 47- 53]

ДОДАТОК Б

Ілюстративні та програмні матеріали до розділу 4 «Реалізація та тестування комп'ютерної нейромережевої системи ППР у процесі буріння НГС»

Лістинг Б.1. Приклад JSON-запиту до API-методу передавання телеметричних даних

```
{ "source_id": "rig_01",  
  "sim_mode": "stable",  
  "points": [  
    { "ts": 1712572801,  
      "depth_m": 2450.2,  
      "wob_klbf": 18.6,  
      "rpm": 118.0,  
      "flow_in_lpm": 1820.0,  
      "spp_psi": 2415.0,  
      "hookload_klbf": 96.4,  
      "torque_kftlb": 8.7,  
      "rop_mph": 11.2},  
    { "ts": 1712572802,  
      "depth_m": 2450.4,  
      "wob_klbf": 18.9,  
      "rpm": 119.0,  
      "flow_in_lpm": 1825.0,  
      "spp_psi": 2420.0,  
      "hookload_klbf": 96.7,  
      "torque_kftlb": 8.9,  
      "rop_mph": 11.0  
  ]  
}}
```

Наведений фрагмент демонструє приклад вхідного JSON-запиту до backend-сервісу нейромережевої СППР, у межах якого до API передається ідентифікатор джерела даних, режим симуляції та пакет телеметричних точок для виконання чергового циклу аналізу.

Лістинг Б.2. Приклад JSON-відповіді API у штатному режимі функціонування

```
{ "state": "stable",  
  "confidence": 0.93,  
  "stability": 0.91,  
  "forecast": {  
    "rop_mph": 11.4,  
    "wob_klbf": 19.1,  
    "rpm": 120.0,  
    "spp_psi": 2430.0},  
  "actions": [  
    "Підтримувати поточні параметри буріння",  
    "Продовжити моніторинг стабільності режиму"],  
  "operator_message": "Режим буріння стабільний, критичних відхилень не виявлено."}
```

Наведений фрагмент демонструє приклад відповіді backend-сервісу у штатному режимі, за якого система визначає стабільний режим функціонування, формує прогнозні значення основних технологічних параметрів та надає оператору рекомендації щодо збереження поточного режиму буріння.

