


Звіт подібності

Метадані

Назва організації		підрозділ		
Ivano-Frankivsk National Technical University of Oil and Gas		Каф. ІТТС		
Заголовок				
2025_Кисляк_П.П._ФІТ_ІТТС_АКСм-24-1				
Автор		Науковий керівник / Експерт		
Кисляк П. П.		Штаєр Л. О.		
Кількість слів	Кількість символів	Дата звіту	Дата редагування	ІД документу
13371	112320	12/22/2025	---	332947463


Обсяг знайдених подібностей

Коефіцієнт подібності визначає, який відсоток тексту по відношенню до загального обсягу тексту було знайдено в різних джерелах. Зверніть увагу, що високі значення коефіцієнта не автоматично означають плагіат. Звіт має аналізувати компетентна / уповноважена особа.



13371

Кількість слів








112320

Кількість символів

Тривога

У цьому розділі ви знайдете інформацію щодо текстових спотворень. Ці спотворення в тексті можуть говорити про МОЖЛИВІ маніпуляції в тексті. Спотворення в тексті можуть мати навмисний характер, але частіше характер технічних помилок при конвертації документа та його збереженні, тому ми рекомендуємо вам підходити до аналізу цього модуля відповідально. У разі виникнення запитань, просимо звертатися до нашої служби підтримки.

Заміна букв		2
Інтервали		0
Мікропробіли		3
Білі знаки		0
Парафрази (SmartMarks)		13

Джерела

Нижче наведений список джерел. В цьому списку є джерела із різних баз даних. Колір тексту означає в якому джерелі він був знайдений. Ці джерела і значення Коефіцієнту Подібності не відображають прямого плагіату. Необхідно відкрити кожне джерело і проаналізувати зміст і правильність оформлення джерела.

10 найдовших фраз

ПОРЯДКОВИЙ НОМЕР	НАЗВА ТА АДРЕСА ДЖЕРЕЛА URL (НАЗВА БАЗИ)	Колір тексту
		КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
1	https://repo.nung.edu.ua/bitstreams/d2a6800a-1c9a-489c-b7cc-94be0b4f44c4/download	53 0.40 %
2	https://lib-old.pnu.edu.ua/bitstream/123456789/4826/1/Monografy_last.pdf	39 0.29 %
3	https://lib-old.pnu.edu.ua/bitstream/123456789/4826/1/Monografy_last.pdf	35 0.26 %
4	2024_Горинський М.І._ІІТ_ІТТС_АКСм-23-1 12/22/2024 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. ІТТС)	23 0.17 %

5	https://zntu.edu.ua/sites/default/files/konf/dip_bvup_shablon_magistr.doc	23 0.17 %
6	https://repo.nung.edu.ua/bitstreams/d2a6800a-1c9a-489c-b7cc-94be0b4f44c4/download	21 0.16 %
7	https://repo.nung.edu.ua/bitstreams/4a5c4b45-6fc4-44a1-935b-bb8ed0d53efe/download	18 0.13 %
8	2024_Горинський М.І._ІІТ_ІТТС_АКСм-23-1 12/22/2024 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. ІТТС)	16 0.12 %
9	https://repo.nung.edu.ua/bitstreams/d2a6800a-1c9a-489c-b7cc-94be0b4f44c4/download	16 0.12 %
10	2024_Горинський М.І._ІІТ_ІТТС_АКСм-23-1 12/22/2024 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. ІТТС)	15 0.11 %

з домашньої бази даних (0.65 %)



ПОРЯДКОВИЙ НОМЕР	ЗАГОЛОВОК	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
1	2024_Горинський М.І._ІІТ_ІТТС_АКСм-23-1 12/22/2024 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. ІТТС)	54 (3) 0.40 %
2	2024_Гава А.П._ІІТ_ІТТС_АКСм-23-1 12/25/2024 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. ІТТС)	14 (1) 0.10 %
3	Магістерська_Пендерецький1.pdf 12/27/2021 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. КМБ)	14 (1) 0.10 %
4	2025_Ваврикович М.П._ФІТ_ІТТС_СІ-23-1К 6/13/2025 Ivano-Frankivsk National Technical University of Oil and Gas (Каф. ІТТС)	5 (1) 0.04 %

з програми обміну базами даних (0.08 %)



ПОРЯДКОВИЙ НОМЕР	ЗАГОЛОВОК	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
5	2024_126_mahistr_PrykhodchukVO_BaranovskyiSV.docx 12/18/2024 National University of Water and Environmental Engineering (National University of Water and Environmental Engineering)	11 (1) 0.08 %

з Інтернету (1.91 %)



ПОРЯДКОВИЙ НОМЕР	ДЖЕРЕЛО URL	КІЛЬКІСТЬ ІДЕНТИЧНИХ СЛІВ (ФРАГМЕНТІВ)
6	https://repo.nung.edu.ua/bitstreams/d2a6800a-1c9a-489c-b7cc-94be0b4f44c4/download	102 (4) 0.76 %
7	https://lib-old.pnu.edu.ua/bitstream/123456789/4826/1/Monografy_last.pdf	74 (2) 0.55 %
8	https://repo.nung.edu.ua/bitstreams/4a5c4b45-6fc4-44a1-935b-bb8ed0d53efe/download	28 (2) 0.21 %
9	https://zntu.edu.ua/sites/default/files/konf/dip_bvup_shablon_magistr.doc	23 (1) 0.17 %
10	http://eprints.library.odeku.edu.ua/6723/1/Averkina_A.O_Vprovadj_such_metodiv_M_2019.pdf	11 (1) 0.08 %
11	https://repo.nung.edu.ua/server/api/core/bitstreams/ac77b02f-91ae-4232-a608-31711b874861/content	11 (1) 0.08 %
12	https://repo.nung.edu.ua/bitstreams/830e0ac7-2a4b-4c35-bc56-c1fe0fa7d76e/download	7 (1) 0.05 %

Список прийнятих фрагментів

ПОРЯДКОВИЙ НОМЕР

ЗМІСТ

КІЛЬКІСТЬ ОДНАКОВИХ СЛІВ (ФРАГМЕНТІВ)

МАГІСТЕРСЬКА РОБОТА КРМ.АКСм-12.00.00.000 ¹¹ Група АКСм-24- 1 Петро КИСЛЯК 2025 Івано-Франківський національний технічний університет нафти і газу

¹ Кафедра інформаційно-телекомунікаційних технологій та систем

Спеціальність: 174 «Автоматизація, комп'ютерно-інтегровані технології та робототехніка»

Кисляк Петро Петрович
ім'я, по батькові)

УДК 621.317

(індекс)

МАГІСТЕРСЬКА РОБОТА

Інтелектуальна безсерверна система аналізу динамограм штангових глибинно-насосних установок з використанням AWS SageMaker
¹ (назва роботи)

Комп'ютеризовані системи управління та автоматика
(назва освітньої програми)

174 - Автоматизація, комп'ютерно-інтегровані технології та робототехніка
(шифр і назва спеціальності)

П.П. Кисляк
(підпис, ініціали та прізвище здобувача освітнього ступеня)

Науковий керівник Штаєр Л.О., доцент, канд.техн.наук
³ (прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

Допущено до захисту

Завідувач кафедри

проф. зав. каф. Заміховський Л.М.

⁶ (посада) (підпис) (дата) (ініціали та прізвище) Рецензент (посада) (підпис) (дата) (ініціали та прізвище) Робота містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело Івано-Франківськ 2025 рік

Івано-Франківський національний технічний університет нафти і газу

(повне найменування закладу вищої освіти) Інститут Факультет інформаційних технологій Кафедра Інформаційно-телекомунікаційних технологій та систем

Освітній рівень ¹ магістр

Спеціальність 174 - Автоматизація, комп'ютерно-інтегровані технології та робототехніка

(шифр і назва)

ЗАТВЕРДЖУЮ

Завідувач кафедри

Заміховський Л.М.

« » 2025 року ЗАВДАННЯ НА МАГІСТЕРСЬКУ

РОБОТУ СТУДЕНТОВІ

Кисляку Петру Петровичу

(прізвище, ім'я, по батькові) 1. Тема роботи Інтелектуальна безсерверна система аналізу динамограм штангових глибинно-насосних установок з використанням AWS SageMaker

керівник роботи Штаєр Л.О., доцент, канд.техн.наук

⁹ (прізвище, ім'я, по батькові, науковий ступінь, вчене звання)

затверджені наказом закладу вищої освіти від «30» жовтня 2025 року No 690/7

2. Строк подання студентом роботи 22.12.25

3. Дані зібрані під час проходження переддипломної практики: набір динамограм штангових глибинно-насосних установок, що відповідають різним технічним станам ШГНУ; параметри та результати попередньої обробки сигналів динамографування; навчальна, валідаційна та тестова

вибірки даних; конфігурація безсерверної інфраструктури на основі сервісів AWS SageMaker.

10. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити):

4.1 аналіз предметної області та сучасних технологічних рішень; _____

4.2 проєктування, реалізація та експериментальне дослідження системи; _____

4.3 інтеграція, експерименти та оцінка ефективності системи. _____

8. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень): _____

5.1 архітектура інтелектуально-безсерверної системи діагностування AWS; _____

5.2 зразки динамограм для оцінки станів ШГНУ; _____

5.3 етапи розробки та валідація нейронної моделі на базі ResNet-18. _____

8. Консультанти розділів роботи

Розділ Прізвище, ініціали та посада

консультанта Підпис, дата

завдання видав завдання прийняв

1-3 Штаєр Л.О. 7. Дата видачі завдання листопад 2024

6. КАЛЕНДАРНИЙ ПЛАН

№ з/п Назва етапів магістерської роботи Термін виконання етапів роботи Примітка

1 **Аналіз** предметної області, методів діагностування ШГНУ та існуючих систем моніторингу 04.11.2024 - 30.04.2025

2 Збір, підготовка динамограм та розробка моделі машинного навчання 01.05.2025 - 31.06.2025

3 Проєктування безсерверної архітектури системи на базі AWS 01.06.2025 - 31.08.2025

4 Інтеграція моделі, проведення експериментів та оцінка ефективності системи 01.08.2025 - 31.10.2025

5 Узагальнення результатів, оформлення та підготовка роботи до захисту 01.11.2025 - 15.12.2025

Студент _____ Кисляк П.П. _____
(підпис) (прізвище та ініціали)

Керівник роботи _____ **Штаєр Л.О.** _____
(підпис) (прізвище та ініціали)

РЕФЕРАТ

Штангові глибинно-насосні установки (ШГНУ) забезпечують понад 70% механізованого видобутку нафти в Україні та світі. Висока аварійність (обрив штанг, витіки клапанів, газове замикання) призводить до значних простоїв і витрат на ремонт. Традиційна діагностика за динамограмами є суб'єктивною та часозатратною. Розвиток хмарних технологій і машинного навчання дозволяє автоматизувати процес у реальному часі, зменшуючи втрати та оптимізуючи експлуатацію. Розробка інтелектуальної безсерверної системи на базі AWS SageMaker є актуальною для цифрової трансформації нафтогазової галузі.

Наукова новизна - полягає у розробці та експериментальному обґрунтуванні підходу до автоматизованої класифікації динамограм ШГНУ на основі глибоких згорткових нейронних мереж із подальшою інтеграцією моделі в безсерверну архітектуру AWS, що забезпечує масштабовану обробку даних у режимі, наближеному до реального часу.

Система забезпечує автоматизовану діагностику ШГНУ в реальному часі, зменшуючи простої та витрати на ремонт. Безсерверна архітектура AWS гарантує масштабованість, низькі витрати та легку інтеграцію з SCADA. Готовий inference-код і датасет дозволяють швидке впровадження на родовищах. Розробка підвищує надійність видобутку, сприяє оптимізації режимів і може бути адаптована для інших об'єктів нафтогазової галузі України.

АНОТАЦІЯ

Кисляк П.П. «Інтелектуальна безсерверна система аналізу динамограм штангових глибинно-насосних установок з використанням AWS SageMaker». Магістерська робота. - Івано-Франківськ: ІФНТУНГ. 2025. - 77 с. Рис.: 20. Табл.: 4. Бібліог.: 42.

Магістерська робота присвячена розробці інтелектуальної безсерверної системи для автоматизованого аналізу динамограм штангових глибинно-насосних установок (ШГНУ) з використанням хмарних сервісів Amazon Web Services та технологій машинного навчання.

У роботі проаналізовано предметну область діагностування ШГНУ, розглянуто фізичні принципи формування динамограм та сучасні методи їх інтерпретації. Виявлено обмеження традиційних підходів (трудомісткість, залежність від експертного досвіду) та обґрунтовано актуальність застосування глибинного навчання для класифікації станів обладнання.

Обґрунтовано вибір архітектури ResNet-18 з transfer learning як оптимальної для задачі класифікації зображень динамограм у безсерверному середовищі. Реалізовано адаптацію моделі до одноканальних зображень, навчання з аргументацією та регуляризацією, а також механізм оцінки ризику аварійних станів на основі вектора ймовірностей.

Запроєктовано багатозарову безсерверну архітектуру системи на базі сервісів AWS (S3, SageMaker, API Gateway), забезпечено підготовку артефактів для розгортання моделі та реалізацію інференсу. Через обмеження sandbox-акаунту виконано локальну емуляцію SageMaker Endpoint, що підтвердила працездатність повного циклу обробки запитів з формуванням JSON-відповіді.

Результатом роботи є готова до промислового впровадження інтелектуальна система, що забезпечує автоматизовану діагностику ШГНУ в реальному часі з високою масштабованістю та низькими експлуатаційними витратами.

Ключові слова: ШТАНГОВА ГЛИБИННО-НАСОСНА УСТАНОВКА, ДИНАМОГРАМА, МАШИННЕ НАВЧАННЯ, КЛАСИФІКАЦІЯ НЕСПРАВНОСТЕЙ, ХМАРНІ ОБЧИСЛЕННЯ.

ABSTRACT

The master's thesis is devoted to the development of an intelligent serverless system for the automated analysis of dynamometer cards of sucker rod pumping units (SRPUs) using Amazon Web Services cloud services and machine learning technologies.

The study analyzes the domain of SRPU diagnostics, examines the physical principles of dynamometer card formation, and reviews modern methods of their interpretation. The limitations of traditional approaches (labor intensity and dependence on expert experience) are identified, and the relevance of applying deep learning for equipment condition classification is substantiated.

