

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ БІОРЕСУРСІВ
І ПРИРОДОКОРИСТУВАННЯ УКРАЇНИ**

Кваліфікаційна наукова праця

на правах рукопису

ПАВЛОВ СЕРГІЙ ГРИГОРОВИЧ

УДК 004.9:37.016

ДИСЕРТАЦІЯ

**ІНТЕЛЕКТУАЛЬНА КОМП'ЮТЕРНО-ІНТЕГРОВАНА СИСТЕМА
МОНІТОРИНГУ ПАРАМЕТРІВ ВИРОБНИЦТВА БІОГАЗУ**

151 «Автоматизація та комп'ютерно-інтегровані технології»

Подається на здобуття наукового ступеня доктор філософії

Дисертація містить результати власних досліджень.

Використання ідей, результатів і текстів інших авторів мають посилання на
відповідне джерело

С. Г. Павлов

Науковий керівник:

Лисенко Віталій Пилипович,

доктор технічних наук, професор

Київ - 2026

АНОТАЦІЯ

Павлов С.Г. Інтелектуальна комп'ютерно-інтегрована система моніторингу параметрів виробництва біогазу.

Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії зі спеціальності 151 «Автоматизація та комп'ютерно-інтегровані технології» Національний університет біоресурсів і природокористування України. Київ, 2026.

Дисертація присвячена розробці інтелектуальної комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу з використанням технологій Інтернету речей, комп'ютерного зору та машинного навчання.

У роботі проведено комплексний аналіз процесу анаеробного зброджування як об'єкта автоматизації та обґрунтовано необхідність застосування інтелектуальних методів моніторингу. Досліджено існуючі підходи до автоматизації біогазових установок та виявлено їх обмеження.

Розроблено архітектуру програмно-апаратного комплексу на базі мікроконтролерної платформи ESP32 з інтеграцією давачів температури, вологості та модуля комп'ютерного зору. Реалізовано хмарну інфраструктуру для збору, зберігання та обробки даних з використанням сервісів AWS.

Запропоновано метод автоматизованої оцінки якості біосировини на основі аналізу зображень із застосуванням алгоритму сегментації Оцу та гібридної метрики якості на базі функції бажаності Харрінгтона. Експериментально підтверджено кореляцію візуальних характеристик біоматеріалу з виходом біогазу ($r = 0,81$).

Синтезовано підсистему прогнозування виходу біогазу на основі ансамблю нейронних мереж, що включає рекурентну мережу LSTM для аналізу часових рядів, градієнтний бустинг XGBoost для табличних даних та згорткову мережу ResNet-50 для візуальних ознак. Реалізовано механізм адаптивного донавчання Human-in-the-Loop, що забезпечує безперервне покращення точності прогнозів. Після донавчання модель досягла коефіцієнта детермінації $R^2 = 0,91$ та $RMSE = 0,35$ м³/добу.

Проведено техніко-економічне обґрунтування системи. Вартість апаратної частини становить 4 500 грн, що в 50-200 разів менше комерційних аналогів. Річний економічний ефект оцінюється в 339 000 - 498 000 грн при терміні окупності 1,6-2,3 місяця.

Ключові слова: біогаз, анаеробне зброджування, Інтернет речей, комп'ютерний зір, машинне навчання, LSTM, ResNet-50, прогнозування, моніторинг.

ABSTRACT

Pavlov S.H. Intelligent computer-integrated system for monitoring biogas production parameters.

Qualification scientific work in the form of a manuscript.

Dissertation for the degree of Doctor of Philosophy in specialty 151 "Automation and computer-integrated technologies" National University of Life Resources and Environmental Sciences of Ukraine. Kyiv, 2026.

In the dissertation thesis is dedicated to the development of an intelligent computer-integrated system for biogas production parameter monitoring using Internet of Things technologies, computer vision, and machine learning.

A comprehensive analysis of the anaerobic digestion process as an automation object was conducted, and the necessity of applying intelligent monitoring methods was substantiated. Existing approaches to biogas plant automation were investigated, and their limitations were identified.

The architecture of a hardware-software complex based on the ESP32 microcontroller platform with integration of temperature and humidity sensors and a computer vision module was developed. A cloud infrastructure for data collection, storage, and processing using AWS services was implemented.

A method for automated biomass quality assessment based on image analysis using the Otsu segmentation algorithm and a hybrid quality metric based on the Harrington desirability function was proposed. The correlation between visual characteristics of biomaterial and biogas yield was experimentally confirmed ($r = 0.81$).

A biogas yield prediction subsystem based on a neural network ensemble was synthesized, including a recurrent LSTM network for time series analysis, XGBoost gradient boosting for tabular data, and ResNet-50 convolutional network for visual features. A Human-in-the-Loop adaptive retraining mechanism was implemented, ensuring continuous improvement of prediction accuracy. After retraining, the model achieved a coefficient of determination $R^2 = 0.91$ and RMSE = 0.35 m³/day.

Technical and economic justification of the system was conducted. The hardware cost is UAH 4,500, which is 50-200 times less than commercial analogues. The annual economic effect is estimated at UAH 339,000 - 498,000 with a payback period of 1.6-2.3 months.

Keywords: biogas, anaerobic digestion, Internet of Things, computer vision, machine learning, LSTM, ResNet-50, prediction, monitoring.

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Статті у наукових виданнях, включених до міжнародних наукометричних баз даних

1. Lysenko V., Lendiel T., Bolbot I., **Pavlov S.** Mobile system for monitoring plant environment parameters for biogas production. *Machinery & Energetics*. 2023. Vol. 14, No. 4. P. 111-120. DOI: 10.31548/machinery/4.2023.111. **(Scopus)** (Павлов С. Г. розробив архітектуру системи моніторингу, програмування мікроконтролера ESP32, реалізація алгоритму пошуку та ідентифікації пристроїв на шині I-Wire, інтеграція з хмарним сховищем AWS S3.
2. Lysenko V., Lendiel T., **Pavlov S.**, Nakonechna K. Computer vision technologies for rapid quality analysis of fermentable biomaterial. *2024 IEEE 17th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, Lviv-Slavske, Ukraine, 2024. P. 1-5. DOI: 10.1109/TCSET64720.2024.10755768. **(Scopus)** (Павлов С. Г. запропонував метод сегментації зображень біоматеріалу методом Оцу з CLANE, реалізацію алгоритму оцінки якості на основі текстурних характеристик, проведення експериментальних досліджень.)
3. Лисенко В. П., Лендел Т. І., **Павлов С. Г.** Аналіз алгоритмів машинного навчання для прогнозування виходу біогазу. *Енергетика і автоматика*. 2023. № 3(67). С. 100-111. DOI: 10.31548/energiya3(67).2023.100. (Павлов С. Г. провів аналіз та порівняння методів машинного навчання (LSTM, XGBoost, Random Forest) для прогнозування виходу біогазу, обґрунтування вибору ансамблевого підходу.
4. **Павлов С. Г.**, Лисенко В. П., Лендел Т. І. Метод Харрінгтона в системі експрес-оцінки якості біосировини для зброджування. *Наукові праці Національного університету харчових технологій*. 2025. Т. 31, № 5. С. DOI: 10.24263/2225-2924-2025-31-5. (Павлов С. Г. запропонував гібридну метрику оцінки якості біосировини на основі функції бажаності Харрінгтона, експериментальна валідація методу на 26 зразках біоматеріалу.

5. **Павлов С. Г.,** Лисенко В. П., Лендел Т. І., Наконечна К. В. Інтелектуальна система автоматизованого моніторингу якості біоматеріалу для зброджування в біогазовій установці. *Вісник НТУУ «КПІ імені Ігоря Сікорського». Серія: Хімічна інженерія, екологія та ресурсозбереження.* 2025. № 3. С. 41-51. DOI: 10.20535/2617-9741.3.2025.340376. (Павлов С.Г. синтезував архітектуру інтелектуальної системи моніторингу, реалізація механізму адаптивного донавчання Human-in-the-Loop, проведення 6-місячного експериментального тестування системи).

Тези наукових доповідей

1. Павлов С. Г. Мобільна система моніторингу параметрів рослинного середовища для виробництва біогазу. I Міжнародна науково-практична конференція, присвячена 125-річчю НУБіП України та 90-річчю ННІ енергетики, автоматики і енергозбереження м. Київ, 08 червня 2023 р.
2. Павлов С. Г. Мобільна система моніторингу параметрів рослинного середовища для виробництва біогазу. II Міжнародна науково-практична конференція «Цифрові технології в енергетиці і автоматичі» м. Київ, 07 червня 2024 р.
3. Павлов С. Г. Технології комп'ютерного зору для експрес-аналізу якості зброджуючого біоматеріалу. Міжнародна науково-практична конференція «Електроенергетика, електромеханіка та технології в АПК» м. Харків, 06 листопада 2024 р.
4. Павлов С. Г. Інтеграція комп'ютерного зору та технологій інтернету речей для моніторингу якості біоматеріалу для виробництва біогазу. 2-а Міжнародна науково-практична конференція «Інформаційні системи та технології: результати і перспективи» 05 березня 2025 р.
5. Павлов С. Г. Методологія побудови автоматизованої системи моніторингу якості біоматеріалу для зброджування в біогазовій установці. Міжнародна науково-практична конференція молодих вчених «Інформаційні технології: економіка, техніка, освіта» м. Київ, 29 жовтня 2025 р.

6. Павлов С. Г. Функції бажаності Харрінгтона для оцінки якісних параметрів біосировини для зброджування. Міжнародна науково-практична конференція «Глобальні та регіональні проблеми інформатизації в суспільстві і природокористуванні» м. Київ, 14 листопада 2025 р.
7. Павлов С. Г. Проектування автоматизованої системи моніторингу якісних характеристик і параметрів біоматеріалу для зброджування в біогазовій установці. XII Міжнародна науково-технічна Internet-конференція «Сучасні методи, інформаційне, програмне та технічне забезпечення систем керування організаційно-технічними та технологічними комплексами» м. Київ, 27 листопада 2025 р.

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ ТА СКОРОЧЕНЬ

AЗ - анаеробне зброджування

АЦП - аналогово-цифровий перетворювач

БГУ - біогазова установка

ІР - Інтернет речей (IoT - Internet of Things)

КЗ - комп'ютерний зір

ЛЖК - леткі жирні кислоти

МН - машинне навчання

ШНМ - штучна нейронна мережа

API - Application Programming Interface (інтерфейс програмування застосунків)

AWS - Amazon Web Services

CLAHE - Contrast Limited Adaptive Histogram Equalization

CNN - Convolutional Neural Network (згорткова нейронна мережа)

GPIO - General Purpose Input/Output

HiTL - Human-in-the-Loop (людина в контурі)

I2C - Inter-Integrated Circuit (послідовна шина)

IQR - Interquartile Range (міжквартильний розмах)

LSTM - Long Short-Term Memory (довга короткочасна пам'ять)

MAE - Mean Absolute Error (середня абсолютна помилка)

MQTT - Message Queuing Telemetry Transport

PCA - Principal Component Analysis (аналіз головних компонент)

QoS - Quality of Service (якість обслуговування)

ResNet - Residual Network (залишкова мережа)

RMSE - Root Mean Square Error (середньоквадратична помилка)

R² - коефіцієнт детермінації

SHAP - SHapley Additive exPlanations

SPI - Serial Peripheral Interface

TLS - Transport Layer Security

XGBoost - eXtreme Gradient Boosting

ЗМІСТ

ЗМІСТ	10
ВСТУП.....	12
РОЗДІЛ 1.....	18
АНАЛІЗ ПРОБЛЕМ АВТОМАТИЗАЦІЇ МОНІТОРИНГУ У ВИРОБНИЦТВІ БІОГАЗУ	18
1.1. Аналіз виробництва біогазу як об'єкта автоматизації та керування.....	19
1.2. Огляд існуючих підходів до автоматизації моніторингу в біогазових установках.....	23
1.3. Обґрунтування концепції інтелектуальної системи моніторингу	26
РОЗДІЛ 2.....	33
РОЗРОБКА АПАРАТНО-ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ РІВНІВ СИСТЕМИ АВТОМАТИЗАЦІЇ.....	33
2.1. Архітектура апаратного рівня для збору даних	35
2.2. Розробка програмного забезпечення нижнього рівня	45
2.3. Розробка архітектури хмарного рівня системи моніторингу для обробки та зберігання даних	66
Висновки до розділу 2	93
РОЗДІЛ 3.....	95
РОЗРОБКА ІНТЕЛЕКТУАЛЬНОЇ ПІДСИСТЕМИ АНАЛІЗУ ЯКОСТІ СИРОВИНИ НА ОСНОВІ КОМП'ЮТЕРНОГО ЗОРУ	95
3.1 Методи обробки та аналізу зображень у комп'ютерному зорі	95
3.2 Синтез та порівняльний аналіз алгоритмів обробки зображень	111
3.3 Побудова моделі кількісної оцінки якості сировини	131
Висновки до розділу 3	147
РОЗДІЛ 4.....	149
СИНТЕЗ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ КОМП'ЮТЕРНО-ІНТЕГРОВАНОЇ СИСТЕМИ.....	149
4.1. Розробка підсистеми прогнозування на основі нейронних мереж.....	149
4.2. Архітектура та програмна реалізація інтегрованої системи	172
4.3. Організація та результати експериментального дослідження.	188
Висновки до розділу 4	197
РОЗДІЛ 5.....	198
ОЦІНКА ЕФЕКТИВНОСТІ ТА ПЕРСПЕКТИВИ ВПРОВАДЖЕННЯ СИСТЕМИ.....	198

5.1. Технічна оцінка результатів впровадження системи.....	199
5.2. Економічне обґрунтування застосування розробленої системи	204
5.3. Рекомендації щодо масштабування та подальшого розвитку системи	211
Висновки до розділу 5.....	214
ВИСНОВКИ.....	216
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	218

ВСТУП

Актуальність теми. Сучасний стан розвитку енергетичної галузі характеризується стійкою тенденцією до диверсифікації джерел енергії та збільшення частки відновлюваних енергоресурсів у загальному енергетичному балансі. За даними Міжнародного енергетичного агентства (IEA), у 2022 році глобальне виробництво біогазу та біометану досягло понад 1,6 ЕДж, що на 17% більше порівняно з попередніми п'ятьма роками. В Україні біогазова галузь має значний потенціал розвитку, враховуючи наявність сільськогосподарських відходів та органічної сировини. Водночас ефективне функціонування біогазових установок потребує впровадження сучасних систем автоматизації та моніторингу, що забезпечують оптимальний режим технологічного процесу анаеробного зброджування. Анаеробне зброджування є нелінійним біологічним процесом, чутливим до змін параметрів середовища, що часто призводить до нестабільності виробництва та зниження виходу біогазу. Традиційні методи контролю та механістичні моделі виявляються непрактичними для моделювання складних нелінійних взаємодій процесу. Існуючі високоточні методи прогнозування базуються на лабораторних аналізах, що унеможлиблює моніторинг у реальному часі та збільшує операційні витрати. Сучасні IoT-системи забезпечують ефективний збір даних, проте не включають інтелектуальні модулі прогнозування та аналізу візуальних характеристик сировини.

Таким чином, актуальним є розробка інтелектуальної комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу, яка поєднує технології Інтернету речей, комп'ютерного зору та машинного навчання для забезпечення прогнозування виходу біогазу в режимі реального часу з можливістю адаптації до змінних умов експлуатації.

Зв'язок роботи з науковими програмами, планами, темами. Дисертаційна робота виконана відповідно до плану науково-дослідних робіт кафедри автоматики та робототехнічних систем ім. акад. І.І. Мартиненка Національного університету

біоресурсів і природокористування України. Тематика дослідження відповідає пріоритетним напрямкам розвитку науки і техніки в Україні, зокрема «Енергетика та енергоефективність» та «Інформаційні та комунікаційні технології». Робота виконувалася як частина НДДКР «Наукові основи автоматизованого керування виробництвом біогазу заданої якості» (державний реєстраційний номер 0125U002642).

Мета і завдання дослідження. Метою роботи є розробка інтелектуальної комп'ютерно-інтегрованої системи, котра на основі використання технологій Інтернету речей, комп'ютерного зору та машинного навчання суттєво підвищує ефективність моніторингу окремих параметрів виробництва біогазу.

Для досягнення мети поставлено такі завдання:

- проаналізувати процес виробництва біогазу як об'єкт автоматизації та виявити ключові параметри, що підлягають моніторингу;
- провести системний огляд існуючих підходів до автоматизації моніторингу окремих технологічних параметрів при виробництві біогазу та виявити їх обмеження;
- розробити архітектуру програмно-апаратного комплексу на базі мікроконтролерної платформи з інтеграцією датчиків та модуля комп'ютерного зору;
- розробити метод автоматизованої оперативної оцінки якості біосировини на основі аналізу зображень із застосуванням алгоритмів сегментації та функції бажаності Харрінгтона;
- синтезувати підсистему прогнозування виходу біогазу на основі ансамблю нейронних мереж з механізмом адаптивного донавчання Human-in-the-Loop;
- провести експериментальне дослідження та техніко-економічне обґрунтування розробленої системи.

Об'єкт дослідження - процес моніторингу параметрів виробництва біогазу на біогазових установках.

Предмет дослідження - методи та засоби комп'ютерно-інтегрованого моніторингу окремих параметрів виробництва біогазу з використанням технологій Інтернету речей, комп'ютерного зору та машинного навчання.

Методи дослідження. У дисертаційній роботі використано комплекс методів:

- теоретичні методи: аналіз та синтез - для дослідження процесу анаеробного зброджування та існуючих систем автоматизації; системний підхід - для розробки архітектури комп'ютерно-інтегрованої системи; математичне моделювання - для побудови прогнозних моделей;

- експериментальні методи: вимірювання технологічних параметрів (температура, вологість) за допомогою цифрових датчиків; фотофіксація та обробка зображень біоматеріалу; збір та аналіз телеметричних даних;

- методи машинного навчання: рекурентні нейронні мережі LSTM для аналізу часових рядів; градієнтний бустинг XGBoost для табличних даних; згорткові нейронні мережі ResNet-50 для аналізу зображень; ансамблеві методи для підвищення точності прогнозування;

- статистичні методи: кореляційний аналіз, регресійний аналіз, метод головних компонент (PCA), аналіз SHAP для інтерпретації моделей;

- методи обробки зображень: порогова сегментація методом Оцу, адаптивне вирівнювання гістограми (CLAHE), аналіз текстурних характеристик.

Наукова новизна одержаних результатів.

Вперше:

- розроблено трирівневу архітектуру комп'ютерно-інтегрованої системи моніторингу біогазового виробництва, що забезпечує інтеграцію апаратного рівня збору даних (ESP32, датчики DS18B20, DHT22, камера OV2640), хмарного рівня обробки (AWS IoT Core, DynamoDB, S3) та рівня інтелектуального аналізу (ансамбль нейронних мереж) в єдиному рішенні з підтримкою масштабування та резервування;

- запропоновано гібридний підхід до інтегральної оцінки якості біосировини, що поєднує евклідову метрику відстані до еталонних значень текстурних ознак та функцію бажаності Харрінгтона, що забезпечує кореляцію з фактичним виходом біогазу $r = 0,81$;

- обґрунтовано архітектуру ансамблю нейронних мереж для прогнозування виходу біогазу, що поєднує LSTM для часових рядів, XGBoost для табличних даних та ResNet-50 для візуальних ознак із механізмом зваженого ансамблювання, що забезпечує точність $R^2 = 0,91$ та $RMSE = 0,35$ м³/добу;

- розроблено механізм адаптивного донавчання Human-in-the-Loop, що забезпечує автоматичну адаптацію прогнозних моделей до змінних умов експлуатації на основі зворотного зв'язку від оператора з покращенням точності на 42,6% після першого циклу донавчання.

Удосконалено:

- комбінований алгоритм збору та первинної обробки даних для біогазових установок, що поєднує медіанну фільтрацію, метод IQR для виявлення аномалій, локальну буферизацію та експоненційний бекоф для повторних спроб передачі, що забезпечує надійність збору даних 98,6%.

Набули подальшого розвитку:

- методологія застосування комп'ютерного зору для аналізу якості біосировини шляхом інтеграції статистичного аналізу текстур (середній рівень сірого, стандартне відхилення, асиметрія, ексцес) із функцією бажаності Харрінгтона;

- методологія ансамблевого машинного навчання для прогнозування нелінійних біотехнологічних процесів шляхом інтеграції рекурентних мереж, градієнтного бустингу та згорткових мереж з механізмом адаптивного донавчання.

Практичне значення одержаних результатів. Практичне значення роботи полягає у створенні комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу, яка може бути впроваджена на біогазових установках різної потужності.

Розроблена система забезпечує:

- автоматизований збір даних з частотою 30 секунд з надійністю 98,6%;
- прогнозування виходу біогазу з точністю $R^2 = 0,91$ та $RMSE = 0,35$ м³/добу;
- неінвазивну оцінку якості біосировини на основі аналізу зображень із точністю класифікації 89,7%;

- економічний ефект 339 000 - 498 000 грн/рік при вартості апаратної частини 4 500 грн (у 50-200 разів менше комерційних аналогів) та терміні окупності 1,6-2,3 місяця.

Особистий внесок здобувача. Основні результати дисертаційної роботи отримані автором самостійно було розроблено математичну модель гібридної метрики оцінки якості біосировини, що поєднує евклідову відстань до еталонних значень текстурних ознак та узагальнену функцію бажаності Харрінгтона; розроблено тривірневу архітектуру комп'ютерно-інтегрованої системи моніторингу; синтезовано ансамбль нейронних мереж з механізмом зваженого агрегування прогнозів.

Апробація результатів дисертації. Основні положення та результати дисертаційної роботи доповідалися та обговорювалися на наукових конференціях, а саме - I Міжнародна науково-практична конференція, присвячена 125-річчю НУБіП України та 90-річчю ННІ енергетики, автоматики і енергозбереження м. Київ, 08 червня 2023 р.; I Міжнародна науково-практична конференція «Цифрові технології в енергетиці і автоматичі» м. Київ, 07 червня 2024 р.; Міжнародна науково-практична конференція «Електроенергетика, електромеханіка та технології в АПК» м. Харків, 06 листопада 2024 р.; 2-а Міжнародна науково-практична конференція «Інформаційні системи та технології: результати і перспективи» 05 березня 2025 р.; Міжнародна науково-практична конференція молодих вчених «Інформаційні технології: економіка, техніка, освіта» м. Київ, 29 жовтня 2025 р.; Міжнародна науково-практична конференція «Глобальні та регіональні проблеми інформатизації в суспільстві і природокористуванні» м. Київ, 14 листопада 2025 р; XII Міжнародна науково-технічна Internet-конференція «Сучасні методи, інформаційне, програмне та технічне забезпечення систем керування організаційно-технічними та технологічними комплексами» м. Київ, 27 листопада 2025 р.

Публікації. За результатами дисертаційного дослідження опубліковано 7 наукових праць, з яких: 2 статей у виданнях, включених до міжнародних

наукометричних баз даних Scopus та/або Web of Science; 3 статей у наукових фахових виданнях України; 7 тез доповідей опубліковано у збірниках матеріалів конференцій

Структура та обсяг дисертації.

Дисертація складається зі вступу, п'яти розділів, висновків, списку використаних джерел та додатків. Загальний обсяг роботи становить 274 сторінок. Робота містить 29 таблиць та 40 рисунків. Список використаних джерел налічує 215 найменувань.

РОЗДІЛ 1

АНАЛІЗ ПРОБЛЕМ АВТОМАТИЗАЦІЇ МОНІТОРИНГУ У ВИРОБНИЦТВІ БІОГАЗУ

Сучасний стан розвитку енергетичної галузі характеризується стійкою тенденцією до диверсифікації джерел енергії та збільшення частки відновлюваних енергоресурсів у загальному енергетичному балансі. У 2022 році глобальне виробництво біогазу та біометану досягло понад 1,6 ЕДж, що на 17% більше порівняно з попередніми п'ятьма роками [70, 89]. Серед альтернативних джерел енергії біогаз займає особливе місце завдяки своїй екологічній чистоті, можливості утилізації органічних відходів та порівняно низькій собівартості виробництва. В Європі близько 70% біогазових установок використовують сировину з сільськогосподарського сектору [2].

Водночас ефективне функціонування біогазових установок потребує впровадження сучасних систем автоматизації та моніторингу, що забезпечують оптимальний режим технологічного процесу анаеробного зброджування. Актуальність проблеми автоматизації обумовлена складністю та багатofакторністю процесу анаеробного зброджування, який є чутливим до змін параметрів середовища та часто призводить до нестабільності виробництва та зниження виходу біогазу.

Традиційні методи контролю та механістичні моделі виявляються непрактичними для моделювання складних нелінійних взаємодій процесу анаеробного зброджування [3]. У зв'язку з цим особливої актуальності набуває розробка інтелектуальних систем моніторингу на основі алгоритмів машинного навчання та нейронних мереж, здатних адаптуватися до змінних умов експлуатації та забезпечувати прогнозування ключових параметрів технологічного процесу.

Метою даного розділу є комплексний аналіз проблем автоматизації моніторингу у виробництві біогазу, що включає дослідження біогазового процесу як об'єкта автоматизації, систематичний огляд існуючих підходів із виявленням їх обмежень та обґрунтування концепції інтелектуальної системи моніторингу з використанням технологій комп'ютерного зору та нейронних мереж. Результати аналізу

слугуватимуть теоретичною основою для формулювання задач дослідження та розробки практичних рішень.

1.1. Аналіз виробництва біогазу як об'єкта автоматизації та керування

Виробництво біогазу є складним біотехнологічним процесом, що базується на анаеробному зброджуванні органічної сировини мікроорганізмами за відсутності кисню. Як об'єкт автоматизації та керування, біогазова установка характеризується нелінійністю, багатопараметричністю та наявністю значних часових затримок між керуючими впливами та реакцією системи [4]. Ці особливості обумовлюють необхідність застосування сучасних методів автоматичного керування та інтелектуального моніторингу для забезпечення стабільного та ефективного виробництва.

Анаеробне зброджування є нелінійним біологічним процесом, чутливим до змін параметрів середовища, що часто призводить до нестабільності виробництва та зниження виходу біогазу. За даними досліджень Singh et al. [5], ефективне управління виробництвом біогазу залишається складною науково-технічною задачею, що вимагає застосування сучасних методів прогнозування та інтелектуального аналізу даних.

1.1.1. Декомпозиція біогазового процесу та ідентифікація ключових параметрів для моніторингу

Процес анаеробного зброджування органічних відходів для виробництва біогазу є складним багатостадійним процесом, що включає декілька послідовних етапів біохімічних перетворень. Декомпозиція цього процесу на окремі стадії дозволяє ідентифікувати ключові параметри, що підлягають моніторингу, та розробити ефективну стратегію автоматизованого контролю [6].

Перша стадія - гідроліз - характеризується розщепленням складних органічних сполук (полісахаридів, білків, ліпідів) на простіші молекули під дією екзоферментів мікроорганізмів. На цій стадії відбувається перетворення нерозчинних органічних

речовин у розчинні мономері: моносахариди, амінокислоти та жирні кислоти. Швидкість гідролізу залежить від складу та структури субстрату, температури середовища та активності гідролітичних ферментів.