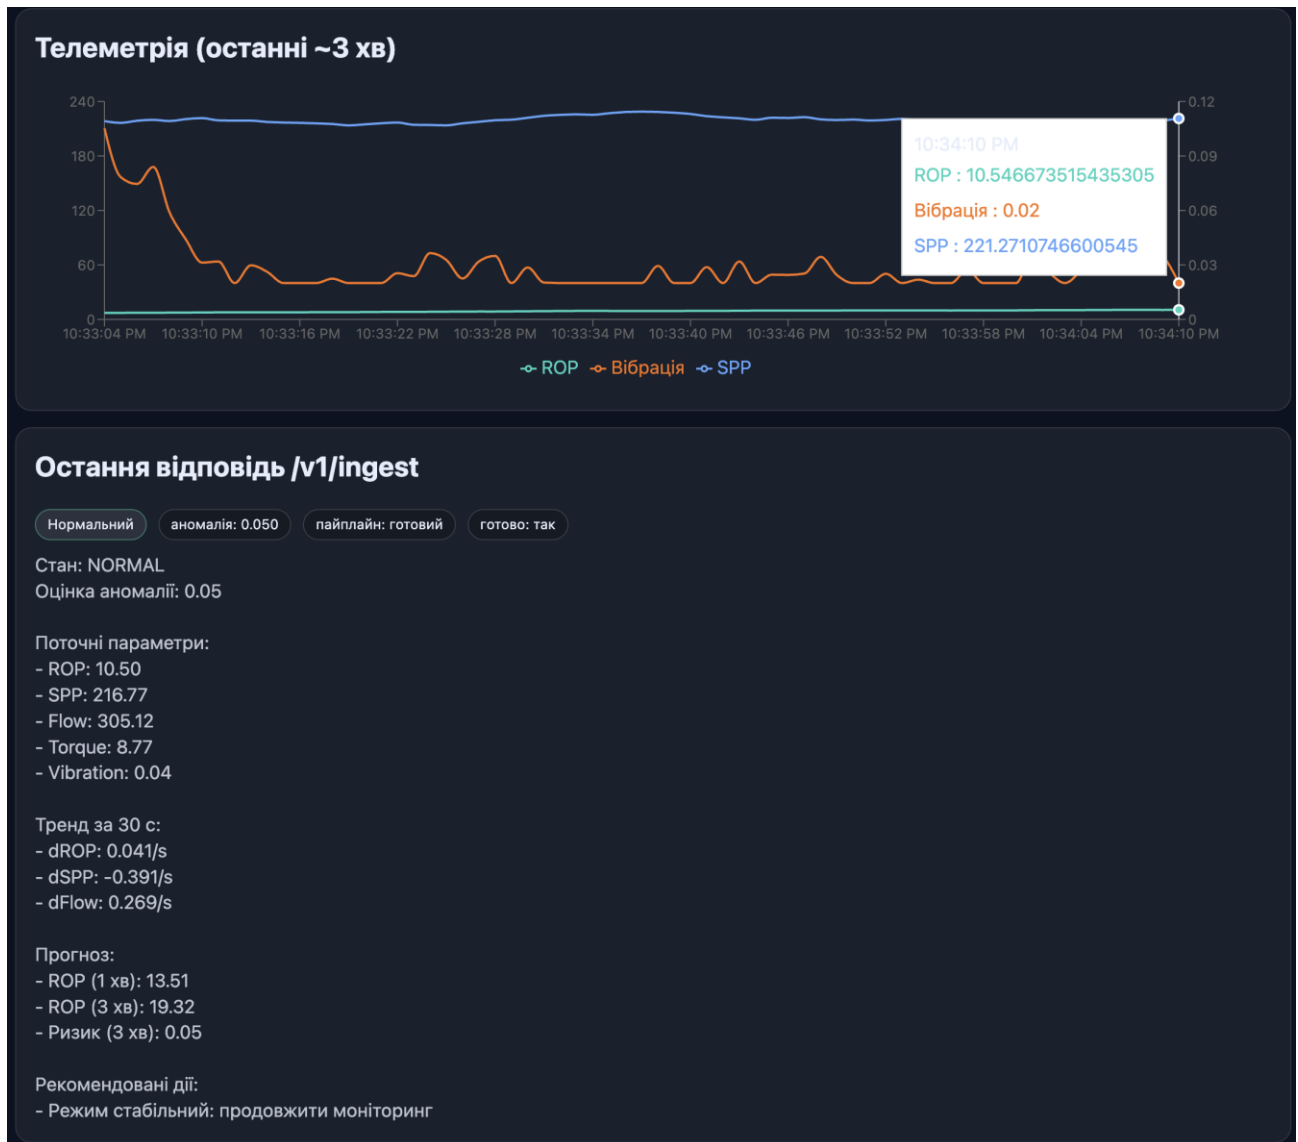


Рис. Б.1. Інтерфейс оператора нейромережевої СППР у стаціонарному режимі

Таблиця Б.1 – Основні тестові сценарії функціонування СППР

Сценарій	Характер вхідних даних	Очікувана реакція системи	Очікуваний статус рекомендації
Нормальний режим	Телеметричні параметри змінюються в межах штатного технологічного режиму, без різких стрибків і конфліктних значень	Коректне приймання даних, стабільний прогноз, відсутність ознак нестабільності, високий рівень довіри	normal / рекомендація зберігати поточний режим
Попереджувальний режим	Поступове зростання вібрацій, крутного моменту або навантаження на долото, локальне погіршення стабільності	Формування прогнозу з ознаками нестабільності, зниження рівня довіри, генерація попереджувального повідомлення	warning / рекомендація скоригувати RPM, WOB або інші параметри
Аварійний режим	Різкі або неузгоджені відхилення телеметричних параметрів, характерні для передаварійного або нештатного стану	Виявлення аномалії, суттєве зниження достовірності прогнозу, активація захисної логіки або обмеженого режиму	critical або warning / рекомендація негайної перевірки режиму
Некоректні або неповні дані	Відсутність частини обов'язкових параметрів, некоректний формат полів, порушення структури JSON-запиту	Відхилення запиту на етапі валідації або блокування формування нової рекомендації	invalid / службове повідомлення про помилку вхідних даних