The choice of the ResNet-18 architecture with transfer learning is justified as optimal for the task of classifying dynamometer card images in a serverless environment. The adaptation of the model to single-channel images, training with data augmentation and regularization, as well as a mechanism for assessing the risk of emergency conditions based on a probability vector are implemented.

A multilayer serverless system architecture based on AWS services (S3, SageMaker, API Gateway) is designed, providing preparation of deployment artifacts and implementation of inference. Due to sandbox account limitations, a local emulation of a SageMaker Endpoint was performed, which confirmed the operability of the complete request-processing cycle with the generation of a JSON response.

The result of the work is an intelligent system ready for industrial implementation, providing automated real-time diagnostics of SRPUs with high scalability and low operating costs.

Keywords: SUCKER ROD PUMPING UNIT, DYNAMOMETER CARD, MACHINE LEARNING, FAULT CLASSIFICATION, CLOUD COMPUTING.

ЗМІСТ

ВСТУП.....	9
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА СУЧАСНИХ ТЕХНОЛОГІЧНИХ РІШЕНЬ.....	12
1.1. ШГНУ як об'єкт діагностування.....	12
1.2. Способи діагностування стану ШГНУ за даними динамографа.....	20
1.3. Огляд існуючих систем моніторингу та діагностики ШГНУ.....	24
1.4. Постановка завдання на розробку.....	29
Висновки до розділу 1.....	30
2 ПРОЄКТУВАННЯ, РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ СИСТЕМИ.....	32
2.1. Збір та підготовка динамограм для діагностування стану ШГНУ.....	32
2.2. Визначення структури моделі машинного навчання для прогнозування стану.....	38
2.3. Проєктування структури автоматизованої системи діагностування фактичного стану ШГНУ на основі сервісів AWS.....	46
Висновки до розділу 2.....	49
3 ІНТЕГРАЦІЯ, ЕКСПЕРИМЕНТИ ТА ОЦІНКА ЕФЕКТИВНОСТІ СИСТЕМИ.....	51
3.1. Інтеграція моделі у безсерверну інфраструктуру та реалізація інференсу.....	51
3.2. Експериментальні дослідження: методика та набір даних.....	57
3.3. Результати та оцінка ефективності.....	61
Висновки до розділу 3.....	68
ВИСНОВКИ.....	70
СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	72

ВСТУП

Сучасна нафтогазова промисловість характеризується постійним ускладненням умов видобутку, зростанням глибини свердловин, старінням фонду обладнання та необхідністю підвищення ефективності експлуатації родовищ. Одними з найпоширеніших засобів механізованого видобутку нафти залишаються штангові глибинно-насосні установки (ШГНУ), які завдяки простоті конструкції та надійності широко використовуються на родовищах України та світу. Проте їх робота супроводжується численними відмовами, зниженням дебіту свердловини, втратою герметичності та іншими дефектами.

Для раннього виявлення таких несправностей широко застосовується аналіз динамограм, які відображають залежність навантаження на штангову колону від ходу полірованого штока протягом циклу роботи установки. Форма динамограми містить інформацію про фактичний технічний стан ШГНУ та дозволяє ідентифікувати типові режими роботи й аварійні стани.

Традиційний аналіз динамограм проводиться інженером вручну або з використанням локального програмного забезпечення. Проте цей процес є трудомістким, залежним від досвіду оператора і не забезпечує своєчасного виявлення аномалій у реальному часі. У зв'язку з розвитком технологій машинного навчання та хмарних обчислень виникає потреба у створенні інтелектуальної автоматизованої системи, здатної виконувати аналіз динамограм у безсерверному середовищі із високою масштабованістю та мінімальними витратами на інфраструктуру.

Одним із найперспективніших рішень для реалізації таких систем є AWS SageMaker, який забезпечує повний цикл розробки моделей штучного інтелекту - від підготовки даних до розгортання моделей у продакшн-середовище. У поєднанні з безсерверними сервісами AWS Lambda, Amazon API Gateway, Amazon S3, DynamoDB та інструментами Step Functions створюється можливість побудови системи, яка працює автономно, обробляє вхідні динамограми в реальному часі та видає висновки щодо технічного стану обладнання.

Мета роботи - розробка інтелектуальної безсерверної системи аналізу динамограм штангових глибинно-насосних установок із використанням AWS SageMaker.

Для досягнення мети необхідно виконати такі завдання:

1. проаналізувати принцип роботи ШГНУ та фізичну природу динамограм;
2. дослідити методи інтерпретації динамограм та існуючі системи моніторингу;
3. обґрунтувати вибір AWS-технологій та моделей машинного навчання;
4. розробити архітектуру безсерверної системи обробки динамограм;
5. реалізувати модель класифікації типових станів ШГНУ в AWS SageMaker;
6. **провести тестування системи та оцінити її ефективність.**

Об'єкт дослідження - процес діагностики технічного стану штангових глибинно-насосних установок.

Предмет дослідження - методи аналізу та класифікації динамограм із використанням машинного навчання та безсерверних хмарних технологій.

Методи дослідження - математичне моделювання, аналіз часових рядів, методи глибокого навчання та класифікації, експериментальні дослідження, хмарні технології AWS, мова програмування Python та сервіси AWS SageMaker.

Наукова новизна - полягає у розробці та експериментальному обґрунтуванні підходу до автоматизованої класифікації динамограм ШГНУ на основі глибоких згорткових нейронних мереж із подальшою інтеграцією моделі в безсерверну архітектуру AWS, що забезпечує масштабовану обробку даних у режимі, наближеному до реального часу.

Практичне значення - роботи полягає у можливості використання розробленої системи на промислових об'єктах для підвищення надійності експлуатації штангових глибинно-насосних установок, скорочення часу виявлення несправностей та зменшення витрат на технічне обслуговування обладнання.

Структура та обсяг кваліфікаційної роботи. Кваліфікаційна робота написана на 77 сторінках друкованого тексту, складається з вступу, трьох розділів, висновків, списку використаної літератури. Список використаної літератури включає 42 джерела.

1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА СУЧАСНИХ ТЕХНОЛОГІЧНИХ РІШЕНЬ

- ШГНУ як об'єкт діагностування

Штангові глибинно-насосні установки (ШГНУ) є одним із найпоширеніших засобів механізованого видобутку нафти з фонтануючих і слабо фонтанних свердловин. Штангове відкачування, також відоме як «балкове відкачування», забезпечує механічну енергію для підйому нафти з вибоїв свердловин на поверхню [1]. Воно ефективне, просте та легке в експлуатації для польових працівників, і може прокачувати свердловину до дуже низького тиску для максимізації дебіту нафти (рис. 1.1).

Рисунок 1.1 - Типова наземна частина ШГНУ

Штангове відкачування застосовується для вузьких свердловин, багаторазового закінчування, а також для високотемпературної та в'язкої нафти. Систему також легко замінити на інші свердловини з мінімальними витратами [1].

В Україні понад 70% фонду видобувних свердловин експлуатується із застосуванням ШГНУ, що зумовлює актуальність оптимізації їхньої роботи за допомогою інтелектуальних систем моніторингу.

ШГНУ призначені для механізованого видобутку рідини з свердловин, що втратили природний енергетичний потенціал. Порційний принцип роботи плунжерного насоса дозволяє ефективно експлуатувати свердловини з нерівномірним припливом, причому найкраща ефективність досягається в прямолінійних стовбурах з мінімальним тертям штанг [2].

ШГНУ складається з підземної (стовбурної) та наземної (поверхневої) частини (рис. 1.2) [2]:

1. підземна (стовбурна) частина - представлена колоною насосно-компресорних труб, які формують підймальний канал для продукції, та колоною штанг, що передає механічний рух до плунжера. Матеріал і діаметр штанг добирають за умовами навантаження, корозійності середовища та глибини підвіски насоса, щоб забезпечити достатній запас міцності та мінімізувати пружні деформації [2];
2. наземна (поверхнева) частина включає привід, редуктор і верстат-качалку, що перетворює обертальний рух двигуна на зворотно-поступальний рух полірованого штока. Балансир із противагами компенсує змінні навантаження штангової колони, зменшуючи пікові крутні моменти та енергоспоживання. На голівці балансира через сальниковий вузол забезпечується герметизація виходу полірованого штока, що критично важливо для безпечної роботи й запобігання втратам флюїду [2].

Глибинний плунжерний насос складається з циліндра, плунжера та двох зворотних клапанів - стоячого, що розташований у нижній частині насоса, і ходового, інтегрованого в плунжер [2]. Існують два основні варіанти конструкцій: вставний насос, який фіксується у спеціальному перевіднику в НКТ (насосно-компресорні труби) і зручний для оперативного підйому на штангах, та трубний насос, змонтований безпосередньо в НКТ, що вирізняється підвищеною герметичністю та жорсткістю вузлів. Вибір типу залежить від режиму експлуатації, доступності підймальних операцій, вимог до обслуговування та умов складності флюїду.

Рисунок 1.2 - Основні елементи типової глибинно-насосної установки [3]

Подача штангової установки визначається ходом, частотою та площею плунжера, але реальна зменшується через газоміст, стисливість і витоки; газові якорі/сепаратори знижують газову фракцію та підвищують коефіцієнт наповнення [3]. Нестационарні навантаження (вага штанг і стовпа рідини, інерція, тертя, гідроопір) діагностують динамограмами, а ККД (коефіцієнт корисної дії) обмежують механічні, об'ємні й гідравлічні втрати, які зменшують правильним добором матеріалів/зазорів, фільтрацією й газовідділенням, заходами проти абразиву, парафіну та корозії, інтелектуальним керуванням і регулярним моніторингом.

Для кращого розуміння принципу роботи та діагностування ШГНУ доцільно систематизувати основні компоненти установки та їх призначення.

Табл. 1.1 демонструє ключові елементи системи та їх функціональну роль, що дозволяє оцінювати вплив кожного з них на динамічні процеси та формування динамограм.

Таблиця 1.1 - Основні компоненти ШГНУ та їх призначення

Компонент	Опис
Станція управління	Контролює роботу електродвигуна та захищає від перевантажень
Електродвигун	Джерело енергії для установки
Редуктор	Зменшує швидкість обертання та збільшує крутний момент
Кривошипно-шатунний механізм	Перетворює обертальний рух на зворотно-поступальний
Балансир	Зрівноважує навантаження на штангову колону
Полірований шток	Передає зворотно-поступальний рух від балансира до штангової колони
Штангова колона	Передає рух від поверхні до плунжера насоса
Насосно-компресорні труби (НКТ)	Формують канал для підйому продукції зі свердловини на поверхню
Глибинний плунжерний насос	Основний робочий орган, який безпосередньо видобуває рідину
Стоячий (вхідний) клапан	Розташований у нижній частині насоса, забезпечує односпрямований потік рідини в робочу порожнину

Ходовий (вихідний) клапан Інтегрований у плунжер, пропускає рідину з-підплунжера в надплунжерний простір
Газовий якір (сепаратор) Знижує вплив газу на наповнення насоса, підвищує коефіцієнт наповнення
Трубопровід Канал для підйому рідини на поверхню

Принцип роботи базується на послідовності ходів угору та вниз. Під час ходу угору плунжер піднімається, ходовий клапан зачинений, а стоячий відкритий, тож рідина з під плунжерної зони заповнює робочу порожнину циліндра, водночас стовп рідини над плунжером витісняється в НКТ на поверхню. Під час ходу вниз стоячий клапан закривається, відкривається ходовий, і рідина з-під плунжера проходить крізь нього в надплунжерний простір, готуючи наступний цикл нагнітання. Безперервна череда цих циклів забезпечує порційний, але стабільний у середньому підйом продукції [3].

Енергія електродвигуна перетворюється ланцюгом механізмів, при цьому лише близько ~30-60% витрачається безпосередньо на підйом рідини; решта губиться у механічних, об'ємних і гідравлічних та гідродинамічних втратах (тертя штанг у криволінійних стовбурах, деформації, опір руху, витоки) [2]. Зменшення цих втрат - ключова мета оптимізації.

Однією з важливих діагностичних особливостей ШГНУ є наявність багатокомпонентної колони штанг, яка працює в умовах циклічного розтягування та стискання. Внаслідок цього навантаження передається уздовж колони не миттєво, а з певними деформаціями та запізненнями, що формує характерні хвильові процеси. Саме ці процеси дозволяють визначити такі несправності, як розрив штанг, часткове наповнення насоса, негерметичність клапанів або заклинювання плунжера, оскільки кожне з них залишає унікальний «підпис» на формі динамограми. Крім того, ШГНУ працюють в умовах зміни пластового тиску, в'язкості продукції, газового фактора, обводненості та температури, що впливають на навантаження і хід насоса. З цієї причини діагностування потребує врахування не лише механічних характеристик установки, а й гідродинамічних властивостей середовища. Зокрема, наявність газу може призвести до газового «замикання», що проявляється у зниженні ефективності наповнення насоса і характерній деформації верхньої частини динамограми [3].

Ще однією характерною ознакою ШГНУ як об'єкта діагностування є нерівномірність навантажень протягом циклу роботи. На початку ходу угору спостерігається максимальне навантаження, що обумовлене підйомом колони рідини та інерційними силами. У нижній точці ходу може виникати ударне навантаження, пов'язане з перемиканням клапанів. Сукупність цих факторів формує складний динамічний режим, який вимагає високої точності вимірювань та застосування алгоритмів машинного аналізу для достовірної інтерпретації сигналів [4].

7 Сьогодні відома значна кількість методів і засобів технічної діагностики ШГНУ для видобутку нафти. Серед них одні перевірені практикою, інші знаходяться на стадії впровадження або розробки. До останніх відносяться методи, що базуються на використанні складних математичних залежностей, які реалізуються мікропроцесорною технікою. Однак, на сьогодні відсутні загальноприйняті промислові методи та засоби технічної діагностики ШГНУ в процесі експлуатації, на що вказують багаточисельні аварійні ситуації, а також ситуації, пов'язані з обривом штангової колони. Методи діагностування ШГНУ можна представити у вигляді класифікації, наведеної на рис. 1.3 [4].

Як показано на рис. 1.3, всі методи можна умовно поділити на три групи: діагностичні методи, що базуються на аналізі динамограм; методи, які використовують ватметрограми та методи, що ґрунтуються на аналізі віброакустичних сигналів, які виникають під час роботи елементів ШГНУ, передаються вздовж колони штанг механічним каналом зв'язку та реєструються на гирлі свердловини [4].