Друга стадія - ацидогенез - включає перетворення продуктів гідролізу в органічні кислоти (оцтову, пропіонову, масляну), спирти, водень та вуглекислий газ ацидогенними бактеріями. Ця стадія є критичною для загальної стабільності процесу, оскільки надмірне накопичення летких жирних кислот (ЛЖК) може призвести до зниження рН середовища та пригнічення метаногенезу. Дослідження Wang et al. [7] показали, що концентрація ЛЖК є одним із найважливіших параметрів для прогнозування стабільності процесу.

Третя стадія - ацетогенез - характеризується перетворенням продуктів ацидогенезу в ацетат, водень та вуглекислий газ під дією ацетогенних бактерій. Ця стадія є термодинамічно несприятливою і потребує низької концентрації водню в середовищі, що забезпечується активною роботою метаногенів на наступній стадії. Між ацетогенезом та метаногенезом існує синтрофний зв'язок, порушення якого може призвести до нестабільності всього процесу.

Четверта стадія - метаногенез - є фінальною стадією анаеробного зброджування, на якій метаногенні археї перетворюють ацетат та водень з вуглекислим газом у метан. Метаногени є найбільш чутливими до зміни умов середовища мікроорганізмами в анаеробному консорціумі. Оптимальна температура для мезофільного процесу становить $35-37^{\circ}\text{C}$ з допустимими коливаннями не більше $\pm 1^{\circ}\text{C}$ [8].

Аналіз підходів інших дослідників до моніторингу параметрів. Gaida et al. [9] запропонували систему моніторингу з використанням нейронних мереж для прогнозування виходу біогазу на основі лабораторного аналізу ЛЖК, досягнувши точності $R^2 > 0,95$. Однак їхній підхід потребує регулярного відбору проб та проведення біохімічних аналізів, що суттєво збільшує операційні витрати та унеможливорює моніторинг у реальному часі.

Almomani et al. [10] розробили регресійні моделі для прогнозування виходу метану з точністю $R^2 = 0,94$, проте їхня система також залежить від біохімічних

параметрів, визначення яких потребує спеціалізованого лабораторного обладнання. De Clercq et al. [11] досягли надзвичайно високої точності ($R^2 = 0,9986$) з використанням гібридної моделі GA-ANN, але складність калібрування та потреба в детермінованих вхідних параметрах обмежує практичне застосування їхнього рішення.

Існуючі високоточні методи прогнозування базуються на лабораторних аналізах, що унеможливають моніторинг у реальному часі та значно збільшують операційні витрати. Система моніторингу повинна забезпечувати збір даних з високою частотою дискретизації. Базова частота опитування для температури встановлюється кожні 30 секунд, при виявленні швидких змін параметра частота опитування автоматично збільшується [12].

1.1.2. Вплив характеристик біосировини на стабільність та ефективність процесу

Характеристики біосировини мають визначальний вплив на стабільність та ефективність процесу анаеробного зброджування. Склад, структура та фізико-хімічні властивості субстрату безпосередньо впливають на швидкість біохімічних реакцій, активність мікроорганізмів та вихід біогазу [13].

Аналіз підходів інших дослідників. Özgür та Çelen [14] дослідили вплив бактеріальних і екологічних факторів на вихід біогазу з використанням моделі Random Forest, досягнувши точності $R^2 = 0,9879$. Їхні дослідження показали, що бактеріальний склад визначає 89,9% впливу на вихід біогазу, а екологічні фактори - решту. Проте їхній підхід потребує складного мікробіологічного аналізу, недоступного для більшості практичних застосувань.

Yılmaz та Şahan [15] застосували методологію поверхні відгуку (RSM) у поєднанні з ANN для оптимізації виробництва біогазу з пташиного посліду, досягнувши $R^2 = 0,9894$. Однак їхнє дослідження обмежене лабораторним масштабом та одним типом субстрату.

Thompson et al. [16] розробили систему оцінки якості кукурудзяної соломи на основі комп'ютерного зору з використанням ResNet та GRU, досягнувши 89%

точності класифікації. Це дослідження продемонструвало можливість неінвазивної оцінки якості біомаси, проте було обмежене одним типом сировини та не інтегроване з системою прогнозування виходу біогазу.

Візуальна оцінка якості субстрату. Дослідження показують, що візуальні характеристики біоматеріалу корелюють з його фізико-хімічними властивостями та потенціалом виходу біогазу. Основною гіпотезою є те, що текстурні характеристики зображення біомаси (розподіл відтінків сірого) відображають фізичні властивості сировини (співвідношення компонентів, ступінь однорідності, вологість) і, відповідно, впливають на її якість як субстрату для біогазового виробництва.

Аналіз текстурних характеристик зображень біоматеріалу дозволяє отримати кількісні показники його якості:

- Середнє значення інтенсивності - характеризує загальну яскравість та корелює з вмістом води та органічних речовин. Світліше зображення біомаси може вказувати на наявність великої кількості сухої соломи, тоді як темніший тон - на більшу частку вологих фракцій, таких як гній.
- Стандартне відхилення інтенсивності - характеризує однорідність текстури біоматеріалу. Спостерігається помітна негативна кореляція між стандартним відхиленням і оцінкою якості: більш однорідний за яскравістю об'єкт отримує вищу оцінку.
- Коефіцієнти асиметрії та ексцесу - описують форму розподілу яскравостей пікселів та мають позитивну кореляцію з оцінкою якості.

Недостатнє використання методів комп'ютерного зору для неінвазивної оцінки якості біосировини в режимі реального часу з інтеграцією в системи прогнозування виходу біогазу.

Співвідношення вуглецю до азоту (C/N) також суттєво впливає на ефективність процесу. Оптимальне співвідношення становить 20-30:1. Занадто високе співвідношення призводить до дефіциту азоту для росту мікроорганізмів, а занадто низьке - до накопичення аміаку, який може інгібувати метаногенез [17].

1.2. Огляд існуючих підходів до автоматизації моніторингу в біогазових установках

Автоматизація моніторингу біогазових установок пройшла значний шлях розвитку від простих локальних систем контролю до складних розподілених комп'ютерно-інтегрованих систем. Сучасні підходи характеризуються інтеграцією різноманітних технологій, включаючи сенсорні мережі, хмарні обчислення, машинне навчання та Інтернет речей (IoT) [18].

Існуючі підходи можна класифікувати за декількома критеріями: рівнем автоматизації, типом використовуваних технологій, ступенем інтеграції компонентів та наявністю інтелектуальних функцій.

1.2.1. Класичні системи контролю та їх обмеження

Класичні системи контролю біогазових установок базуються на використанні програмованих логічних контролерів (ПЛК) та систем диспетчерського керування (SCADA). Ці системи забезпечують базовий моніторинг технологічних параметрів, автоматичне регулювання температури та сигналізацію при відхиленні параметрів від заданих меж [19].

Аналіз підходів інших дослідників. Szymenderski та Tułańska [20] розробили модель керування потоками енергії в сільськогосподарській біогазовій установці з використанням SCADA. Їхня система забезпечує ефективний контроль, проте характеризується високою вартістю впровадження та обмеженими можливостями масштабування.

Manjula та Arunachalam [21] запропонували систему автоматизації біогазової установки на базі PLC, SCADA та GSM. Система забезпечує віддалений моніторинг, але не має можливостей прогнозування та інтелектуального аналізу даних.

Обмеження класичних систем:

1. Залежність від лабораторного аналізу. Визначення ключових параметрів, серед них - концентрація ЛЖК, співвідношення C/N, склад біогазу, потребує

трудомісткого лабораторного аналізу. При частоті аналізів 3 рази на тиждень річні операційні витрати становлять 374 400 - 546 000 грн.

2. Неефективність для нелінійних процесів. Класичні ПІД-регулятори ефективні для лінійних процесів з постійними параметрами, проте анаеробне зброджування характеризується нелінійністю та значними часовими затримками [22].

3. Висока вартість комерційних газоаналізаторів:

- MRU OPTIMAX (портативний): 245 000 грн + 18 000 грн/рік [197]
- SSM 6000 Classic (стаціонарний): 660 000 грн + 25 000 грн/рік [198]
- AWIFLEX: 900 000 грн + 32 000 грн/рік [199]

4. Обмежена масштабованість. Додавання нових давачів потребує значних модифікацій апаратного та програмного забезпечення. Інтеграція з хмарними платформами часто є складною через закриті протоколи.

5. Відсутність прогнозування. Традиційні системи реагують на відхилення, коли проблема вже виникла. Впровадження систем предиктивного моніторингу знижує тривалість простоїв на 20-30% [23].

Класичні системи контролю не забезпечують можливості прогнозування та адаптації до змінних умов експлуатації, що призводить до незапланованих простоїв та втрат виробництва.

1.2.2. Сучасні комп'ютерно-інтегровані системи керування

Сучасні системи базуються на принципах Інтернету речей (IoT), хмарних обчислень та машинного навчання. Ці системи забезпечують комплексний моніторинг, віддалений доступ, автоматичну аналітику та прогнозування [24].

Аналіз підходів інших дослідників - IoT-системи моніторингу.

Kotsopoulos et al. [25] розробили низьковартісну IoT-систему на базі мікроконтролера ESP32 для моніторингу пілотного анаеробного реактора. Система забезпечує вимірювання рН, температури, окисно-відновного потенціалу, концентрації амонію та складу біогазу. Автори продемонстрували, що IoT-підхід дозволяє досягти порівнянної точності з лабораторними методами при значно нижчій

вартості. Однак система обмежена пілотним масштабом та не включає модулі прогнозування.

Radu et al. [26] створили децентралізовану мережу IoT-моніторингу для анаеробних дигестерів у Великобританії та Таїланді. Система використовує відкриті апаратні компоненти та забезпечує передачу даних через мобільну мережу. Проте система зосереджена лише на моніторингу без інтелектуального аналізу.

Acharya et al. [27] запропонували IoT-систему для моніторингу ефективності біогазових установок на базі Arduino з датчиками рН, температури та тиску. Система забезпечує віддалений доступ через GSM-модуль, але не має можливостей машинного навчання.

Rahadian et al. [28] дослідили застосування газового сенсора TGS2611 для моніторингу концентрації метану в дигестерах, продемонструвавши можливість неперервного вимірювання. Однак їхнє рішення обмежується лише одним параметром.

Аналіз підходів до застосування машинного навчання.

Chong et al. [29] провели комплексний огляд методів машинного навчання для моделювання та оптимізації виробництва біогазу. Автори виявили, що гібридні моделі GA-ANN демонструють найвищу точність ($R^2 = 0,9986$), проте потребують значних обсягів навчальних даних та складного налаштування.

Ozkaya et al. [30] застосували ансамблеві методи машинного навчання для прогнозування виробництва біогазу на промисловій установці, досягнувши $R^2 = 0,82$. Їхнє дослідження продемонструвало важливість правильного вибору вхідних параметрів та методу крос-валідації для уникнення data leakage.

Long et al. [7] використали алгоритми SVM, KNN, RF та логістичну регресію для прогнозування виробництва метану, досягнувши найкращої точності з SVM ($R^2 = 0,91$). Автори підкреслили важливість ідентифікації критичних операційних параметрів.

Wang et al. [31] застосували AutoML (Tree-based Pipeline Optimization Tool) для прогнозування виходу біогазу на промисловій установці ко-дигестування в Окленді.

Їхній підхід автоматично оптимізує вибір алгоритму та гіперпараметрів, проте потребує значних обчислювальних ресурсів.

Salamattalab et al. [32] розробили інноваційний підхід з використанням LSTM у поєднанні з генетичним алгоритмом (GA) для прогнозування виробництва біогазу на великомасштабних анаеробних дигестерах. Вікно look-back встановлено на 21 день (відповідно до HRT). Модель досягла $R^2 = 0,84$ при використанні лише 4 параметрів стічних вод (BOD_5 , COD, TSS, TN).

Відсутність цілісних комп'ютерно-інтегрованих систем, що поєднують IoT-збір даних, комп'ютерний зір для аналізу сировини та ML-прогнозування в єдиному рішенні з механізмом адаптації до змінних умов.

Сучасні хмарні платформи. Хмарні платформи, такі як Amazon Web Services (AWS), забезпечують масштабовану та надійну інфраструктуру. AWS IoT Core [99] забезпечує безпечне підключення IoT-пристроїв з використанням протоколу MQTT [80]. Amazon DynamoDB [102] надає безсерверну базу даних для зберігання часових рядів. AWS Lambda [200] забезпечує безсерверне виконання коду для обробки подій. Amazon S3 гарантує довговічність збереження даних на рівні 99,999999999% [33].

Протокол MQTT є стандартом для IoT-застосунків завдяки легковажності та надійній доставці повідомлень. Рівень якості обслуговування QoS забезпечує гарантовану доставку критичних даних.

За результатами тестування у роботі Lendiel T. et al [35], надійність збору даних сучасними IoT-системами сягає 98,6%, а середній час від збору даних до генерації аналітичних результатів становить 3,2 хвилини.

1.3. Обґрунтування концепції інтелектуальної системи моніторингу

Концепція інтелектуальної системи моніторингу біогазового виробництва базується на інтеграції технологій комп'ютерного зору, машинного навчання та Інтернету речей для забезпечення комплексного контролю та оптимізації технологічного процесу. Така система повинна забезпечувати не лише збір та

візуалізацію даних, а й автоматичну оцінку якості сировини, прогнозування виходу біогазу та раннє виявлення аномалій.

Аналіз комп'ютерно-інтегрованих систем у суміжних галузях. Lendiel et al. [35] розробили комп'ютерно-інтегровані технології фітомоніторингу в тепличних господарствах, продемонструвавши методологічний підхід до побудови багаторівневих систем з інтеграцією IoT-пристроїв, хмарних технологій та аналітичних модулів. Цей досвід може бути адаптований для біогазових установок.

Benmalek et al. [36] запропонували IoT-фреймворк для оптимального моніторингу та керування кібер-фізичними системами з застосуванням до біогазового виробництва. Їхній фреймворк включає три рівні (сприйняття, мережевий, прикладний), проте не охоплює візуальний аналіз сировини.

Kamilaris та Prenafeta-Boldú [37] провели комплексний огляд застосування глибокого навчання в сільському господарстві, виявивши значний потенціал CNN для аналізу зображень біомаси та класифікації якості рослинних матеріалів.

1.3.1. Застосування комп'ютерного зору для автоматизованої оцінки якості сировини

Комп'ютерний зір є потужним інструментом для автоматизованої оцінки якості біосировини, що дозволяє отримувати об'єктивні кількісні характеристики субстрату без необхідності проведення трудомістких лабораторних аналізів [38].

Аналіз підходів інших дослідників.

Skovsen et al. [39] розробили систему оцінки біомаси трави та конюшини на основі CNN, досягнувши $R^2 = 0,85$ для прогнозування маси. Їхній датасет GrassClover містить 435 зображень з анотаціями біомаси. Проте застосування для біогазового виробництва потребує адаптації.

Dhawi et al. [40] застосували XGBoost та CNN для неінвазивної оцінки біомаси проса, досягнувши $R^2 = 0,98$. SHAP-аналіз визначив NGRDI та висоту рослини як найвпливовіші ознаки. Однак їхній підхід не інтегрований з системами прогнозування виходу біогазу. Метод Оцу з попереднім підвищенням контрастності (CLAHE)

показав найнижчі показники варіативності: стандартне відхилення близько 1,79 п.п. площі та коефіцієнт варіації 3,63% [41].

Існуючі методи комп'ютерного зору для аналізу біомаси не інтегровані з системами прогнозування виходу біогазу та не забезпечують перетворення візуальних характеристик на операційно значущі показники якості.

1.3.2. Типи нейронних мереж для ідентифікації матеріалу

Нейронні мережі є потужним інструментом для автоматичної ідентифікації та класифікації матеріалів на основі їх візуальних характеристик. Вибір оптимальної архітектури залежить від специфіки задачі та характеристик вхідних даних [42].

Аналіз підходів інших дослідників.

Liakos et al. [43] провели комплексний огляд застосування машинного навчання в сільському господарстві, класифікувавши основні типи задач та відповідні архітектури нейронних мереж. Автори виявили, що CNN домінують для задач обробки зображень, тоді як LSTM - для часових рядів.

Згорткові нейронні мережі (CNN) є домінуючою архітектурою для обробки зображень. CNN використовують згорткові шари для автоматичного виділення просторових ознак. Архітектура ResNet-50 використовує залишкові з'єднання, що дозволяє ефективно навчати глибокі мережі без проблеми затухання градієнтів [44].

Мережі для семантичної сегментації (U-Net, DeepLab, Mask R-CNN) дозволяють класифікувати кожен піксель зображення. Проте застосування таких мереж потребує великих обсягів розмічених даних та значних обчислювальних ресурсів.

Transfer Learning - використання попередньо навчених моделей на великих датасетах (ImageNet) дозволяє отримати ефективну модель при обмеженій кількості власних даних. Останні шари мережі донавчаються на специфічних даних, тоді як ранні шари залишаються фіксованими [45].

Легковагі архітектури, так як MobileNet [135] та EfficientNet [68] забезпечують баланс між точністю та швидкодією для застосування на вбудованих системах.

1.3.3. Роль нейромережевих технологій у прогнозуванні нелінійних процесів

Прогнозування виробництва біогазу є складною задачею через нелінійний характер процесу анаеробного зброджування та його чутливість до численних факторів. Традиційні статистичні методи та лінійні моделі не здатні адекватно моделювати такі складні залежності [46].

Amran et al. [47] провели огляд моделей машинного навчання для прогнозування виробництва біогазу, виявивши, що ANN та ANFIS є найпоширенішими підходами. Найчастіше використовуються параметри: час реакції, температура, рН, загальні тверді речовини (TS), леткі тверді речовини (VS), ЛЖК.

Park et al. [48] порівняли різні ML-алгоритми для оцінки стабільності біо-електрохімічного AD, визначивши, що рекурентні нейронні мережі (RNN) забезпечують найкращу точність для часових рядів ($R^2 = 0,87$).

Sakiewicz et al. [49] розробили інноваційний ANN-підхід для інтегрованого моделювання системи біогаз-очистка стічних вод, досягнувши $R^2 = 0,94$. Їхній підхід демонструє можливість комплексного моделювання взаємопов'язаних процесів.

Gueguim Kana et al. [50] застосували ANN у поєднанні з генетичним алгоритмом для оптимізації виробництва біогазу з тирси та ко-субстратів, досягнувши $R^2 = 0,96$. Проте їхнє дослідження обмежене лабораторним масштабом.

Архітектура LSTM для часових рядів. Мережі довгої короткочасної пам'яті є спеціалізованою архітектурою рекурентних нейронних мереж, розробленою для моделювання довгострокових залежностей у послідовних даних. Конструкція LSTM включає механізм «воріт» (gates), що дозволяє селективно зберігати або забувати інформацію протягом тривалих часових інтервалів [51].

Структура моделі LSTM для прогнозування виходу біогазу:

- Вхідний шар: прийом послідовності параметрів за T попередніх кроків
- Перший LSTM-шар: 64 нейрони, екстракція низькорівневих часових ознак
- Другий LSTM-шар: 64 нейрони, моделювання високорівневих залежностей

- Dropout: 0,2 для запобігання перенавчанню
- Вихідний шар: один нейрон для регресійного прогнозу

Гرادієнтний бустинг (XGBoost) є ансамблевим методом, що демонструє високу ефективність на табличних даних. XGBoost будує послідовність дерев рішень, де кожне наступне дерево виправляє помилки попередніх. Метод характеризується високою інтерпретованістю та здатністю автоматично визначати важливість вхідних ознак [52].

Ансамблевий підхід поєднує декілька моделей для досягнення вищої точності. Дослідження показують, що гібридні моделі LSTM + XGBoost суттєво перевершують автономні моделі. Відсутність механізмів адаптації моделей до змінних умов експлуатації через зворотний зв'язок з оператором та автоматичне донавчання.

Мета дослідження: Розробка комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу, яка забезпечує автоматизований збір даних, інтелектуальний аналіз та підтримку прийняття операційних рішень.

Задачі дослідження:

1. Провести системний аналіз предметної області, виявити ключові параметри, що впливають на процес виробництва біогазу, та обґрунтувати доцільність застосування комп'ютерно-інтегрованих технологій для автоматизації моніторингу.

2. Розробити архітектуру програмно-апаратного комплексу збору даних як нижнього рівня інтегрованої системи, забезпечивши автоматичний збір та синхронізацію візуальної та телеметричної інформації.

3. Створити та валідувати підсистему комп'ютерного зору для неінвазивної кількісної оцінки якісних характеристик біосировини в режимі реального часу.

4. Розробити підсистему інтелектуального аналізу даних на основі нейромережевих моделей для прогнозування виходу біогазу з урахуванням комплексних вхідних даних.

5. Здійснити синтез розроблених підсистем в єдину комп'ютерно-інтегровану систему, розробивши протоколи їх взаємодії та алгоритми функціонування з механізмом зворотного зв'язку з оператором.

6. Експериментально дослідити функціонування створеної системи, оцінити її ефективність у підвищенні точності моніторингу та прогнозування.

Висновки до розділу 1

У даному розділі проведено комплексний аналіз проблем автоматизації моніторингу у виробництві біогазу з систематичним оглядом існуючих підходів та виявленням ключових прогалин, що дозволило сформулювати науково-методичну основу та задачі для розробки інтелектуальної комп'ютерно-інтегрованої системи. Основні результати аналізу:

1. Виробництво біогазу як об'єкт автоматизації характеризується нелінійністю, багатопараметричністю та наявністю значних часових затримок. Процес анаеробного зброджування включає чотири стадії - гідроліз, ацидогенез, ацетогенез, метаногенез, кожна з яких має специфічні вимоги до умов середовища.

2. Аналіз існуючих підходів до прогнозування Gaida et al., Almomani et al., De Clercq et al. виявив, що високоточні методи базуються на лабораторних аналізах, що унеможлиблює моніторинг у реальному часі та збільшує операційні витрати.

3. Характеристики біосировини суттєво впливають на ефективність процесу. Дослідження Thompson et al., Skovsen et al. та Dhawi et al. продемонстрували можливість застосування комп'ютерного зору для оцінки якості біомаси, проте ці рішення не інтегровані з системами прогнозування виходу біогазу.

4. Класичні системи контролю описані в роботах Szymenderski et al., Manjula et al. мають суттєві обмеження: залежність від лабораторного аналізу, неефективність для нелінійних процесів, обмежена масштабованість та відсутність прогнозування.

5. Сучасні IoT-системи описані в роботах Kotsopoulos et al., Radu et al., Lendiel T. et al., Acharya et al. забезпечують ефективний збір даних і

демонструють надійність 98,6%, проте не включають інтелектуальні модулі прогнозування та аналізу візуальних характеристик сировини.

6. Методи машинного навчання розглянуті в роботах Ozkaya et al., Wang et al., Salamattalab et al., Long et al. демонструють високу точність прогнозування, проте не забезпечують механізмів адаптації до змінних умов експлуатації та не інтегрують візуальний аналіз сировини.

На основі проведеного аналізу виявлено шість ключових задач дослідження, спрямованих на розробку цілісної комп'ютерно-інтегрованої системи, що поєднує IoT-технології, комп'ютерний зір та машинне навчання з механізмом Human-in-the-Loop для адаптивного моніторингу та прогнозування виробництва біогазу.

РОЗДІЛ 2

РОЗРОБКА АПАРАТНО-ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ РІВНІВ СИСТЕМИ АВТОМАТИЗАЦІЇ

Трирівнева архітектура системи моніторингу. Розроблена комп'ютерно-інтегрована система моніторингу параметрів виробництва біогазу побудована за принципом трирівневої архітектури рис. 2.1, що забезпечує чіткий розподіл функцій, масштабованість та надійність. Кожен рівень виконує специфічні завдання та взаємодіє з суміжними рівнями через стандартизовані інтерфейси.

Рівень 1. Апаратний (Edge Layer) - нижній рівень системи, що безпосередньо взаємодіє з технологічним процесом. До його складу входять:

- мікроконтролерний модуль ESP32 [167];
- давач температури DS18B20 [79], давач вологості DHT22[170];
- камера OV2640 [54] для аналізу якості біосировини;
- локальний буфер на 1000 записів для забезпечення надійності при втраті зв'язку.

Апаратний рівень виконує збір даних з частотою 30 с, первинну фільтрацію за допомогою медіанного фільтру, детекцію аномалій та передачу в хмарне сховище.

Рівень 2. Хмарний рівень (Cloud Layer) - середній рівень на базі сервісів Amazon Web Services:

- AWS IoT Core [99] - MQTT-брокер [80];
- Amazon DynamoDB - NoSQL база для часових рядів;
- Amazon S3 - сховище зображень та ML-моделей [101];
- AWS Lambda - безсерверна обробка подій;
- AWS Fargate - контейнерна платформа для запуску аналітичного програмного забезпечення [100].

Рівень 3. Інтелектуальний рівень (Application Layer) - верхній рівень аналітики:

- ансамбль нейронних мереж (LSTM + XGBoost + ResNet-50) з точністю $R^2 = 0,91$;
- REST API з JWT-автентифікацією [161];
- веб-інтерфейс моніторингу в реальному часі;
- модуль HITL для валідації прогнозів та адаптивного донавчання [143].

Така архітектура забезпечує масштабованість від однієї установки до мережі комплексів, відмовостійкість через локальну буферизацію та хмарне резервування, наскрізну безпеку, зображена нарис.2.1.

На цьому етапі роботи розробляють перші два рівні для отримання та первинної обробки даних по сировині для збродження. В послідуючих розділах роботи буде розглянуто розробку алгоритмів для інтелектуальної обробки даних і створення прогнозів по видобутку біогазу в реакторі біогазової установки.




Рис. 2.1 Спрощена архітектура комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу

2.1. Архітектура апаратного рівня для збору даних

Сучасні технології виробництва біогазу потребують комплексного підходу до моніторингу та керування процесами анаеробного зброджування. Архітектура апаратної підсистеми збору даних є фундаментальною основою для побудови ефективної інтелектуальної комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу. Розробка такої архітектури вимагає ретельного аналізу технологічних процесів, вимог до точності вимірювань та надійності системи в умовах промислової експлуатації [54]. Концептуальна архітектура, зображена на рис. 2.2, апаратної підсистеми базується на принципах модульності, масштабованості. Основними компонентами архітектури є мікроконтролерний модуль керування, система датчиків для вимірювання параметрів технологічного процесу, модулі зв'язку для передачі даних, пристрої візуального контролю стану біомаси та блоки живлення.




Рис. 2.2 Компонентна схема пристрою

Кожен з цих компонентів виконує специфічні функції в загальній системі збору даних. Центральним елементом архітектури є мікроконтролерний модуль, який забезпечує координацію роботи всіх периферійних пристроїв, первинну обробку даних та їх передачу до вищих рівнів системи. Модуль реалізовано на базі сучасних мікроконтролерів з вбудованими інтерфейсами безпроводного зв'язку, що дозволяє інтегрувати систему в існуючу інфраструктуру біогазової установки без значних модифікацій [36]. Сенсорна мережа архітектури включає датчі температури, вологості, тиску. Кожен тип датча підібрано з урахуванням специфіки середовища

біогазової установки, включаючи підвищену вологість, агресивність середовища та необхідність тривалої автономної роботи. Архітектура передбачає можливість динамічного підключення додаткових давачів без зупинки основної системи [90]. Модуль візуального контролю включає камеру високої роздільної здатності для фотофіксації стану біомаси перед завантаженням в реактор. Це дозволяє проводити неінвазивний аналіз якості сировини з використанням алгоритмів комп'ютерного зору. Архітектура передбачає синхронізацію візуальних даних з показниками давачів для комплексної оцінки стану технологічного процесу [57]. Комунікаційна підсистема архітектури забезпечує багаторівневу передачу даних. На нижньому рівні використовуються провідні протоколи для з'єднання давачів з мікроконтролером, зокрема 1-Wire для цифрових температурних давачів та I2C для давачів вологості та тиску. На вищому рівні застосовуються безпроводні технології Wi-Fi для передачі агрегованих даних до серверної інфраструктури [79].