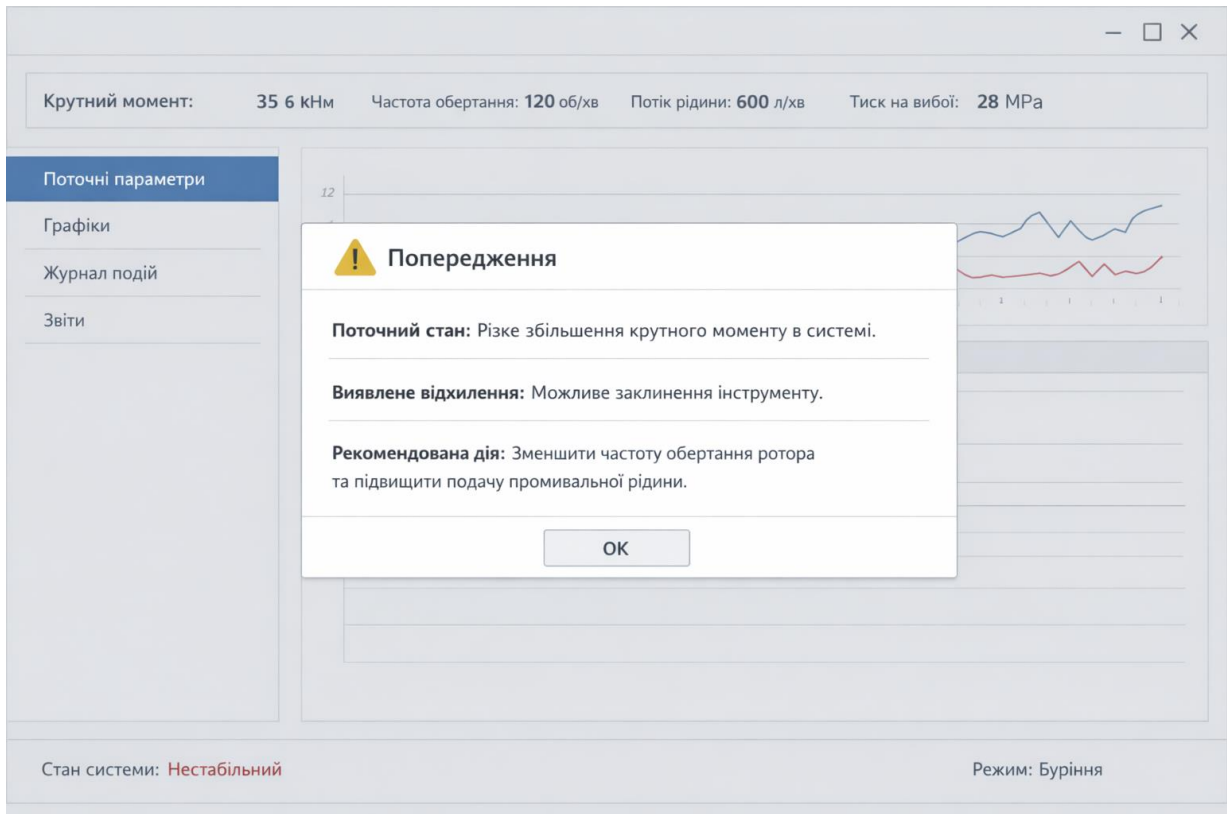


Рис. Б.2. Приклад відображення рекомендації в інтерфейсі оператора нейромережевої СППР

Таблиця Б.2 – Основні показники продуктивності API-сервісу СППР

Показник	Значення
Середній час відповіді API	96 мс
Медіанна затримка	84 мс
95-й перцентиль латентності	162 мс
Частка успішно завершених запитів	99,2 %
Пропускна здатність у стабільному режимі	8–12 запитів/с
Середній час нейромережевого інференсу	38 мс
Середній час постобробки та формування рекомендації	24 мс

Таблиця Б.3 – Відповідність реалізованих функцій системи ознакам нейромережевої СППР

Ознака системи підтримки прийняття рішень	Реалізація в розробленій нейромережевій СППР
Прийом і обробка вхідних даних	Прийом телеметричних параметрів буріння через API, валідація структури запиту, перевірка коректності полів та нормалізація значень