Ватметрографічні методи розвиваються двома шляхами: через перерахунок ватметрограм у динамограми для використання методів аналізу динамограм і безпосередньо через аналіз кривих споживаної потужності, що дозволяє діагностувати дефекти наземного обладнання. Методи вібродіагностики використовують коливні процеси в ШГНУ як джерело інформації про технічний стан установки, забезпечуючи швидку реакцію на зміни та оперативне прийняття рішень у аварійних ситуаціях [4].

Особливістю ШГНУ як об'єкта діагностування є поєднання механічних, гідродинамічних та пружних процесів, що відбуваються у прихованому середовищі свердловини. Установка має нелінійну динаміку, значну інерційність та пружність елементів, тому навантаження передається вздовж колони штанг із деформаціями та запізненнями. Через ці діагностичні ознаки формуються як результат спільного впливу багатьох факторів, а зміни в роботі окремого вузла відображаються на всій системі [5].

Рисунок 1.3 - Класифікація методів діагностування ШГНУ [4]

Найінформативнішими параметрами діагностики є навантаження на полірованому штоку, форма F-s-петлі динамограми, вихід плунжера, коефіцієнт наповнення, споживана потужність та зміна крутного моменту. Механічні відмови (знос плунжера, негерметичність клапанів, обрив штанг) проявляються у зміні фази навантаження та геометрії динамограми. Гідродинамічні (газове замикання (gas lock), часткове наповнення, підвищена в'язкість) - у деформації окремих ділянок циклу [5]. Поверхневі несправності, як розбалансування або ударні навантаження, краще реєструються ватметрограмою та віброакустичними сигналами.

Діагностика ускладнюється впливом зовнішніх факторів: зміною пластового тиску, газового фактора, обводненості, температури та в'язкості флюїду. Ці чинники можуть маскувати або спотворювати ознаки технічних відмов, тому оцінка стану установки вимагає комплексного аналізу взаємодії приводу, колони штанги, глибинного насоса та умов роботи. Насправді ШГНУ можна розглядати як динамічну систему з кількома ступенями свободи, де втрати енергії та навантаження розподіляються по всій колоні [5, 6].

На ефективність діагностування штангових глибинно-насосних установок визначальний вплив мають такі параметри [5]:

1. глибина підвіски насоса;
2. довжина та діаметр штангової колони;
3. девіація стовбура свердловини;
4. газовий фактор;
5. властивість флюїду (в'язкість, обводненість);
6. режим роботи (хід та частота).

Таким чином, штангові глибинно-насосні установки є складним динамічним об'єктом діагностування через поєднання механічних, пружних і гідродинамічних процесів, нелінійність характеристик та значний вплив експлуатаційних факторів (глибина підвіски, газовий фактор, властивості флюїду тощо). Основними діагностичними сигналами є динамограми, які відображають навантаження на полірованому штоку протягом циклу качання та дозволяють виявляти більшість типових несправностей. Аналіз конструктивних особливостей і принципів роботи ШГНУ показав, що традиційні методи діагностування мають обмеження щодо швидкості та точності інтерпретації в умовах змінних режимів експлуатації. Це обґрунтовує необхідність розробки інтелектуальних систем на основі машинного навчання, здатних автоматизовано класифікувати динамограми та підвищувати оперативність і достовірність діагностики.

1.2 Способи діагностування стану ШГНУ за даними динамографа

Діагностика штангових глибоко-насосних установок (ШГНУ) переважно спирається на динамометричний метод, який дає змогу оцінити технічний стан обладнання за динамограмою - графічною залежністю навантаження на штанги від їх переміщення протягом робочого циклу насоса [5, 6]. Із розвитком цифрових технологій з'явилися як стаціонарні, так і портативні комп'ютеризовані комплекси збору даних, що забезпечують більш оперативну, автоматизовану обробку та інтерпретацію отриманих динамограм.

Динамограми представляють собою криві залежності навантаження на штанги від їхнього переміщення протягом циклу насоса, тому їх обробка включає попередню підготовку даних: нормалізацію, фільтрацію шумів та сегментацію на фази [6].

Динамографічний метод діагностування стану ШГНУ є одним із найбільш ефективних та інформативних способів оцінювання технічного стану штангових глибоко-насосних установок. Основні способи діагностування, які використовуються для аналізу динамограм, можна розділити на традиційні (візуально-експертні) та сучасні (автоматизовані, інтелектуальні).

Для отримання достовірної діагностичної інформації динамограми підлягають попередній обробці та аналізу. Основні методи включають [7]:

1. фільтрація та згладжування сигналу - усувають високочастотні шуми та коливання, що не відображають реальний робочий процес насоса;
2. сегментація циклів - виділення робочих і холостих фаз руху плунжера, що дозволяє оцінити ефективність підйому рідини на кожному циклі;
3. нормалізація сигналу - забезпечує порівняння фактичних динамограм із еталонними кривими для виявлення відхилень від нормального режиму;
4. виділення характеристичних ознак - визначення піків навантаження, площі петлі, асиметрії, співвідношення робочої та витратної роботи.

Ці параметри слугують ключовими критеріями для ідентифікації дефектів та оцінки ККД установки.

Попри високу інформативність, динамографічний метод має певні обмеження. Точність діагностики залежить від якості вимірювальних сигналів, рівня шумів та коректності калібрування датчиків. У випадках комбінованих дефектів інтерпретація динамограм ускладнюється, а експертний аналіз має суб'єктивний характер, що знижує відтворюваність результатів (рис. 1.4).

При оцінці стану ШГНУ враховують форму і площу динамопетлі, піки навантаження та симетрію за ходами, активну потужність і крутний момент у часі, частоту ходу SPM (Strokes Per Minute), фактичну подачу, коефіцієнт наповнення і ККД, тиск на вході насоса, газовміст, стан сальникового вузла та рівень вібрацій [7]. Кількісні пороги значення встановлюються внутрішніми регламентами, а якісні ознаки включають стабільність карт і відсутність аномальних піків.

Типові проблеми та експлуатаційні виклики полягають у тому, що в криволінійних (девійованих) свердловинах істотно зростають сили тертя й інтенсивність зношування насосних штанг. За наявності газу у продукції спостерігається зниження коефіцієнта наповнення насоса внаслідок утворення газових замків. Крім того, можливі порушення герметичності сальникового вузла, відмови або зношування клапанів насоса, а також розбалансування приводних механізмів. Ідентифікація зазначених несправностей здійснюється на основі комплексного аналізу динамометричних, ватметричних і вібраційних сигналів у поєднанні з технологічними параметрами роботи установки [7, 8].

У процесі діагностики використовуються два типи динамограм [9]:

1. поверхнева динамограма - формується за даними датчика сили та датчика переміщення на полірованому штоку;
2. підземна динамограма - показує сили безпосередньо на плунжері насоса та розкриває гідравлічну картину у циліндрі: наповнення, роботу клапанів, вплив газу і фактичний ефективний хід плунжера.

Поверхнева динамограма відображає характер взаємодії між приводом і штанговою колоною, показуючи, як змінюється навантаження на полірованому штоку протягом ходу. Вона дає змогу оцінити механічну рівномірність роботи установки, виявити дисбаланс, зношення елементів приводу чи порушення кінематики верстата-качалки.

Підземна динамограма не вимірюється безпосередньо, її формують шляхом математичної реконструкції за моделями хвильового переносу навантажень у колоні штанг. Така реконструкція дозволяє оцінити фактичну роботу плунжера, ступінь наповнення насоса та ефективність клапанного механізму.

Рисунок 1.4 - Динамограми для різних технічних станів ШГНУ [4]

Форма динамограми залежить від реальних умов роботи насоса. У нормальному режимі вона має замкнуту овальну форму [10], що відповідає правильному ходу плунжера та функціонуванню клапанів. Зміни у формі або площі динамограми свідчать про дефекти - негерметичність клапанів, поломку штанг, неповне наповнення насоса, тощо.

Типові форми динамограм та відповідні несправності із рис. 1.4 наведено у таблиці 1.2

Таблиця 1.2 - Основні типи динамограм

Тип динамограми	Характерна форма	Відповідний рисунок	Можлива несправність
Нормальна	Овальна, замкнута	-	Робота насоса справна
Часткове наповнення	Звуження в нижній частині	Низький динамічний рівень	Недостатній приплив робить петлю вузькою в нижній частині
Пропускання стоячого клапана	Зрив лінії в низу	Вітик в приймальній частині	Негерметичність призводить до провалу форми в нижній частині графіка.
Пропускання рухомого клапана	Деформація верхньої частини	Вітик в нагінатільній частині	Негерметичність рухомого клапана
Обрив штанг	Вертикальна лінія	Обрив штанг	Втрата зв'язку з плунжером
Газування	Зміщення петлі	Вплив газу	Наявність газу деформує петлю та зміщує її форму.

За даними динамограм інженер може обчислити корисну та витратну роботи насоса, оцінити ККД установки, визначити фактичну подачу, а також оцінити ступінь механічних втрат у колоні штанг [11]. Застосування відповідних математичних моделей дає змогу реконструювати навантаження на вибійний насос, що дозволяє більш точно визначити місце та характер несправності.

Сучасні підходи до діагностування вже не обмежуються візуальною інтерпретацією динамограм. Широке впровадження цифрових датчиків, хмарних платформ та методів машинного навчання значно розширило можливості аналізу [11, 12]. У системах контролю дедалі ширше використовуються методи машинного навчання та глибоких нейронних мереж, які класифікують форми динамограм, визначають приховані аномалії та автоматизують процес діагностування (рис. 1.5). Такі алгоритми здатні аналізувати великі масиви історичних даних, зменшувати

вплив шумів вимірювань і підвищувати точність виявлення характерних несправностей, що є важливим кроком до побудови інтелектуальних систем моніторингу ШГНУ.

Рисунок 1.5 - Схема, яка показує зв'язок між різноманітними галузями штучного інтелекту (ШІ), машинного та глибокого навчання [11]

Отже, динамографічний метод є ключовим інструментом діагностики ШГНУ. Комбінування традиційного аналізу, математичного моделювання та методів машинного навчання забезпечує комплексну оцінку технічного стану, дозволяє підвищити точність визначення несправностей, зменшити вплив людського фактора та закладає основу для побудови інтелектуальних систем моніторингу.

1.3 Огляд існуючих систем моніторингу та діагностики ШГНУ

Сучасні системи моніторингу та діагностики штангових глибинно-насосних установок (ШГНУ) спрямовані на підвищення ефективності видобутку нафти, зменшення простоїв обладнання та оптимізацію витрат на технічне обслуговування. Такі системи дозволяють у реальному часі контролювати параметри роботи насосів, виявляти дефекти та здійснювати прогнозування їхнього технічного стану. Основними завданнями цих систем є [13]:

1. забезпечення безперервного контролю параметрів роботи верстата-качалки та підземного насоса;
2. оперативне виявлення несправностей;
3. підвищення ефективності виробництва шляхом оптимізації режимів роботи;
4. формування динамограм та їх автоматизована інтерпретація.

Системи моніторингу можуть містити різний ступінь автоматизації - від традиційних локальних динамографів до інтелектуальних платформ з алгоритмами машинного навчання. Розвиток таких систем визначається появою хмарних платформ, штучного інтелекту та безсерверних архітектур, що дозволяє аналізувати великі масиви даних у режимі реального часу та виконувати прогнозовані обчислення [14].

Архітектурно системи моніторингу ШГНУ складаються з кількох шарів. На польовому рівні працюють датчики та виконавчі пристрої, що знімають ключові параметри з поверхневого привода і, за наявності, з підземної частини насоса. На рівні керування дані збираються контролерами свердловини, RTU (Remote Terminal Unit) або PLC (Programmable Logic Controller) [13, 14], а також інтегрованими регуляторами приводу, які виконують первинну фільтрацію, нормалізацію, базову діагностику та локальні алгоритми керування. Комунікаційний рівень забезпечує надійний зв'язок із центральними серверними або хмарними платформами через стільникові, радіорелейні та супутникові канали з використанням промислових протоколів.

На рис. 1.6 зображено типову багатшарову архітектуру сучасної системи моніторингу ШГНУ. Дані з польових датчиків (навантаження, переміщення, потужність) збираються локальними контролерами (RTU/PLC або Pump Off Controller), передаються через комунікаційні канали до SCADA-системи для візуалізації та базової обробки, а далі - до хмарної платформи для глибокої аналітики, машинного навчання та прогнозування. Така структура забезпечує масштабованість, віддалений доступ і інтеграцію інтелектуальних алгоритмів.

Рисунок 1.6 - Архітектура сучасної системи моніторингу ШГНУ

У промисловості активно використовуються SCADA-платформи, які забезпечують централізований контроль за станом ШГНУ. Серед них:

1. WellWatcher (Schlumberger) - система моніторингу родовищ, що збирає дані з сенсорів реального часу, використовуючи алгоритми машинного навчання для визначення дефектів [15];
2. Pump Off Controller (POC) - контролер, який входить до складу більшості сучасних систем керування ШГНУ (Allspeeds, Lufkin, Weatherford). Він регулює роботу приводу на основі аналізу динамограм, зупиняючи насос при «зриві подачі», або при перевищенні навантаження [16];
3. WellPilot (Weatherford) є інтегрованою системою керування, що поєднує POC, телеметрію та SCADA, забезпечуючи моніторинг у реальному часі, віддалене налаштування режимів і автоматичне формування попереджень про можливі збої [17];
4. Siemens WinCC / PCS 7 використовується для створення гнучких SCADA-рішень у системах нафтовидобутку, підтримує промислові протоколи (Modbus, OPC UA, MQTT) і може інтегруватися з хмарними платформами, такими як AWS IoT або MindSphere, для подальшого аналізу даних. [18].

У сучасних нафтогазових компаніях дедалі більшу роль відіграє перехід до хмарних технологій, які дозволяють централізовано обробляти великі обсяги телеметрії та зберігати історичні дані у масштабованих сховищах [19]. На відміну від локальних SCADA-комплексів, хмарні підходи дають можливість швидко інтегрувати аналітичні моделі, методи машинного навчання та сервіси прогнозування технічного стану обладнання.

Платформи на кшталт AWS [20], Microsoft Azure або Google Cloud пропонують інструменти для побудови розподілених аналітичних систем, що охоплюють увесь цикл опрацювання даних - від збору та фільтрації до деплою моделей і моніторингу результатів.