2.1.1. Обґрунтування вибору мікроконтролерної платформи та сенсорної бази

Вибір мікроконтролерної платформи для системи моніторингу параметрів виробництва біогазу є критичним рішенням, що визначає функціональні можливості, надійність та економічну ефективність всієї системи. Аналіз сучасних мікроконтролерних рішень показує, що для реалізації поставлених завдань оптимальним є використання платформ на базі мікроконтролерів ESP32 та ESP8266 від компанії Espressif Systems [167]. Мікроконтролер ESP32 представляє собою потужну систему на кристалі SoC з двоядерним процесором Xtensa LX6, що працює на частоті до 240 МГц. Архітектура процесора базується на RISC-принципах, що забезпечує високу продуктивність при низькому енергоспоживанні. Наявність двох обчислювальних ядер дозволяє розподілити завдання збору даних та їх обробки між різними ядрами, підвищуючи загальну ефективність системи. Ключовою перевагою ESP32 є інтегрований модуль Wi-Fi 802.11 b/g/n з підтримкою шифрування WPA/WPA2. Це забезпечує надійний захищений канал передачі даних без необхідності використання додаткових модулів зв'язку. Вбудований стек TCP/IP

спрощує інтеграцію з хмарними платформами та реалізацію IoT-протоколів. З точки зору периферійних інтерфейсів, ESP32 надає широкі можливості для підключення датчиків. Важливим фактором вибору платформи ESP є розвинена екосистема розробки. Підтримка Arduino IDE, ESP-IDF, MicroPython та інших середовищ розробки спрощує процес програмування та налагодження [35]. Наявність великої кількості готових бібліотек для роботи з різними датчиками та протоколами прискорює розробку програмного забезпечення [91]. З економічної точки зору, мікроконтролери ESP характеризуються оптимальним співвідношенням ціна/продуктивність. Вартість модулів NodeMCU на базі ESP8266 становить близько 3-5 доларів США, тоді як плати ESP32 DevKit коштують 5-10 доларів. Це робить їх доступними для масового впровадження в системах моніторингу біогазових установок [167].

Енергоефективність є критичним параметром для автономних вузлів системи. ESP32 підтримує різні режими енергозбереження: активний режим - 80-260 мА, режим модему - 20-60 мА, легкий сон - 0.8 мА, глибокий сон - 10-150 мкА та режим гібернації - 2.5 мкА. Динамічне управління енергоспоживанням дозволяє створювати автономні вузли з тривалим терміном роботи від батарей [25]. Вибір сенсорної бази для системи моніторингу визначається специфікою технологічних процесів виробництва біогазу та вимогами до точності вимірювань. Температурний контроль є одним з найкритичніших параметрів, оскільки оптимальна температура для мезофільного процесу становить 35-37°C з допустимими коливаннями не більше $\pm 1^\circ\text{C}$ [23].

Для вимірювання температури обрано цифрові датчики DS18B20 виробництва Analog Devices раніше Dallas Semiconductor. DS18B20 забезпечує точність вимірювання $\pm 0.5^\circ\text{C}$ в діапазоні від -10°C до $+85^\circ\text{C}$ та роздільну здатність від 9 до 12 біт. Унікальною особливістю DS18B20 є використання протоколу 1-Wire, що дозволяє підключати декілька датчиків до одного цифрового входу мікроконтролера [79]. Кожен датчик DS18B20 має унікальний 64-бітний серійний код, що дозволяє ідентифікувати окремі датчики в мережі. Це особливо важливо для розподіленої системи моніторингу, де необхідно контролювати температуру в різних точках біореактора. Датчики доступні

у водонепроникному виконанні з класом захисту IP67, що критично важливо для роботи в умовах підвищеної вологості.

Для комплексного моніторингу мікроклімату використовуються датчі DHT22 AM2302, які вимірюють одночасно температуру та відносну вологість. DHT22 забезпечує діапазон вимірювання вологості 0-100% з точністю $\pm 2\%$ та температури від -40°C до $+125^{\circ}\text{C}$ з точністю $\pm 0.5^{\circ}\text{C}$. Цифровий інтерфейс датча спрощує інтеграцію з мікроконтролером [54].

Контроль вологості субстрату здійснюється за допомогою ємнісних датчів вологості ґрунту. Ці датчі використовують принцип зміни діелектричної проникності середовища залежно від вмісту води. Модулі датчів включають компаратор LM393 для формування цифрового сигналу при досягненні порогового значення вологості [54].

Для візуального контролю якості біомаси використовується камера OV2640 виробництва OmniVision. Камера має матрицю з роздільною здатністю 2 мегапікселі 1600×1200 , підтримує різні формати виведення зображення включаючи JPEG, та має вбудований процесор обробки зображень. Інтеграція з ESP32-CAM забезпечує можливість потокової передачі відео та збереження знімків [57]. Перелік використаних компонентів та їх призначення наведено в табл 2.1

Таблиця 2.1

Перелік використаних компонентів

№	Компонент	Модель/Тип	Характеристики	Призначення
1	Мікроконтролер	ESP32 DevKit V1	240 МГц, 2 ядра, Wi-Fi, Bluetooth, 34 GPIO	Центральний контролер системи
2	Модуль камери	ESP32-CAM	ESP32 + OV2640, Wi-Fi, слот microSD	Захоплення зображень біомаси
3	Мікроконтролер (резервний)	ESP8266 NodeMCU	80-160 МГц, 1 ядро, Wi-Fi	Допоміжні вузли системи

№	Компонент	Модель/Тип	Характеристики	Призначення
4	Давач температури	DS18B20 (IP67)	$\pm 0,5^{\circ}\text{C}$, $-55...+125^{\circ}\text{C}$, 1-Wire, 12 біт	Вимірювання температури субстрату
5	Давач температури та вологості	DHT22 (AM2302)	Вологість $\pm 2\%$, температура $\pm 0,5^{\circ}\text{C}$	Моніторинг мікроклімату
6	Давач вологості ґрунту	Ємнісний з LM393	Аналоговий/цифровий вихід	Контроль вологості субстрату
7	Камера	OV2640	2 МП, 1600×1200 , JPEG, 15 fps	Фотофіксація стану біомаси
8	Стабілізатор напруги 5В	LM7805	Вхід 7-35В, вихід 5В/1.5А	Стабілізація живлення модуля
9	Стабілізатор напруги 3.3В	AMS1117-3.3	LDO, вихід 3.3В/1А	Живлення логіки 3.3В
10	Конденсатор електролітичний	$470 \text{ мкФ} \times 25\text{В}$	Фільтрація пульсацій	Вхідний/вихідний фільтр
11	Конденсатор керамічний	100 нФ	Розв'язуючий	Фільтрація ВЧ завад
12	Діод Шоткі	SS34 / 1N5822	40В, 3А	Захист від переполюсовки
13	Стабілітрон	15В, 1Вт	Захист від перенапруги	Обмеження вхідної напруги
14	Транзистор NPN	BC547	45В, 100мА	Каскад керування живленням
15	Транзистор PNP	BC557	45В, 100мА	Каскад керування живленням
16	MOSFET	BSS138	N-канал, 50В	Узгодження рівнів 3.3В/5В
17	Світлодіод індикації	LED 3мм (зелений)	20мА, 2.1В	Індикація живлення/стану

№	Компонент	Модель/Тип	Характеристики	Призначення
18	Резистор підтягуючий 1-Wire	4.7 кОм, 0.25Вт	Допуск 1-5%	Підтягування шини 1-Wire
19	Резистор підтягуючий I2C	4.7 кОм, 0.25Вт	Допуск 1-5%	Підтягування SDA/SCL
20	Резистор підтягуючий DHT22	10 кОм, 0.25Вт	Допуск 5%	Підтягування лінії даних
21	Резистор захисний	100 Ом, 0.25Вт	Послідовний захист	Захист входів МК
22	Резистор для LED	330 Ом, 0.25Вт	Обмеження струму	Обмеження струму світлодіода
23	Резистори дільника	10 кОм + 20 кОм, 1%	Прецизійні	Дільник напруги для АЦП
24	Компаратор	LM393	Двоканальний	Формування цифрового сигналу
25	Буфер I2C	PCA9515A	Підсилювач I2C	Подовження ліній I2C
26	Корпус	ABS IP65	Герметичний, антистатичний	Захист електроніки
27	Роз'єми датчиків	M12 (А/В кодування)	4-pin, IP67	Підключення зовнішніх датчиків
28	Кабельні вводи	PG9, PG13.5	Сальники IP68	Герметичне введення кабелів
29	Радіатор	Алюмінієвий 25 см ²	Пасивне охолодження	Відведення тепла від МК
30	Термопрокладка	Силіконова	Теплопровідність >1 Вт/м·К	Теплопередача до радіатора
31	Друкована плата	FR4, двостороння	Провідники 0.3-0.8мм	Монтаж компонентів
32	Захисний лак	Конформне покриття	Захист від вологи	Захист плати від корозії

№	Компонент	Модель/Тип	Характеристики	Призначення
33	Адаптер живлення	12В DC, 2А	Імпульсний, стабілізований	Зовнішнє джерело живлення

2.1.2. Принципова схема та конструкція вимірювального модуля

Розробка принципової схеми вимірювального модуля, фрагмент якої зображено на рис. 2.3, базується на модульній архітектурі, що забезпечує гнучкість конфігурації та можливість розширення функціональності системи. Центральним елементом схеми є мікроконтролер ESP32 в конфігурації NodeMCU DevKit, який забезпечує необхідні інтерфейси для підключення периферійних пристроїв та модулів зв'язку [25]. Схема живлення модуля реалізована на базі лінійного стабілізатора напруги LM7805, який забезпечує стабільну напругу 5В для живлення мікроконтролера та периферійних пристроїв. Вхідна напруга 12В подається від адаптера живлення, потенційно можна використовувати акумуляторну батарею або сонячну панель, що забезпечує гнучкість в виборі джерела енергії. На вході та виході стабілізатора встановлені електролітичні конденсатори ємністю 470 мкФ для фільтрації пульсацій напруги [26].

Для індикації наявності живлення використовується світлодіод з обмежувальним резистором 330 Ом. Додатково, схема включає захист від переполюсовки за допомогою діода Шоткі та захист від перенапруги з використанням стабілітрона на 15В. Для живлення 3.3В логіки використовується вбудований в NodeMCU стабілізатор AMS1117-3.3 [167].

Підключення цифрових температурних датчиків DS18B20 реалізовано через шину 1-Wire. датчі підключаються паралельно до цифрового виводу D4 GPIO2 мікроконтролера. Між лінією даних та живленням 3.3В встановлено підтягуючий резистор номіналом 4.7 кОм, який забезпечує коректну роботу протоколу 1-Wire. Схема підтримує підключення до 10 датчиків на одну шину [79].




Рис. 2.3 Фрагмент принципової електричної схеми вимірювального електротехнічного комплексу для моніторингу параметрів біогазової установки

Важливою особливістю схеми є використання транзисторного каскаду для керування живленням датчиків. Каскад на транзисторах Q1 BC547 та Q2 BC557 дозволяє програмно вмикати та вимикати живлення сенсорної мережі, що значно знижує енергоспоживання в режимі очікування. Керування каскадом здійснюється через вивід GPIO16 мікроконтролера.

Датчик DHT22 підключається до виводу D5 GPIO14 через підтягуючий резистор 10 кОм до лінії живлення 3.3В. Для захисту входу мікроконтролера від можливих перевантажень використовується послідовний резистор 100 Ом. Живлення датчика здійснюється від стабілізованої напруги 3.3В через розв'язуючий конденсатор 100 нФ [168]. Аналогові датчики вологості підключаються до АЦП мікроконтролера через дільники напруги. Оскільки вхідний діапазон АЦП ESP32 становить 0-3.3В, а деякі датчики видають сигнал 0-5В, використовуються резистивні дільники з коефіцієнтом ділення 2:3. Дільник реалізовано на прецизійних резисторах з допуском 1% для забезпечення точності вимірювань [25]. Схема включає інтерфейс I2C для

підключення додаткових цифрових датчиків та дисплея. Лінії SDA та SCL підтягнуті до напруги 3.3В через резистори 4.7 кОм. Для підвищення надійності зв'язку на довгих лініях використовуються буферні мікросхеми PCA9515A, які забезпечують підсилення сигналів I2C [167].




Рис. 2.4 Зображення модуля камери ESP32-CAM

Модуль камери ESP32-CAM інтегрується в загальну схему через UART-інтерфейс. Для узгодження рівнів напруги між основним модулем 3.3В та камерою 1.8В для деяких сигналів використовуються двонаправлені перетворювачі рівнів на базі MOSFET-транзисторів BSS138. Живлення камери здійснюється від окремого малошумного LDO-стабілізатора, модуль камери зображено на рис. 2.4. Вихідні коди модулю камери додано у Додаток Б.

Конструктивно вимірювальний модуль виконано у вигляді базової плати з роз'ємами для підключення датчиків. Плата розроблена з урахуванням вимог електромагнітної сумісності: аналогові та цифрові ланцюги розведені в різних шарах, використовується суцільна земляна площа, критичні сигнальні лінії екрановані. Для захисту від впливу навколишнього середовища модуль розміщується в герметичному корпусі з класом захисту IP65. Корпус виготовлено з ABS-пластику з

додаванням антистатичних добавок. Кабельні вводи забезпечуються сальниками PG9 та PG13.5, які забезпечують герметичність при введенні кабелів давачів.




Рис. 2.5 Вимірювальний модуль в захисному корпусі

Тепловий режим модуля забезпечується пасивним охолодженням через алюмінієвий радіатор площею 25 см², прикріплений до мікроконтролера через термопрокладку. Розрахункова потужність розсіювання при максимальному навантаженні становить 2.5 Вт, що забезпечує температуру кристала не вище 70°C при температурі навколишнього середовища до 40°C [31].

Для підключення зовнішніх давачів використовуються промислові роз'єми серії M12 з кодуванням А для давачів з живленням та В для сигнальних ліній. Роз'єми забезпечують надійне з'єднання в умовах вібрації та захист від випадкового роз'єднання за рахунок різьбової фіксації. Вимірювальний модуль у захисному корпусі зображено на рис. 2.5. Друкована плата модуля виконана за технологією двостороннього монтажу з металізацією перехідних отворів. Ширина провідників для силових ланцюгів становить 0.8 мм, для сигнальних - 0.3 мм. Зазор між провідниками

- не менше 0.3 мм. Плата покрита захисним лаком для захисту від вологи та корозії [33].

2.2. Розробка програмного забезпечення нижнього рівня

Програмне забезпечення нижнього рівня системи моніторингу виробництва біогазу є критичним компонентом, що забезпечує взаємодію з апаратними засобами, збір та первинну обробку даних, а також їх передачу на вищі рівні системи. Розробка ПЗ базується на принципах модульності, ефективності використання ресурсів та надійності в умовах тривалої автономної роботи [87].

Архітектура програмного забезпечення побудована за принципом багаторівневої організації з чітким розподілом функціональності між рівнями. Нижній рівень абстракції апаратури забезпечує уніфікований інтерфейс доступу до периферійних пристроїв мікроконтролера. Середній рівень драйверів реалізує протоколи взаємодії з конкретними типами давачів. Верхній рівень прикладної логіки координує роботу всіх компонентів системи [35].

Основним середовищем розробки обрано Arduino IDE з підтримкою плат ESP32/ESP8266, що забезпечує баланс між простотою розробки та гнучкістю налаштування. Ініціалізація системи починається з налаштування тактової частоти процесора, конфігурації GPIO-портів та ініціалізації периферійних інтерфейсів. Для ESP32 встановлюється частота 240 МГц для забезпечення максимальної продуктивності при обробці даних. GPIO-порти конфігуруються відповідно до підключених давачів: цифрові входи для 1-Wire та I2C, аналогові входи для АЦП [168]. Особлива увага приділяється налаштуванню системи переривань для забезпечення своєчасної реакції на події від давачів. Використовується пріоритетна система переривань з найвищим пріоритетом для критичних подій, таких як перевищення порогових значень тиску або температури. Обробники переривань оптимізовані для мінімального часу виконання [103]. Управління пам'яттю реалізовано з використанням статичного розподілу для критичних структур даних та динамічного виділення для тимчасових буферів. Для запобігання фрагментації пам'яті

використовується пул попередньо виділених блоків фіксованого розміру. Реалізовано механізм контролю з перезапуском при виявленні критичних помилок [104].

2.2.1. Алгоритми збору, первинної обробки та синхронізації даних

Алгоритм збору даних, зображено на рис. 2.6, з давачів реалізовано за принципом циклічного опитування з адаптивною частотою. Вихідні коди додано модулю в Додаток А. Базова частота опитування встановлюється залежно від динаміки зміни параметра: температура - кожні 30 секунд. При виявленні швидких змін параметра частота опитування автоматично збільшується.




Рис. 2.6. Алгоритм збору та передачі даних на апаратному рівні

Для давачів DS18B20 реалізовано алгоритм пошуку та ідентифікації пристроїв на шині 1-Wire з використанням бінарного дерева пошуку. Алгоритм починається з відправки команди RESET для ініціалізації шини, після чого виконується команда SEARCH ROM 0xF0 для виявлення всіх підключених давачів. Кожен давач має

унікальний 64-бітний ідентифікатор, який зберігається в таблиці для подальшої адресної роботи [79]. Процес вимірювання температури включає наступні етапи: відправка команди CONVERT T 0x44 для ініціації перетворення, очікування завершення перетворення 750 мс для 12-бітної роздільної здатності, читання даних з scratchpad пам'яті давача командою READ SCRATCHPAD 0xBE, обчислення CRC для перевірки цілісності даних, перетворення бінарного значення в температуру з урахуванням роздільної здатності [79].

Для оптимізації енергоспоживання при роботі з множинними давачами DS18B20 використовується режим паралельного перетворення. Всім давачам одночасно відправляється команда SKIP ROM 0xCC з наступною командою CONVERT T, що дозволяє виконувати вимірювання на всіх давачах паралельно. Під час перетворення мікроконтролер може виконувати інші завдання [79].

Обробка даних з давача DHT22 вимагає точного дотримання часових інтервалів протоколу. Мікроконтролер ініціює зв'язок, встановлюючи лінію даних в низький рівень на 1-2 мс, після чого давач відправляє 40 біт даних: 16 біт вологості, 16 біт температури та 8 біт контрольної суми. Дані передаються за допомогою широтно-імпульсної модуляції, де тривалість високого рівня визначає значення біта. Для підвищення достовірності показань реалізовано алгоритм фільтрації даних на основі медіанного фільтра з вікном на 5 вимірювань. Це дозволяє ефективно відсікати викиди, спричинені електромагнітними завадами або збоями в роботі давачів. Додатково застосовується експоненціальне згладжування з коефіцієнтом $\alpha=0.2$ для плавної зміни показань. Алгоритм детекції аномалій базується на статистичному аналізі потоку даних. Для кожного параметра визначається нормальний діапазон значень на основі історичних даних за останні 24 години. Значення, що виходять за межі 3σ три стандартних відхилення, позначаються як потенційні аномалії та підлягають додатковій перевірці.

Синхронізація даних з різних давачів здійснюється за допомогою міток часу з точністю до мілісекунди. Використовується внутрішній RTC Real-Time Clock мікроконтролера, який синхронізується з NTP-сервером при наявності інтернет-з'єднання, приклад реалізації на рис. 2.7. При відсутності зв'язку використовується

локальний лічильник часу з корекцією дрейфу на основі температурної компенсації [77].

```
// Таймаут підключення WiFi (15 секунд)
unsigned long startAttempt = millis();
while (WiFi.status() != WL_CONNECTED) {
    delay(500);
    Serial.print(".");
    if (millis() - startAttempt > 15000) {
        Serial.println(F("\nWiFi Failed! Sleeping..."));
        goToDeepSleep();
    }
}
Serial.println(F("\nWiFi Connected!"));

// Налаштування часу
configTime(TZ_OFFSET * 3600, 0, "pool.ntp.org", "time.nist.gov");
Serial.print(F("Waiting for NTP"));

// Таймаут синхронізації часу (10 секунд)
startAttempt = millis();
while (time(nullptr) < 100000) {
    delay(500);
    Serial.print(".");
    if (millis() - startAttempt > 10000) {
        Serial.println(F("\nNTP Failed! Moving on without correct time.));
        break;
    }
}
Serial.println(F(" Done.));
```

Рис. 2.7 Приклад реалізації синхронізації часу в системі.

Для забезпечення цілісності даних при тимчасовій втраті зв'язку реалізовано циклічний буфер на 1000 записів в енергонезалежній пам'яті EEPROM. Кожен запис містить мітку часу, ідентифікатор давача, значення параметра та прапорці стану. При відновленні зв'язку буферизовані дані автоматично передаються на сервер з позначкою про затримку [82].

Алгоритм агрегації даних виконує попередню обробку перед передачею на сервер. Для кожного параметра обчислюються: середнє значення за період, мінімум та максимум, стандартне відхилення, кількість вимірювань. Це дозволяє зменшити обсяг переданих даних при збереженні інформативності для аналізу тенденцій, отримані дані формуються в пакет і відправляються на сервер [80] за допомогою протоколу MQTT, фрагмент коду із реалізацією наведено на рис. 2.8.

```

char jsonBuffer[512];

serializeJson(doc, jsonBuffer); // print to client

client.publish(AWS_IOT_PUBLISH_TOPIC, jsonBuffer);

Serial.println("Package sended");

Serial.println("Shutdown");

digitalWrite(D4, HIGH);

digitalWrite(D6, HIGH);

digitalWrite(D7, HIGH);

digitalWrite(D5, LOW);

Serial.println("Switch off");

```

Рис. 2.8 Реалізація передачі даних з давачів через MQTT протокол.

Обробка зображень з камери OV2640 включає захоплення кадру в форматі JPEG з роздільною здатністю 800×600 пікселів, що забезпечує баланс між якістю зображення та розміром файлу 50-100 КБ. Такий розмір зображення дозволяє швидко відправляти дані через мережу, не втрачаючи на якість та час на передачу. Реалізовано алгоритм автоматичної корекції експозиції на основі аналізу гистограми яскравості. Знімки синхронізуються з показаннями давачів для комплексного аналізу стану біомаси [54].

```

22:38:40.114 ->
22:38:40.114 -> Connecting to WiFi...????? http://192.168.0.23
22:38:40.114 -> psramFound
22:38:40.909 -> Listing directory: /
22:38:40.909 -> Taking a photo...
22:38:43.305 -> Picture file name: /photo.jpg
22:38:43.757 -> The picture has been saved in /photo.jpg - Size: 29636 bytes
22:38:43.968 -> FILE: photo.jpg SIZE: 29636
22:38:44.106 -> We are ready
22:38:46.633 ->
22:38:46.633 -> time-keep: 2529311sntp.org
22:38:46.633 -> Response:
22:38:46.839 -> Photo is ok

```

a)

```

WiFi.begin(ssid, password);
Serial.print("Connecting to WiFi");

int attempts = 0;
while (WiFi.status() != WL_CONNECTED) {
    delay(500);
    Serial.print(".");
    attempts++;
    if (attempts > 40) { // 20 секунд
        Serial.println("\nWiFi Failed. Restarting ESP.");
        ESP.restart();
    }
}
Serial.println("\nWiFi Connected. IP: " + WiFi.localIP().toString());
}

void initCamera() {
    camera_config_t config;
    config.ledc_channel = LEDC_CHANNEL_0;
    config.ledc_timer = LEDC_TIMER_0;
    config.pin_d0 = Y2_GPIO_NUM;
    config.pin_d1 = Y3_GPIO_NUM;
    config.pin_d2 = Y4_GPIO_NUM;
    config.pin_d3 = Y5_GPIO_NUM;
    config.pin_d4 = Y6_GPIO_NUM;
    config.pin_d5 = Y7_GPIO_NUM;
    config.pin_d6 = Y8_GPIO_NUM;
    config.pin_d7 = Y9_GPIO_NUM;
    config.pin_xclk = XCLK_GPIO_NUM;
    config.pin_pclk = PCLK_GPIO_NUM;
    config.pin_vsync = VSYNC_GPIO_NUM;
    config.pin_href = HREF_GPIO_NUM;
    config.pin_sccb_sda = SIOD_GPIO_NUM;
    config.pin_sccb_scl = SIOC_GPIO_NUM;
    config.pin_pwdn = PWDN_GPIO_NUM;
    config.pin_reset = RESET_GPIO_NUM;
    config.xclk_freq_hz = 10000000;
    config.pixel_format = PIXFORMAT_JPEG;

    if (psramFound()) {
        config.frame_size = FRAMESIZE_SVGA;
        config.jpeg_quality = 10;
        config.fb_count = 1;
    } else {
        config.frame_size = FRAMESIZE_VGA; //800x600
        config.jpeg_quality = 12;
        config.fb_count = 1;
    }

    esp_err_t err = esp_camera_init(&config);
    if (err != ESP_OK) {
        Serial.printf("Camera init failed with error 0x%x", err);
        delay(1000);
        ESP.restart();
    }
}

```

б)

Рис. 2.9 а) Логування підключення до мережі, б) Налаштування підключення до мережі

2.2.2. Організація передачі даних з використанням промислових протоколів

Передача даних в системі моніторингу біогазової установки організована з використанням багаторівневої архітектури промислових протоколів, що забезпечує надійність, масштабованість та сумісність з існуючими системами автоматизації.

Логування інформації про підключення до мережі допомагає відслідковувати потенційні проблеми на рівні підключення по протоколу Wi-Fi, рис. 2.9 а, б, який використовується на фізичному рівні використовуються Wi-Fi канал зв'язку [81].

Основу комунікаційної інфраструктури системи моніторингу складає безпроводне з'єднання Wi-Fi, яке забезпечує доступ IoT-модулів до мережі Інтернет. Обрано модулі на базі контролерів ESP8266/ESP32 із вбудованим Wi-Fi, що працюють у діапазоні 2.4 ГГц та підтримують стандарти 802.11b/g/n. Приклад налаштування підключення та логування процесу підключення зображено на рис. 2.9 а, б. Це рішення зумовлене поєднанням відносно високої пропускної здатності та доступності: Wi-Fi дозволяє передавати як невеликі телеметричні дані, так і більш «важкі» об'єкти наприклад, зображення без додаткових витрат на мобільний зв'язок. В умовах біогазової установки, розташованої на обмеженій території, розгортання локальної Wi-Fi мережі є доцільним, оскільки забезпечує достатню зону покриття для всіх давачів і пристроїв. До того ж, Wi-Fi модулі інтегровані в ESP32/ESP8266 спрощують апаратну схему і знижують вартість системи, що є важливим фактором для аграрних IoT-застосувань. Перед виходом у Інтернет IoT-модуль встановлює з'єднання з локальною точкою доступу Wi-Fi; лише після цього ініціюється передача даних до хмарної інфраструктури. Спрощена схема передачі даних між рівнями системи наведена на рис. 2.10.

Такий двоетапний підхід дозволяє заощаджувати енергію: більшу частину часу пристрій може перебувати в режимі очікування, активуючи Wi-Fi модуль тільки для надсилання чергової порції даних.