Формування інформаційного контексту	Побудова ковзного часового вікна з послідовності телеметричних вимірювань для подальшого аналізу
Аналітичне ядро системи	Нейромережевий інференс на основі гібридної CNN-LSTM моделі для прогнозування технологічного параметра
Оцінювання поточного стану режиму	Аналіз ознак стабільності, виявлення передаварійних або нестабільних режимів буріння
Оцінювання достовірності результату	Розрахунок показників довіри до прогнозу, індикаторів стабільності та службових станів
Формування рекомендації	Генерація текстової рекомендації щодо коригування параметрів буріння з урахуванням поточного режиму та рівня довіри
Подання результату оператору	Відображення прогнозу, індикаторів стану та рекомендації у frontend-інтерфейсі оператора
Супровід та контроль працездатності	Журналювання API-подій, контроль health/ready/status endpoint'ів, фіксація часу відповіді та службових метрик
Робота в умовах невизначеності	Перехід до консервативного режиму рекомендацій за зниження довіри або виявлення нестабільного стану
Завершений цикл підтримки рішення	Один цикл API-взаємодії відповідає завершеному акту аналізу, оцінювання та формування рекомендації для оператора

Таблиця Б.4 – Результати функціонального тестування системи у різних режимах буріння

№	Характер входних умов	Ключові аналітичні ознаки	Визначений режим	Сформована рекомендація	Оцінка коректності результату
1	Стабільні значення ROP, SPP та Flow, низький рівень вібрацій, відсутність різких коливань телеметрії	anomaly score ≈ 0.05 ; позитивний прогноз ROP; високий рівень стабільності	Нормальний	Продовжити моніторинг без зміни параметрів буріння	Коректно; система не формує зайвих втручань у штатному режимі
2	Зниження швидкості проходки за відносно стабільного тиску та помірних навантажень	ROP ↓; помірне зниження ефективності; anomaly score $\approx 0.20-0.30$	Неефективний	Скоригувати WOB, перевірити гідравлічні параметри та режим руйнування породи	Коректно; система виявляє втрату ефективності без переходу до аварійного сценарію
3	Підвищення вібрацій і нестійка динаміка телеметричних параметрів	Vibration ↑; ROP ↓; anomaly score ≈ 0.60 ; зниження інтегральної стабільності	Нестабільний	Зменшити RPM та WOB для зниження динамічних навантажень	Коректно; система формує попереджувальну стратегію реагування

4	Критичне зниження швидкості проходки, зростання тиску в стояку та високий рівень вібрацій	ROP ↓↓; SPP ↑; Vibration ↑↑; anomaly score ≈ 0.90–1.00; високий ризик	Критичний ризик	Утримати параметри в безпечних межах, перейти до діагностики циркуляції та перевірки бурового інструменту	Коректно; система переходить до консервативної безпечної стратегії
5	Недостатнє наповнення ковзного часового вікна телеметрії	collected < required; недостатність даних для інференсу	Аналіз відкладено	Продовжити накопичення телеметрії до заповнення вікна	Коректно; система запобігає передчасному формуванню рішення
6	Короткочасний одиничний сплеск вібрації без стійкого погіршення інших параметрів	Короткий пік вібрацій; відсутність стабільного негативного тренду; помірний рівень передаварійної ситуації	Нормальний / попереджувальний контроль	Посилити моніторинг без негайного коригування параметрів	Коректно; система не переходить до надмірно жорсткої реакції на одиничний сплеск

Таблиця Б.5 – Порівняльна характеристика процесу прийняття рішень до та після впровадження нейромережевої СППР

Характеристика процесу	До впровадження нейромережевої СППР	Після впровадження нейромережевої СППР
Джерело інформації для прийняття рішень	Поточні телеметричні показники, досвід оператора, регламентні інструкції	Поточні телеметричні дані, результати нейромережевого аналізу, прогнозні оцінки та сформовані рекомендації
Характер аналізу стану процесу	Переважно реактивний, за фактом відхилення параметрів	Проактивний, з урахуванням короткострокового прогнозу та раннього виявлення ознак нестабільності
Виявлення неефективних режимів	Залежить від досвіду оператора та може бути несвоєчасним	Алгоритмічне виявлення на основі аналізу часової динаміки параметрів
Виявлення нестабільних та передаварійних станів	Часто базується на запізній реакції після появи виражених відхилень	Виконується на основі оцінки аномальності, класифікації режиму та аналізу ризику
Оперативність реагування	Варіюється залежно від кваліфікації оператора та навантаження	Підвищується за рахунок автоматичного формування висновку та рекомендації в реальному часі