Одним із прикладів таких інструментів є сервіси екосистеми AWS, що використовуються у промисловій автоматизації для побудови гнучких безсерверних рішень [19]. До них належать засоби для обробки подій, організації API, підключення пристроїв інтернету речей та виконання короткоживучих функцій на вимогу. Крім того, у низці хмарних платформ доступні спеціалізовані сервіси для машинного навчання, які можуть забезпечувати автоматизований аналіз динамограм, виявлення аномалій або прогнозування відмов. Використання таких інструментів дозволяє будувати інтелектуальні системи діагностики, у яких значна частина обчислювальних процесів виконується автоматично, без постійного втручання інженера.

Попри широкі можливості традиційних і хмарних платформ, більшість наявних рішень усе ще не забезпечує повної автоматизації діагностики ШГНУ. Частина систем не підтримує інтеграцію з сучасними методами машинного навчання, а інші обмежені архітектурно й не дозволяють масштабувати аналіз на значну кількість свердловин. Саме це створює передумови для розроблення нових підходів, що поєднують телеметрію, аналітику та інтелектуальні алгоритми в єдину адаптивну систему.

Аналізуючи всі підходи, можна виділити ключові прогалини, які залишаються відкритими у сучасних системах ШГНУ [20, 21]:

1. недостатня інтеграція даних: датчики, полірований шток, POC, SCADA та хмарні сервіси часто працюють, як розрізнені модулі;
2. відсутність повноцінних прогностичних моделей: більшість рішень визначає наявну несправність, а не її наближення;
3. неврахування багатфакторності: частина систем аналізує лише динамограму, ігноруючи тиск, дебіт, температуру, характеристики пласта та приводного обладнання;
4. обмежена адаптивність моделей: SVM та CNN вимагають перенавчання при зміні глибин, діаметрів, плунжерів, характеристик пласта чи типу проводу;

5. недостатня кількість локальних рішень для України, що відповідають наявній інфраструктурі, формату телеметрії та особливостям свердловин.

Сучасні системи моніторингу та діагностики ШГНУ поєднують локальні динамографи, SCADA-платформи та інтелектуальні алгоритми для аналізу динамограм і телеметричних даних [19, 20, 21]. Вони забезпечують контроль роботи насосного обладнання, виявлення несправностей та оптимізацію режимів експлуатації. Застосування хмарних платформ, зокрема AWS, дозволяє автоматизувати обробку великих обсягів даних, інтегрувати алгоритми машинного навчання та прогнозування технічного стану обладнання.

Водночас існуючі рішення мають обмежену інтеграцію даних, недостатню підтримку багатofакторного аналізу та обмежену адаптивність моделей, що створює потребу у розробці нових інтелектуальних систем, здатних об'єднати телеметрію, аналітику та машинне навчання для ефективної діагностики та оптимізації роботи ШГНУ.

1.4 Постановка завдання на розробку

Метою даної роботи є розробка інтелектуальної системи моніторингу та діагностики штангових глибинно-насосних установок (ШГНУ) на основі сучасних безсерверних хмарних платформ та алгоритмів машинного навчання. Система повинна забезпечувати автоматизований збір, обробку та аналіз динамограм і телеметричних даних для виявлення несправностей, прогнозування технічного стану обладнання та оптимізації режимів роботи.

Завдання, які необхідно вирішити у процесі розробки, включають:

1. аналіз існуючих методів моніторингу та діагностики ШГНУ, визначення їхніх сильних та слабких сторін, а також виявлення прогалин, які можуть бути усунуті за допомогою інтелектуальних рішень;
2. проектування архітектури системи, що передбачає інтеграцію польових датчиків, контролерів свердловини та SCADA-платформ з хмарною обчислювальною інфраструктурою для централізованого збору та обробки даних;
3. розробка безсерверного рішення на базі хмарних сервісів (AWS), здатного автоматично обробляти великі масиви телеметричних даних, виконувати нормалізацію та попередню фільтрацію інформації;
4. імплементація алгоритмів машинного навчання для класифікації типів динамограм, виявлення аномалій, прогнозування відмов та визначення оптимальних режимів роботи насосного обладнання;
5. тестування та валідація системи на основі реальних або синтетично згенерованих динамограм, оцінка точності прогнозів та ефективності алгоритмів діагностики.

Для вирішення поставлених завдань використовуються методи системного аналізу, машинного навчання (transfer learning на базі ResNet-18), хмарних обчислень (AWS Lambda, S3, SageMaker) та експериментального тестування на реальних динамограмах.

Результатом виконання цих завдань має стати адаптивна інтелектуальна система діагностики ШГНУ, здатна працювати у промислових умовах, забезпечуючи підвищення надійності обладнання, зменшення простоїв та оптимізацію експлуатаційних витрат.

Висновки до розділу 1

У першому розділі магістерської роботи проведено комплексний аналіз предметної області діагностування штангових глибинно-насосних установок як складних технічних об'єктів з нелінійною динамікою та багатofакторним впливом експлуатаційних умов.

Встановлено, що динамографічний метод є одним із найбільш інформативних способів діагностування стану ШГНУ, оскільки форма динамограми відображає механічні та гідродинамічні процеси, що відбуваються в системі «привід - колона штанг - глибинний насос».

Проаналізовано основні типи динамограм та їх відповідність характерним несправностям, таким як часткове наповнення насоса, негерметичність клапанів, газове замикання та обрив штанг.

Розглянуто сучасні методи аналізу динамограм, включно з традиційними експертними підходами, математичним моделюванням та алгоритмами машинного навчання. Показано, що використання інтелектуальних методів дозволяє автоматизувати процес діагностики, зменшити вплив людського фактора та підвищити точність виявлення дефектів.

Проведений огляд існуючих систем моніторингу та діагностики ШГНУ показав, що більшість промислових рішень базуються на локальних контролерах і SCADA-платформах та мають обмежену інтеграцію з сучасними методами машинного навчання і хмарними технологіями. Виявлено низку недоліків, зокрема недостатню адаптивність моделей, обмежені можливості масштабування та відсутність повноцінного прогнозування технічного стану обладнання.

На основі виконаного аналізу сформульовано мету та завдання розробки інтелектуальної безсерверної системи моніторингу та діагностики ШГНУ з використанням хмарної платформи AWS та сервісів машинного навчання.

Отримані результати створюють теоретичне й методологічне підґрунтя для проектування, реалізації та експериментального дослідження системи, що буде виконано у наступних розділах магістерської роботи.

1. ПРОЄКТУВАННЯ, РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ СИСТЕМИ

- Збір та підготовка динамограм для діагностування стану ШГНУ

Якість функціонування інтелектуальної системи для визначення технічного стану штангових глибинно-насосних установок (ШГНУ) тісно пов'язана із характеристиками тренувального набору динамічних показників. Наявність у базі даних виключно «нормальних» сценаріїв чи недостатня кількість прикладів певних несправностей обмежує здатність моделі машинного навчання коректно ідентифікувати ці стани в процесі практичної експлуатації.

Сучасні динамометричні комплекси зазвичай представляють один цикл великою кількістю дискретних точок - кілька сотень, що дозволяє точно відтворити криву залежності «хід-зусилля» [22]. Інформація може передаватися:

1. у формі табличних документів (CSV, JSON), де кожний рядок відображає одну точку ходу;
2. у вигляді попередньо створених графічних малюнків (PNG, JPEG), отриманих контролером.

Щоб стандартизувати процес, у розробленому програмному забезпеченні вибрали формат CSV як основний для кожного окремого циклу. Файл повинен мати принаймні два стовпчики - Displacement (відносний хід) та Load (відносне зусилля), тоді як інші допоміжні параметри (налагодження, джерело інформації, вид дефекту) зберігаються у метаданих (JSON або запис Amazon DynamoDB), яка вказує на місцезнаходження файлу у сховищі [22].

Одразу після завантаження динамограм до сховища Amazon S3 розпочинається фаза попереднього опрацювання, яка реалізована за допомогою Python-скриптів, що працюють у SageMaker Processing Job або AWS Lambda. Ключові операції включають наступні:

1. контроль достовірності: видалення неповних циклів, повторів та явно неправильних даних;
2. видалення аномалій: усунення фрагментів із проблемними датчиками (нульове навантаження, блокування сигналу, імпульсні стрибки);
3. зменшення/пригнічення шуму: застосування фільтрів (ковзне середнє, Савицького-Голея) для пом'якшення високочастотних коливань;
4. стандартизація: приведення ходу та навантаження до уніфікованої частини або кількості точок, нормалізація для фокусування на формі динамограми;
5. маркування дефектів: визначення стану експертами або параметрами моделювання для синтетичних даних.

Важливо, щоб етапи попереднього опрацювання виконувались у фіксованому порядку: спочатку контроль цілісності й видалення очевидно некоректних циклів, далі усунення аномалій сенсора, після чого - згладжування та нормалізація. Оскільки частина дефектів проявляється у локальних піках і зламах кривої, параметри фільтрації слід підбирати так, щоб зменшувати високочастотний шум. Практично це означає необхідність візуального контролю вибірки «до/після» та збереження в метаданих параметрів фільтрів для подальшого аналізу впливу препроцесингу на якість класифікації.

Реальні промислові набори даних динамограм штангових глибинно-насосних установок (ШГНУ) є комерційно конфіденційними та практично недоступними для наукових досліджень. Водночас саме якість і репрезентативність навчальних даних визначають кінцеву точність та узагальнюючу здатність моделей глибинного навчання.

З метою подолання цієї проблеми в роботі розроблено та реалізовано оригінальний фізично обґрунтований генератор реалістичних динамограм, який синтезує зображення, що максимально наближені до реальних польових даних за формою кривої, характером шумів та візуальними артефактами.

При застосуванні ковзного середнього до динамограм зазвичай обирають розмір вікна від п'яти до п'ятнадцяти точок, щоб охопити кілька вимірювань у межах одного циклу насоса, при цьому не змиваючи важливі деталі сигналу. Менше вікно дозволяє зберегти локальні зміни, але слабко усуває високочастотний шум, тоді як більше вікно ефективніше згладжує шум, але може розмивати піки та платформи, критично важливі для діагностики [22].

Для побудови датасету було розроблено спеціалізований модуль, який автоматично створює зображення динамограм із високою варіативністю параметрів. Під час формування синтетичного набору динамограм важливо забезпечити одночасно достатню варіативність даних для навчання моделі та прийнятний час обчислень при тренуванні глибоких нейронних мереж. Синтез динамограм здійснюється у три етапи [22]:

1. формування ідеальної (безшумової) динамограми на основі класичної параметричної моделі навантаження-переміщення з урахуванням випадкової асиметрії ходу штока та довжини полірованих штанг;
2. моделювання дев'яти експлуатаційних станів і типових несправностей ШГНУ шляхом цілеспрямованої модифікації кривої навантаження:

- нормальний режим;
- газове перешкодження;
- часткове заповнення насоса;
- витоки в ходовому та стоячому клапанах;
- пружні удари;

1. обрив штанг;
2. перевантаження привода;
3. робота на мертвому ході.

Кожна несправність моделюється фізично обґрунтовано (зміщення нуля, зменшення амплітуди, поява імпульсних піків тощо);

3. додавання багатфакторних реалістичних деградацій сигналу та візуальних артефактів, що характерні для реальних систем телеметрії:

1. гаусівський шум (до 32 % від максимального навантаження);
2. високочастотний «дзвін» датчика;
3. дрейф нуля та повільний тренд;
4. імпульсні стрибки;
5. випадкове зміщення осей;
6. JPEG-стиснення з якістю 12-55;
7. імітація подряпин екрану та розмиття об'єктива;
8. випадкова зміна контрастності та яскравості.

Використання стиснення JPEG є одним із видів артефактів. У промисловому середовищі вимірювання потужності часто передаються не як необроблені дані вимірювань, а як скріншоти або графічні зображення екранів керування, систем SCADA або веб-інтерфейсів. Щоб зменшити обсяг переданих даних та пришвидшити обмін інформацією, такі зображення зазвичай зберігаються або передаються з використанням стиснення JPEG з різними рівнями якості.

На відміну від PNG, який є форматом без втрат і майже не викликає спотворень, стиснення JPEG створює характерні блоки та частотні артефакти, які впливають на геометричну структуру зображення. Моделювання таких артефактів у синтетичному наборі даних дозволяє підвищити надійність нейронної мережі до деградацій, типових для реальної телеметрії.

У результаті було згенеровано 1170 синтетичних динамограм розміром 224×224 пікселів, розподілених на три піднабори (рис. 2.1):

1. тренувальний (900 зображень, низький-середній рівень шуму);
2. валідаційний (135 зображень, середній рівень шуму);
3. тестовий (135 зображень, максимальний рівень шуму та артефактів).

Рисунок 2.1 - Використаний датасет для навчання та оптимізації моделі машинного навчання

Тестовий піднабір спеціально формувався з найвищим рівнем деградацій, що дозволяє об'єктивно оцінити стійкість розробленої моделі в умовах, максимально наближених до реальних родовищ.

Приклади згенерованих динамограм для кожного з дев'яти класів наведено на рис. 2.2:

1. нормальний режим - класична замкнута петля з рівномірними піками;
2. Газове перешкодження - коливання та зменшення амплітуди;
3. Часткове заповнення насоса - звуження нижньої частини петлі;

4. Витік у ходовому клапані - деформація та провал у верхній частині;
5. Витік у стоячому клапані - зрив лінії в нижній частині;
6. Пружні удари - імпульсні піки в точках перемикання;
7. Обрив штанг - втрата циклічності, майже вертикальна лінія;
8. Перевантаження приводу - асиметричне розширення петлі з підвищеними піками;
9. Робота на мертвому ході - різке падіння навантаження в нижній точці (fluid pound).

Приклади ілюструють високу реалістичність синтезу, що дозволяє ефективно використовувати набір даних для навчання моделей глибинного навчання.

Рисунок 2.2 - Приклади згенерованих динамограм для дев'яти класів стану ШГНУ при noise_level = 0

Таким чином, сформований синтетичний набір динамограм є репрезентативним, збалансованим за класами та різномірним щодо деградацій сигналу. Це забезпечує надійну основу для подальших етапів - навчання, оптимізації та експериментальної оцінки точності моделі в рамках запропонованої безсерверної системи аналізу динамограм.

- Визначення структури моделі машинного навчання для прогнозування

Далі необхідно створити модель машинного навчання, яка на основі форми динамограми прогнозуватиме поточний технічний стан ШГНУ та ризик переходу в аварійний стан. Враховуючи попередню обробку даних, задача визначається як багатокласова класифікація зображень динамограм (K=9), де кожен клас відображає конкретний стан або несправність (нормальна робота, газове перешкоджання, часткове заповнення насоса, витік клапанів, обрив штанг тощо).