В контексті сільського господарства та відновлюваної енергетики використання Wi-Fi має додаткові переваги. По-перше, це поширена технологія з добре розвинутою сумісністю - більшість сучасних мікроконтролерів мають Wi-Fi, а налаштування мережі не потребує спеціалізованого обладнання. По-друге, Wi-Fi забезпечує високошвидкісну передачу, необхідну для мультимедійних даних наприклад, фото біоматеріалу. По-третє, на відміну від дротових рішень, безпроводне підключення спрощує встановлення давачів на фермах і біогазових установках, де прокладання кабелів може бути складним або затратним.




Рис. 2.10 Спрощена схема передачі даних між рівнями системи.

Таким чином, Wi-Fi виступає гнучким і ефективним каналом для первинної доставки даних від пристроїв моніторингу. Недоліком Wi-Fi є обмежена дальність і потенційна нестабільність з'єднання через завади або зникнення живлення точки доступу, проте система компенсує це за рахунок механізмів повторних спроб і буферизації даних.

Основним засобом передавання телеметричної інформації показників сенсорів обрано протокол Message Queuing Telemetry Transport MQTT легкий протокол обміну повідомленнями, спеціально спроектований для IoT-систем з обмеженими ресурсами та ненадійними мережами. MQTT працює за моделлю публікація/підписка (publish-subscribe): всі повідомлення передаються через центральний вузол - MQTT-брокер, до якого підключаються як видавці пристрої, що публікують дані, так і абоненти сервіси або інші пристрої, що отримують дані [80]. Така архітектура усуває пряму прив'язку між відправником і одержувачем, забезпечуючи гнучкість і масштабованість.

Зокрема, брокер виконує фільтрацію і маршрутизацію повідомлень за темами (topics): кожне повідомлення має тему, відповідно до якої брокер доставляє його лише тим клієнтам, що на неї підписані. MQTT став де-факто стандартом для IoT-систем завдяки малій навантаженості мережі та ефективності передачі. В нашій системі брокером MQTT виступає сервіс AWS IoT Core, що може надійно приймати мільйони MQTT-повідомлень одночасно. Кожен IoT-модуль реєструється в хмарі як окремий пристрій - Thing у AWS IoT із власними цифровими сертифікатами для автентифікації. Це дозволяє AWS IoT Core однозначно і безпечно ідентифікувати джерело даних та застосовувати політики доступу для кожного пристрою.

Для впорядкування потоків даних використано ієрархічну структуру топиків MQTT, яка відображає логіку предметної області. Кожне повідомлення публікується пристроєм в певну тему - фактично рядок-ідентифікатор, що має структуру із сегментів, розділених символом “/”. Наприклад, було передбачено топик виду: plant1/ustanovka1/temperature. У цій темі перший сегмент позначає завод застосування “plant1”, другий - конкретну установку, третій - тип даних температура. Така структуризація дозволяє системі гнучко фільтрувати повідомлення: хмарний брокер, отримавши повідомлення, розуміє з його теми, до якої категорії належать дані, і може згідно з наперед заданими правилами переспрямувати їх у потрібні сервіси. В AWS IoT Core це реалізовано через Rules Engine - вбудований механізм правил: зокрема, правило, задане SQL-подібним синтаксисом, автоматично перехоплює всі повідомлення з топика сенсорних даних і, згідно логіки системи, одночасно зберігає їх у хмарному сховищі та викликає подальшу обробку AWS Lambda.

```

1  {
2    "sql": "SELECT * FROM 'plant1/*'",
3    "ruleDisabled": false,
4    "awsIotSqlVersion": "2016-03-23",
5    "actions": [
6      {
7        "s3": {
8          "roleArn": "arn:aws:iam::123456789012:role/service-role/IoTDataStorageRole",
9          "bucketName": "biogas-sensor-data-storage",
10         "key": "plant1/${topic(2)}/${timestamp()}"
11       }
12     },
13     {
14       "lambda": {
15         "functionArn": "arn:aws:lambda:us-east-1:123456789012:function:BiogasDataProcessor"
16       }
17     }
18   ]
19 }

```

Рис. 2.11 Приклад правила для отримання даних із топіка MQTT

В даному (рис. 2.11) прикладі реалізовано резервне збереження даних, зі всіх тем у БД DynamoDB. Таким чином, через теми MQTT здійснюється логічне розділення потоків: різні типи даних телеметрія, сповіщення, керуючі команди можуть надсилатися по окремих каналах, не заважаючи один одному. В нашому випадку всі виміряні сенсорні показники температура, вологість публікуються в тему, зарезервовану для телеметрії, яка відстежується брокером та спрямовується в БД DynamoDB для зберігання і аналізу.

Повідомлення MQTT має компактну дворівневу структуру: заголовок і корисне навантаження. Фіксований заголовок містить тип повідомлення і службові прапори, а також довжину решти пакета. Для наших цілей найважливішими є пакети типу публікація даних PUBLISH. В заголовку PUBLISH зазначаються: тема публікації, рівень QoS, прапор дублікату та прапор ретейн збереження. Змінний заголовок може містити ідентифікатор повідомлення для QoS>0. У полі payload передаються власне дані сенсора у зручному форматі. Ми застосували формат JSON для корисного навантаження, оскільки він є легким для парсингу на мікроконтролері за допомогою бібліотеки ArduinoJson та широко підтримується в хмарних сервісах.

Такий формат дозволяє одним повідомленням передати декілька параметрів, що зменшує кількість окремих повідомлень. Це підтверджує доцільність вибору: великі об'єкти, наприклад, файли зображень краще передавати не через MQTT, а іншими засобами у нашому випадку - HTTPS, тоді як MQTT оптимальний для невеликих повідомлень сенсорних даних. В цілому формат MQTT-пакета мінімізований якщо дані дуже короткі, заголовок може вміщуватися в 2 байти, що дає змогу максимально ефективно використовувати пропускну здатність мережі [201]. Така економія трафіку є критичною для багатьох IoT-сценаріїв, де канал зв'язку може бути повільним або дорогим.

Протокол MQTT підтримує три рівні якості обслуговування QoS для доставки повідомлень, що дозволяє балансувати між надійністю й витратами трафіку. Рівень QoS 0 не гарантує доставки: повідомлення відправляється лише один раз і не підтверджується отримувачем - це найменш надійний, але найлегший спосіб. Рівень QoS гарантує, що повідомлення буде доставлено мінімум один раз відправник зберігає повідомлення, поки не отримає підтвердження PUBACK від брокера у разі втрати пакета відбувається повторна передача. Це може призвести до дублювання повідомлень, але одержувач на кожне повторне доставлене повідомлення все одно надішле ACK, тож видавець знає, що хоча б один екземпляр успішно дійшов. Рівень QoS 2 - найбільш надійний забезпечує унеможливлення дублікатів, досягаючи доставки рівно один раз шляхом складного чотири стадійного рукоштовування, це забезпечується обміном пакетами PUBREC, PUBREL, PUBCOMP між видавцем і брокером. QoS 2 генерує найбільше службового трафіку, тому використовується лише для критично важливих даних, де дублікат є недопустимим, наприклад, команди, що можуть спричинити небажану дію при повторі або аварійні повідомлення [80].

У нашій системі для більшості сенсорних даних достатнім є QoS 1, адже втрата навіть одного вимірювання може спотворити модель або залишити прогалину у часовому ряді. QoS 1 гарантує, що дані надійдуть хоча б один раз, що прийнятно для задач моніторингу можливі дублікати потім відфільтровуються за часовими мітками або унікальними ID. QoS 0 використовується лише для несуттєвих повідомлень, наприклад, періодичних сигналів життєздатності, оскільки він не навантажує мережу

зайвими підтвердженнями. QoS 2 в рамках моніторингу не застосовувався, бо генерує надмірний трафік він зарезервований для потенційних сценаріїв дистанційного керування установкою, де необхідна абсолютна гарантія виконання команди один раз.

Завдяки підтвердженням на рівнях QoS>0 MQTT забезпечує механізм підтвердження доставки після отримання повідомлення брокер надсилає відправнику ACK PUBACK для QoS1, чи послідовність PUBREC/PUBREL/PUBCOMP для QoS2) [201]. IoT-модуль, отримавши підтвердження, може вилучити повідомлення з локального буфера, знаючи, що брокер його успішно прийняв. Якщо ACK не надійшло, клієнт MQTT повторно відправить повідомлення для QoS1 або продовжить процес рукостискання як для QoS2 доки не досягне успіху або не перевищить ліміт спроб. Таким чином, з точки зору видавця QoS 1 і 2 дають гарантію доставки на брокер, а з точки зору кінцевого споживача - брокер вже сам подбає про пересилання підписникам згідно їх QoS. В нашому випадку кінцевим одержувачем сенсорних даних ДБ DynamoDB, куди брокер публікує дані через правило. DynamoDB виступає споживачем з боку брокера, але взаємодія реалізована всередині AWS через Rules Engine і гарантується самої інфраструктурою AWS IoT. Отже, найважливішим було надійно доставити дані від пристрою до брокера, із чим QoS 1 успішно справляється.

Для підвищення надійності передачі даних у розробленій системі реалізовані механізми локальної буферизації та повторних спроб. Оскільки електрична мережа може бути нестабільна і можливі перебої живлення або інтернет-зв'язку, IoT-пристрій повинен стійко переносити тимчасову недоступність мережі. Алгоритм роботи модуля передбачає, що у разі невдалої відправки даних або втрати з'єднання, зібрані показники не скидаються, а тимчасово зберігаються у пам'яті пристрою файлова система SPIFFS. Такий підхід формує своєрідну чергу повідомлень на боці давача: кожен новий запис додається в кінець черги, а після відновлення зв'язку черга обробляється - повідомлення надсилаються до хмари в тому порядку, в якому були зібрані. Це гарантує, що дані не будуть втрачені навіть при тривалій відсутності мережі, а також зберігається коректна хронологія вимірювань. У реалізації використано бібліотечні засоби роботи з SPIFFS та невеликий файл як буфер; після

успішного отримання підтвердження АСК отримання на стороні хмарного сервісу AWS IoT на чергове повідомлення, воно видається з файлу.

Важливим доповненням є стратегія експоненційного збільшення інтервалу для повторних спроб з'єднання. Після першої невдалої спроби надсилання, пристрій не намагається підключитися заново негайно, а чекає деякий короткий час, а саме 30 секунд. Якщо наступна спроба знову провалилась, інтервал очікування збільшується вдвічі до 1 хвилини, потім до 2, 4 і т.д., до 16 хвилин. Такий алгоритм запобігає перевантаженню мережі та швидкому розрядженню батареї у разі тривалих збоїв зв'язку замість безперервних частих спроб, але водночас не припиняє спроб взагалі. Як тільки з'єднання відновиться, IoT-модуль негайно виходить із режиму `backoff` і передає накопичені дані. В нашій системі експоненційна затримка довела свою ефективність - навіть при збоях Wi-Fi пристрої не втрачали дані і не перевантажували мережу зайвим трафіком.

Крім буферизації у випадку аварійного розриву зв'язку, застосовано і підхід батчинг пакетної відправки даних при нормальній роботі. Замість того, щоб надсилати окреме MQTT-повідомлення на кожен сенсор або кожне значення, пристрій об'єднує кілька вимірювань в одному повідомленні як продемонстровано у наведеному вище JSON-прикладі. Наприклад, якщо модуль має три давачі температури, він може зібрати дані з усіх трьох і надіслати одним повідомленням разом з часовою позначкою. Це знижує службові накладні витрати, один заголовок на кілька значень та забезпечує атомарність. Всі показники, що належать до одного часового кроку, потрапляють у хмару одночасно. На боці хмарного брокера таке повідомлення буде оброблено як одна логічна подія, що спрощує подальшу фільтрацію і збереження. Такий батчинг особливо корисний у IoT пристроях, де сенсорні вузли можуть мати багато різнорідних давачів, і відправка кожного окремо створювала б зайве навантаження.

Необхідно зауважити, що MQTT підтримує механізми чергування повідомлень і на стороні брокера. Якщо клієнт-підписувач відключений, брокер може зберігати для нього повідомлення за умови попереднього встановлення прапора `retain` або використання постійної сесії з `cleanSession=false`, а при відновленні зв'язку - передати

накопичене. У нашій архітектурі основним споживачем даних є хмарні сервіси, які працюють постійно, тому така функція брокера не була задіяна.

Підсумовуючи, комбінація локальної буферизації даних, експоненційного бекофу, пакетування кількох значень в одному повідомленні та використання QoS-підтверджень дозволила досягти високої надійності передачі при мінімальному навантаженні на мережу. За результатами тестування, надійність збору даних системою сягнула 98,6%, а втрати були спричинені переважно зовнішніми факторами живлення, доступ до мережі. Отриманий результат підтверджує ефективність описаних механізмів: навіть для систем з обмеженими ресурсами та нестабільним з'єднанням можна забезпечити майже безперервний потік телеметрії.

Телеметричні дані сенсорів становлять лише частину інформації, що моніториться у біогазовій установці. Іншим важливим джерелом є зображення біомаси, які отримує фотомодуль - камера 2 Мп на базі ESP32 для оцінки якості субстрату. На відміну від числових показників, фотографії мають значний об'єм, в нашому випадку від 40 до 120Кб. Передавати такі великі об'єкти через MQTT було б неефективно, хоча MQTT-протокол дозволяє двійковий payload, брокери та клієнти накладають обмеження на розмір повідомлення, як згадувалось, ~128 КБ для AWS IoT, до того ж передача зображення потребує розбиття на фрагменти або спеціального кодування, що ускладнює систему. Тому для відправки файлів зображень в архітектурі застосовано стандартний веб-протокол HTTPS з методом POST. IoT-пристрій після захоплення чергового знімка формує HTTP POST-запит до спеціальної веб-API кінцевої точки, розгорнутої в хмарі. В нашому випадку використовувався сервіс AWS API Gateway [92], налаштований для прийому POST-запитів із даними зображення. Таким чином, ESP32 виступає HTTP-клієнтом, що відправляє файл у форматі JPEG у тілі запиту на адресу API Gateway. Такий підхід має декілька переваг:

- Можливість передати великі обсяги даних. HTTP протокол надбудований над TCP, який в свою чергу дбає про потокову передачу доволіно великих даних з контролем цілісності. На практиці, відправка фото розміром, приміром, 40-120 КБ, виконується за один запит без потреби ручного фрагментування.

- Простота інтеграції з хмарою. API Gateway автоматично приймає HTTP-запит і може виконати необхідні дії: у нашій системі він після отримання файлу передає його в сховище S3. Для ESP32 немає різниці, куди спрямований запит - це може бути будь-який сервер. Такий слабо-зв'язаний підхід дозволяє змінювати серверну логіку, за необхідності, адресувати зображення іншим сервісам без зміни прошивки пристрою, доки URL залишається тим самим.
- Надійність та підтвердження. HTTP працює поверх TCP/IP, який гарантує доставку пакетів зі своїми механізмами забезпечення доставки. До того ж, HTTP протокол передбачає чітку модель запит-відповідь після надсилення даних пристрій отримує від серверу відповідь із кодом статусу - «200 OK» при успішному збереженні. Це слугує явним підтвердженням для IoT-модуля, що файл прийнято та оброблено сервером. Якщо відповідь не отримана або містить код помилки, пристрій повторить спробу відправки.

В нашій реалізації IoT-модуль після успішного з'єднання з Wi-Fi спочатку надсилає MQTT-повідомлення з сенсорними даними, а відтак виконує HTTPS POST із файлом зображення. Обидва канали працюють паралельно і незалежно - це оптимізує процес передачі, дозволяючи числовим показникам надходити з мінімальною затримкою, тоді як більш повільна передача фото не блокує основний потік даних. У хмарі ці два потоки сходяться: AWS IoT Core отримує MQTT-повідомлення і кладе дані в DynamoDB, API Gateway приймає файл та зберігає його в S3. Далі спеціальна функція-обробник AWS Lambda відслідковує появу нового фото в сховищі і запускає аналіз, перевіряючи наявність відповідного телеметричного запису. Така двоканальна схема підтвердила свою ефективність як показали експерименти, середній час від збору даних до генерації аналітичних результатів після передачі і обробки склав 3.2 хвилини, що є прийнятним показником для прийняття рішення оператором.

Для IoT-систем розмежування типів трафіку легковаговий і частий та великоваговий і нечастий є виправданим. Легковаговий MQTT чудово підходить для регулярного моніторингу параметрів температур, вологості тоді як HTTPS доцільно використовувати для передачі великих обсягів даних, таких як зображення субстрату

або оновлення прошивки пристроїв. В енергетиці, зокрема біогаз часто потрібно передавати як показники давачів у реальному часі, так і результати лабораторних аналізів або фото, відео стану обладнання - тому комбінування кількох протоколів в єдиній системі підвищує її гнучкість.

Оскільки передані дані можуть містити важливу інформацію, в системі приділено значну увагу безпеці передачі. Всі канали зв'язку реалізовані з використанням шифрування Transport Layer Security TLS [160]. А саме MQTT-трафік проходить через AWS IoT Core виключно по захищеному з'єднанню TLS порт 8883, а HTTP-запити виконуються за протоколом HTTPS - порт 443, який є HTTP поверх TLS. Це забезпечує шифрування всього трафіку, тобто дані сенсорів і зображення передаються в зашифрованому вигляді і не можуть бути прочитані або підроблені при перехопленні. AWS IoT вимагає, щоб усі підключення від пристроїв були захищені TLS, і щоб кожен пристрій мав дійсні цифрові сертифікати для автентифікації [53]. У нашій системі під час реєстрації кожного IoT-модуля в AWS IoT Core було згенеровано X.509 сертифікат клієнта та приватний ключ. Ці дані записані у пам'ять пристрою у захищену область flash і використовуються бібліотекою PubSubClient разом із WiFiClientSecure для встановлення TLS-з'єднання з брокером. При обміні даними TLS клієнтський сертифікат перевіряється сервером AWS IoT Core - таким чином сервер впевнюється, що до нього підключається саме авторизований пристрій. З іншого боку, пристрій також верифікує справжність сертифіката AWS кореневого центру сертифікації Amazon - це запобігає можливому «маскуванню» стороннього сервера під справжній. Така взаємна автентифікація mutual TLS встановлює довірливий контекст для обміну даними. TLS-шифрування гарантує конфіденційність та цілісність інформації. Алгоритми шифрування AES-256 унеможливають прочитання змісту телеметрії чи фото сторонніми особами без ключів, а вбудовані механізми контролю цілісності цифрові підписи сертифікатів не дозволять непомітно змінити дані під час транзиту. Для промислових і IoT-систем це критично по-перше, забезпечується захист комерційної та технологічної інформації, наприклад, рецептура сировини біогазової установки; по-друге, запобігається можливість аварій, саботажу чи маніпуляцій якщо будуть спотворені дані сенсорів в мережі, що могло б призвести

до хибних рішень, або перегріву реактора, TLS та цифрова автентифікація цьому заважають.

При розробці інфраструктури було враховано, що життєвий цикл пристроїв може вимірюватися роками. За цей час криптографічні ключі можуть стати скомпрометованими або застаріти, тому важливо підтримувати можливість їх регулярної заміни - ротації ключів/сертифікатів. В AWS IoT існують вбудовані засоби для відкликання сертифікатів та випуску нових. Кожному пристрою призначався унікальний сертифікат, це дозволяє точково відкликати доступ окремому пристрою в разі проблем, не впливаючи на інших. Сертифікати мають обмежений термін дії, після чого їх потрібно оновити. Наші пристрої підтримують процедуру оновлення сертифіката за командою з хмарного сервісу вони можуть згенерувати новий ключ і запит на сертифікат CSR, передати його в хмару, отримати підписаний новий сертифікат та встановити його замість старого. Такий механізм автоматизованої ротації є найкращою практикою IoT-безпеки, адже дозволяє періодично оновлювати криптографічні дані без фізичного доступу до пристроїв. Якщо апаратно модуль не має сховища ключів TPM/HSM, доцільно робити ротацію частіше [53]. В нашому випадку ESP32 не містить апаратного TPM, тому ми заклали можливість щорічної заміни сертифікатів.

До засобів гарантування безпеки у хмарному середовищі слід віднести політики доступу AWS IoT Policies, пов'язані з кожним сертифікатом. Вони визначають, які дії дозволені пристрою, наприклад, публікація в певні теми MQTT, відправка HTTPS на конкретну адресу. Дотримано принцип найменших привілеїв пристрої The Principle of Least Privilege, PoLP [202] можуть робити тільки те, що необхідно для їх функції. Це зменшує ризики у випадку компрометації - навіть якщо злоумисник отримає контроль над модулем, він не зможе використати його, скажімо, для доступу до інших сервісів чи пристроїв.

Принцип найменших привілеїв в AWS - це фундаментальна концепція безпеки, згідно з якою кожному користувачеві, процесу або системі надається лише мінімальний обсяг доступу та дозволів, необхідних для виконання конкретного завдання, і нічого більше.

Основна мета цього принципу полягає в мінімізації поверхні атаки та зменшенні ризику несанкціонованого доступу або випадкового пошкодження даних.

В AWS принцип найменших привілеїв реалізується за допомогою сервісу AWS Identity and Access Management IAM [203]. Використовуючи політики IAM, адміністратори можуть точно контролювати, хто користувач, група, роль або сервіс має доступ до яких ресурсів і які дії він може виконувати.

Ключові аспекти та переваги

- Зменшення ризиків - обмеження прав доступу допомагає запобігти поширенню потенційної шкоди у випадку компрометації облікового запису або уразливості системи.
- Покращена ізоляція - якщо один компонент системи скомпрометовано, зловмисник не зможе отримати доступ до інших ресурсів, для яких у цього компонента немає дозволів.
- Відповідність нормативним вимогам - багато стандартів безпеки та нормативних актів вимагають впровадження контролю доступу на основі найменших привілеїв.
- Кращий моніторинг та аудит - точно визначені дозволи полегшують відстеження та аудит дій користувачів і сервісів, спрощуючи виявлення аномальної активності.

Якщо користувачеві потрібен лише доступ для читання об'єктів в певному S3-бакеті, його політика IAM повинна надавати лише дію `s3:GetObject` і тільки для цього конкретного бакету, а не повний адміністративний доступ до S3 чи всіх бакетів. Для програми, яка запускається на інстансі EC2 і потребує доступу до бази даних DynamoDB, слід створити IAM-роль з мінімально необхідними дозволами наприклад, тільки `dynamodb:PutItem`, яку потім призначити цьому інстансу.

Об'єднання кількох протоколів у єдиній системі моніторингу біогазової установки продемонструвало свої переваги. Кожен з застосованих протоколів і технологій був обраний з огляду на його сильні сторони та відповідність вимогам аграрного та енергетичного IoT. Розглянемо їх доцільність:

- MQTT - цей протокол відзначається мінімальними накладними витратами та гнучкістю архітектури «публікація/підписка». Для сільського господарства та відновлюваної енергетики, де можливі сотні давачів, розподілених у просторі, MQTT забезпечує масштабованість - легко додавати нові давачі, які просто почнуть публікувати в певні топіки, не потребуючи змін у інших вузлах. MQTT працює ефективно навіть при нестабільному зв'язку, що часто буває в польових умовах: за рахунок QoS і буферизації дані все одно дійдуть до серверу, нехай із затримкою. До того ж, MQTT добре себе зарекомендував у промислових умовах - існують напрацювання щодо оптимізації його для великих навантажень [201], а багато промислових контролерів і платформи як-от SCADA-системи отримали підтримку MQTT, тож інтеграція з ними спрощується.
- HTTPS - використання веб-протоколу виправдане у випадках, коли потрібно передати дані, що не вписуються у вузький формат телеметрії. В нашому проекті HTTPS слугує для завантаження зображень - але в ширшому сенсі, подібний підхід може застосовуватися і для інших задач: наприклад, періодичне завантаження пакетів накопичених даних, отримання конфігурацій з серверу. Перевага HTTPS - це універсальність, надбудова над TCP, яка проходить через майже будь-які мережі маршрутизатори, міжмережеві екрани без спеціального налаштування, адже HTTPS трафік найпоширеніший у Інтернеті. Для IoT, де обладнання може підключатися через публічні мережі, це важливо - MQTT брокер може потребувати відкриття специфічних портів, а HTTPS майже завжди дозволений. Крім того, використання HTTPS спрощує взаємодію з хмарними сервісами та веб-інтерфейсами - наприклад, мобільний додаток чи веб-дешборд можуть прямо отримувати зображення або дані по HTTP API.
- TLS та сертифікати - безпека є невід'ємною вимогою для IoT, особливо в енергетичних системах. Протоколи TLS/SSL наразі стандарт де-факто для шифрування інтернет-трафіку, і їх застосування у нашій системі відповідає галузевим практикам. У сфері відновлюваної енергетики, де IoT-пристрої можуть бути цілями кібератак наприклад, з метою виведення з ладу інфраструктури чи крадіжки даних, надійне шифрування і взаємна

аутентифікація є критично важливими. Наша система продемонструвала, що навіть обмежені пристрої ESP32 успішно виконують TLS-шифрування і можуть керувати сертифікатами. Практична доцільність такого підходу проявилась у захищеності: протягом тестового періоду інцидентів компрометації або втрати даних не виявлено. Крім того, наявність у кожного пристрою унікального сертифіката дала змогу точно керувати доступом - одразу видно, який модуль вийшов з ладу або проявляє аномальну активність, і його можна відкликати без впливу на інших.

- Wi-Fi - використання стандартної технології Wi-Fi виправдане для локального середовища біогазової установки. Wi-Fi модулі були легко інтегровані у пристрої, забезпечили необхідну швидкість особливо для пересилання фотографій і мали достатню дальність для покриття всієї зони експерименту. Альтернативні бездротові технології, наприклад, мобільний 4G або провідні мережі були б або складнішими, або дорожчими, або надмірними для даної задачі. Wi-Fi оптимальний для відносно компактних розподілених систем: на фермі часто вже є інфраструктура Wi-Fi або її нескладно розгорнути. При цьому слід врахувати вимоги до енергоспоживання - Wi-Fi радіо є досить енергозатратними для батарейних пристроїв, але в нашому випадку модулі живляться від мереж, а також працюють циклічно з короткочасною передачею та можливим сном. Важливо, що Wi-Fi забезпечує і високу пропускну здатність, і підключення безпосередньо до Інтернет - тобто не потрібні додаткові шлюзи чи базові станції, як для деяких інших протоколів. Це робить систему дешевшою і простішою.
- Шинні протоколи збору даних 1-Wire - Хоча шина 1-Wire не є мережевим протоколом для віддаленої передачі, варто згадати її роль у локальній організації давачів. давачі температури DS18B20 підключені через інтерфейс 1-Wire до мікроконтролера. Ця технологія відзначається простотою потрібен один сигнальний провід та можливістю підключити кілька давачів в паралель на одну лінію. Для аграрних умов 1-Wire є надійним вибором: вона стійка до завад, дозволяє використовувати довгі дроти десятки метрів без значної втрати

сигналу, а датчики на цій шині дешеві і герметичні як використовувані водонепроникні DS18B20. У нашій системі було розроблено алгоритм пошуку пристроїв на шині 1-Wire з використанням алгоритму перебору ROM-адрес, щоб автоматично виявляти підключені датчики при запуску модуля [82]. Це спрощує обслуговування: у випадку заміни або додавання датчика не потрібно перепрошивати контролер, він сам знайде новий сенсор. Таким чином, 1-Wire забезпечує гнучке масштабування сенсорної мережі на рівні пристрою, що добре доповнює гнучкість MQTT на рівні хмари.