Узгодженість рішень	Можлива варіативність рішень для схожих ситуацій	Вища відтворюваність рішень за рахунок стандартизованої логіки оцінювання стану
Роль людського фактора	Висока залежність від індивідуального досвіду та суб'єктивної оцінки	Знижена за рахунок використання інтелектуальної підтримки прийняття рішень
Наявність прогнозної складової	Обмежена або відсутня	Реалізовано прогнозування ключових параметрів і попереджувальну оцінку ризику
Формування рекомендацій	Ручне, на основі практичного досвіду та нормативних підходів	Автоматичне, з урахуванням режиму, прогнозу та рівня ризику
Загальна характеристика процесу прийняття рішень	Реактивне оперативне керування	Інтелектуалізоване прогнозно-рекомендаційне керування

ДОДАТОК В

Фрагменти програмної реалізації та параметри навчання гібридної CNN-LSTM моделі

Лістинг В.1. Фрагмент реалізації структури гібридної CNN-LSTM моделі для класифікації режиму буріння та прогнозування ROP

```
import torch import torch.nn as nn
class CNNLSTMHybrid(nn.Module): def init(self, input_size, num_classes): super().init()
    # Згортковий блок для виділення локальних патернів у часовому вікні
    self.conv_block = nn.Sequential(
        nn.Conv1d(input_size, 32, kernel_size=3, padding=1),
        nn.ReLU(),
        nn.Conv1d(32, 64, kernel_size=3, padding=1),
        nn.ReLU(),
        nn.MaxPool1d(kernel_size=2),
        nn.Dropout(0.3),
    )

    # LSTM-блок для моделювання часових залежностей
    self.lstm = nn.LSTM(
        input_size=64,
        hidden_size=128,
        num_layers=1,
        batch_first=True,
    )

    # Гілка класифікації режиму буріння
    self.state_head = nn.Linear(128, num_classes)

    # Гілка регресії для прогнозу механічної швидкості проходки (ROP)
    self.rop_head = nn.Linear(128, 1)

def forward(self, x):
    # x: [batch_size, time_steps, features]
    x = x.transpose(1, 2) # -> [batch_size, features, time_steps]
    x = self.conv_block(x)
    x = x.transpose(1, 2) # -> [batch_size, reduced_steps, channels]

    lstm_out, _ = self.lstm(x)
    features = lstm_out[:, -1, :] # Останній часовий стан

    state_logits = self.state_head(features)
    rop_pred = self.rop_head(features)

    return state_logits, rop_pred
```

Наведений фрагмент демонструє реалізацію гібридної структури CNN-LSTM, у якій згорткові шари виконують виділення локальних просторово-часових патернів у межах ковзного вікна телеметрії, а рекурентний LSTM-блок моделює довготривалі часові залежності технологічного процесу. На виході моделі передбачено дві функціональні гілки: класифікацію поточного режиму буріння та регресійний прогноз механічної швидкості проходки.

Лістинг В.2. Фрагмент формування вхідного тензора для гібридної CNN-LSTM моделі на основі ковзного вікна

```
import numpy as np

def build_windows(data, labels, window_size=60, stride=1):
    x, y = [], []

    for i in range(0, len(data) - window_size, stride):
        window = data[i : i + window_size]
        target = labels[i + window_size - 1]

        x.append(window)
        y.append(target)

    x = np.array(x, dtype=np.float32)
    y = np.array(y)

    return x, y
```

Наведений фрагмент демонструє формування вхідної вибірки на основі ковзного часового вікна, у межах якого безперервний потік телеметричних даних перетворюється на послідовність навчальних прикладів для CNN-LSTM моделі. Кожне вікно містить фіксовану кількість послідовних вимірювань, що дає змогу враховувати часову динаміку технологічних параметрів у процесі буріння.