Ризик переходу ШГНУ в аварійний стан оцінюється на основі вихідного вектора ймовірностей softmax. Класи, що відповідають критичним несправностям, агрегуються в групу аварійних станів, а сумарна ймовірність цієї групи використовується як інтегральний показник ризику. Такий підхід дозволяє не лише класифікувати стан, але й кількісно оцінювати ступінь небезпеки експлуатації установки [22, 23].

Для даного завдання найкраще підходить нейронна мережа з архітектурою CNN. Нормалізована траєкторія переміщення штока інтерполюється до заданої кількості точок (256), після чого будується графік «навантаження - переміщення», що зберігається як зображення у градаціях сірого кольору, розміром 224×224 пікселі.

На практиці динамограму можна подавати моделі як одновимірний сигнал «хід-зусилля» (послідовність точок) або як двовимірне зображення кривої. Перший підхід дає змогу застосовувати 1D-CNN/рекурентні або трансформерні моделі для часових рядів, однак вимагає окремої інженерії ознак та, як правило, менш уніфікованої інфраструктури для навчання й інференсу. Другий підхід уніфікує задачу до класифікації зображень, дозволяє напряму використати transfer learning і типові конвеєри SageMaker для image classification, а також збігається з тим, як інженер-діагност інтерпретує форму петлі «переміщення-зусилля». З огляду на вимоги до швидкого розгортання та передбачуваної затримки в безсерверному середовищі у роботі обрано саме представлення у вигляді зображень.

У цій дослідницькій роботі було вибрано перший варіант - представлення динамограм у вигляді зображень, оскільки це дозволяє застосовувати механізми трансферного навчання в Amazon SageMaker та готові контейнеризовані середовища навчання та інференсу для класифікації зображень. Більш того, саме форма кривої «переміщення - зусилля» є основним візуальним показником типу несправності для досвідчених фахівців, що робить такий метод представлення інформації інтуїтивно зрозумілим.

Для реалізації системи було обрано архітектуру ResNet-18, оскільки вона забезпечує оптимальний компроміс між точністю класифікації, швидкістю інференсу та обчислювальними витратами. У порівнянні з глибшими варіантами ResNet (ResNet-34, ResNet-50) дана модель має меншу кількість параметрів і, відповідно, нижчі вимоги до оперативної пам'яті та обчислювальних ресурсів, що є критичним для використання в безсерверній інфраструктурі [23].

Вибір ResNet-18 доцільно розглядати в контексті альтернативних архітектур для класифікації зображень: більш глибоких ResNet (34/50), EfficientNet, MobileNet та інших компактних моделей. Критерії вибору в межах задачі оперативного діагностування:

1. точність і повнота виявлення критичних дефектів;
2. стабільність навчання на відносно невеликому наборі;
3. затримка інференсу та чутливість до «холодного старту»;
4. обсяг параметрів і вимоги до пам'яті, що впливають на вартість та масштабованість. ResNet-18 обрана як збалансований варіант, що зменшує ризик перенавчання на обмеженій вибірці та спрощує експлуатацію в архітектурі з автоматичним масштабуванням.

ResNet-18 складається з 18 шарів, включаючи згорткові шари, шари активації ReLU та повністю зв'язані шари. Від CNN його відрізняє спосіб організації шарів. Моделі ResNet будуються з серії блоків, як показано нижче (рис. 2.3) кожен з яких містить два згорткові шари та швидке (пропускання) з'єднання [24].

Рисунок 2.3 - Будівельний блок залишкового навчання архітектури ResNet-18 [24]

Ці пропускані з'єднання дозволяють моделі пропускати шари під час прямого та зворотного поширення, допомагаючи зберегти інформацію та стабілізувати її під час навчання. ResNet-18 використовує простіші блоки (рис. 2.4), щоб бути обчислювально легшою та швидшою, зберігаючи при цьому переваги залишкового навчання [24].

Архітектури більшої глибини, хоча й здатні демонструвати високу точність на великих і різноманітних наборах даних, характеризуються збільшеним часом інференсу та вищою вартістю обробки, що не є доцільним для задач оперативного діагностування стану ШГНУ. Крім того, використання компактною моделі зменшує ризик перенавчання за обмеженого обсягу навчальних динамограм.

У порівнянні з сучасними сімействами EfficientNet, ResNet-18 має простішу структуру та стабільну поведінку під час розгортання в Amazon SageMaker Endpoint, зокрема при використанні CPU-інференсу або обмежених GPU-ресурсів [23, 24]. Це робить ResNet-18 більш придатною для безсерверного підходу, де ключовими вимогами є мінімальний час холодного старту, передбачувана затримка відповіді та ефективне автоматичне масштабування.

Рисунок 2.4 - Узагальнена структура моделі ResNet-18 для класифікації динамограм [25]

Щоб адаптувати ResNet-18 до задачі класифікації динамограм, були внесені наступні зміни:

1. вхідний згортковий шар перенаштовано на один канал (single-channel input) замість трьох (RGB), оскільки зображення динамограм є чорно-білими;
2. стандартний вихідний повнозв'язний шар замінено на шар із K виходами, де K - кількість класів стану, включно з класом «нормальний стан»;
3. поверх вихідного шару застосовано функцію активації softmax, що перетворює логіти на вектор ймовірностей належності до кожного класу. Навчання моделі здійснюється шляхом мінімізації функції перехресної ентропії. Для оптимізації параметрів використовується оптимізатор Adam з L2-регуляризациєю. З метою зменшення перенавчання у повнозв'язному шарі застосовано dropout. Для підвищення стабільності та збіжності процесу навчання використовується планувальник швидкості навчання StepLR (рис. 2.5).

Рисунок 2.5 - Лістинг підготовки моделі ResNet-18 до навчання

Гіперпараметри моделі, такі як кількість епох, розмір батчу, швидкість навчання, коефіцієнти регуляризації та параметри аргументації, задаються у конфігураційних файлах і передаються до SageMaker Training Job. Дані розділені на тренувальний (~70%), валідаційний (~15%) та тестовий (~15%) набори із збереженням співвідношення класів, що забезпечує коректну оцінку здатності моделі до узагальнення та запобігає зміщенню через дисбаланс класів [25].

Вибір гіперпараметрів доцільно виконувати на навчальному та валідаційному наборах, залишаючи тестовий набір недоторканим до остаточної оцінки. Як критерій вибору конфігурації слід використовувати не лише загальну асигуасу, але й насамперед метрики для критичних класів (зокрема такі, як grecall та F1), останній пропущений аварійний стан є більш небезпечним, ніж хибна тривога. Щоб запобігти перенавчання, варто фіксувати криві навчання (train/val loss), блокувати ранню зупинку або вибирати найкращу епоху для метрики валідації, а також документувати кінцеві значення гіперпараметрів в експерименті з конфігурацією.

Для тренувальної вибірки застосовуються незначні випадкові перетворення [25, 26]:

1. масштабування навантаження по вертикалі;
2. невеликі розтягнення або стискання по осі ходу;
3. додавання низькоамплітудного шуму;
4. зсув початку циклу вздовж осі ходу.

Важливо, щоб такі перетворення не змінювали топологію динамограми настільки, щоб вона набула ознак іншого класу, а лише імітували реальні варіації вимірювань.

Для кількісної оцінки якості класифікації використано стандартні метрики багатокласової класифікації [26]:

1. **accuracy** - частка правильно класифікованих динамограм:

де TP, TN, FP, FN - відповідно число істинно позитивних, хибнопозитивних та хибнонегативних передбачень;

2. precision для кожного класу - частка правильних спрацювань серед усіх прогнозів цього класу:

Precision = ; (2.2)

3. grecall - частка правильно виявлених динамограм певного класу **серед усіх реальних прикладів**:

4. f1-miqa - гармонійне середнє між precision і grecall, що дозволяє оцінити баланс між пропуском дефектів і хибними спрацюваннями:

Для аналізу точності класифікації в кількох класах побудована матриця неточностей (confusion matrix) а також macro- та weighted-усереднення precision/grecall/F1 [24]. Матриця неточностей дозволяє виявити «пари» класів, які модель плутає найчастіше (зокрема, близькі за формою режими), і на цій основі уточнювати генерацію даних, аргументації або політику порогів для аварійного ризику.

Навчання моделі здійснювалося протягом 10 епох (рис. 2.6), що було визначено експериментально як компроміс між досягненням стабільної збіжності функції втрат та запобіганням перенавчання на синтетичному наборі даних. Аналіз кривих навчання показав, що основне зростання точності та F1-міри на валідаційному наборі відбувається протягом перших 7-9 епох. Починаючи з 10-ї епохи темп покращення валідаційних метрик ставав мінімальним, а подальше збільшення кількості епох не призводило до статистично значущого підвищення якості, водночас збільшуючи розрив між train- та validation-loss.

З огляду на це кількість епох 10 була обрана як раціональна межа, що забезпечує достатню узагальнюючу здатність моделі та мінімізує ризик підлаштування до особливостей синтетичного набору динамограм.

Особливу увагу приділяють класам, що відповідають критичним станам (обрив штанг, витік клапанів, повне газове блокування), де допустимі значення grecall мають бути максимально високими, навіть за ціною деякого збільшення кількості хибнопозитивних спрацювань [24, 25]. Отримані результати класифікації можуть бути використані як в автоматизованих системах підтримки прийняття рішень, так і для інженерного аналізу оператором.

Рисунок 2.6 - Лістинг навчання моделі

Отже, у підрозділі визначено та обґрунтовано структуру моделі машинного навчання для багатокласової класифікації динамограм з метою діагностування технічного стану ШГНУ. Обґрунтовано вибір представлення динамограм у вигляді зображень і використання архітектури ResNet-18, яка забезпечує оптимальний компроміс між точністю, швидкістю інференсу та обчислювальними витратами в умовах безсерверної інфраструктури. Запропоновано підхід до оцінки ризику аварійних станів на основі вихідного вектора ймовірностей softmax із пріоритетом виявлення критичних режимів. Отримані результати створюють основу для подальшої інтеграції моделі в хмарну інфраструктуру AWS.

2.3 Проектування структури автоматизованої системи діагностування фактичного стану ШГНУ на основі сервісів AWS

На базі розробленої моделі класифікації динамограм сформовано автоматизовану безсерверну систему діагностування фактичного стану штангових глибинно-насосних установок, побудовану на сервісах Amazon Web Services. Основне призначення системи - забезпечити наскрізний цикл обробки динамограм: від надходження сирих даних з промислових об'єктів до формування інженеру діагнозу та рекомендацій у режимі, наближеному до реального часу.

Система побудована як послідовність логічних шарів, кожен з яких відповідає за конкретні завдання [27, 28]:

1. етап збору даних (Data Ingestion);
2. етап зберігання та обробки даних (Data Lake / Processing);
3. етап навчання та управління моделями (Model Training & Management);
4. етап інференсу та взаємодії з користувачем (Inference & Application);
5. рівень моніторингу та логування (Monitoring & Logging).

Для наочного подання взаємодії компонентів на рис. 2.7 подано структурну схему безсерверної архітектури системи діагностування: від польових контролерів до інтерфейсу інженера.

Розроблена архітектура системи діагностики ґрунтується на принципах AWS Well-Architected Framework і реалізує безсерверний підхід до збору, обробки та аналізу телеметрії від польових вимірювальних пристроїв. Такий підхід забезпечує масштабованість, надійність та мінімальні експлуатаційні витрати, оскільки всі елементи системи працюють у керованому хмарному середовищі [27, 28].

Рисунок 2.7 - Структурна схема безсерверної архітектури системи діагностування на AWS

Дані формуються польовими контролерами, серед яких можуть бути ПЛК, телеметричні модулі та різні сенсори. Передача телеметрії здійснюється через захищені HTTP(S) - запити, які отримує сервіс Amazon API Gateway. Він виступає шлюзом між обладнанням та хмарою, забезпечуючи автентифікацію, контроль доступу й базову фільтрацію даних.

Для підвищення безпеки системи впроваджено наступні механізми захисту даних та доступу [29, 30, 31, 32]:

1. IAM-ролі та політики - кожному сервісу (Lambda, SageMaker, API Gateway) призначено мінімально необхідні IAM-ролі з принципом найменших привілеїв. Наприклад, Lambda-функції мають права лише на читання/запис у визначені бакети S3 та таблиці DynamoDB, а SageMaker Endpoint - лише на доступ до моделі в S3;
2. Автентифікація та авторизація в API Gateway - для захисту ендпоінтів використано API keys або інтеграцію з Amazon Cognito. Це дозволяє обмежити доступ лише авторизованими польовими контролерами або IoT-пристроями, запобігаючи несанкціонованим запитам;
3. Шифрування даних - усі об'єкти в Amazon S3 зберігаються з увімкненим серверним шифруванням (SSE-S3 або SSE-KMS з ключами AWS KMS). Трафік між сервісами (HTTPS) та дані в DynamoDB також шифруються за замовчуванням.

Основна обробка виконується у функціях AWS Lambda (рис. 2.8), що автоматично запускаються для кожного вхідного пакета. Lambda реалізує валідацію, нормалізацію та структурування даних, готуючи їх до подальшої аналітики [30]. Завдяки serverless-моделі обчислення масштабуються відповідно до навантаження, а ресурси тарифікуються лише за фактичний час виконання.

Рисунок 2.8 - Приклад логіки обробки динамограми в AWS Lambda-функції

Оброблена інформація передається у дві ключові підсистеми. Перша - база даних Amazon DynamoDB, у якій зберігаються значення телеметрії, історія режимів роботи та результати діагностичних обчислень [31]. Друга - сервіс машинного навчання Amazon SageMaker, де відбувається інференс моделей класифікації або прогнозування технічного стану обладнання [32]. Повернуті моделлю результати знову передаються в Lambda та записуються у DynamoDB, утворюючи замкнутий цикл обробки діагностичної інформації. Для зберігання даних, моделей і артефактів навчання використовується Amazon S3 [33].

Інженери взаємодіють із системою через інтерфейси, що використовують дані з DynamoDB у режимі реального часу. Завдяки низьким затримкам і відсутності необхідності в управлінні серверами забезпечується швидкий доступ до актуальної діагностичної інформації.

Таким чином, завдяки безсерверній архітектурі та автоматичному масштабуванню ресурсів, система здатна обробляти великий обсяг телеметрії навіть у пік навантаження, зберігаючи стабільну продуктивність. Це забезпечує надійну та безперебійну роботу у реальних промислових умовах, де швидкий доступ до актуальної діагностичної інформації є критично важливим для прийняття рішень оператором.