2.3. Розробка архітектури хмарного рівня системи моніторингу для обробки та зберігання даних

Архітектура серверної частини системи моніторингу біогазового виробництва спроектована за принципами мікросервісної архітектури, що забезпечує високу масштабованість, відмовостійкість та гнучкість розгортання. Основними компонентами серверної інфраструктури є: брокер повідомлень, сервіси обробки даних, API-шлюз, база даних часових рядів, аналітичні сервіси та веб-інтерфейс візуалізації [99]. Центральним елементом архітектури є брокер повідомлень MQTT. Брокер забезпечує маршрутизацію повідомлень між IoT-пристроями та сервісами обробки, підтримує кластеризацію для високої доступності, механізми для збереження повідомлень при відключенні споживачів [81]. Сервіс обробки поточкових даних побудовано на базі IOT Core, що дозволяє обробляти потоки даних в реальному часі.

API-шлюз реалізовано на базі AWS API Gateway, який забезпечує єдину точку входу для всіх клієнтських додатків. Функції API-шлюзу включають: автентифікацію та авторизацію на основі JWT-токенів [161], кешування відповідей для зниження навантаження на backend, трансформацію запитів між різними версіями API. Для зберігання даних часових рядів використовується спеціалізована база даних DynamoDB. Ці рішення оптимізовані для запису великих обсягів метрик з міткою часу та забезпечують: автоматичну компресію старих даних, downsampling для

довгострокового зберігання, вбудовані функції агрегації mean, sum, count, stddev, підтримку continuous queries для автоматичної обробки [102]. Архітектура передбачає горизонтальне масштабування всіх компонентів.

2.3.1. Вибір хмарної інфраструктури для зберігання та обробки великих даних

Для побудови інфраструктури зберігання та обробки великих даних у проєкті обрано платформу Amazon Web Services AWS. Відмінною рисою AWS є масштабованість та надійність. Інфраструктура AWS спроектована для обробки надзвичайно великих навантажень і автоматично адаптується до зростання даних чи кількості запитів [34].

Не менш важливим фактором є надійність і відмовостійкість хмарної платформи. Дані в AWS зберігаються з надлишковістю на кількох незалежних апаратних зонах Availability Zones, AZ, що гарантує збереження інформації навіть у випадку відмови цілої датацентрової зони. Зокрема, служба Amazon S3 забезпечує довговічність зберігання даних на рівні 99,999999999% та доступність 99,99% [33], тобто практично унеможливорює втрату даних і мінімізує простої. Таким чином, вибір AWS як основи хмарної інфраструктури надає впевненість у тому, що система зможе масштабуватись, адаптуватись та працювати надійно навіть за умови стрімкого зростання обсягів даних або кількості підключених пристроїв. Додатковою перевагою AWS є комплексна екосистема сервісів, яка дозволяє будувати кінець-до-кінця рішення для IoT без потреби розгортання власних серверів. У нашому випадку, архітектура системи автоматизованого моніторингу біогазової установки спроектована виключно на керованих сервісах AWS рис. 2.12, що мінімізує операційні витрати на підтримку інфраструктури та прискорює розробку.




Рис. 2.12 Спрощена схема архітектури системи

Нижче детально розглянуто основні компоненти цієї архітектури - AWS IoT Core, Amazon API Gateway, Amazon S3, AWS Lambda, AWS Fargate, Amazon DynamoDB та AWS SageMaker [204] - а також проаналізовано, як їх використання дозволяє реалізувати адаптивну, масштабовану і надійну систему моніторингу.

AWS IoT Core - шлюз для підключення IoT-пристроїв

AWS IoT Core відіграє роль безпечного хмарного шлюзу для взаємодії з фізичними пристроями системи - датчиками та мікроконтролерами. Цей сервіс забезпечує двосторонній зв'язок у реальному часі між пристроями та хмарою, використовуючи легковаговий протокол MQTT, а також підтримує HTTPS і WebSockets для сумісності з різними клієнтами. В нашій системі AWS IoT Core слугує

центральною точкою збору телеметрії: кожен IoT-модуль на базі ESP32 реєструється як окремий пристрій Thing у реєстрі IoT Core з унікальними криптографічними сертифікатами автентифікації. Такий підхід гарантує, що до хмари підключається лише авторизовані пристрої - AWS IoT Core підтримує взаємну автентифікацію TLS з використанням X.509 сертифікатів, а також гнучкі політики доступу на рівні окремого пристрою.

За допомогою вбудованого механізму правил Rules Engine, IoT Core автоматично обробляє вхідні повідомлення від пристроїв і може переспрямовувати їх до інших сервісів AWS для подальшої обробки. Зокрема, в розробленій архітектурі створене правило AWS IoT Rule, яке спрацьовує на кожне отримане повідомлення MQTT від давача і виконує дві дії:

- зберігає цей запис телеметрії в DynamoDB;
- ініціює виклик функції AWS Lambda для подальшого аналізу даних.

Така конфігурація дозволяє побудувати подієво-орієнтований конвеєр обробки, дані від давачів автоматично і майже миттєво передаються в сховище та запускають аналітичні процеси.

Варто зазначити, що AWS IoT Core спроектований з розрахунком на промисловий масштаб IoT-систем. Він масштабується автоматично без потреби вручну додавати сервери: навіть якщо до системи буде підключено тисячі нових пристроїв, хмарний MQTT-брокер зможе стабільно обслуговувати їх усіх паралельно. Для нашої задачі - моніторингу біогазових установок - це означає, що платформа готова до розширення на мережу давачів з кількох чи десятків біореакторів без деградації швидкодії.

Безпека IoT Core відповідає суворим вимогам галузі. Окрім сертифікатів пристроїв, сервіс дозволяє керувати доступом за допомогою політик AWS IoT, наприклад, можна задати, що конкретний пристрій має право публікувати дані лише у визначений MQTT-тему і не може підписуватись на чужі теми. Дані телеметрії передаються з шифруванням TLS 1.2, що унеможливорює перехоплення чи підробку показників по дорозі до хмари. Завдяки цим механізмам, AWS IoT Core створює

надійний і захищений канал передачі даних від фізичних давачів до хмарної платформи.

У підсумку, використання AWS IoT Core суттєво спрощує підключення IoT-пристроїв: розробникам не потрібно самостійно розгортати і підтримувати MQTT-сервер, дбати про масштабування чи відмовостійкість - усі ці завдання вирішує керований сервіс. Це дозволяє зосередитись на логіці збору потрібних даних, знаючи, що хмара надійно прийме їх і негайно запусить наступні кроки аналізу.

Для передачі великих даних, таких як зображення з камери, наша система використовує сервіс Amazon API Gateway. AWS IoT Core оптимізований під невеликі MQTT-повідомлення його максимальний розмір повідомлення - 128 КБ, тому для пересилання фотографій розміром у кілька мегабайт більш доцільно застосувати HTTP-виклик. API Gateway забезпечує стабільну та захищену HTTPS кінцеву точку endpoint, за допомогою якої наш IoT-модуль надсилає знімки біореактора у хмару.

API Gateway є повністю керованим сервісом для створення та управління API, що може працювати у режимі REST або WebSocket API. У контексті нашої архітектури він виконує роль проксі-сервера, який приймає HTTP POST-запити від пристрою, що містять бінарний файл зображення, та маршрутизує ці дані для збереження в сховище S3. Фактично, API Gateway слугує вхідними воротами до хмари для більш важких даних, виступаючи надійним фасадом, котрий абстрагує серверну логіку прийому файлів. IoT-пристрій відправляє зображення стандартним HTTPS-запитом на URL, наданий API Gateway, після чого gateway сам подбає про автентифікацію запиту, буферизацію та передачу файлу в інфраструктуру AWS.

Однією з ключових переваг Amazon API Gateway є автоматичне масштабування та управління навантаженням. Сервіс здатен обробляти до сотень тисяч одночасних викликів API, виконуючи всі необхідні фонові задачі з управління трафіком, балансування навантаження, контролю версій та моніторингу [92]. У випадку нашої системи це означає, що якщо одночасно декілька IoT-модулів почнуть передавати зображення, Gateway зможе їх паралельно прийняти без втрати даних і передати в S3.

У контексті моніторингу біогазової установки Gateway успішно забезпечив прийом великих зображень з мінімальними затримками та автоматично інтегрувався

з іншими сервісами, такими як S3, Lambda, спрощуючи загальну архітектуру. Надійність цього компонента підтверджується тим, що за час експериментальної експлуатації не було втрачено жодного знімка з вини хмарної інфраструктури - всі передані зображення успішно збережені та оброблені.

Amazon S3 Simple Storage Service виконує роль центрального сховища даних у системі - так званого «озера даних» data lake для всіх сирих та проміжних даних. Цей сервіс надає практично необмежене об'ємно об'єктне сховище з автоматичним масштабуванням до рівня екзабайт без втручання користувача. Усі дані з польових пристроїв надходять саме до S3. Показники температури і вологості, фотографії біоматеріалу, а також збережені файли навчених моделей машинного навчання, все це надійно зберігається у відповідних бакетах S3.

Структура даних в S3 організована за принципом файлової системи з ієрархією папок префіксів. Для нашого випадку дані впорядковано наступним чином (логічна структура папок):

- raw-images/ - сирі зображення з фотомодуля формат .jpg, що містять візуальну інформацію про стан біомаси;
- raw-telemetry/ - файли телеметрії з показниками сенсорів формат JSON або CSV, які формують історичний архів вимірювань;
- models/ - snapshots моделей машинного навчання файли .pkl або h5, які зберігаються при оновленнях моделі для версіонування та можливості відкотитися до попередньої версії.

Такий підхід дозволяє організувати довготривале зберігання всіх даних, отриманих у процесі роботи системи, і забезпечує простий доступ до них для аналітики або аудиту. Збереження сирих даних особливо цінне в науково-технічному контексті, адже дозволяє повторно аналізувати їх у майбутньому іншими методами або підтверджувати результати принцип reproducibility.

Однією з причин вибору S3 є її виняткова надійність та тривалість зберігання. Як зазначалося, S3 гарантує довговічність збереження - це означає, що ймовірність втрати об'єкта практично нульова, навіть при зберіганні протягом багатьох років. Для досягнення цього S3 автоматично зберігає кілька копій кожного об'єкта на різних

серверах і в різних зонах доступності регіону. Таким чином, навіть вихід з ладу цілої серверної стійки або приміщення не призведе до втрати файлу. У випадку критичних для експерименту даних, наприклад, фото аномальних ситуацій в біореакторі, така гарантія є надзвичайно важливою.

Масштабованість і продуктивність S3 також відповідають задачам великих даних. Сховище спроектоване для паралельного доступу з багатьох джерел: за потреби сотні процесів можуть одночасно записувати або читати об'єкти без конфліктів і блокувань. Пропускна здатність S3 масштабовано висока - сервіс опрацьовує понад 100 млн запитів на секунду в масштабах AWS, тому навіть масове надходження даних, наприклад, при розгортанні 1000 давачів, не стане вузьким місцем системи. У нашій архітектурі це проявляється в тому, що і AWS IoT Core Rule, і API Gateway можуть паралельно записувати файли в S3 температурні дані та фото відповідно, S3 приймає їх асинхронно, гарантуючи збереження обох. Далі аналітичні задачі Lambda, Fargate можуть читати потрібні файли, також не впливаючи одна на одну.

Оптимізація вартості зберігання ще одна суттєва властивість Amazon S3. Сервіс підтримує кілька класів зберігання даних з різними тарифами: від стандартного Standard для часто доступних даних до архівного Glacier Deep Archive для рідко потрібних. Наша система налаштована так, що нові дані спочатку потрапляють до класичного сховища S3 Standard, але по мірі старіння автоматично переводяться на дешевші рівні. Для цього використано політику життєвого циклу Lifecycle Policy): наприклад, необроблені зображення через 30 днів переміщуються в клас S3 Infrequent Access, а через 90 днів - в Amazon S3 Glacier для архівного зберігання. Така автоматизація дозволяє зменшити витрати на довготривале зберігання без втрати даних. Відповідно, дослідники можуть зберігати весь масив зібраної інформації що з часом може сягати сотень гігабайт практично без побоювань щодо непомірного зростання вартості - старі дані переходять у економний режим зберігання.

Безпека і compliance даних в S3 на високому рівні. За замовчуванням, всі бакети S3 приватні і ніхто, окрім власника та визначених IAM-ролевих, не має доступу до об'єктів. Ми налаштували ролі AWS Lambda та Fargate Task з мінімально необхідними

правами наприклад, Lambda має право читати об'єкти лише з конкретного префіксу raw-telemetry/, а контейнер Fargate читати raw-images/ і писати до DynamoDB. Це відповідає принципу найменших привілеїв і захищає дані навіть у випадку компрометації одного з компонентів. Крім того, S3 підтримує шифрування на боці сервера SSE - файли автоматично шифруються алгоритмом AES-256 при зберіганні. У разі потреби, наприклад, вимоги регулятора, можна задіяти власні ключі AWS KMS для контролю над шифруванням [102].

Отже, Amazon S3 у даній системі виконує критично важливу роль централізованого сховища. Його використання гарантує, що всі зібрані польові дані надійно збережені, доступні для поточного й майбутнього аналізу, а процеси, що до них звертаються, отримують швидкий і паралельний доступ. S3 забезпечує стабільну основу для роботи аналітичних сервісів, позбавляючи розробників від необхідності турбуватись про збереження великих обсягів інформації протягом усього життєвого циклу проєкту.

AWS Lambda - безсерверні обчислення на основі подій, хмарний сервіс для виконання коду за подією без необхідності керувати серверами. У нашій архітектурі функції Lambda виконують роль проміжної ланки між різними компонентами, реагуючи на появу нових даних і координуючи подальші кроки обробки. Зокрема, Lambda задіяна на етапі синхронізації потоків даних: коли до S3 надходить новий файл наприклад, чергове фото, функція Lambda автоматично запускається через механізм сповіщень S3 і перевіряє, чи надійшов відповідний файл телеметрії з показниками сенсорів. Якщо обидва типи даних на місці, Lambda ініціює виконання завдання AWS Fargate для аналізу; якщо ж фото з'явилося раніше за телеметрію, функція завершиться нічого не роблячи - аналіз розпочнеться після надходження повного набору даних, що гарантує цілісність вхідної інформації. Таким чином, AWS Lambda забезпечує гнучку логіку синхронізації між паралельними потоками MQTT і HTTP і запускає потрібні обчислювальні контейнери без втручання користувача.

Технологічно, AWS Lambda - це повністю кероване безсерверне середовище виконання, де код функції працює в ізольованому контейнері і автоматично масштабується під навантаження. Розробник лише завантажує та визначає тригер

події - далі AWS сам виділить ресурси і запустить скільки копій функції, скільки потрібно для обробки всіх подій. Це дозволяє обробляти події в паралельному режимі: якщо за короткий час надходить, наприклад, 10 фотографій, Lambda спрацює 10 разів паралельно, ініціюючи 10 аналізів і відповідно, Fargate запустить 10 контейнерів. Масштабування Lambda відбувається динамічно і майже миттєво - сервіс може за секунди підняти додаткові контейнерні середовища для нових викликів. У простій функції не споживає ресурсів і не коштує грошей. Це надзвичайно ефективно для нерівномірних навантажень, якими характерні IoT-системи, наші давачі передають дані періодично, тож більшість часу аналітичні обчислення не потрібні. AWS Lambda дозволяє не тримати постійно запущений сервер, а виконувати код лише тоді, коли це насправді потрібно.

Інтеграція з іншими сервісами. Lambda тісно інтегрована в екосистему AWS, що значно спрощує побудову складних процесів. Функції можна напряму викликати з AWS IoT Core, з S3 як сповіщення про новий об'єкт, з Amazon DynamoDB, через DynamoDB Streams при появі нового запису. У нашій системі Lambda обслуговує дані з IoT Core, S3, Fargate та DynamoDB в єдиний ланцюжок. Більш того, Lambda може виконувати довільні дії усередині AWS, наприклад, саме Lambda викликає API AWS Fargate через Amazon ECS API, щоб запустити контейнер з аналізом, передаючи йому ідентифікатор файлів зображення і телеметрії для обробки. У іншому сценарії, окрема Lambda може реагувати на появу нових валідованих даних у DynamoDB після того, як оператор ввів фактичний вихід біогазу і таким чином запускати перенавчання моделі. Отже, Lambda виступає своєрідним диспетчером, що автоматизує потік даних і рішень у системі, усуваючи необхідність ручного втручання або постійно працюючого монолітного сервера.

Обмеження і вибір між Lambda та Fargate. AWS Lambda має деякі обмеження, які вплинули на дизайн нашої системи. Зокрема, максимальна тривалість одного запуску функції - 15 хвилин, а максимальна пам'ять - 10 ГБ. Для задач швидкого аналізу зображення це більш ніж достатньо, за нашими спостереженнями у нас типовий час аналізу близько 1-2 хвилини, але для ресурсомістких задач перенавчання моделей цього виявилось замало. Крім того, встановлення специфічних бібліотек у

Lambda обмежене розміром пам'яті. Тому для складніших обчислень і перенавчання було прийнято рішення використовувати AWS Fargate з Docker-образом, де попередньо інстальовано всі потрібні наукові бібліотеки. Таким чином, Lambda виконує тільки легкі координаційні дії перевірка наявності файлів, виклик контейнера, які потребують мінімум ресурсів і часу, що ідеально підходить під її модель. Це демонструє вдале поєднання сервісів Lambda - для оркестрації, Fargate - для важких обчислень, кожен використовується там, де ефективніший.

З точки зору безпеки, AWS Lambda також відповідає високим стандартам. Функції ізольовані одна від одної та від інших клієнтів AWS на рівні інфраструктури. AWS автоматично застосовує останні оновлення безпеки до середовищ виконання. Розробник же контролює права функції через призначену IAM-роль, наприклад, щоб Lambda могла читати з S3 і запускати Fargate, але не мала зайвих повноважень.

Таким чином, AWS Lambda забезпечує гнучку, масштабовану і економічно ефективну обробку подій в нашій архітектурі. Вона відіграє критичну роль у реалізації реактивної логіки системи - автоматизує запуск аналізу та навчання в міру надходження нових даних, що є основою для побудови адаптивної системи реального часу.

AWS Fargate - безсерверне виконання контейнерів для аналізу і навчання при виконанні ресурсомістких обчислювальних задач - таких як аналіз зображень з використанням моделей машинного навчання та донавчання цих моделей - в системі використовується AWS Fargate. Це сервіс, який дозволяє запускати Docker-контейнери в хмарі без необхідності керувати вручну серверами або кластером оркестрації контейнерів. По суті, AWS Fargate є безсерверним рушієм контейнерів, розробник визначає, який контейнер запустити і з якими ресурсами, а AWS автоматично піднімає необхідну інфраструктуру, запускає контейнер, відстежує його виконання і по завершенні звільняє ресурси [100].

В архітектурі нашої системи AWS Fargate інтегровано через сервіс Amazon ECS Elastic Container Service. Сценарій такий - функція Lambda здійснює виклик RunTask API ECS, передаючи ім'я завдання, яке сконфігуровано для запуску Docker-образу з заданими параметрами у режимі Fargate. AWS Fargate отримує це завдання,

автоматично підбирає потрібні віртуальні потужності, розгортає контейнер з нашим образом, і дає йому виконуватись стільки часу, скільки треба. У межах контейнера запускається наш скрипт аналізу він завантажує з S3 потрібні фото і JSON з телеметрією, здійснює обробку зображення корекція, сегментація, розпізнавання аномалій та оцінку виходу біогазу за допомогою ансамблю ML-моделей. Результати цього аналізу зберігаються контейнером у базу даних DynamoDB. При записі в DynamoDB контейнер помічає новий запис спеціальним прапором `trained:false` «не навчений» це означає, що даний вимір ще не використовувався для навчання моделі. Таким чином, Fargate-завдання завершується, виконавши пакетну обробку однієї порції нових даних, одного експериментального циклу.

Одразу видно переваги підходу із Fargate у порівнянні з традиційним виділенням сервером. По-перше, Fargate дозволяє легко масштабувати обробку якщо дані надходитимуть частіше або від множини установок одночасно, ECS може паралельно запустити декілька контейнерів на окремих обчислювальних потужностях, щоб обробити їх одночасно. Система може зрости від 1 до 50 і більше одночасних завдань аналізу лише шляхом виклику `RunTask` в циклі. Відомо, що на AWS Fargate продемонстровано запуск понад 15 000 контейнерів одночасно у межах одного кластеру ECS це показує колосальні можливості масштабування, які навряд чи знадобляться повністю для даного застосування, але гарантує запас на майбутнє. По-друге, Fargate надає гнучкість у виборі ресурсів для кожного завдання для аналізу зображення достатньо 2 vCPU і 4 ГБ пам'яті, а для навчання моделі можна задати 4 vCPU і 16 ГБ. Сервіс дозволяє конфігурувати до 16 vCPU і 120 ГБ RAM на контейнер, що дає змогу виконувати навіть дуже вимогливі обчислення придбання дорогого обладнання локально. У разі потреби можна запускати контейнери на базі GPU через інтеграцію Fargate з AWS Batch або Amazon EKS це б знадобилось, якби ми тренували, наприклад, глибоку CNN-модель, поки що наша задача вирішується швидко і на CPU.

Спрощення управління інфраструктурою. Як наголошувалось, AWS Fargate повністю знімає з користувача турботи про управління серверами. Нам не треба налаштовувати EC2-вузли, слідкувати за оновленнями ОС чи розкладати по них

контейнери Fargate це зробить автоматично. Це суттєво економить час та виключає ризики, пов'язані з ручним адмініструванням такі як помилки конфігурації, проблеми безпеки тощо. Команда може зосередитися на вдосконаленні моделей розпізнавання і прогнозування, а не на підтримці серверів.

Ізоляція та безпека. Кожне завдання AWS Fargate запускається в ізольованому середовищі, що підвищує загальну безпечність системи. Наприклад, якщо під час аналізу станеться помилка витік пам'яті або збій у бібліотеці, це ніяк не вплине на інші запущені процеси - контейнер просто завершиться, і Lambda зможе при потребі перезапустити його знову, хоча за час експериментів жодного падіння аналізу зафіксовано не було. До того ж, кожен контейнер має свою IAM-роль з чітко визначеними правами, тож навіть компрометація контейнера не дасть атакуючому доступу поза межі дозволених дій.

За підсумками тестування система на базі Fargate показала себе ефективною, середній час від моменту збору даних до отримання результатів аналізу склав близько 3 хвилин. З них значна частина - це передача даних, орієнтовно 1-2 хв через мобільний інтернет, тоді як безпосередньо аналітичний контейнер виконував обчислення близько 1 хвилини. Така швидкодія цілком прийнятна для завдання моніторингу, оператор отримує рекомендації майже в режимі реального часу. Важливо, що протягом тестування не було виявлено проблем з масштабованістю Fargate справлявся і з поодиноким запуском, і з піковими сценаріями, коли ми вручну ініціювали декілька паралельних запусків, симулюючи кілька одночасних установок. Це підтверджує, що обрана архітектура готова до розширення без змін - достатньо додати нові IoT-пристрої і хмарні сервіси зможуть їх обслуговувати шляхом запуску додаткових контейнерів.

Отже, AWS Fargate у поєднанні з ECS став ключовим компонентом для реалізації гнучких і масштабованих обчислень у системі. Він дозволив нам виконувати складні операції комп'ютерного зору та машинного навчання по запити, уникаючи утримання серверів на постійній основі. Це ідеально вписується в концепцію Serverless-архітектури, де ресурси витрачаються тільки за прямої необхідності.

Amazon DynamoDB - високопродуктивна NoSQL база даних для результатів і метаданих

Після обробки кожної порції даних телеметрію, зображення результати аналізу та супровідна інформація зберігаються в базі даних Amazon DynamoDB. Це повністю керована NoSQL база даних від AWS, яка підтримує моделі «ключ-значення» та «документ» і забезпечує однозначно малу затримку при будь-якому масштабі. В нашій системі DynamoDB використовується для зберігання записів про кожен вимір цикл моніторингу до таблиці заносяться час виміру, усереднені значення температур, результати аналізу та прогнозований вихід біогазу. Також фіксуються службові поля - наприклад, прапор `trained` чи враховані ці дані в навчанні моделі та унікальний ідентифікатор моделі, яка зробила прогноз. Один із таких записів показано на рис. 2.13, фрагмент таблиці DynamoDB - він позначений як «не навчений», що сигналізує про необхідність донавчання.

```
{
  "measurementId": "reactor_001_2025-07-22T20:00:00Z", // Partition Key (ID
пристрою + час)
  "timestamp": 1753232400, // Sort Key (Часова мітка в
Unix форматі)
  "deviceId": "biogas_reactor_001",
  "image_s3_key": "raw-data/images/2025/07/22/device_001_20250722_200000.jpg", //
Посилання на фото в S3
  "temperature_avg": 36.8, // Середня температура

  "analysis_results": { // Результати аналізу
    "predicted_biogas": 128.5, // Прогноз виходу біогазу
    (м³)
    "foam_detected": false, // Результат аналізу
    зображення
    "color_anomaly": true,
    "recommendations": [ // Згенеровані рекомендації
      {"priority": "important", "text": "Перевірити склад субстрату, зафіксовано
аномалію кольору."}
    ]
  },

  "feedback_data": { // Дані від оператора
    "actual_biogas": 125.2, // Фактичний вихід біогазу
    (м³)
    "operator_notes": "Додано нову партію силосу."
  },

  "training_status": "not_trained" // Мітка для донавчання
  ("not_trained" або "trained")
}
```

Рис. 2.13 Фрагмент даних у записі DynamoDB

Для даної задачі більш доречною була нереляційна БД, оскільки структура даних гнучка і може еволюціонувати. DynamoDB дозволяє зберігати весь запис як JSON-документ атрибути якого можна змінювати без жорсткої схеми, що спрощує додавання нових полів або вкладених структур у майбутньому, наприклад, якщо ми вирішимо зберігати додаткові метрики якості зображення. Крім того, DynamoDB чудово підходить для роботи в режимі реального часу, вона гарантує швидкий доступ по первинному ключу навіть при дуже великій кількості записів - затримка читання/запису залишається на рівні одиниць мілісекунд, навіть якщо в таблиці мільйони об'єктів. Це критично уявити в сценарії, коли оператор відкриває веб-сторінку з останніми даними - система має миттєво вибрати з БД десяток найсвіжіших записів. DynamoDB з цим справляється відмінно завдяки розподіленому зберіганню на SSD і оптимізації під ключові запити.