Таблиця В.1 - Основні параметри навчання гібридної CNN-LSTM моделі

Параметр навчання	Значення	Коротка характеристика
Оптимізатор	Adam	Забезпечує стабільну збіжність на шумних телеметричних даних
Початкова швидкість навчання (Learning Rate)	0.001	Базове значення для початкового етапу оптимізації
Розмір пакета (Batch Size)	64	Баланс між стабільністю градієнта та швидкістю навчання
Кількість епох (Epochs)	50	Достатньо для збіжності без надмірного перенавчання
Розмір часового вікна (Window Size)	60	Відображає короткостроковий контекст процесу буріння
Крок зсуву вікна (Stride)	1	Забезпечує щільне перекриття та безперервний моніторинг

Кількість фільтрів CNN	32, 64	Виділення локальних просторово-часових патернів
Розмір прихованого стану LSTM	128	Модельовання довготривалих часових залежностей
Коефіцієнт прорідження (Dropout)	0.3	Зменшення ризику перенавчання
Функція втрат	Комбінована (класифікація + регресія)	Одночасне навчання класифікації режиму та прогнозу ROP
Стратегія розділення даних	70% / 15% / 15%	Хронологічне розділення train / validation / test

У таблиці В.1 наведено основні параметри навчання гібридної CNN-LSTM моделі, використані для формування стабільного процесу оптимізації на часових рядах телеметричних даних буріння. Вибір конфігурації орієнтований на забезпечення збіжності моделі, збереження часового контексту та зменшення ризику перенавчання при роботі з багатопараметричними технологічними сигналами.

Лістинг В.3. Фрагмент навчального циклу гібридної CNN-LSTM моделі

```
def train_epoch(model, loader, optimizer, loss_cls_fn, loss_reg_fn, device):
    model.train()
    total_loss = 0.0

    for x_batch, y_state, y_rop in loader:
        x_batch = x_batch.to(device)
        y_state = y_state.to(device)
        y_rop = y_rop.to(device)

        optimizer.zero_grad()

        state_logits, rop_pred = model(x_batch)

        # Комбінована функція втрат для класифікації режиму та прогнозу ROP
        loss_cls = loss_cls_fn(state_logits, y_state)
        loss_reg = loss_reg_fn(rop_pred.squeeze(-1), y_rop)
        loss = loss_cls + 0.5 * loss_reg

        loss.backward()
        optimizer.step()

    total_loss += loss.item()
```

```
return total_loss / len(loader)
```

Наведений фрагмент (лістинг В.3) демонструє реалізацію одного навчального циклу гібридної CNN-LSTM моделі, у межах якого виконується пряме поширення сигналу, обчислення комбінованої функції втрат, зворотне поширення похибки та оновлення ваг моделі. Такий підхід дає змогу одночасно навчати класифікаційну гілку визначення режиму буріння та регресійну гілку прогнозування механічної швидкості проходки.

Таблиця В.2. Приклад динаміки train/validation метрик під час навчання гібридної CNN-LSTM моделі

Епоха	Втрати на навчальній вибірці (Train Loss)	Втрати на валідаційній вибірці (Validation Loss)	Точність на валідаційній вибірці (Validation Accuracy)	Середня абсолютна похибка прогнозу ROP (Validation MAE)
1	1.284	1.102	0.781	1.94
10	0.842	0.791	0.856	1.41
20	0.603	0.574	0.902	1.08
30	0.471	0.452	0.928	0.86
40	0.396	0.389	0.941	0.74
50	0.351	0.347	0.948	0.69

У таблиці В.2 наведено приклад динаміки основних train/validation метрик у процесі навчання гібридної CNN-LSTM моделі. Зменшення значень функції втрат на тренувальній і валідаційній вибірках, а також зростання точності класифікації та зниження середньої абсолютної похибки прогнозу ROP свідчать про стабільну збіжність моделі та достатню узгодженість між двома вихідними гілками — класифікаційною і регресійною.

Лістинг В.4. Фрагмент API-виклику для передавання телеметричних даних до backend-сервісу

```
// Файл: src/api/drilling.ts
```

```
import api from "./client";

export async function ingestTelemetry(payload: TelemetryPayload) {
  const { data } = await api.post("/ingest", payload);
  return data;
}

// Фрагмент виклику у компоненті сторінки
const handleSubmit = async () => {
  const result = await ingestTelemetry(formData);
  saveLastAnalysis(result);
};
```

Наведений фрагмент демонструє базову логіку взаємодії frontend-застосунку з backend-сервісом, у межах якої телеметричні дані передаються до API для виконання нейромережевого аналізу, а отриманий результат зберігається для подальшого відображення в інтерфейсі оператора.