Висновки до розділу 2

У другому розділі було послідовно розроблено повний технологічний цикл створення інтелектуальної системи діагностування фактичного стану штангових глибинно-насосних установок - від формування навчальної вибірки до побудови безсерверної архітектури, готової до промислового використання.

На першому етапі сформовано репрезентативний синтетичний набір динамограм, який охоплює дев'ять характерних режимів роботи та типових несправностей ШГНУ. Реалізовано фізично обґрунтований генератор, що моделює реалістичні ефекти роботи обладнання, шумові спотворення, артефакти телеметрії та деградацію сигналу в польових умовах. Проведено стандартизовану підготовку даних - валідацію, нормалізацію, маркування та поділ на підмножини у співвідношенні 900/135/135, що забезпечило баланс між варіативністю вибірки та ефективністю тренування нейронної мережі.

На другому етапі визначено та обґрунтовано структуру моделі машинного навчання. Задачу діагностування сформульовано як багатокласову класифікацію зображень динамограм (K=9). Обґрунтовано вибір архітектури ResNet-18 з transfer learning як оптимального компромісу між точністю, швидкістю інференсу та обчислювальними витратами в безсерверному середовищі. Виконано адаптацію моделі (вхідний шар для одноканальних зображень, вихідний шар з 9 нейронами, dropout) та описано процес навчання з аргументацією даних, регуляризацією та оцінкою за стандартними метриками (accuracy, precision, recall, F1).

На третьому етапі побудовано безсерверну архітектуру з використанням AWS Lambda для обробки вхідних динамограм, SageMaker Endpoint для інференсу та S3/DynamoDB для зберігання. Реалізована локальна емуляція повного циклу інференсу компенсує обмеження тестового акаунту та демонструє готовність системи до розгортання в production-середовищі.

Спроектовано багатозарову безсерверну архітектуру системи на базі сервісів AWS, що забезпечує захищений збір телеметрії, автоматичну обробку, інференс моделі та зберігання результатів з високою масштабованістю та низькими експлуатаційними витратами.

У наступному розділі наведено результати інтеграції розробленої моделі машинного навчання у безсерверну інфраструктуру AWS, а також результати експериментальної оцінки точності, стійкості та практичної ефективності запропонованої системи діагностування.

3 ІНТЕГРАЦІЯ, ЕКСПЕРИМЕНТИ ТА ОЦІНКА ЕФЕКТИВНОСТІ СИСТЕМИ

3.1 Інтеграція моделі у безсерверну інфраструктуру та реалізація інференсу

Інтеграція розробленої моделі класифікації динамограм у безсерверну інфраструктуру Amazon Web Services передбачала підготовку всіх необхідних артефактів для розгортання на SageMaker Endpoint, збереження результатів та реалізацію механізму інференсу, доступного у форматі, подібному до REST API. Основною метою було забезпечення повного циклу обробки запитів - від отримання зображення динамограми до повернення діагностичного висновку у стандартизованому JSON-форматі.

Спочатку навчена модель ResNet-18 була збережена у форматі state_dict під назвою best_resnet18.pth. Цей файл ваг моделі разом з кастомним inference-кодом було підготовлено до деплою відповідно до вимог SageMaker. Зокрема, створено архів model.tar.gz, який містив файл ваг на кореневому рівні та теку code з скриптом inference.py. Така структура архіву є стандартною для кастомного розгортання моделей у SageMaker і дозволяє контейнеру автоматично завантажити як вагу моделі, так і допоміжний код обробки запитів [34]. Архів було завантажено в бакет Amazon S3 за шляхом s3://c183728a4756948112911015f1w637423646-sandboxbucket-0i7euamtnqql/models/model.tar.gz, що забезпечує централізоване та надійне зберігання артефактів (рис. 3.1).

Рисунок 3.1 - Збереження навченої моделі ResNet-18 та її завантаження до сховища Amazon S3

У межах model_fn виконується [34]:

1. ініціалізація архітектури нейронної мережі ResNet - 18;
2. модифікація вхідного згорткового шару роботи з одноканальними зображеннями;
3. завантаження ваг із файлу моделі, розміщеного в каталозі, що передається SageMaker;
4. переведення моделі у режим оцінювання (eval).

Спроба розгортання endpoint виконувалася через SageMaker Python SDK з використанням класу PyTorchModel, де вказувалися шлях до архіву в S3, роль виконання, entry_point на inference.py та тип інстансу ml.m5.large. Під час виконання виникла помилка, пов'язана з відсутністю у ролі SageMakerExecutionRole дозволу BatchGetImage для завантаження офіційного контейнера PyTorch. Це обмеження типове для sandbox-акаунтів AWS, призначених для навчальних цілей, де користувачі не мають прав на модифікацію IAM-ролей або доступ до ECR.

Для забезпечення функціональності інференсу підготовлено спеціальний код inference.py [34,35], який реалізує ключові функції model_fn для завантаження та ініціалізації моделі, input_fn для обробки вхідних зображень (підтримка PNG/JPEG, grayscale, нормалізація) та output_fn для формування JSON-відповіді з передбаченим класом, ймовірністю (рис. 3.2).

Рисунок 3.2 - Ключові функції файлу inference.py для SageMaker Endpoint

Для кращого розуміння роботи інференс-сервісу розглянемо архітектуру взаємодії його основних компонентів та особливості обробки вхідних і вихідних даних.

Для забезпечення масштабованої та гнучкої інтеграції моделі машинного навчання в хмарне середовище було обрано безсерверний підхід, за якого обчислювальні ресурси виділяються динамічно у відповідь на запити користувача [35]. Запропонована архітектура передбачає відсутність постійно активних серверів, що зменшує експлуатаційні витрати та спрощує адміністрування системи.

У типовому сценарії експлуатації клієнтський компонент (динамометричний комплекс, IoT-модуль або веб-інтерфейс оператора) формує HTTP POST-запит, що містить зображення динамограми у стандартному графічному форматі (PNG або JPEG), та передає його через Amazon API Gateway. Далі запит маршрутизується до обчислювального шару - AWS Lambda або безпосередньо до SageMaker Endpoint, де виконується інференс моделі [35].

Результат прогнозування повертається клієнту у вигляді структурованої JSON-відповіді, що забезпечує просту інтеграцію системи з зовнішніми сервісами моніторингу та диспетчеризації.

Вхідними даними для системи інференсу є зображення підземних динамограм, що відображають залежність навантаження на шток від положення плунжера. Для уніфікації обробки всі вхідні зображення приводяться до єдиного формату незалежно від джерела отримання.

У межах функції input_fn реалізовано наступні етапи попередньої обробки [35, 36, 37, 38]:

1. декодування бінарного зображення з тіла HTTP-запиту;
2. перетворення зображення у відтінки сірого;
3. масштабування до фіксованого розміру, що відповідає вхідному шару нейронної мережі;
4. нормалізація значень пікселів відповідно до параметрів, використаних під час навчання моделі;
5. формування тензора PyTorch для подальшого подання в модель.

Такий підхід гарантує ідентичність обробки даних на етапах навчання та експлуатації, що є критично важливим для стабільності результатів інференсу.

Після отримання та підготовки вхідних даних виконується безпосередній інференс нейронної мережі ResNet-18 у режимі оцінювання.

Обчислення виконуються на CPU-інстансі, що є типовим сценарієм для інференсу моделей середньої складності в безсерверних середовищах. Вихід моделі представляє собою вектор логітів, який додатково обробляється за допомогою функції softmax для отримання ймовірнісного розподілу по всіх класах стану ШГНУ.

Функція output_fn формує стандартизовану JSON-відповідь, яка містить [35, 36, 37, 38]:

1. передбачений клас технічного стану установки;
2. числову оцінку впевненості прогнозу;
3. повний вектор ймовірностей по всіх класах;
4. службову інформацію (мітку часу або ідентифікатор запиту).

Використання JSON як формату обміну даними дозволяє легко інтегрувати систему інференсу з інформаційними системами верхнього рівня, зокрема SCADA-платформами або аналітичними панелями.

Запропонований механізм інференсу орієнтований на обробку окремих запитів у режимі, близькому до реального часу. Обчислювальна складність ResNet-18 у поєднанні з відсутністю етапів постобробки, що потребують значних ресурсів, забезпечує малу затримку між отриманням зображення та формуванням діагностичного висновку.

Це дозволяє використовувати систему не лише для офлайн-аналізу, а й у складі оперативних контурів контролю технічного стану ШГНУ, де важливо швидко виявляти критичні відмови, такі як обрив штанг або робота насоса на мертвому ході.

Для підвищення надійності роботи системи передбачено базові механізми обробки помилкових ситуацій. Зокрема, виконується перевірка

коректності формату вхідних даних, контроль типу файлу та обробка виключень, пов'язаних із неможливістю декодування зображення. У випадку помилки користувачеві повертається JSON-відповідь з описом причини відмови, що дозволяє реалізувати повторні запити або логування проблемних ситуацій на стороні клієнта.

Застосування безсерверної архітектури для реалізації інференсу забезпечує автоматичне масштабування системи залежно від кількості запитів, відсутність необхідності в ручному керуванні інфраструктурою та оплату виключно за фактично виконані обчислення [38, 39, 40].

Це робить запропоновану систему придатною для промислового впровадження на родовищах з великою кількістю штангових глибинно-насосних установок, де інтенсивність діагностичних запитів може суттєво змінюватися в часі.

Оскільки повний деплой на SageMaker Endpoint виявився технічно неможливим через обмеження, реалізовано локальну емуляцію хмарного endpoint, яка повністю відтворює його поведінку. Емуляція включає завантаження збереженої моделі, застосування тих самих трансформацій, обчислення softmax-ймовірностей та повернення стандартизованої JSON-відповіді (рис. 3.3).

Рисунок 3.3 - Приклад JSON-відповіді локальної емуляції SageMaker Endpoint для динамограми нормального режиму роботи ШГНУ

У повноцінному промислому акаунті AWS система розгорталася б як повністю безсерверна: клієнт (IoT-датчик або веб-інтерфейс) надсилає динамограму через API Gateway, який викликає Lambda-функцію або безпосередньо SageMaker Endpoint [35, 36, 39, 40, 41]. Endpoint, використовуючи inference.py, повертає JSON-відповідь, яка логувалася б у CloudWatch та, за потреби, ініціювала сповіщення через SNS при виявленні критичних дефектів.

Таким чином, у межах пункту реалізовано повний інференс-ланцюг безсерверної системи діагностування ШГНУ - від підготовки та збереження моделі до її інтеграції в масштабовану хмарну архітектуру, придатну для практичного використання [42].

3.2 Експериментальні дослідження: методика та набір даних

Метою експериментальних досліджень є оцінка здатності розробленої моделі ResNet-18 коректно класифікувати стани ШГНУ за динамограмами та перевірка її загальної здатності в умовах шумів і спотворень, характерних для промислової експлуатації.

Використання імітаційної моделі динамограм зумовлене обмеженою доступністю повністю розмічених промислових даних та складністю отримання репрезентативних вибірок для аварійних режимів роботи ШГНУ. Синтетичне формування динамограм дозволяє керувати змінювати параметри сигналу та забезпечити наявність достатньої кількості прикладів для кожного класу технічного стану, що є надзвичайно важливим для коректного навчання згорткових нейронних мереж.

Процес розпочинається із генерації синтетичних динамограм, що імітують різні технічні стани ШГНУ. Далі сформований набір даних поділяється на навчальну, валідаційну та тестову вибірки. На наступному етапі виконується обробка зображень, що забезпечує уніфікацію вхідних даних для нейронної мережі. Після чого здійснюється навчання згорткової нейронної мережі ResNet-18, валідація та тестування роботи. Завершальним етапом є виконання інференсу, що моделює практичне використання даної системи для визначення технічного стану ШГНУ за вхідною динамограмою.

Загальну методику проведення експериментальних досліджень наведено на рис. 3.4. Вона охоплює повний цикл роботи з даними - від формування набору динамограм до виконання інференсу навченої моделі.

Рисунок 3.4 - Загальна схема проведення експериментальних досліджень системи аналізу динамограм

Усі динамограми зберігалися у вигляді двовимірних зображень фіксованого розміру, що відповідає вхідному формату нейронної мережі ResNet-18. Перед подачею в модель зображення приводилися до одноканального (grayscale) формату, що дозволяє зменшити обчислювальну складність та зосередити увагу моделі на формі навантажувальної кривої, а не на кольорових характеристиках.

Для аналізу результатів використовувалися динамограми, що відповідають дев'яти різним умовам експлуатації ШГНУ, зокрема нормальному режиму, а також типовим передаварійним та аварійним станам. До набору даних увійшли такі класи: нормальний режим, газове перешкоджання, часткове заповнення насоса, витік у ходовому клапані, витік у стоячому клапані, пружні удари, обрив штанг, перевантаження привода та робота насоса на мертвому ході. Такий перелік класів дозволяє охопити основні дефекти та відхилення в роботі штангових глибинно-насосних установок.

При формуванні імітаційних динамограм враховувалися характерні особливості навантажувальних кривих для кожного режиму роботи ШГНУ, зокрема форма замкнутого циклу, співвідношення ділянок підйому та спуску штока, а також наявність характерних зламів і асиметрій. Це дозволило відтворити типові візуальні ознаки, які використовуються фахівцями при експертному аналізі динамограм.

Набір даних проаналізований шляхом створення імітаційної моделі динамограм з різними характеристиками, такими як амплітуда навантаження, асиметрія ходу та кількість прямих точок. Для покращення продуктивності реалістичних умов експлуатації до зображень були додані шум та артефакти, зокрема гауссівський шум, імпульсні перешкоди, дрейф базової лінії, а також спотворення та розмиття зображення через наявність шуму. Такий метод дозволяє отримати репрезентативний набір даних, що відображає характерні особливості динамограм, отриманих у польових умовах.

Додавання шумів та спотворень до зображень динамограм дозволяє перевірити стійкість моделі до якості вхідних даних, яка у реальних умовах експлуатації може суттєво змінюватися внаслідок збоїв вимірювальних каналів, механічних вібрацій, неточностей калібрування та перешкод при передаванні даних. Таким чином, модель навчається виділяти інформативні ознаки навіть за наявності суттєвих завад.

Датасет включає дев'ять класів технічного стану штангових глибинно-насосних установок і має збалансовану структуру, що забезпечує коректне навчання та оцінювання моделі. Для кожного класу було сформовано навчальну, валідаційну та тестову вибірки у співвідношенні 100/15/15 відповідно. Загальний обсяг набору даних становить 1170 зображень.