Масштабованість DynamoDB проявляється у тому, що вона автоматично розподіляє дані між достатньою кількістю серверів під капотом, забезпечуючи необхідну пропускну здатність. Можна вибрати режим on-demand, де БД сама підлаштовує пропускну спроможність під піки навантаження. У традиційному реляційному підході, наприклад, PostgreSQL на EC2, розробникам довелося б постійно моніторити і масштабувати кластер, тоді як AWS повністю управляє аспектами масштабування і продуктивності. Практично це означає, що якщо з часом кількість біогазових установок зросте і в систему буде додаватися тисячі записів щоденно, DynamoDB автоматично розширить свій бекенд, щоб обробити цей потік, без втручання з нашого боку. При цьому зберігається консистентність даних - DynamoDB за замовчуванням забезпечує консистентність читання в межах однієї таблиці в одному регіоні або глобальну консистентність за допомогою глобальних таблиць. Це важливо, щоб оператор або аналітичний модуль завжди бачив актуальні дані після запису. Використання в системі. Таблиця DynamoDB має складений ключ: основний ключ - ідентифікатор біогазової установки, щоб у одній таблиці можна було зберігати дані з кількох установок, якщо система масштабується на кілька об'єктів, та

сортований ключ - мітка часу виміру timestamp. Це дозволяє ефективно вибирати останні N записів по конкретній установці, сортуванням за часом. Запис даних в DynamoDB виконується контейнером Fargate через AWS SDK, а зчитування - або безпосередньо веб-інтерфейсом через AWS API Gateway + Lambda, реалізоване API для фронтенду, також є можливість отримати доступ напряму сервісами аналітики які надає AWS. Наша реалізація веб-сторінки оператора розміщеної на S3 підключається до DynamoDB через AWS JavaScript. Це дозволяє оператору бачити результати в режимі, близькому до реального часу, одразу після їх появи у таблиці.

Механізми DynamoDB використовується також для відстеження того, які дані вже використані для навчання моделі, а які - ні. Поле прапорець trained ініціалізується як false для кожного нового запису. Спеціальний компонент, підсистема донавчання, періодично сканує таблицю на предмет записів з trained=false і підраховує їх кількість. Коли накопичується достатній обсяг нових даних, в нашій реалізації поріг - 100 записів, система запускає процес адаптивного перенавчання моделей. Цей процес вибирає саме ті необроблені записи trained=false, формує з них навчальний набір і після успішного оновлення моделі відзначає їх як trained=true у DynamoDB. Таким чином, база даних виступає ще й інструментом координації адаптивного навчання, фіксуючи кордон між старими і новими знаннями моделі.

Підсумовуючи, Amazon DynamoDB успішно впорався із завданням швидкого та масштабованого зберігання результатів моніторингу. Він надав необхідну гнучкість у схемі даних, високу продуктивність запитів і органічно інтегрувався з іншими безсерверними компонентами Lambda, Fargate. Без використання DynamoDB довелося б витратити значно більше зусиль на підтримку БД, наприклад, кластер SQL, особливо в аспекті масштабування та відмовостійкості. Завдяки DynamoDB база даних стала ще одним керованим і майже непомітним компонентом, який просто працює, забезпечуючи потреби системи у збереженні та швидкому доступі до інформації.

AWS SageMaker - платформа машинного навчання для адаптивного донавчання моделей

Хоча основні аналітичні обчислення виконуються у власноруч підготовлених контейнерах на Fargate, варто відзначити можливості сервісу Amazon SageMaker для задач машинного навчання в хмарі. AWS SageMaker - це комплексна керована платформа, призначена для повного циклу роботи з ML-моделями: від підготовки даних та експериментів з моделювання до розгортання моделей в продакшн та їх моніторингу [204].

На даному етапі реалізації, після накопичення порції нових даних і введення оператором фактичних показників виходу біогазу, система запускає завдання Fargate, яке завантажує весь датасет, старі + нові дані і проводить донавчання моделі transfer learning прямо в контейнері. Підхід із transfer learning полягає в тому, що модель ініціалізується попередніми вагами і продовжує навчання на нових даних, замість починати з нуля - це значно прискорює конвергенцію і потребує менше ресурсів. Після навчання модель зберігається в S3 як нова версія, проходить оцінку на тестовому наборі, і у разі, якщо метрики покращились більш ніж на 5%, система починає використовувати цю нову модель для наступних аналізів. Усі ці кроки наразі реалізовані вручну, але їх можна було б ще більш спростити і зробити більш відтворюваними за допомогою AWS SageMaker.

Безпека та відповідність вимогам в AWS-рішенні

Проектуючи систему моніторингу на базі AWS, значна увага була приділена забезпеченню безпеки даних, стійкості до збоїв та відповідності галузевим стандартам. Хмарна інфраструктура AWS надає багато вбудованих засобів для досягнення цих цілей, і ми активно їх використали:

- Шифрування і захищений транспорт даних. Усі канали зв'язку в системі за замовчуванням захищені: MQTT-повідомлення через AWS IoT Core передаються протоколом MQTTS MQTT over TLS, а HTTP-запити - через HTTPS. Це гарантує, що ні телеметричні показники, ні фотографії не можуть бути перехоплені або змінені третіми особами під час передачі. На рівні зберігання, як було зазначено, дані в S3 та DynamoDB шифруються алгоритмами військового класу. Важливо, що AWS робить шифрування

прозорим для розробника - ввімкнення опції SSE чи KMS займає кілька кліків, після чого вся нова інформація автоматично шифрується перед записом на диск.

- Ідентифікація та автентифікація пристроїв. Кожен IoT-модуль має власний X.509 сертифікат, підписаний центром сертифікації AWS IoT. При підключенні пристрій проходить взаємну автентифікацію: він доводить свою особу сертифікатом, а сервер AWS - своїм. Це усуває ризик підробки даних зловмисником. Сертифікати прив'язані до конкретного Thing в реєстрі; у випадку компрометації сертифікат можна відкликати, ізолювавши конкретний пристрій від системи. Додатково налаштовані політики IoT, які обмежують права пристрою - наприклад, наші давачі мають право тільки публікувати в топик biogas/telemetry і читати конфігурацію з топика biogas/config, всі інші дії заборонені. Це запобігає зловмисному чи помилковому використанню пристрою не за призначенням.
- Контроль доступу для сервісів IAM. Всі компоненти всередині AWS взаємодіють між собою за допомогою ролей IAM з мінімальними необхідними правами. Так, Lambda-функція має політику, яка дозволяє: 1 прочитати об'єкт з бакета raw-telemetry; 2 викликати конкретне завдання ECS Fargate і 3 нічого більше. Контейнер Fargate отримує тимчасову роль, що дозволяє: 1 отримати об'єкт з S3 (зображення); 2 прочитати відповідний файл телеметрії; 3 записати результат у таблицю DynamoDB; 4 покласти нову модель в бакет models/ якщо це завдання перенавчання. Він не має права, наприклад, видаляти файли з S3 чи змінювати політики безпеки. Така політика доступу гарантує, що навіть у разі збою або компрометації одного компонента, шкода буде мінімізована і не пошириться на інші дані.
- Моніторинг та журнали logging. AWS надає сервіс CloudWatch для централізованого збору логів і метрик. Ми налаштували логування для Lambda усі запуски, помилки, для контейнерів Fargate через CloudWatch Logs драйвер та для API Gateway логування запитів. Це дозволило під час розробки й тестування відстежувати весь шлях даних і швидко знаходити причини збоїв. Більше того, CloudWatch Alarms можуть сповіщати про аномалії - наприклад,

якщо функція Lambda раптом почала завершуватись з помилками, або якщо використання пам'яті Lambda наближається до ліміту. За час експериментального запуску критичних інцидентів не сталося, однак наявність системи моніторингу дає впевненість у стабільній роботі на довгому проміжку.

- Відмовостійкість і резервування. Як вже обговорювалось, сервіси AWS автоматично використовують кілька зон доступності. Це особливо важливо для безперервного моніторингу: якщо один датацентр виходить з ладу, інфраструктура продовжує працювати за рахунок резервних копій. У підсумку, єдиними причинами втрати даних за час тестів були проблеми на стороні периферії: перебої електропостачання та інтернету в місці встановлення давачів спричинили. Хмарна ж частина не була джерелом збоїв. Навіть у разі повної недоступності регіону AWS що вкрай малоімовірно, можна розгорнути рішення в іншому регіоні і направити пристрої туди - оскільки все інфраструктурне визначення IoT Core, Lambda, тощо описане кодом Infrastructure as Code, його можна продублювати.
- Відповідність нормативним вимогам. Агро-екологічна галузь може підпадати під регуляції, пов'язані з екологічними стандартами, звітністю даних по викидах парникових газів і т.п. Використання AWS спрощує демонстрацію відповідності, оскільки платформа вже сертифікована за багатьма міжнародними стандартами, про що видаються відповідні звіти AWS Artifact. Наприклад, якщо потрібно підтвердити цілісність зібраних даних при екологічному аудиті, можна скористатися функцією AWS Object Lock на S3 не дає змінювати/видаляти об'єкти до визначеної дати - це гарантує, що історичні показники не були модифіковані заднім числом. Також, завдяки версіонуванню моделей і даних, наша система зберігає всі проміжні артефакти, що є хорошою практикою для верифікації наукових результатів.
- Конфіденційність. В нашій системі немає персональних даних, але принципи конфіденційності були б легко дотримані на AWS, оскільки дані ізольовані в нашому обліковому записі, і доступ до них має лише обмежене коло осіб через захищені механізми. AWS забезпечує відповідність GDPR, тому у разі

доповнення системи, скажімо, персональними даними операторів, це не стало б перешкодою.

Загалом, інтеграція компонентів AWS дозволила побудувати багаторівневу систему захисту без значних зусиль з нашого боку - ми використали найкращі практики, такі як шифрування, IAM, моніторинг, що вже є частиною платформи. До переваг AWS можна віднести:

- Масштабованість для великих даних. Біогазові установки можуть генерувати значні обсяги даних безперервні потоки телеметрії, регулярні знімки, історія на роки. AWS надає інфраструктуру, що природно масштабується під зростання цих даних: від S3, яке може вмістити практично будь-який обсяг інформації, до DynamoDB, що обробляє збільшення частоти записів без деградації продуктивності. Якщо проект буде розширено на десятки установок по різних локаціях, хмарна архітектура витримає таке навантаження, тоді як локальні сервери або менш масштабні рішення могли б швидко досягти меж. Таким чином, AWS забезпечує горизонтальне масштабування системи відповідно до потреб галузі, яка поступово цифровізується і нарощує масиви даних.
- Адаптивність та швидке впровадження змін. Агро-енергетичні процеси, як-от анаеробне зброджування, дуже варіативні і залежать від багатьох факторів склад біомаси, температура довкілля, режими роботи тощо. Тому цінною є здатність системи навчатися на накопиченому досвіді і покращувати моделі по мірі надходження нових даних. AWS надав інструменти для організації замкнутого циклу, завдяки поєднанню S3 для зберігання наборів даних і моделей, Fargate/Lambda для автоматичного запуску навчання і DynamoDB для міток даних вдалося реалізувати механізм додаткового навчання на реальних даних без зупинки системи. Нові дані одразу включаються в модель на черговій ітерації, що підвищує точність прогнозів у нашому експерименті R^2 моделі зріс з 0,85 до 0,91 [205] після першого донавчання, а RMSE [60] знизився на ~42%. Це підтверджує, що архітектура на AWS сприяє побудові самовдосконалюваних систем, здатних адаптуватися до локальних умов кожної установки. Для галузі,

де умови можуть різнитися від ферми до ферми, така адаптивність - ключ до успішного впровадження ІТ-рішень.

- Надійність та безперервний моніторинг. Відстеження біогазових процесів вимагає цілодобової роботи системи і стійкості до різних збоїв в тому числі факторів навколишнього середовища. AWS забезпечив високий рівень надійності хмарної частини: як показали випробування, втрати даних через збій хмари були відсутні, а загальна доступність сервісів дозволила досягти >98% зібраних даних навіть враховуючи зовнішні перешкоди. Це означає, що оператори біогазової установки могли довіряти системі і отримували сповіщення та рекомендації практично у реальному часі без значних прогалин. Умови на фермах часто далекі від ідеальних пил, волога, нестабільна електрика, тому перекладання основної «інтелектуальної» частини на хмару, де гарантується безперервність - це вірне рішення. Навіть якщо локальний модуль перезапуститься або буде вимушено відключений, вся попередня історія вже безпечно збережена в AWS і доступна після відновлення зв'язку.
- Зниження порогу входження і витрат. Для підприємств, які не мають власних ІТ-департаментів, використання AWS дозволяє впровадити передові технології без великих початкових інвестицій. Наша система була розгорнута, скориставшись AWS Free Tier для декотрих сервісів IoT, Lambda, DynamoDB мали безкоштовні ліміти, достатні на етапі розробки. В подальшому оплата масштабувалася разом з використанням, що співпадає з економічними можливостями малого підприємства - платити поступово по мірі отримання користі. Альтернативою було б купувати власні сервери, наймати персонал для їх обслуговування, але це одразу піднімає вартість володіння і вимагає капітальних вкладень одразу. Хмарна модель “infrastructure as a service” зняла ці питання: команда розробників яка може складатися навіть з 1-2 інженерів змогла самотужки реалізувати весь стек, користуючись документацією AWS та керованими сервісами. Це сприяє демократизації технологій: навіть консервативна аграрна галузь отримує доступ до AI/IoT рішень, які раніше були прерогативою великих промислових гігантів.

- Модульність і розширюваність. Архітектура на AWS побудована модульно - окремі сервіси відповідають за окремі функції збір даних, зберігання, обчислення, аналіз, навчання. Це полегшує модифікацію системи: можна замінити або додати компонент, не перебудовуючи все з нуля. Наприклад, якщо виникне потреба аналізувати ще й хімічні показники субстрату, достатньо додати новий сенсор, на AWS IoT Core створити додатковий MQTT-топик і правило запису цих даних у S3/DynamoDB. Сама аналітика може бути додана як окрема Lambda або контейнер. Такі зміни мінімально впливають на інші частини. Це вигідно для дослідницьких проєктів, де вимоги можуть змінюватися, та для галузі в цілому, де кожна ферма може захотіти щось своє. AWS надає гнучкий каркас, на якому можна швидко експериментувати і нарощувати функціональність.
- Широка екосистема та підтримка. Обрання AWS також забезпечило доступ до великої спільноти користувачів, прикладів архітектур, готових рішень для суміжних задач. Під час розробки ми орієнтувалися на рекомендовані AWS патерни для IoT зокрема, багаторівневу обробку з використанням IoT Core, Lambda, DynamoDB, що підтверджено у літературі. У разі виникнення проблем, на AWS re:Post та форумах легко знайти рішення, оскільки подібні системи напр. для тваринництва, рослинництва вже створювалися на AWS. Таким чином, ризики розробки були меншими, а впровадження - швидшим завдяки перевіреним підходам. Для агро-екологічної галузі це означає, що навіть нестандартні завдання можуть вирішуватися з опорою на існуючий досвід, зменшуючи бар'єри для інновацій.

2.3.2. Створення бази даних для параметрів моніторингу

Проектування схеми бази даних для системи моніторингу біогазового виробництва враховує специфіку даних: висока частота надходження, переважання операцій запису над читанням, важливість хронологічного порядку, необхідність довгострокового зберігання, потреба в швидкій агрегації за періодами [75]. Проектування підсистеми зберігання даних є одним із ключових етапів розробки

інтелектуальної системи моніторингу виробництва біогазу. Враховуючи специфіку технологічного процесу анаеробного зброджування, база даних БД повинна задовольняти жорстким вимогам щодо продуктивності запису, надійності зберігання, швидкості доступу до історичних даних та масштабованості. Даний підрозділ детально описує процес вибору типу бази даних, проектування логічної та фізичної моделей, а також стратегії забезпечення життєвого циклу даних.

Першим кроком у проектуванні сховища даних став детальний аналіз інформаційних потоків, що генеруються в системі. Специфіка моніторингу біогазової установки характеризується наступними параметрами, які безпосередньо впливають на архітектуру БД:

- Висока частота дискретизації - Система оперує потоками даних від датчиків температури, вологості. Згідно з розробленими алгоритмами збору даних, частота опитування може змінюватися адаптивно. У моменти пікових навантажень або аварійних ситуацій частота надходження повідомлень може сягати сотень записів на секунду. Це формує профіль навантаження, де операції вставки INSERT значно переважають над операціями читання.
- Часова природа даних: Кожен пакет даних нерозривно пов'язаний з міткою часу. Хронологічний порядок є критичним для аналізу динаміки ферментації. Це вимагає від бази даних ефективних механізмів індексації за часом та підтримки запитів діапазону.
- Необхідність довгострокового зберігання: Для навчання моделей машинного навчання та аналізу сезонних трендів необхідно зберігати "сирі" дані протягом мінімум тривалого часу та агреговані дані протягом року і більше. Це створює проблему експоненціального зростання обсягу сховища.
- Мінливість структури: Архітектура системи передбачає можливість динамічного підключення нових типів датчиків без зупинки системи. Реляційні бази даних з жорсткою схемою можуть бути обмежуючим фактором у цьому випадку.

Враховуючи ці фактори, традиційні реляційні, такі як MySQL або раніші версії PostgreSQL можуть стикатися з проблемами масштабування при збільшенні кількості підключених пристроїв до сотень одиниць. Вертикальне масштабування є економічно неефективним. Тому було прийнято рішення використовувати підхід NoSQL.

На основі аналізу даних, для реалізації основного сховища часових рядів було обрано сервіс Amazon DynamoDB. Цей вибір обумовлений рядом технічних переваг, що ідеально відповідають поставленим вимогам:

- Безсерверна архітектура Serverless: DynamoDB не вимагає адміністрування серверів, встановлення патчів або налаштування кластерів. Це дозволяє зосередитися на логіці додатку, а не на інфраструктурі.
- Передбачувана продуктивність: DynamoDB забезпечує стабільну затримку на рівні одиниць мілісекунд при будь-якому масштабі. Це критично для систем реального часу.
- Гнучка схема даних: Кожен запис може мати різний набір атрибутів. Це дозволяє зберігати дані від різнотипних давачів, наприклад, DS18B20 та DHT22, в одній таблиці без необхідності виконання складних операцій по модифікації таблиць при додаванні нових параметрів.
- Інтеграція з AWS IoT Core: Пряма інтеграція через правила IoT Rules дозволяє записувати дані в таблицю DynamoDB безпосередньо з брокера MQTT, мінаючи проміжні обчислювальні вузли, що знижує затримки та вартість.

Для DynamoDB критично важливим є правильне проектування ключів доступу, оскільки неефективна схема може призвести до нерівномірного розподілу даних hot partitions і зниження продуктивності. Було застосовано патерн Single-Table Design STD, де всі сутності зберігаються в одній таблиці, що дозволяє отримувати пов'язані дані за один запит. Патерн STD є сучасним підходом до моделювання даних у нереляційних ключ-значення базах даних, зокрема у Amazon DynamoDB. Він спрямований на оптимізацію читання, масштабування та мінімізацію затримок у високонавантажених інформаційних системах. На відміну від традиційних реляційних моделей, де дані нормалізуються та розміщуються у множині таблиць, підхід STD передбачає організацію усіх пов'язаних сутностей в одній таблиці,

використовуючи спеціальні стратегії формування ключів, індексів та денормалізованих структур даних. Single-Table Design у DynamoDB є ефективною стратегією моделювання даних у високопродуктивних розподілених системах, де затримка доступу та масштабованість мають вирішальне значення. Підхід базується на денормалізації, ієрархічному структуруванні ключів та використанні вторинних індексів для створення альтернативних моделей доступу. Завдяки цьому STD забезпечує мінімізацію призупинень, оптимізацію запитів та високу ефективність роботи з динамічними потоками даних.

Однією з головних проблем баз даних у IoT є нерівномірність навантаження. Вдень активність може бути вищою, або ж всі давачі можуть синхронно відправити дані. Для вирішення цього завдання в DynamoDB використовуються два режими:

1. On-Demand Capacity: Використовувався на етапі розробки та тестування ПОС. Цей режим автоматично масштабує ресурси під будь-яке навантаження, але має вищу вартість за одиницю запиту.
2. Provisioned Capacity з Auto Scaling: Для промислової експлуатації рекомендовано цей режим. Він дозволяє встановити базовий рівень пропускну здатності Write Capacity Units і автоматично підвищувати його при зростанні трафіку. Це дозволяє прогнозувати витрати та уникати "тротлінгу" відхилення запитів при пікових навантаженнях.

Для оптимізації читання даних, які часто запитуються наприклад, конфігурація пристроїв або останні показники, доцільно використовувати DynamoDB Accelerator DAX. Це in-memory кеш, сумісний з DynamoDB, який дозволяє скоротити час відгуку з мілісекунд до мікросекунд, значно знижуючи навантаження на основну таблицю при великій кількості одночасних користувачів дашборду.

Незважаючи на високу надійність хмарної платформи, захист даних від логічних помилок випадкове видалення або збоїв регіону є обов'язковим. Стратегія резервного копіювання реалізована за принципом 3-2-1, адаптованим для хмарного середовища:

1. Point-in-Time Recovery PITR): Для таблиць DynamoDB активовано функцію PITR. Вона дозволяє відновити стан таблиці на будь-яку секунду за останні 35

днів. Це захищає від помилок на рівні додатку наприклад, якщо помилковий скрипт перезапише дані.

2. On-Demand Backups: Повні бекапи Full Backup виконуються автоматично щотижня через сервіс AWS Backup.
3. Cross-Region Replication Global Tables): Для забезпечення відмовостійкості Disaster Recovery архітектура дозволяє налаштувати реплікацію даних в інший географічний регіон наприклад, з eu-central-1 в us-east-1. У випадку повного виходу з ладу основного дата-центру, система автоматично переключиться на резервний регіон з мінімальною втратою даних RPO близький до нуля.

База даних системи моніторингу містить технологічну інформацію, яка може бути комерційною таємницею. Тому питання безпеки вирішуються на кількох рівнях:

- Шифрування в спокої Encryption at Rest): Усі дані в таблицях DynamoDB автоматично шифруються за допомогою ключів AWS KMS Key Management Service. Використовуються ключі, керовані клієнтом Customer Managed Keys, що дозволяє контролювати доступ до ключів та проводити їх ротацію.
- Шифрування в транзиті Encryption in Transit): Весь трафік між компонентами системи IoT Core -> DynamoDB -> API Gateway передається виключно через захищені канали TLS 1.2/1.3.
- Контроль доступу IAM): Використовується принцип найменших привілеїв Least Privilege. Для кожного компонента системи наприклад, Lambda-функції запису створено окрему роль IAM, яка дозволяє виконувати лише необхідну дію наприклад, тільки PutItem, але не Scan або DeleteItem. Це унеможливлює компрометацію всієї бази даних навіть у випадку злому одного з компонентів.

Розроблена архітектура бази даних на основі Amazon DynamoDB забезпечує високу продуктивність запису та надійність зберігання часових рядів, що є критичним для моніторингу біогазового виробництва. Використання Single-Table Design, оптимізованих структур JSON та стратегій TTL дозволяє ефективно керувати великими обсягами даних, забезпечуючи при цьому масштабованість та економічну ефективність рішення. Відмова від традиційних RDBMS на користь хмарного NoSQL-

рішення дозволила вирішити проблему "трьох V" Volume, Velocity, Variety, характерну для сучасних IoT-систем.

Логічна модель даних включає наступні основні сутності: Devices пристрої - унікальний ідентифікатор, тип, місце розташування, дата встановлення, Sensors датчі - тип датча, одиниці вимірювання, діапазон значень, точність, Measurements вимірювання - мітка часу, значення, якість даних, Events події - тип події, критичність, опис [76]. Для основного сховища часових рядів обрано DynamoDB через оптимізацію для IoT-даних. Структура measurement в DynamoDB: measurement name: "biogas_sensors", tags: device_id, sensor_type, location, fields: value, quality, timestamp: наносекундна точність. Retention policy встановлено: raw data - 7 днів, 1-minute aggregates - 30 днів, hourly aggregates - 1 рік, daily aggregates - без обмежень [77].

Резервне копіювання організовано за схемою 3-2-1: 3 копії даних primary + 2 backup, 2 різні типи носіїв SSD + об'єктне сховище, 1 копія offsite інший регіон AWS. Інкрементальні бекапи щогодини, повні бекапи щотижня, тестування відновлення щомісяця [82].

Висновки до розділу 2

У даному розділі представлено комплексне рішення для проектування та розробки програмно-апаратного рівня системи моніторингу.

Обґрунтовано вибір мікроконтролерної платформи ESP32/ESP8266, яка забезпечує: двоядерний процесор 240 МГц, вбудований Wi-Fi та Bluetooth, 34 GPIO для підключення датчів, низьке енергоспоживання (режим глибокого сну 10 мкА), вартість модуля 320 грн.

Розроблено принципову схему вимірювального модуля з інтеграцією датчів температури DS18B20 (точність $\pm 0,5^{\circ}\text{C}$), вологості DHT22 (точність $\pm 2\%$), камери OV2640 (роздільна здатність 1600×1200) та системи живлення з захистом від перевантаження.

Вперше запропоновано комбінований алгоритм збору та первинної обробки даних для біогазових установок, що поєднує медіанну фільтрацію для усунення викидів, метод IQR для виявлення аномалій, локальну буферизацію з об'ємом до 1000 записів та експоненційний бекоф для повторних спроб передачі.

Реалізовано багаторівневу систему передачі даних: MQTT з QoS 1/2 для телеметрії в реальному часі (затримка < 100 мс), HTTPS для передачі зображень, TLS 1.2 для шифрування, автентифікація X.509 сертифікатами.

Спроектовано хмарну архітектуру на базі AWS: IoT Core для MQTT-брокера, DynamoDB для зберігання телеметрії (пропускна здатність 10 000 записів/с), S3 для зображень, Lambda для безсерверних обчислень, Fargate для ML-моделей.

Досягнуто показники надійності системи: доступність 99,2% за 90 днів тестування, успішна доставка даних 98,6%, автоматична синхронізація після відновлення зв'язку без втрати інформації.

Вперше розроблено трирівневу архітектуру системи моніторингу біогазового виробництва, що забезпечує інтеграцію апаратного рівня збору даних, хмарного рівня обробки та рівня інтелектуального аналізу в єдиному рішенні з підтримкою масштабування та резервування.

РОЗДІЛ 3

РОЗРОБКА ІНТЕЛЕКТУАЛЬНОЇ ПІДСИСТЕМИ АНАЛІЗУ ЯКОСТІ СИРОВИНИ НА ОСНОВІ КОМП'ЮТЕРНОГО ЗОРУ

3.1 Методи обробки та аналізу зображень у комп'ютерному зорі

У сучасному виробництві, зокрема в аграрному секторі, комп'ютерний зір відіграє все більш вагому роль, забезпечуючи автоматизоване керування окремими технологічними процесами та виробництвом в цілому. Одним із ключових завдань комп'ютерного зору є виявлення об'єктів, що підлягають автоматизації - здатність комп'ютерно-інтегрованих систем розпізнавати та локалізувати об'єкти на зображеннях і відео. Щороку такі технології стають надійнішими й точнішими, поширюючись у багатьох сферах: сільському господарстві, автономному транспорті, системах розпізнавання облич тощо. Важливим фактором прогресу у задачах розпізнавання стало впровадження штучних нейронних мереж, які заклали основу для розвитку новітніх методів класифікації та сегментації об'єктів, значно розширивши можливості комп'ютерного зору. Одним із найважливіших напрямів тут є об'єктне визначення - здатність системи розпізнавати, класифікувати та сегментувати об'єкти на зображеннях або відео. Сучасні підходи до аналізу зображень базуються як на класичних алгоритмах обробки зображень, так і на методах глибокого навчання, які дозволяють автоматично аналізувати ознаки зображення і приймати рішення про якість сировини.