Додаток Г
Акт впровадження результатів дисертаційного дослідження в навчальний процес кафедри ІІЗ ІФНТУНГ



МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ІВАНО-ФРАНКІВСЬКИЙ НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ
УНІВЕРСИТЕТ НАФТИ І ГАЗУ

вул. Карпатська, 15, м. Івано-Франківськ, 76019, тел./факс (0342) 54-71-39, тел. (0342) 54-72-66
E-mail: admin@nung.edu.ua, код ЄДРПОУ 02070855

№ _____
На № 519 від 18.03.2026

АКТ

**про впровадження у навчальний процес результатів дисертаційної роботи
аспіранта Іванотчака О.М.**

засвідчує, що результати дисертаційного дослідження Іванотчака О.М. на тему «Комп'ютерна нейромережева система підтримки прийняття рішень у процесі буріння нафтогазових свердловин» використані співробітниками кафедри інженерії програмного забезпечення факультету інформаційних технологій ІФНТУНГ при підготовці та викладанні дисципліни «Web-базовані інтелектуальні додатки та сервіси».

Впровадження отриманих за дисертаційною роботою Іванотчака О.М. результатів дослідження в навчальний процес підвищує якість підготовки студентів за спеціальностями 121 «Інженерія програмного забезпечення» та 123 «Комп'ютерна інженерія» оскільки відображає стан та перспективи розвитку наукових досліджень в Україні та світі.

В.о. декана факультету ІТ,
к.т.н., доцент

Завідувач кафедри ІІЗ,
к.т.н., доцент

Аспірант



Володимир ПІХ

Вікторія БАНДУРА

Олександр ІВАНОТЧАК

Додаток Д СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Наукові праці, в яких опубліковано основні наукові результати дисертації:

1. Іванотчак О., Кеденко І., Куліш С., Глібчук А., & Дмитренко С. (2024). Концептуалізація нейромоделей задач підтримки прийняття рішень. Herald of Khmelnytskyi National University. Technical Sciences, 335(3(1)), 78-87. **(Фахове видання України).**

2. Іванотчак О. Новітні концептуальні основи реалізації методології та стратегії інтелектуальної підтримки прийняття рішень в процесі буріння нафтогазових свердловин в Україні. Herald of Khmelnytskyi National University. Technical Sciences, 361(1), 175-183. **(Фахове видання України).**

3. Іванотчак О. Експериментальні результати та валідація моделей Інтелектуальної системи підтримки прийняття рішень (ІСППР) у процесі буріння нафтових свердловин. Вчені записки ТНУ імені В.І. Вернадського. Серія Технічні науки, Том 36(75) №6 за 2025, с.146-152. **(Фахове видання України).**

4. Іванотчак, О. 2026. Розробка гібридної нейромережевої моделі CNN-LSTM для інтелектуальної оптимізації та раннього прогнозування ускладнень у процесі буріння НГС. Herald of Khmelnytskyi National University. Technical sciences. 363, 2 (Mar. 2026), 125–134. **(Фахове видання України).**

5. Іванотчак О. М., Мельник В. Д., Бандура В. В., Кутинський А. Я., Дмитрів І. Я., Іванців Н.Т., Дячук А. В., Місюрак Т. Я. Особливості задач класифікації на множині контенту в контексті реалізації індуктивного логічного програмування // «Інформаційні технології в освіті, техніці та промисловості»: Збірник наукових праць Всеукраїнської науково-практичної конференції молодих учених і студентів (м. Івано-Франківськ, 10 жовтня 2024р.), Івано-Франківськ, 2024. С.220-221. **(Тези конференції).**

6. Іванотчак О., Мельник В., Бандура В., Петришин Р., Глібчук А., Дмитренко С. Особливості інноваційних методів мультиагентного управління комп'ютерними мережами. Міжнародна науково – практична конференція

«Інформаційні технології та комп'ютерне моделювання» ІТСМ-2024, 21-24 травня 2024р., Івано-Франківськ, С.162-165. **(Тези конференції).**

7. О.М. Іванотчак., В.Д. Мельник, Д.І. Толочко, В.В. Бандура, Н.Т. Іванців, І.Я Дмитрів, Інтелектуальна діагностика та корекція керуючих впливів у багатоагентних системах для енергетики та нафтогазовидобувної галузі. Матеріали Всеукр. наук.-практ. конф. молодих учених і студентів «Інформаційні технології в освіті, техніці та промисловості», 09 жовтня 2025 р., Івано-Франківськ: ІФНТУНГ, 2025. – С.119-120. **(Тези конференції).**