Для оцінки ефективності розробленої моделі класифікації було використано стандартні метрики машинного навчання. Основним інтегральним показником є точність класифікації, яка відображає частку правильно класифікованих динамограм від загальної кількості тестових вибірок.

Для більш детального аналізу якості розпізнавання окремих технічних станів ШГНУ додатково використовувалися показники точності (precision), повноти (recall) прогнозування та F1-міри. Аналіз матриці плутанини дозволяє оцінити характер помилок класифікації та виявити найскладніші для моделі класи.

Навчання моделі виконувалося в умовах фіксованої конфігурації експерименту, що забезпечує коректне порівняння результатів між різними

етапами дослідження. Критерієм завершення навчання слугувала стабілізація значення функції втрат на валідаційній вибірці та відсутність подальшого покращення показників точності класифікації.

Для забезпечення відтворюваності експериментальних результатів використовувалася фіксована ініціалізація генераторів випадкових чисел та незмінна конфігурація гіперпараметрів моделі. Це дозволяє повторити експеримент за ідентичних умов та отримати порівнювані результати. Обчислення метрик здійснювалося на тестовій вибірці, яка не використовувалася на жодному з етапів навчання або налаштування параметрів моделі.

Експериментальні дослідження проводилися в контрольованому програмному середовищі з фіксованими параметрами навчання, що забезпечує відтворюваність отриманих результатів. Модель навчалася з використанням оптимізатора Adam та крос-ентропійної функції втрат (Cross-Entropy Loss).

Для запобігання перенаванчання дані були розділені на навчальний, валідаційний та тестовий набори, а значення функції втрат та метрик точності контролювалися на валідаційній вибірці. Тестовий набір не використовувався для фази навчання та остаточної оцінки продуктивності моделі.

Проведені експериментальні дослідження моделюють типовий сценарій використання інтелектуальної системи аналізу динамограм у промислових умовах, де модель отримує на вхід поодинокі зображення динамограм та формує діагностичний висновок у режимі, близькому до реального часу.

Таким чином, сформована методика експериментальних досліджень та підготовлений набір динамограм забезпечують об'єктивну та комплексну оцінку ефективності розробленої системи аналізу. Збалансована структура датасету, використання імітаційної моделі та застосування стандартних метрик оцінювання створюють надійну основу для подальшого аналізу результатів класифікації, які наведені у наступному підрозділі.

1. Результати та оцінка ефективності

Після завершення навчання моделі ResNet-18 було проведено оцінювання її ефективності на тестовому наборі динамограм, що включає дев'ять характерних режимів роботи штангових глибинно-насосних установок. Для оцінювання якості класифікації насамперед було визначено загальну точність моделі як відношення кількості правильно класифікованих зразків до загальної кількості елементів тестової вибірки.

Для більш глибокого аналізу поведінки моделі було побудовано матрицю неточностей, яка дозволяє встановити, які саме класи розпізнаються правильно та між якими типами динамограм виникають помилки. Графічне зображення матриці неточностей у вигляді теплової карти дає можливість наочно оцінити здатність моделі відтворювати закономірності у даних та виявляти характерні ознаки конкретних режимів роботи. По діагоналі матриці зосереджені правильні класифікації, тоді як поза діагональні елементи демонструють кількість хибних визначень. На основі отриманої візуалізації було сформовано й табличне представлення матриці неточностей, що дозволяє детальніше простежити взаємні плутанини між окремими класами.

Оцінка проводилася на валідаційному наборі під час навчання для вибору найкращих ваг моделі та на тестовому наборі для фінальної перевірки узагальнення. Для перевірки стійкості моделі до реальних деградацій сигналу використано robustness-тест, де генерувалися додаткові приклади з екстремальним рівнем шуму (noise_level=0.2), що імітує перешкоди на родовищах, з подальшим обчисленням тих самих метрик на цих даних.

Для оцінювання якості роботи навченої нейромережевої моделі класифікації технічних станів штангової глибинно-насосної установки використано валідаційний набір даних. Аналіз проводиться із застосуванням параметрів моделі, що забезпечили найкращі показники під час навчання, а сама модель функціонує в режимі оцінювання, який гарантує коректну роботу механізмів пакетної нормалізації та регуляризації. За результатами класифікації сформовано матрицю неточностей, яка надає можливість детально проаналізувати правильність розпізнавання кожного з дев'яти технічних станів ШГНУ та виявити характерні помилки моделі.

Характеристика набору даних підкреслює його репрезентативність: синтетичні динамограми генерувалися з варіативними параметрами (асиметрія ходу, амплітуда навантаження, кількість точок 170-280), з моделюванням типових дефектів ШГНУ (газове перешкоджання як компресія кривої, обрив штанг як зменшення амплітуди тощо) та реалістичними шумовими ефектами (гаусівський шум, імпульсні стрибки, дрейф тренду, JPEG-стиснення з якістю 12-55, розмиття та подряпини), що робить набір більш наближеним до реальних даних порівняно з доступними відкритими датасетами. Поділ набору з різними рівнями шуму забезпечує тестування моделі на узагальнення, а тестування на екстремальному шумі (генерація 100 додаткових прикладів, по 15 на клас, з підвищеним шумом та артефактами) дозволяє оцінити її працездатність в умовах сильних перешкод, характерних для промислової експлуатації, з акцентом на критичні класи дефектів, де висока recall є пріоритетом для запобігання аварій.

Аналіз матриці неточностей (рис. 3.5) показує, що модель ResNet-18 у цілому демонструє високий рівень коректної класифікації більшості режимів роботи ШГНУ, однак між окремими класами спостерігаються характерні помилки, зумовлені схожістю візуальних ознак динамограм.

Рисунок 3.5 - Матриця неточностей (Confusion Matrix)

Аналіз матриці неточностей, наведеної на рис. 3.5, свідчить про високий рівень якості класифікації динамограм штангових глибинно-насосних установок. Загальна точність моделі на валідаційній вибірці становить близько 86 %, що підтверджує ефективність застосування згортової нейронної мережі ResNet-18 для розпізнавання основних режимів роботи та характерних дефектів ШГНУ.

Для більшості класів спостерігається висока частка правильних класифікацій, що підтверджується домінуванням значень на головній діагоналі матриці. Зокрема, практично безпомилково розпізнаються режими «газове перешкоджання», «нормальний режим» та «робота на мертвому ході», для яких зафіксовано лише поодинокі хибні передбачення або їх повну відсутність. Це свідчить про наявність у цих режимах чітко виражених та стабільних візуальних ознак динамограм.

Найбільша кількість хибних класифікацій спостерігається для класу «витік у стоячому клапані». У низці випадків динамограми цього режиму були помилково віднесені до класів «нормальний режим», «часткове заповнення насоса», «обрив штанг» та «перевантаження привода». Така плутанина зумовлена схожими змінами навантаження на окремих ділянках ходу та частковим «сплюсненням» контуру динамограми, що є характерним для кількох дефектів клапанної групи.

Окремо варто відзначити наявність хибних передбачень між класами «часткове заповнення насоса» та «витік у ходовому клапані», а також між «витік у ходовому клапані» та «витік у стоячому клапані». Усі зазначені режими супроводжуються зменшенням навантаження на етапі всмоктування та деформацією лівої частини динамограми, що з точки зору фізики процесу закономірно призводить до формування подібних візуальних патернів і ускладнює їх автоматичне розмежування.

Незначна кількість помилок також спостерігається між класами «пружні удари» та «часткове заповнення насоса», що пов'язано зі змінами характеру навантаження у верхній частині ходу та локальними деформаціями кривої. Водночас кількість таких помилок є обмеженою і не чинить суттєвого впливу на загальну ефективність класифікації (табл. 3.1).

Загалом результати аналізу матриці неточностей підтверджують, що основні помилки класифікації виникають між режимами зі спільною фізичною природою та близькими візуальними характеристиками динамограм. Досягнутий рівень точності є достатнім для практичного застосування моделі в задачах інтелектуального моніторингу технічного стану штангових глибинно-насосних установок, а подальше підвищення якості можливе за рахунок розширення навчальної вибірки та залучення додаткових інформативних ознак технологічного процесу.

Таблиця 3.1 - Основні метрики якості моделі на тестовій вибірці за класами стану

No	Клас стану ШГНУ	Precision	Recall	F1-міра
1	Нормальний режим	0.9333	0.9333	0.9333
2	Газове перешкодження	0.7895	1.0000	0.8824
3	Часткове заповнення насоса	0.8571	0.8000	0.8276
4	Витік у ходовому клапані	0.9286	0.8667	0.8966
5	Витік у стоячому клапані	0.5000	0.6000	0.5455
6	Пружні удари	1.0000	0.8000	0.8889
7	Обрив штанг	0.8000	0.8000	0.8000
8	Перевантаження привода	0.9286	0.8667	0.8966
9	Робота на мертвому ході	1.0000	0.9333	0.9655
Accuracy		-	-	0.8444
Macro average F1		-	0.8597	0.8444
Weighted average F1		-	0.8597	0.8444

Оцінювання моделі ResNet-18 на тестовому наборі показало високу якість класифікації з загальною точністю 0.8444. Модель добре розпізнає більшість станів ШГНУ, особливо з чіткими ознаками: нормальний режим (F1=0.9333), робота на мертвому ході (F1=0.9655), пружні удари (F1=0.8889) та витік у ходовому клапані (F1=0.8966).

Найнижчі показники у вибірку у стоячому клапані (F1=0.5455) через візуальну подібність до нормального режиму та інших дефектів клапанів при шумі. Критичні аварійні стани (обрив штанг, робота на мертвому ході) виявляються надійно (F1 ≥ 0.8000).

Macro та weighted average F1 = 0.8485 підтверджують збалансовану продуктивність. Результати демонструють ефективність моделі в реалістичних умовах та доцільність її використання в безсерверній системі на AWS SageMaker.

На графіку функції втрат (рис. 3.6) спостерігається стале монотонне зниження поточної втрати, що впливає на правильну роботу алгоритму оптимізації та поступове наближення моделі до мінімальної функції втрат. Валідаційна втрата також зменшується, залишаючись дещо вищою за тренувальну, що є типовим для завдань машинного навчання та показує на адекватну узагальнювальну здатність моделі.

Рисунок 3.6 - Зміна функції втрат під час навчання (Train / Val Loss)

Графік показує стійку точність росту як на поточному, так і на валідаційних вибірках. Тренувальна точність досягає показника близько 0,9, тоді як валідаційна - близько 0,85 наприкінці навчання. Різниця між цими значеннями є незначною, що свідчить про відсутність суттєвого перенавчання. Загалом результати підтверджують, що модель навчається стабільно, демонструє хорошу збіжність і забезпечує збалансоване співвідношення між точністю та узагальнювальною здатністю, що є прийнятним для практичного застосування в задачі автоматизованого діагностування стану ШГНУ за динамограмами (табл. 3.2).

Таблиця 3.2 - Результати емуляції SageMaker Endpoint (передбачення на одному прикладі кожного класу)

No	Справжній клас	Передбачений клас	Ймовірність
1	Нормальний режим	Газове перешкодження	84.2%
2	Газове перешкодження	Газове перешкодження	82.0%
3	Часткове заповнення насоса	Часткове заповнення насоса	72.7%
4	Витік у ходовому клапані	Витік у стоячому клапані	99.4%
5	Витік у стоячому клапані	Обрив штанг	47.5%
6	Пружні удари	Пружні удари	76.2%
7	Обрив штанг	Обрив штанг	95.2%
8	Перевантаження привода	Пружні удари	79.3%
9	Робота на мертвому ході	Робота на мертвому ході	35.5%

Аналіз результатів емуляції свідчить, що модель ResNet-18 демонструє найвищу ефективність для технічних станів із чітко вираженими візуальними ознаками динамограм. Зокрема, режим «Обрив штанг» класифікується коректно з високою впевненістю (95,2%), що зумовлено характерним зменшенням амплітуди навантаження та спрощенням форми кривої. Аналогічно, клас «Пружні удари» розпізнається стабільно (76,2%), що підтверджує здатність моделі виявляти локальні піки навантаження.

Водночас для режимів зі схожими динамічними проявами спостерігається плутанина. Так, нормальний режим був помилково віднесений до газового перешкодження з високою впевненістю (84,2%), а витік у ходовому клапані класифіковано як витік у стоячому клапані (99,4%), що пояснюється подібністю форм динамограм при шумових спотвореннях. Знижена впевненість прогнозу для роботи на мертвому ході (35,5%) вказує на часткове перекриття його ознак з іншими режимами за наявності завад.

Помилка класифікації перевантаження привода як пружних ударів (79,3%) також є закономірною, оскільки обидва стани супроводжуються підвищенням навантаженням у верхній частині ходу.

Загалом проведена емуляція підтверджує працездатність системи інференсу в умовах, наближених до хмарного endpoint. Середній рівень впевненості прогнозів для зашумлених прикладів перебуває в межах 70-80%, що свідчить про достатню стійкість моделі та її придатність до практичного використання у системах моніторингу ШГНУ.

Таким чином, проведені експериментальні дослідження підтверджують здатність моделі ResNet-18 ефективно розпізнавати основні режими роботи та характерні дефекти штангових глибинно-насосних установок за динамограмами. Отримані значення точності та збалансованих метрик свідчать про стійку роботу моделі навіть за наявності шумових спотворень, зокрема для критичних аварійних станів, що мають найбільше практичне значення. Результати емуляції хмарного endpoint додатково демонструють готовність розробленої системи до інтеграції у безсерверну інфраструктуру та її придатність для використання в задачах промислового моніторингу технічного стану ШГНУ.

Висновки до розділу 3

У третьому розділі роботи було зосереджено увагу на практичних аспектах використання створеної моделі аналізу динамограм, а саме на її інтеграції у хмарне середовище, проведенні експериментальних досліджень та оцінюванні здобутих результатів.

У підрозділі 3.1 розглянуто процес інтеграції навченої моделі ResNet-18 у безсерверну інфраструктуру Amazon Web Services. Було підготовлено всі потрібні артефакти для розгортання моделі, реалізовано кастомний інференс-код та описано механізм обробки вхідних запитів і формування результатів класифікації. Запропонований підхід дозволяє отримувати діагностичний висновок у стандартизованому форматі JSON, що є зручним для подальшої інтеграції із зовнішніми системами моніторингу. Незважаючи на обмеження навчального AWS-акаунту, виконана локальна емуляція SageMaker Endpoint підтвердила коректність роботи інференс-ланцюга та його відповідність промислому сценарію застосування.