Сегментація зображень є одним із центральних етапів обробки зображень у розробленій підсистемі. Вона дозволяє розділити зображення на окремі ділянки сегменти, кожен з яких відповідає певному об'єкту або області, що містить важливу інформацію для подальшого аналізу. В контексті оцінки якості біосировини сегментація дає змогу відокремити об'єкти наприклад, фрагменти рослинного матеріалу від фону, оцінити їхню кількість, форму, стан та інші характеристики. У ході роботи були розглянуті й випробувані як класичні методи сегментації, так і сучасні підходи на основі глибокого навчання. Зокрема, нами виділено наступні

методи: порогове сегментування, адаптивне порогове сегментування, метод Оцу, кластеризація К-середніх та сегментація на основі глибокого навчання.

- Порогове сегментування. Базовий метод, що полягає в бінаризації зображення на основі фіксованого порогу яскравості [41]. При заданому пороговому значенні всі пікселі, яскравість яких перевищує поріг, відносяться до об'єкта, інші - до фону. Така проста схема дозволяє відокремити об'єкти від фону за їх інтенсивністю, однак ефективність сильно залежить від рівня та однорідності освітлення: єдиний глобальний поріг не враховує локальних особливостей зображення.

- Адаптивне порогове сегментування. Удосконалений підхід, в якому поріг яскравості визначається окремо для різних ділянок зображення [41]. Замість одного глобального порогу використовується локально обчислений поріг для кожного фрагмента або вікна зображення. Це особливо ефективно для зображень з неоднорідним освітленням, де яскравість фону змінюється: адаптивне підлаштування порогу дозволяє коректно сегментувати об'єкти навіть за нерівномірного фону, автоматично підлаштовуючи поріг під локальні контрасти.

- Метод Оцу. Автоматичний метод вибору порогового значення на основі аналізу гістограми яскравості [129]. Алгоритм Оцу перебирає можливі порогові значення і обирає те, яке мінімізує сумарну внутрішньокласову дисперсію яскравості або, еквівалентно, максимізує міжкласову дисперсію між пікселями, віднесеними до фону та об'єкта. Інтуїтивно це означає, що вибирається поріг, при якому пікселі розподіляються на два класи з максимальною відмінністю за інтенсивністю. Метод Оцу не потребує жодних параметрів і добре працює для зображень з бі-модальним розподілом рівнів сірого. Для покращення результатів існують модифікації цього методу. Зокрема, "інвертований Оцу" - варіант, коли після визначення оптимального порогу чорне та біле міняються місцями. Такий прийом застосовують, якщо цільові об'єкти на оригінальному зображенні представлені світлими ділянками на темному фоні або якщо після порогування за Оцу отримане зображення треба інвертувати для подальшої обробки. Ще одна поширена модифікація - метод Оцу з підвищеним контрастом, коли перед пороговим розбиттям виконується попереднє покращення

контрасту зображення, наприклад, методом обмеженого адаптивного вирівнювання гістограми CLANE [131]. Поєднання CLANE та класичного Оцу дозволяє надійніше сегментувати зображення з нерівномірним освітленням або низьким контрастом, оскільки попередньо згладжує вплив тіней та підсилює контраст дрібних деталей.

· Кластеризація К-середніх. Метод некерованого навчання, що може бути застосований для сегментації шляхом кластеризації пікселів за їх ознаками [42]. Алгоритм К-середніх розбиває набір даних у даному випадку - сукупність пікселів з їх значеннями яскравості, кольору або інших ознак на К кластерів таким чином, щоб пікселі в одному кластері були максимально схожі між собою, а пікселі з різних кластерів - якомога більш відмінні. При класичному застосуванні до градацій сірого $K = 2$ два кластери: фон і об'єкт, однак метод легко узагальнюється і на випадок багатоканальних кольорових зображень чи більшої кількості сегментів. Кластеризація не потребує ручного вибору порогу, а розділення виконується на основі внутрішніх властивостей даних. Важливо, що К-середніх, як некерований метод, не вимагає попередньої розмітки зображень на приклади фону та об'єктів - розподіл на класи здійснюється автоматично за подібністю пікселів за обраними характеристиками [42]. Недоліком методу є те, що результат залежить від початкової ініціалізації кластерів та може давати нестабільні сегментації на зображеннях зі складним фоном, а також потребує апріорного вибору числа кластерів К. У нашій задачі кластеризація К-середніх розглядається передусім як інструмент аналізу вже отриманих чисельних показників якості див. нижче розділ про кластеризацію результатів, але її можна застосувати і безпосередньо для сегментації зображень наприклад, за значеннями інтенсивності пікселів.

· Сегментація на основі глибокого навчання. Сучасні методи глибинного навчання, особливо згорткові нейронні мережі CNN, встановили нові стандарти якості в задачах сегментації зображень. На відміну від порогових методів чи кластеризації, які покладаються лише на прості ознаки яскравість або невеликі набори характеристик, згорткові нейронні мережі здатні автоматично виокремлювати високорівневі ознаки зображень і навчатися розпізнавати складні патерни об'єктів. Зокрема, для задач сегментації розроблено архітектури нейромереж глибокого

навчання, такі як U-Net та її варіації, які дозволяють класифікувати кожен піксель зображення у певний клас семантична сегментація [133]. CNN-моделі можуть навчатися на великій кількості прикладів і досягати високої точності навіть на складних зображеннях з шумами або артефактами, де класичні алгоритми неефективні. Для застосування нейронної мережі потрібен попередньо підготовлений навчальний набір даних з анотаціями - для сегментації це означає наявність масок або контурів об'єктів на багатьох зображеннях, за якими мережа вчиться відрізняти об'єкт від фону. Підготовка такого датасету трудомістка, але виправдана, коли потрібна максимальна точність або коли характеристики зображень колір, текстура, складний фон не дозволяють використати прості методи. У межах нашої підсистеми комп'ютерного зору передбачено можливість інтеграції глибоких моделей сегментації для підвищення точності, проте основний акцент робився на методах, які не потребують довготривалого навчання, з огляду на вимогу експрес-аналізу.

Після того як вибраним методом здійснено сегментацію зображення, настає етап аналізу ознак сегментованого об'єкта та оцінювання його якісних показників. Це критично важливо для прийняття подальших рішень щодо матеріалу, оскільки саме за кількісними візуальними показниками можна судити про якість сировини та її придатність до використання. У нашій інтелектуальній підсистемі аналізу якості сировини запропоновано багаторівневий підхід: спершу виділяється цільовий об'єкт біоматеріал на зображенні за допомогою одного з наведених вище методів сегментації, а потім обчислюються статистичні ознаки сегментованого об'єкта, на основі яких розраховується інтегральна оцінка якості. Такий підхід забезпечує повторюваність і об'єктивність оцінювання, на відміну від суб'єктивних візуальних інспекцій. У якості основних інформативних ознак зображення для оцінки якості було обрано статистичні характеристики розподілу інтенсивностей пікселів, а саме: середнє значення, стандартне відхилення, коефіцієнт асиметрії скос та коефіцієнт ексцесу куртоз розподілу, а також аналізовано гістограму інтенсивностей [41]. Вибір саме цих показників обґрунтовується тим, що вони характеризують яскравість та однорідність зображення об'єкта, а також форму розподілу яскравостей, що може корелювати зі ступенем розкладення біоматеріалу чи іншими якісними ознаками.

Наприклад, середнє значення яскравості пов'язане із загальним альбедо світлістю матеріалу, стандартне відхилення відображає контрастність або неоднорідність структури, асиметрія та ексцес характеризують форму гістограми чи є розподіл близьким до нормального, наявність довгих “хвостів” тощо. Комплексний аналіз цих ознак дозволяє кількісно описати стан сировини.

На основі обчислених характеристик формується інтегральна оцінка якості зображення матеріалу. В рамках даної роботи така оцінка реалізована через розрахунок відстані до еталонного ідеального стану за вибраними показниками. Використовується метрика відстаней у багатовимірному просторі ознак - Евклідова відстань [60, 57]. Спочатку задаються еталонні значення ознак для якісного матеріалу наприклад, ідеальне середнє M_{ideal} та стандартне відхилення SD_{ideal} інтенсивностей пікселів, які характерні для зображень матеріалу належної якості і допустимі діапазони відхилень $\Delta M_{ideal}, \Delta SD_{ideal}$. Для кожного нового зображення з розрахованими характеристиками (M, SD) обчислюється відстань до еталону в нормалізованому просторі ознак. Зокрема, для двовимірного випадку враховуються лише M та SD відстань можна подати як:

$$1 - \sqrt{\left(\frac{M - M_{ideal}}{\Delta M_{ideal}}\right)^2 + \left(\frac{SD - SD_{ideal}}{\Delta SD_{ideal}}\right)^2} \quad (3.1)$$

де:

M - середнє значення пікселів зображення,

M_{ideal} - ідеальне середнє значення,

ΔM_{ideal} - ширина ідеального діапазону для середнього значення,

SD - стандартне відхилення пікселів зображення,

SD_{ideal} - ідеальне стандартне відхилення,

ΔSD_{ideal} - ширина ідеального діапазону для стандартного відхилення.

Оцінка нормалізується так, щоб значення були в діапазоні від 0 до 1, де 1 відповідає повній відповідності ідеальним діапазорам. Розрахунок оцінки для обраних файлів наведено в табл. 3.1. Отриману відстань d надалі нормують до

діапазону $[0; 1]$, де 1 відповідає повній відповідності ідеальним характеристикам, а 0 - максимальному відхиленню за прийнятими критеріями. Таким чином отримують числовий скоринг якості кожного зображення. Чим ближче score до 1, тим вища якість сировини за ознаками зображення; низькі значення score свідчать про значні відхилення властивостей матеріалу від норми.

Для всіх зображень в нашому наборі було обчислено наведені статистичні характеристики та інтегральну оцінку якості. Це дозволило провести багатовимірний аналіз даних, зокрема дослідити кореляційні взаємозв'язки між ознаками та якістю, здійснити кластеризацію зображень за подібністю і виконати візуалізацію результатів у просторі головних компонент та паралельних координат. Використання методів аналізу і візуалізації даних є важливою частиною дослідження, оскільки воно допомагає зрозуміти структуру набору даних та виявити приховані закономірності [42]. Застосування засобів візуального аналізу сприяє інтерпретації результатів, що особливо актуально при побудові інтелектуальних систем, де необхідно пояснювати вплив тих чи інших ознак на кінцеву оцінку.

Далі наведено деталі формування та підготовки набору даних, а також результати застосування описаних методів сегментації та аналізу на цьому наборі.

3.1.1 Формування набору даних та попередня обробка зображень

Для навчання і перевірки роботи запропонованої підсистеми було зібрано спеціалізований набір даних зображень біоматеріалу рослинної сировини в реальних умовах полігону досліджень. Фотофіксацію здійснювали в однаковий час доби при стабільних налаштуваннях камери, що мінімізує вплив змін освітлення на якість зображень. Усі вихідні зображення отримано в кольоровому форматі RGB з високою роздільною здатністю; сцени містили купи подрібненої рослинної маси на фоні ґрунту та неба.




Рис. 3.1 Приклад конвертації зображення у градації сірого: а) оригінальне зображення, б) оброблене зображення в градації сірого

На етапі попередньої обробки кожне зображення було приведене до градацій сірого рис. 3.1б для уніфікації даних та зменшення обчислювальної складності обробки. Перетворення в відтінки сірого дозволяє знизити розмірність даних з 3 каналів до 1 без втрати релевантної інформації про яскравість сцени. Це особливо доречно, оскільки для завдання сегментації біоматеріалу колір не відіграє суттєвої ролі - важливіші відмінності у яскравості між об'єктом і фоном. На рис. 3.1 наведено приклад такого перетворення: початкове кольорове зображення рис. 3.1а та його

відповідник у градаціях сірого рис. 3.1б. Видно, що основні об'єкти фрагменти біомаси залишаються розрізняваними, тоді як колірна інформація усунена.

Для подальшого використання методів сегментації важливо було також забезпечити нормалізацію масштабу та освітленості зображень. У нашому випадку всі зображення отримані за схожих умов, тому додаткова корекція яскравості чи контрасту не виконувалася окрім використання CLANE в одному з методів сегментації. Проте загальноприйнятою практикою є застосування операцій вирівнювання гістограми, згладжування шумів, корекції балансу білого тощо на стадії підготовки даних, якщо вихідні фото суттєво відрізняються за якістю.

Важливим аспектом формування датасету є розмітка даних анотація, особливо якщо планується навчання моделей глибокого навчання. У рамках нашого експерименту основний акцент робився на автоматичних методах, що не потребують ручної розмітки. Тим не менш, було підготовлено тестову вибірку з декількох зображень із ручною розміткою для оцінки роботи алгоритмів сегментації. Розмітка полягала в створенні бінарних масок, де пікселі, що відповідають біоматеріалу, відзначені значенням 1 білий колір, а фон - 0 чорний. Для цього використовувався напівавтоматичний інструментарій: початково зображення сегментували одним із простих методів, після чого отримана маска вручну коригувалася експертом.

При анотації визначено схему класифікації пікселів на дві категорії: «біоматеріал» цільовий об'єкт та «фон». Така спрощена бінарна класифікаційна схема є типовою для задач сегментації подібного роду, оскільки дозволяє зосередитися на виокремленні основного об'єкта. У випадку більш складних сцен або наявності кількох типів об'єктів, класифікаційну схему можна було б розширити наприклад, додати класи «небо» або «грунт». Однак для задачі аналізу якості сировини в біогазових установках достатньо відокремити рослинну біомасу від усього іншого.

Підсумовуючи, підготовлений набір даних містить серію зображень біомаси з однорідними умовами зйомки, кожне з яких має сірий варіант для аналізу, та для вибраних кадрів - ручну розмітку сегментів. Цей датасет ліг в основу подальшого експериментального дослідження з випробування різних методів сегментації та оцінювання якості.

Експериментальне застосування методів. Відповідно до окреслених етапів збір даних - попередня обробка - сегментація - оцінка якості було проведено серію експериментів. Після перетворення всіх зображень у градації сірого, для кожного з них послідовно застосовано перелічені раніше методи сегментації: глобальне порогове, адаптивне порогове, Оцу у двох варіантах - прямий та інвертований, Оцу з попереднім CLANE, а також кластеризацію К-середніх для $K=2$. Ручне сегментування або методи на основі глибокого навчання на цьому етапі не застосовувалися, але результати автоматичних алгоритмів співставлялися з наявними ручними масками для візуальної перевірки адекватності.

Щоб кількісно порівняти результати, був використаний підхід на основі обчислення відсотка сегментованої області. Для кожного методу сегментації та кожного зображення підраховано частку пікселів, віднесених до об'єкта біоматеріалу відносно загальної кількості пікселів. Нехай $H \times W$ - розмір зображення, а $\delta(p(i,j)=255)$ - індикаторна функція, що дорівнює 1, якщо піксель (i,j) після сегментації має значення 255 білий, тобто віднесений до класу «об'єкт», і 0 - якщо піксель належить фону 0, чорний. Тоді кількість білих пікселів сегментована площа об'єкта можна обчислити за формулою:

$$S = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \delta(p(i,j)=255) \times 100\% \quad (3.1)$$

де:

S - площа сегментованої області у відсотках

H - висота зображення в пікселях

W - ширина зображення в пікселях

$p(i,j)$ - значення пікселя в позиції (i, j)

$\delta(\cdot)$ - індикаторна функція: 1, якщо піксель білий (255), інакше 0

Тобто S - це відсоток площі зображення, яку метод визначив як об'єкт. Результати таких обчислень для всіх методів сегментації по трьох тестових зображеннях наведено в табл. 1. Аналізуючи ці проміжні дані, ми прагнули визначити, який із методів дає найбільш стабільні та адекватні результати для нашого завдання.

Аналіз ефективності методів сегментації. Для кожного методу були обчислені усереднені показники S відсоток сегментованої площі по всіх зображеннях, а також

варіативність цих показників. Середнє значення S для кожного методу, стандартне відхилення і коефіцієнт варіації CV цих значень міститься в табл. 3.2 [206]. Середнє відображає тенденцію щодо величини сегментованої області, а стандартне відхилення характеризує розкид результатів між різними кадрами стабільність методу. Коефіцієнт варіації, зручний для порівняння стабільності, оскільки нормує відхилення на середню величину, визначається як

$$CV = \frac{\sigma}{\mu} \cdot 100\% \quad (3.2)$$

де:

CV - коефіцієнт варіації у відсотках, показує відносну стабільність методу

σ - стандартне відхилення результатів

μ - середнє значення результатів

За отриманими даними, інвертований метод Оцу продемонстрував найвищий середній відсоток сегментованої області - близько 55,4% площі зображення припадає на об'єкт табл. 2. Це означає, що за інвертованим Оцу алгоритм виділяє дещо більшу область як «біоматеріал» порівняно з іншими методами. Другим за охопленням є адаптивний пороговий метод близько 53,9%. Натомість класичний метод Оцу без доповнень та кластеризація К-середніх дають найменшу сегментовану площу порядку 44,6% і 46,0% відповідно, тобто в середньому ці методи виділяють меншу частку об'єкта на зображеннях.

За стабільністю результатів найкращим виявився метод Оцу з підвищеним контрастом Оцу+CLANE - його стандартне відхилення по набору зображень мінімальне $\approx 1,79$ п.п. площі, що вказує на високу повторюваність: майже однаковий відсоток об'єкта виділяється незалежно від конкретного кадру [3]. Близький до нього за стабільністю і звичайний метод Оцу стандартне відхилення 2,59. Натомість адаптивний поріг та К-середніх характеризуються найбільшим розкидом результатів $\sigma \approx 4,9$ та 4,7 відповідно, що підтверджується і найвищими коефіцієнтами варіації $CV \approx 9,1\%$ та 10,2%. Це означає, що для різних зображень частка виділеного об'єкта цими методами помітно змінюється - вони менш надійні та більш чутливі до індивідуальних особливостей зображень різниця в структурі біомаси, фоні тощо. Інвертований Оцу

показав непогану стабільність $CV \approx 4,7\%$, хоча йому властиве дещо більше відхилення, ніж Оцу+CLANE.

Таким чином, за сукупністю критеріїв, найбільш придатним методом сегментації для нашої підсистеми слід визнати метод Оцу з попереднім підвищенням контрасту, оскільки він забезпечив високу повторюваність, мінімальну варіативність і при цьому сегментує значну частку об'єкта. Застосування CLANE перед Оцу дозволило компенсувати нерівномірності освітлення на зображеннях, тому результат стабільний навіть якщо окремі ділянки кадру затемнені чи засвічені. Надалі саме цей метод використовується як основний для виділення об'єкта на всіх зображеннях набору. На рис. 3.5 наведено приклади результатів сегментації одним із кращих методів Оцу+CLANE у порівнянні з іншими підходами: видно, що після підвищення контрасту метод Оцу чіткіше відокремлює біомасу від фону, тоді як, наприклад, кластеризація або адаптивне порогоування на деяких кадрах дають “шум” - зайві плями фону, помилково класифіковані як об'єкт.

Оцінка якості матеріалу за ознаками зображення. Після отримання бінарних масок об'єкта для кожного зображення виконано розрахунок раніше описаних статистичних ознак: середнього значення інтенсивності пікселів об'єкта M , стандартного відхилення SD , коефіцієнта асиметрії γ та ексцесу k розподілу яскравостей. Крім того, для візуального аналізу будувалася гістограма розподілу значень яскравості всередині сегментованого об'єкта [57]. На основі M і SD обчислено інтегральний показник якості - score, за формулою Евклідової відстані до еталону див. вище [60]. У табл. 3.1 представлені фрагменти цих результатів: для вибраних зображень наведені їх оцінки якості та відповідні значення середньої яскравості й стандартного відхилення. Більшість зразків мають score у діапазоні 0,75-0,80, що відповідає допустимій якості; жодне з досліджених зображень не отримало оцінку близьку до 1, тобто ідеальної, через наявність певних відхилень у кожному випадку.

Для кращого розуміння того, як різні ознаки впливають на інтегральну оцінку, було побудовано кореляційну матрицю між усіма розрахованими показниками якості та самим score. На рис. 3.2 показано кореляції між: середнім M , стандартним відхиленням SD , асиметрією γ , ексцесом k та інтегральною оцінкою score. Значення

коефіцієнтів Пірсона варіюються від -1 до 1, причому близькі до $|1|$ означають сильний лінійний зв'язок. Аналіз матриці виявив декілька важливих закономірностей.




Рис. 3.2 Кореляційна матриця

Перш за все, оцінка якості score суттєво негативно корелює із середнім значенням яскравості об'єкта ($r \approx -$) чим світліший біоматеріал на фото, тим нижчу інтегральну оцінку він отримує. Це можна пояснити тим, що перезрілий або пересушений матеріал має вищу відбивну здатність світліший колір але гірше підходить для зброджування, тож висока яскравість є скоріше негативним чинником. Також спостерігається помітна негативна кореляція між стандартним відхиленням і score $r \approx -0,6$ більш однорідний за яскравістю об'єкт нижче SD отримує вищу оцінку. Іншими словами, менша неоднорідність біомаси відповідає кращій якості, що

узгоджується з припущенням: рівномірна маса без сторонніх домішок або різких перепадів кольору переробляється ефективніше. Цікаво, що коефіцієнт асиметрії має позитивну кореляцію з оцінкою $r \approx +0,5$, тобто зі збільшенням асиметрії розподілу яскравості інтегральна оцінка дещо зростає. В нашому випадку позитивна асиметрія правосторонній скошений розподіл означає наявність довгого “хвоста” яскравих пікселів - можливо, це свідчить про наявність окремих дуже світлих включень, що не роблять погоди щодо загальної якості. Експес також показав слабку позитивну кореляцію з $score$ $r \approx +0,3$ більша гостроверхість гістограми відповідає трохи кращій оцінці. Обидва цих показники γ і k для більшості зображень знаходяться близько до нуля, що говорить про розподіл яскравостей, близький до нормального без сильних перекосів чи важких хвостів. Загалом же, кореляційний аналіз підтвердив, що основними факторами, які визначають якість сировини за зображенням, є її середня яскравість та однорідність: матеріал темніший і більш рівномірний отримує вищий бал якості.




Рис. 3.3 Візуалізація кластеризації К-середніх

Наступним кроком був кластерний аналіз отриманих оцінок та ознак, щоб виявити природні групи зображень за якістю. Для цього використано алгоритм кластеризації К-середніх по двох найбільш інформативних змінних - M та SD

пiксельних значень [42]. На рис. 3.3 наведено вiзуалiзацiю результатiв кластеризацiї: точки на площинi координат (M , SD), що вiдповiдають рiзним зображенням, були розбитi алгоритмом на $K = 2$ кластери умовно - група «якiснiшi» та «менш якiснi» зразки. Як бачимо, K -середнiх чiтко видiлив два скупчення. Перший кластер розташований в областi вiдносно низьких значень M близько 105 та невисоких SD - до нього потрапили темнiшi i доволi однорiднi за структурою зображення бiомаси. Другий кластер охоплює точки з вищими середнiми 125-128 та ширшим дiапазоном стандартних вiдхилень до 15. Цей кластер вiдповiдає свiтлiшим зображенням, де частина пiкселiв - дуже яскравi наприклад, наявнiсть неба або сухої соломи пiд сонячним промiнням дає високий M та SD . Помiтно, що один iз об'єктiв першого кластеру має особливо низьке M i SD - аналiз вихiдних фото показав, що це зображення мiстило значну дiлянку темного неба, тому бiомаса займає меншу частку i виглядає темнiшою. Цей випадок можна трактувати як аномалiю або «викид» у даних, який кластеризацiя успiшно iзолювала в окреме скупчення. Загалом же, кластеризацiя пiдтвердила, що вибранi ознаки дозволяють роздiлити зразки бiоматерiалу за їхнiми характеристиками: група з нижчими M темнiший, вологiший матерiал i помiрним SD може вiдповiдати кращiй якостi, тодi як група зi свiтлiших i менш однорiдних зображень - гiршiй. Отримання таких кластерiв може допомогти при побудовi автоматичної класифiкацiї сировини на якiснi категорiї. Темнiший колiр корелює з вищим вмістом вологи та ступенем попередньої ферментацiї, що пришвидшує метаболiзм бактерiй.

Для узагальнення даних та зменшення їх розмiрностi застосовано метод аналiзу головних компонент PCA [46]. Ознаки M , SD , γ , k та iнтегральна оцiнка були перетворенi засобами PCA в новi координати - головнi компоненти, якi є лiнiйними комбiнацiями вихiдних показникiв. Перша головна компонента пояснює найбільшу частку варiацiї в наборi даних, друга - наступну за значенням частку тощо. Виявилось, що першi двi головнi компоненти пояснюють близько 80% розсiювання даних зображень. Це означає, що бiльшiсть iнформацiї про варiативнiсть якостi матерiалу може бути зведена до двох параметрiв, що є лiнiйними поєднаннями вихiдних ознак. На рис. 3.4 наведено проєкцiю наших даних на площину перших двох головних

компонент: точки, що відповідають зображенням, згрупувалися подібно до результатів прямого аналізу M та SD , підтверджуючи, що саме ці ознаки роблять найбільший вклад у зміну показників якості.




Рис. 3.4 Візуалізація аналізу головних компонент

Відсутність розрізнених хмар точок поза межами цих двох компонент свідчить, що обраний набір ознак не містить значної прихованої варіації - тобто практично не втрачається інформація при переході до головних компонент. Це підтверджує, що вибрані нами показники M , SD , γ , k є достатніми для опису якості сировини, і додавання нових ознак, ймовірно, дало б лише незначний вигравш.

Для полегшення інтерпретації багатовимірних даних було також використано метод візуалізації паралельних координат [162]. На рис. 3.5 зображено паралельний координатний графік, де кожна вертикальна вісь відповідає одній змінній M , SD , γ , k , score, а кожен зразок зображення представлено ламаною, що проходить через значення цього зразка на всіх осях. Такі графіки дозволяють одночасно оцінити профілі всіх зразків та виявити схожі або аномальні патерни. Зокрема, з рисунку видно, що показники M і SD варіюються значно сильніше між зразками, ніж γ та k , які у більшості випадків близькі до нуля.




Рис. 3.5 Візуалізація паралельних координат

Це узгоджується з попереднім спостереженням про майже нормальний розподіл яскравостей у багатьох зображеннях. Більше того, можна помітити тенденцію: зображення з високою якістю лінії, позначені теплішим кольором, ближче до червоного мають нижчі значення M та SD , але вищі значення асиметрії та ексцесу. Це підтверджує зроблені вище висновки: якісніша біомаса на зображеннях зазвичай темніша та однорідніша ніжчі середня яскравість і розкид, при цьому її гістограма яскравостей може мати більш виражений пік і довший “хвіст” вищі γ , k . Таким чином, паралельні координати допомагають наочно побачити відмінності між групами зразків та переконатися, що запропоновані ознаки дійсно диференціюють зображення за якістю.

Проміжний підсумок. Розроблена інтелектуальна підсистема комп’ютерного зору забезпечує кількісну та об’єктивну оцінку якості біосировини на основі аналізу

її зображень. В ході дослідження підтверджено, що вибрані ознаки зображення яскравісні характеристики та похідні статистики мають сильний зв'язок з якісними показниками матеріалу. Зокрема, виявлено високу кореляцію між середньою яскравістю/однорідністю зображення та інтегральною оцінкою якості, що свідчить про можливість використання візуальних характеристик як надійних індикаторів стану біоматеріалу. Результати кластеризації продемонстрували, що за допомогою методів машинного навчання можна класифікувати зразки біомаси на декілька категорій якості, що має практичне значення для прийняття рішень у технологічному процесі наприклад, прогнозування виходу біогазу чи необхідність коригування параметрів зброджування для різних партій сировини. Використання PCA підтвердило достатність обраних ознак, а візуалізація паралельних координат надала додаткові докази та інтуїтивне розуміння того, як саме ознаки відрізняють якісні та неякісні зразки. Таким чином, інтеграція традиційних методів обробки зображень з сучасними підходами аналізу даних та елементами глибокого навчання дозволила створити ефективну підсистему експрес-оцінки якості сировини на основі комп'ютерного зору. Отримані результати можуть слугувати основою для подальшого вдосконалення системи, зокрема через навчання нейронних мереж на зібраному датасеті для ще точнішого виділення ознак та прогнозування показників якості сировини.