У підрозділі 3.2 наведено методику проведення експериментальних досліджень та детально описано сформований набір даних. Використання імітаційної моделі динамограм було обґрунтовано складністю отримання повністю розмічених промислових даних, особливо для аварійних режимів роботи ШГНУ. Синтетичні динамограми формувалися з урахуванням характерних особливостей кожного технічного стану, а також із додаванням шумів і спотворень, притаманних реальним умовам експлуатації. Такий підхід дозволив отримати збалансований і репрезентативний датасет та забезпечити відтворюваність експериментів.

Результати експериментальних досліджень, наведені у підрозділі 3.3, свідчать про те, що модель ResNet-18 демонструє задовільну узагальнювальну здатність та коректно розпізнає більшість розглянутих режимів роботи ШГНУ. Аналіз матриці неточностей показав, що основні помилки класифікації виникають між технічними станами з близькими візуальними ознаками, що є логічним з точки зору фізики процесів у насосній установці.

У цілому результати третього розділу підтверджують, що розроблена інтелектуальна система аналізу динамограм є працездатною та придатною для використання у промислових умовах. Поєднання згортової нейронної мережі з безсерверною хмарною інфраструктурою забезпечує масштабованість, гнучкість інтеграції та можливість автоматизованого діагностування технічного стану ШГНУ в режимі, близькому до реального часу.

ВИСНОВКИ

У ході виконання магістерської роботи проведено комплексне дослідження теоретичних і практичних аспектів створення інтелектуальної безсерверної системи аналізу динамограм штангових глибинно-насосних установок з використанням хмарних сервісів AWS SageMaker. Перший розділ присвячений аналізу предметної області діагностування ШГНУ та сучасних технологічних рішень. Встановлено, що динамограми є найбільш інформативним джерелом даних для виявлення несправностей, але традиційні методи обмежені суб'єктивністю експертної оцінки та низькою оперативністю. Огляд існуючих систем моніторингу виявив недостатню інтеграцію методів машинного навчання та хмарних технологій, що обґрунтовує актуальність розробки автоматизованої інтелектуальної системи в безсерверному середовищі.

У другому розділі через обмежену доступність реальних промислових даних розроблено оригінальний фізично обґрунтований генератор ультрареалістичних синтетичних динамограм. Сформовано репрезентативний датасет обсягом 1170 зображень, що охоплює дев'ять класів технічного стану з градацією шумів та артефактів. Обґрунтовано вибір архітектури ResNet-18 з transfer learning як оптимального рішення для класифікації зображень динамограм у безсерверній інфраструктурі. Виконано адаптацію моделі, впроваджено аргументацію та регуляризацію, а також запропоновано механізм оцінки ризику аварійних станів. Запроєктовано багатозарову безсерверну архітектуру системи на базі сервісів AWS.

У третьому розділі реалізовано інтеграцію моделі в хмарну інфраструктуру. Підготовлено артефакти для розгортання на SageMaker Endpoint та виконано локальну емуляцію інференсу через обмеження sandbox-акаунту. Емуляція підтвердила повний цикл обробки запитів з формуванням стандартизованої JSON-відповіді. Експериментальні дослідження на тестовій вибірці з максимальним рівнем шумів показали загальну точність класифікації 84,44 %, macro-average F1-міру 84,85 %. Модель надійно виявляє критичні аварійні стани навіть за сильних спотворень сигналу. Аналіз матриці неточностей та robustness-тестування підтвердили стійкість і узагальнюючу здатність моделі.

Отримані результати підтверджують доцільність запропонованої системи для автоматизованого діагностування ШГНУ. Система забезпечує масштабованість, низькі експлуатаційні витрати та оперативне виявлення несправностей, що дозволяє зменшити простої обладнання та підвищити надійність експлуатації родовищ. Подальший розвиток може включати інтеграцію реальних даних, ансамблі моделей та повне розгортання в production-акаунті AWS з автоматичними сповіщеннями про критичні стани.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Golan, M., & Whitson, H. C. (1995). Well Performance (2nd ed.). Hoboken, NJ, USA: Prentice Hall. URL: <https://www.scribd.com/document/509611334/Well-Performance-by-Michael-Golan-Curtis-H-Whitson-Z-lib-org>
2. Boomer, P. M., & Podio, A. L. (2015). The Beam Lift Handbook. Austin, TX: PETEX. URL: https://www.scribd.com/document/850589553/Beam-Lift-HandBook?language_settings_changed=English
3. Desain dan Fungsi Pompa Sucker Rod - Adina Dwi Lathifa. Sucker Rod Pumping Design. URL: <https://www.scribd.com/document/341040422/Sucker-Rod-Pumping-Design>
4. Діагностика технічного стану штангових глибинно-насосних установок / авт.: Л.М. Заміховський, В.А. Ровінський, О.В. Євчук. - Івано-Франківськ: «Симфонія форте», 2006. - 308 с. URL: https://lib-repo.pnu.edu.ua/bitstream/123456789/4826/1/Monografija_last.pdf
5. Fakher, S., Khlaifat, A., Hossain, M. E., et al. (2021). A comprehensive review of sucker rod pumps' components, diagnostics, mathematical models, and common failures and mitigations. Journal of Petroleum Exploration and Production Technology, 11, 3815-3839. URL: https://www.researchgate.net/publication/354171410_A_comprehensive_review_of_sucker_rod_pumps'_components_diagnostics_mathematical_models_and_common_failures_and_mitigations

6. Zheng B., Gao X., Li X. Diagnosis of Sucker Rod Pump based on generating dynamometer cards // Journal of Process Control. - 2019. - Vol. 77. - P. 76-88. - DOI: 10.1016/j.jprocont.2019.02.008.
7. Zhang, A., & Gao, X. (2018). Fault diagnosis of sucker rod pumping systems based on Curvelet Transform and sparse multi-graph regularized extreme learning machine. International Journal of Computational Intelligence Systems, 11, 428-437. DOI: 10.2991/ijcis.11.1.32.Bello, O.,
8. Chen, Y., Li, Z., & Wang, R. (2021). Dynamometer Card Analysis Based on Deep Convolutional Networks. Energy Reports, 7, 512-520. Elsevier. URL: <https://www.frontiersin.org/journals/earth-science/articles/10.3389/feart.2022.852633/full>
9. Zhou, J., Xiong, J., & Liu, B. (2020). Fault diagnosis of beam pumping units using dynamometer card images and deep learning methods. Applied Sciences, 10(3), 1124. MDPI. URL: <https://www.mdpi.com/2076-3417/12/21/11091>
10. McCoy, J. N., & Rowlan, L. (2005). Pump Card Analysis Simplified. In Proceedings of the Southwestern Petroleum Short Course (SWPSC). Echometer Company. URL: <https://echometer.com/Portals/0/Technical%20Papers/Pump%20Card%20Analysis%20Simplified%20SWPSC%202005.pdf>
11. Sircar, A., Yadav, K., Rayavarapu, K., Bist, N., & Oza, H. (2021). Application of machine learning and artificial intelligence in oil and gas industry. Petroleum Research, 6(4), 379-391. DOI: 10.1016/j.ptlrs.2021.05.009
12. Chen, Y., Li, Z., & Wang, R. (2021). Dynamometer Card Analysis Based on Deep Convolutional Networks. Energy Reports, 7, 512-520. Elsevier. URL: <https://www.frontiersin.org/journals/earth-science/articles/10.3389/feart.2022.852633/full>
13. Cheng, H., Yu, H., Zeng, P., Osipov, E., & Li, S. (2020). Automatic Recognition of Sucker-Rod Pumping System Working Conditions Using Dynamometer Cards with Transfer Learning and SVM. Sensors, 20(19), 5659. DOI: 10.3390/s20195659
14. Hansen, B., Tolbert, B., Vernon, C., & Hedengren, J. D. (2019). Model Predictive Automatic Control of Sucker Rod Pump System with Simulation Case Study. Computers & Chemical Engineering, 121, 265-284. DOI: 10.1016/j.compchemeng.2018.08.018
15. WellWatcher (Schlumberger): <https://www.slb.com/products-and-services/innovating-in-oil-and-gas/completions/stimulation/stimulation-optimization/wellwatcher-stim-service>
16. Pump Off Controller (POC): <https://www.pochydraulics.com/>
17. WellPilot (Weatherford): <https://www.weatherford.com/production-and-intervention/artificial-lift-solutions/automation-and-control/>
18. Siemens Win CC / PCS 7: <https://www.siemens.com/ua/uk/produkty/avtomatyzatsiya-promyslovosti/prohranne-zabezpechennya-dlya-promyslovosti/prohranne-zabezpechennya-dlya-avtomatyzatsiyi/scada/simatic-wincc-v7.html>
19. Kuang, L., Liu, H., Ren, Y., Luo, K., Shi, M., Su, J., & Li, X. (2021). Application and development trend of artificial intelligence in petroleum exploration and development. Petroleum Exploration and Development, 48, 1-14. URL: https://www.researchgate.net/publication/349376757_Application_and_development_trend_of_artificial_intelligence_in_petroileum_exploration_and_development
20. Amazon Web Services: https://aws.amazon.com/what-is-aws/?nc1=h_ls
21. Zhao, H., Wang, J., & Gao, P. (2017). A Deep Learning Approach for Condition-based Monitoring and Fault Diagnosis of Rod Pump. Services Transactions on Internet of Things (STIoT), 1, 32-42. URL: https://www.researchgate.net/publication/322576326_A_Deep_Learning_Approach_for_Condition-Based_Monitoring_and_FaultDiagnosis_of_Rod_Pump_System
22. Zhou, J., Xiong, J., & Liu, B. (2020). Fault Diagnosis of Beam Pumping Units Using Dynamometer Card Images and Deep Learning Methods. Applied Sciences, 10(3), 1124. MDPI. URL: <https://www.mdpi.com/2076-3417/12/21/11091>
23. Wei, J., & Gao, X. (2020). Fault Diagnosis of Sucker Rod Pump Based on Deep-Broad Learning Using Motor Data. URL: https://www.researchgate.net/publication/346728831_Fault_Diagnosis_of_Sucker_Rod_Pump_Based_on_Deep-Broad_Learning_Using_Motor_Data
24. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778. URL: <https://www.semanticscholar.org/reader/2c03df8b48bf3fa39054345bafabfeff15bfd11d>
25. Mohammadinab, P. (2023). Pneumonia Detection Using Deep Convolutional Neural Networks. URL: https://www.researchgate.net/publication/373653509_Pneumonia_Detection_Using_Deep_Convolutional_Neural_Networks
26. Fawcett, T. (2006). Introduction to ROC Analysis. Pattern Recognition Letters, 27(8), 861-874. URL: https://www.researchgate.net/publication/222511520_Introduction_to_ROC_analysis
27. Amazon Web Services. AWS Architecture Patterns for Machine Learning. 2023. URL: <https://docs.aws.amazon.com/wellarchitected/latest/machine-learning-lens/machine-learning-lens.html>
28. Amazon Web Services. AWS Well-Architected Framework - Machine Learning Lens. 2023. URL: <https://docs.aws.amazon.com/wellarchitected/latest/machine-learning-lens/machine-learning-lens.html>
29. Amazon Web Services. Amazon API Gateway Developer Guide. 2024. - URL: <https://docs.aws.amazon.com/apigateway/latest/developerguide/welcome.html>
30. Amazon Web Services. AWS Lambda Developer Guide. 2024. - URL: <https://docs.aws.amazon.com/lambda/>
31. Amazon Web Services. Amazon DynamoDB Developer Guide. 2024. - Режим доступу: <https://docs.aws.amazon.com/dynamodb/>
32. Amazon Web Services. Amazon SageMaker Developer Guide. 2024. - URL: <https://docs.aws.amazon.com/sagemaker/latest/dg/>
33. Amazon Web Services. Amazon S3 Developer Guide. 2024. - URL: <https://docs.aws.amazon.com/AmazonS3/latest/userguide/Welcome.html>
34. Amazon Web Services. SageMaker Training Jobs - Technical Guide. 2024. URL: https://docs.aws.amazon.com/sagemaker/latest/APIReference/API_CreateTrainingJob.html
35. Amazon Web Services. Amazon SageMaker Batch Transform - Developer Guide, 2024. URL: <https://docs.aws.amazon.com/sagemaker/latest/dg/batch-transform.html>
36. Amazon Web Services. SageMaker Model Monitor - Detecting Data Drift. 2024. URL: <https://docs.aws.amazon.com/sagemaker/latest/dg/model-monitor.html>
37. Amazon Web Services. SageMaker Model Deployment Guide, 2024. URL: <https://docs.aws.amazon.com/sagemaker/latest/dg/how-it-works-deployment.html>
38. Amazon Web Services. Building Serverless Applications on AWS - Whitepaper, 2023. URL: <https://aws.amazon.com/ru/blogs/training-and-certification/new-training-building-serverless-applications-on-aws-available-on-coursera-and-edx/>
39. AWS Canary Deployments in SageMaker. Amazon ML Blog, 2024. URL: <https://docs.aws.amazon.com/sagemaker/latest/dg/deployment-guardrails->

blue-green-canary.html

40. Amazon Web Services. Amazon SageMaker Experiments - User Guide. 2024. URL: <https://docs.aws.amazon.com/sagemaker/latest/dg/experiments.html>

41. Amazon Web Services. Amazon CloudWatch User Guide. 2024. - URL: <https://docs.aws.amazon.com/cloudwatch/>

42. Всеукраїнська Інтернет-конференція молодих учених і студентів «Інформаційні технології в освіті, техніці та промисловості». Сертифікат учасника ІТЕТ120250041.

БІБЛІОГРАФІЧНА ДОВІДКА

Тема магістерської роботи - «Інтелектуальна безсерверна система аналізу динамограм штангових глибинно-насосних установок з використанням AWS SageMaker»

Обсяг пояснювальної записки в аркушах - 77

Перелік креслень графічної частини:

КРМ.АКСм - 12.00.00.000 С1 - Схема структурна. Архітектура інтелектуально-безсерверної системи діагностування AWS.

КРМ.АКСм - 12.00.00.001 - Робочі вікна. Зразки динамограм для оцінки станів ШГНУ.

КРМ.АКСм - 12.00.00.002 - Робочі вікна. Етапи розробки та валідація нейронної моделі на базі ResNet-18.

Дата закінчення магістерської роботи «22» грудня 2025р.

Студент-магістер _____ Кисляк П.П.