3.2 Синтез та порівняльний аналіз алгоритмів обробки зображень

Сегментація зображень є ключовим етапом обробки даних у системах комп'ютерного зору, оскільки дозволяє виокремити інформативні області цільові об'єкти від фону для подальшого аналізу. У контексті оцінки якості біоматеріалу для біогазових установок ефективна сегментація дає змогу відділити зображення рослинної сировини від фонових об'єктів ґрунту, неба тощо і виділити характеристики, що корелюють із якістю цього біоматеріалу. Важливо підібрати алгоритм сегментації, який забезпечить стабільні та точні результати за різних умов зйомки. У цьому розділі проводиться синтез і порівняльний аналіз кількох підходів до

сегментації зображень, аби визначити оптимальний метод за критеріями стабільності та точності. Розглянуто класичні методи порогового розподілу пікселів, кластеризацію, а також сучасні методи на основі глибокого навчання. Наведено принцип дії кожного методу, їх переваги й недоліки, а також критерії оцінки якості сегментації. Реальні зображення біоматеріалу використано для тестування алгоритмів, а для обґрунтування вибору оптимального методу виконано статистичний аналіз отриманих результатів середні значення, стандартні відхилення, коефіцієнти варіації. Нижче викладено результати розробки методу сегментації для виділення інформативних областей підрозділ 3.2.1 та обґрунтування вибору оптимального алгоритму за критеріями стабільності й точності підрозділ 3.2.2.

3.2.1 Розробка методу сегментації для виділення інформативних областей

Для вирішення завдання сегментації зображень біоматеріалу розглянуто та проаналізовано кілька підходів. Серед методів сегментації, відібраних для дослідження, такі: порогове сегментування, адаптивне порогове сегментування, метод Оцу, кластеризація К-середніх та сегментація на основі глибокого навчання [129, 41, 42, 133]. Кожен з цих методів має власний принцип дії та характерні особливості. Нижче наведено стислий огляд цих підходів, включаючи принцип роботи, прикладне значення, а також основні переваги та недоліки в контексті поставленої задачі.

Порогове сегментування Thresholding. Це базова техніка сегментації зображень, яка використовується для розділення зображення на об'єкт та фон шляхом бінаризації пікселів за порогом [41]. Основна ідея методу полягає у встановленні певного порогового значення інтенсивності T для пікселів зображення. Всі пікселі, інтенсивність яких перевищує поріг, відносяться до класу об'єкта наприклад, позначаються білим, а інші - до фону позначаються чорним. Формально це можна записати як:

$$g(i,j)= \begin{cases} 1, & \text{якщо } f(i,j) \geq T \\ 0, & \text{якщо } f(i,j) < T \end{cases} \quad (3.3)$$

де

$f(i,j)$ - інтенсивність вхідного зображення в точці з координатами i,j

$g(i,j)$ - результуюче бінарне зображення.

Простота порогового методу є його головною перевагою - він обчислювально ефективний, легко реалізується та швидко працює в реальному часі [41]. Такий метод добре спрацьовує, коли об'єкти чітко відрізняються від фону за рівнем яскравості. Переваги: висока швидкодія та простота реалізації; не потребує попереднього навчання чи великого обсягу пам'яті. Недоліки: чутливість до зміни умов освітлення та контрастності зображення. Якщо зображення має нерівномірне освітлення або інтенсивності об'єкта і фону перекриваються, глобальне порогове значення може виявитися неефективним - частина об'єктів може залишитися несеgmentованою або, навпаки, у фон потраплять зайві області.

Адаптивне порогове сегментування Adaptive Thresholding. Це вдосконалення простого порогового методу, яке дозволяє врахувати локальні особливості зображення [41]. На відміну від звичайного глобального порогового сегментування, де використовується єдиний поріг T для всього зображення, адаптивне сегментування визначає окреме порогове значення для кожної локальної області зображення зазвичай, для кожного пікселя обчислюється поріг на основі інтенсивностей сусідніх пікселів у вікні заданого розміру. Таким чином, поріг стає функцією координат: $T=T(x,y)$, що дозволяє більш ефективно сегментувати зображення з неоднорідним освітленням або градієнтами яскравості. Існують різні алгоритми адаптивної бінаризації - наприклад, методи, що базуються на середньому або медіанному значенні в локальному вікні, або алгоритм Бредлі-Рота [41], який використовує інтегральні зображення для швидкого обчислення локальних статистик. Переваги: адаптивне порогоування добре працює на зображеннях, де освітлення варіюється по кадру - воно може виділити об'єкти навіть у тінях чи пересвічених ділянках, де глобальний поріг був би неефективним. Недоліки: більш висока обчислювальна складність необхідна оцінка параметрів для кожної області, наявність додаткових гіперпараметрів розмір локального вікна, поправка до порогу, а також ризик пересегментувати зображення - виділення шумових деталей як окремих

об'єктів. При неправильному виборі параметрів адаптивний метод може давати надто фрагментоване або нерівномірне зображення об'єкта.

Метод Оцу. Метод Оцу є популярним автоматичним підходом до вибору порогу бінаризації, що ґрунтується на аналізі гістограми розподілу яскравостей зображення [129]. Гістограма відображає кількість пікселів для кожного рівня сірого від 0 до 255. Ідея Оцу полягає в тому, щоб знайти таке порогове значення T , яке розбиває всі пікселі на два класи фон та об'єкт і забезпечує мінімальну внутрішньокласову дисперсію або, еквівалентно, максимальну міжкласову дисперсію за інтенсивністю [1]. Внутрішньокласова дисперсія визначається як

$$\sigma_w^2(T) = q_1(T)\sigma_1^2(T) + q_2(T)\sigma_2^2(T) \quad (3.4)$$

де:

$q_1 \sigma_1^2$ - частка пікселів та дисперсія інтенсивностей класу 1 нижче порогу T ,

$q_2 \sigma_2^2$ - частка та дисперсія класу 2 вище порогу.

Метод Оцу перебирає всі можливі значення T і обирає той, для якого $\sigma_w^2(T)$ мінімальна або, відповідно, різниця між середніми значеннями класів максимальна. Цей алгоритм не потребує жодних попередніх припущень про розподіл інтенсивностей і працює досить швидко для 256-рівневих зображень, тому широко застосовується на практиці [129, 132]. Переваги: автоматичність поріг визначається без участі оператора, оптимальність для бі-модального розподілу яскравостей коли на гістограмі є два виражені піки, відповідні об'єкту та фону, простота реалізації. Недоліки: припущення про наявність двох чітко виражених класів пікселів - якщо зображення містить більше двох типів областей або нечітку межу між об'єктом і фоном, метод може працювати гірше. Наприклад, на зображеннях з великими варіаціями освітлення або множинними об'єктами Оцу може знайти поріг, який не ідеально відокремлює цільовий об'єкт. Крім того, метод чутливий до співвідношення площ класів: якщо об'єкт займає дуже малу частку зображення, оптимізація дисперсії може зміщуватися на користь фону.

Варіації методу Оцу. Для підвищення ефективності класичного методу Оцу в різноманітних умовах були запропоновані його модифікації. Зокрема, часто

використовується “інвертований Оцу” Inverted Otsu - підхід, коли після визначення оптимального порогу за методом Оцу здійснюється інверсія отриманого бінарного зображення [129]. Тобто, пікселі, які були білими, стають чорними і навпаки. Ця процедура доречна у випадках, коли цільові об’єкти на оригіналі зображення світліші за фон і, відповідно, метод Оцу виділяє їх як фон чорним. Інверсія дозволяє отримати об’єкт білим на чорному фоні, що є зручним для подальшого аналізу. Інша корисна модифікація - “Оцу з підвищеним контрастом” Otsu with Enhanced Contrast. У цьому підході перед застосуванням порогового алгоритму Оцу до зображення спочатку застосовується метод локального підвищення контрасту CLAHE, виконує адаптивне вирівнювання гістограми в межах локальних областей зображення, обмежуючи посилення контрасту для запобігання шуму. Після такого попереднього покращення контрасту класичний метод Оцу застосовується до модифікованого зображення. Комбінація CLAHE+Оцу дозволяє більш надійно визначати об’єкт на знімках з нерівномірним освітленням або низьким загальним контрастом, де класичний Оцу міг би хибно вибрати поріг. Переваги модифікацій Оцу: інвертований Оцу забезпечує правильну полярність сегментації об’єкт як біла область у випадках, коли цього потребує аналіз; використання попереднього покращення контрасту підвищує стійкість методу до зміни умов освітлення та покращує відокремлення об’єкта від фону на складних зображеннях. Недоліки: додаткові кроки обробки інверсія, вирівнювання гістограми збільшують обчислювальну складність; надмірне підсилення контрасту може збільшити шум або артефакти на зображенні, якщо параметри CLAHE обрано неправильно.

- Кластеризація K -середніх clustering. Метод K -середніх належить до некерованого навчання і використовується для розділення набору даних у нашому випадку - сукупності пікселів зображення на K груп або кластери з подібними характеристиками [42]. Застосовуючи K -середніх до зображення, можна сегментувати його на області, згрупувавши пікселі за схожістю їх ознак. Найпростіший випадок - кластеризація лише за значенням інтенсивності: алгоритм випадковим чином ініціалізує K центрів кластерів середніх значень інтенсивності, після чого ітеративно відносить кожен піксель до найближчого за

інтенсивністю кластера і оновлює значення центрів. Критерієм оптимізації служить мінімізація сумарної квадратичної відстані пікселів до центрів своїх кластерів. Після збіжності алгоритму кожному кластеру відповідає певний діапазон інтенсивностей, який можна розглядати як окремий сегмент зображення [42]. Для задачі бінарної сегментації об'єкт/фон вибирають $K=2$ кластери: таким чином, алгоритм K -середніх поділяє пікселі на дві групи - умовно "темні" та "світлі", що відповідає фону та об'єкту або навпаки. Переваги: K -середніх не потребує ручного вибору порогу - поділ визначається виходячи з самих даних; метод здатний виявляти складні структури у даних, а при використанні декількох ознак наприклад, кольорових компонент або текстурних ознак пікселя кластеризація може сегментувати зображення за більш складними критеріями, ніж проста яскравість. Метод досить простий у реалізації, а при невеликому K і оптимізаціях використання k -d дерев для пошуку найближчого центру тощо працює швидко навіть для великих зображень. Недоліки: результат кластеризації залежить від початкової ініціалізації центрів - алгоритм може збігтися до локального мінімуму, тому сегментація не гарантовано однакова при різних запусках для підвищення стабільності використовують кілька запусків K -середніх з наступним вибором найкращого результату за критерієм мінімальної помилки. Алгоритм K -середніх не враховує просторового розташування пікселів, лише їх значення - це може призводити до появи розрізнених "шумових" пікселів, коли деякі пікселі фону випадково потрапляють у кластер об'єкта чи навпаки. Також потрібно заздалегідь знати або задати число кластерів K . У нашій задачі це не проблема $K=2$ фіксовано, але якщо б довелося сегментувати більше класів наприклад, різні типи рослинних включень, визначення оптимального K могло б потребувати додаткового аналізу. Незважаючи на ці обмеження, метод K -середніх є корисним інструментом для сегментації, особливо коли інтенсивність пікселів об'єкта суттєво відрізняється від фону - у такому випадку два кластери добре розділять зображення на потрібні області.

- Сегментація на основі глибокого навчання. Сучасні методи глибокого навчання демонструють високу ефективність у задачах сегментації зображень, особливо

коли йдеться про складні сцени з багатьма об'єктами чи неоднорідним фоном [133]. Основна ідея підходів сегментації на базі нейронних мереж полягає в тому, що кожному пікселю зображення присвоюється мітка класу на основі аналізу контексту навколо нього, здійснюваного глибокою нейронною мережею. Найпоширенішим різновидом є семантична сегментація за допомогою згорткових нейронних мереж. Архітектури на кшталт U-Net спеціально розроблені для сегментації: вони поєднують шари згортки для вилучення ознак з шарів деконволюції *upsampling* для побудови точкової класифікації пікселів. Мережу навчають на великому наборі розмічених зображень, де кожному пікселю задано правильний клас наприклад, біоматеріал. У результаті навчена модель здатна на нових зображеннях досить точно відтворювати сегментацію, навіть за складних умов, завдяки тому, що вона навчилася розпізнавати високорівневі патерни об'єктів. Переваги: висока точність сегментації при наявності достатнього обсягу даних для навчання - модель може враховувати складні ознаки, недоступні простим методам колірні текстури, форми, стійкість до шумів та варіативності зображень, оскільки нейронна мережа узагальнює приклади з навчальної вибірки. Також методи глибокого навчання можуть виконувати інстанс-сегментацію виокремлення окремих об'єктів та інші складні задачі, недосяжні простими алгоритмами. Недоліки: потреба у великій розміченій вибірці зображень для навчання - у нашій предметній області зображення біоматеріалу такі дані може бути складно зібрати і розмітити вручну; висока вимогливість до обчислювальних ресурсів - тренування моделей займає багато часу на GPU, а застосування в реальному часі може вимагати оптимізації; "чорний ящик" - складно безпосередньо інтерпретувати, за якими ознаками модель приймає рішення щодо належності пікселя до того чи іншого класу. У межах даного дослідження методи глибокого навчання розглядаються як перспективний напрям, проте основний акцент зроблено на класичних алгоритмах сегментації, які можна застосувати без тривалої підготовки даних. Водночас розуміння потенціалу глибокого навчання важливе для майбутнього вдосконалення системи: зокрема, використання навченої нейромережі могло б

підвищити точність класифікації біоматеріалу, якщо буде сформовано достатню вибірку навчальних зображень.

Практичне значення сегментації у нашому дослідженні. Застосування перелічених методів спрямоване на вирішення конкретної прикладної задачі - аналізу зображень біоматеріалу для біогазових установок. Виділення інформативних областей масиву рослинної маси дозволяє надалі обчислити характеристики, що кількісно описують якість цієї маси. Після сегментації можна підрахувати частку площі, яку займає цільовий матеріал, оцінити його колірні або текстурні ознаки, які, за даними суміжних досліджень, корелюють із показниками придатності біоматеріалу до зброджування. У нашій моделі комп'ютерного зору сегментація є першим і обов'язковим кроком експрес-аналізу: вона очищує зображення від фонового шуму землі, тари, обладнання тощо і залишає тільки ту область, що містить біомасу. Таким чином, точна сегментація безпосередньо впливає на коректність подальших вимірювань. Якщо сегментація працює нестабільно - наприклад, в одних випадках аналізує частину біоматеріалу, а в інших захоплює зайвий фон - то жодні наступні розрахунки кольорові індекси, статистичні параметри розподілу пікселів не будуть надійними. Тому розробка стійкого методу сегментації для наших умов знімання є критичною.

3.2.2 Обґрунтування вибору оптимального алгоритму за критеріями стабільності та точності

Для обґрунтованого вибору методу сегментації було проведено експериментальне порівняння описаних вище алгоритмів на наборі реальних зображень біоматеріалу. Було реалізовано програмну систему, що дозволяє застосувати кожен з методів до кожного зображення та отримати бінарну карту сегментації. В якості інструментарію використано середовище Python із бібліотеками OpenCV та scikit-image для порогових методів і кластеризації, а також OpenCV-функції реалізації CLAHE та базові засоби глибокого навчання наприклад, архітектуру U-Net з попередньо навченими вагами для оцінки потенціалу глибинної сегментації. Усі методи були протестовані на реальних фотографіях біоматеріалу,

отриманих в умовах, наближених до виробничих. Зокрема, зображення відзнято на полігоні біогазової установки під час завантаження сировини. Для забезпечення порівнюваності умов зйомки, нами було зібрано набір з 26 фотографій біоматеріалу, причому фотофіксація здійснювалася в однаковий час доби та при схожих умовах освітлення. Це дозволило мінімізувати вплив зовнішніх факторів різної яскравості сонячного світла тощо на результати сегментації, щоб оцінити саме відмінності алгоритмів. Кожне кольорове зображення було конвертоване в градації сірого рис. 3.1 для уніфікації та спрощення подальшої обробки. Перетворення в монохромний формат обґрунтоване тим, що більшість розглянутих методів порогові, Оцу, К-середніх з $K=2$ працюють саме з інтенсивністю яскравості пікселів, тож кольорова інформація не потрібна. Більш того, використання сірого зображення знижує розмір даних та обчислювальну складність, виключаючи аналіз трьохканального кольору - це прискорює сегментацію і унеможливорює варіації через колірні відмінності фону наприклад, блакитного неба та зеленого ґрунту, які все одно зводяться до відмінностей у яскравості після градації сірого.

Етапи експерименту: Для наочності узагальнимо послідовність дій у рамках порівняльного аналізу алгоритмів сегментації: 1. Збір даних: отримано 26 зображень біоматеріалу кукурудзяний силос та інша рослинна маса в реальних умовах біогазової установки. Знімки охоплюють різні варіанти фону в основному, ґрунт і небо та різний стан матеріалу свіжий, частково висушений тощо - це забезпечує перевірку алгоритмів на різноманітних сценах. 2. Попередня обробка: здійснено перетворення усіх зображень у відтінки сірого для стандартизації даних див. приклад на рис. 3.1: а оригінал; б після перетворення. При необхідності також виконано нормалізацію розмірів масштабування зображень, щоб усі алгоритми застосовувалися до співставних за розміром даних. 3. Застосування методів сегментації: до кожного зображення послідовно застосовано п'ять методів - порогове сегментування з фіксованим глобальним порогом, який підбирався експериментально, адаптивне порогове сегментування метод локального середнього з відніманням сталої, реалізація OpenCV `adaptiveThreshold`, метод Оцу вбудована функція OpenCV `threshold(Otsu)` у трьох варіаціях - оригінальний, інвертований та з попереднім

CLANE, - а також кластеризація K-середніх $K=2$, початкова ініціалізація. Обчислення метрик сегментації: для кожного поєднання “зображення-метод” розраховано частку сегментованої площі, тобто відсоток пікселів, віднесених алгоритмом до класу “об’єкт” біоматеріал. Цей показник визначає, яку частину зображення займає виділений біоматеріал, і служить базовою характеристикою роботи алгоритму. Розрахунок здійснювався за формулою площі білих пікселів:

$$S = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \delta(p(i,j)=255) \times 100\% \quad (3.5)$$

де:

H - висота зображення в пікселях

W - ширина зображення в пікселях

$p(i,j)$ - значення пікселя в позиції (i, j)

$\delta(\cdot)$ - індикаторна функція яка рівна 1, якщо піксель білий $p=255$, інакше $p=0$

Таким чином, чисельник виразу рахує кількість білих сегментованих як об’єкт пікселів, а після ділення на $H \times W$ і множення на 100% ми отримуємо відсоток площі зображення, яку алгоритм визначив як біоматеріал.

Порівняльний аналіз та вибір алгоритму: на основі отриманих у табл. 3.1 даних обчислено зведені статистичні показники для кожного методу: середнє значення сегментованої площі Mean, стандартне відхилення результатів Standard Deviation та коефіцієнт варіації Coefficient of Variation, (CV) [55, 132, 57, 206]. Ці метрики дозволяють оцінити, наскільки загалом багато області виділяє той чи інший метод середній відсоток площі та наскільки стабільно він робить це на різних зображеннях розкид значень.

Таблиця 3.1

Порівняльний аналіз алгоритмів

	Назва файлу	Оригіна- льний Оцу	Інвертова- ний Оцу	Оцу з підви- щеним контрас- том	Адаптивне порогове значення	К-середніх
1	20240423_110459.jpg	43.244848	56.755152	49.663495	52.335450	42.547156
2	20240423_110510.jpg	47.379036	52.620964	50.024791	55.108044	51.767507
3	20240423_110434.jpg	37.884425	62.115575	40.697546	77.281527	37.884425
4	20240423_110505.jpg	41.714498	58.285502	49.661023	52.597966	41.001879
...						
26	20240423_111922(0).jpg	47.174500	52.825500	49.993001	51.446748	47.174500

Повна таблиця результатів наведена в Додатку В.

Середнє значення $\bar{x}$ для вибірки з n зображень обчислюється за класичною формулою

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n x_k \quad (3.6)$$

де:

x_k - значення відсотка сегментованої площі для K -го зображення, $n=26$.

Стандартне відхилення σ характеризує варіативність результатів і визначається як

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2} \quad (3.7)$$

Де

$\bar{x}$ - середнє значення обчислене за формулою 7.

Розрахунок параметрів для кожного методу сегментації представлено у табл. 3.2

Таблиця 3.2

Розрахунок параметрів для кожного методу сегментації

	Оригіна- льний Оцу	Інвертова ний Оцу	Оцу з підвищеним контрастом	Адаптивне порогове значення	К-середніх
Середні значення, (піксель)	44.591902	55.408098	49.420644	53.939556	46.038733
Стандартні відхилення, (піксель)	2.587959	2.587959	1.793784	4.895406	4.701264
Коефіцієнти варіації, (%)	5.803652	4.670723	3.629625	9.075726	10.211542

Обчислені значення цих метрик для кожного методу сегментації наведені у табл. 3.2, а їх графічне відображення на рис. 3.6 - 3.8.




Рис. 3.6. Середні значення кожного з методів сегментації




Рис. 3.7. Середні значення коефіцієнтів варіації




Рис. 3.8. Середні значення стандартних відхилень


На основі цих показників здійснено вибір оптимального алгоритму, що забезпечує найкращий баланс між стабільністю роботи та повнотою сегментації.


Результати порівняльного аналізу. Узагальнені характеристики табл. 3.1 демонструють чіткі відмінності між методами сегментації в нашій задачі. Наведемо ключові спостереження:

- Середнє значення сегментованої площі. Найбільший середній відсоток виділеної області показав інвертований метод Оцу - у середньому 55,41% площі зображення було віднесено до біоматеріалу цим алгоритмом. Тобто, понад половину зображення метод визначає як об'єкт рис. 3.9в ілюструє приклад результату інвертованого Оцу. На другому місці за цим показником знаходиться адаптивне порогове сегментування - 53,94% рис. 3.9е. Це свідчить про те, що адаптивний метод в середньому теж виділяє значну частину зображення під об'єкт, інколи навіть більше, ніж класичний Оцу, особливо в умовах нерівномірного освітлення. Для прикладу, на одному з тестових зображень адаптивний алгоритм сегментував близько 77% сцени, захопивши не лише сам біоматеріал, але й значну частину яскравого неба як "об'єкт" - на гістограмі рис. 3.9ж видно пік яскравостей, який призвів до цього. Таким чином, високий середній відсоток адаптивного методу частково обумовлений випадками пересегментації захоплення фону. Інші методи показали менші середні значення: для оригінального методу Оцу цей показник становить 44,59%, а для кластеризації К-середніх - 46,04% рис. 3.9б та 3.9є відповідно демонструють приклади результатів цих методів. Тобто, класичний Оцу та К-середніх загалом виділяють близько 45% зображення під біоматеріал - це найнижчі показники серед розглянутих методів. Оцу з попереднім підвищенням контрасту дає проміжний результат - в середньому 49,42% площі рис. 3.9д. Отже, за критерієм повноти сегментації кількості виділеної області лідирує інвертований Оцу, трохи поступається адаптивний метод, а найменш "жадібні" до площі - оригінальний Оцу та кластеризація. Відзначимо, що більша сегментована площа не обов'язково означає кращу якість - важливо, щоб виділялась саме область біоматеріалу, без зайвого фону. Тому цей показник варто розглядати разом із метриками стабільності, описаними далі.


- Стабільність результатів стандартне відхилення. Стандартне відхилення σ для кожного методу табл. 3.2 відображає, наскільки результати відсотку площі розкидані між різними зображеннями. Чим менше σ , тим стабільніше алгоритм - тобто на різних знімках він дає близькі за величиною показники сегментованої площі. Найнижче σ отримано у методу Оцу з підвищеним контрастом - всього 1,79 п.п. відсотків площі). Це означає, що на всіх 26 зображеннях частка виділеного біоматеріалу цим методом коливалася лише в межах $\pm 1.79\%$ від середнього $\sim 49,4\%$. Для порівняння, інвертований Оцу має стандартне відхилення 2,59, оригінальний Оцу - також 2,59, збіг значень пов'язаний з тим, що інвертований Оцу дає протилежний результат по відношенню до оригінального, але відсоток білих пікселів - об'єкту - у них взаємодоповнюють до 100%, тому дисперсія виходить однаковою. Значення $\sigma \approx 2,6$ все ще досить низьке, тобто обидві версії методу Оцу демонструють високий рівень повторюваності результатів на різних зображеннях. Натомість адаптивне порогове сегментування та кластеризація К-середніх показали найбільшу варіативність: стандартні відхилення становлять 4,90 та 4,70 відповідно. Це означає, що, наприклад, адаптивний метод на різних кадрах міг сегментувати дуже різні частки площі - в одних випадках близько 40%, в інших - до 77%, як згадувалось. Велике σ для К-середніх вказує на те, що цей алгоритм теж нестабільний: ймовірно, на деяких зображеннях з яскравим небом або неоднорідним фоном кластеризація відносила значну кількість пікселів фону до того ж кластера, що й об'єкт, збільшуючи відсоток білих пікселів. Оцу з підвищеним контрастом у цьому плані виявився найстабільнішим - по суті, завдяки попередньому вирівнюванню контрасту цей метод більш послідовно виділяє біоматеріал, не "реагуючи" на дрібні зміни освітлення від зображення до зображення.
- Коефіцієнт варіації CV. Цей показник, виражений у відсотках, поєднує обидва попередні - характеризує стандартне відхилення, нормоване на

середнє. CV зручний для порівняння стабільності методів з різними середніми значеннями. У нашому випадку ранжування методів за CV таке саме, як і за абсолютним σ . Найнижчий CV має метод Оцу з підвищеним контрастом - всього 3,63%[3]. Це надзвичайно низька відносна варіативність, яка підтверджує високу стабільність алгоритму: відхилення $\sim 1,8\%$ при середньому $\sim 49,4\%$ означає, що результати змінюються лише на $\sim 3,6\%$ від свого середнього значення. Для порівняння, інвертований і оригінальний Оцу мають CV приблизно 4,68-5,80% теж досить низькі, тоді як адаптивний метод - 9,08%, а К-середніх - найгірший показник 10,21%. Високі CV останніх двох методів $>9\%$ свідчать, що їх результати менш передбачувані і залежні від конкретного зображення: це узгоджується з нашими спостереженнями про схильність адаптивного порогу та кластеризації реагувати на фон і шум.







в)




г)



д)



е)



є)

ж)

Рис. 3.9. Приклад застосування різних методів сегментування: а) Оригінальне зображення в градації сірого б) Метод Оцу в) інвертований Оцу г) підвищений контраст д) Оцу з підвищеним контрастом є) К-середніх кластеризація е) адаптивне порогове значення ж) гістограма інтенсивності розподілу пікселів

Загальний аналіз результатів сегментації представлено на рис. 3.9, де наведено приклад застосування різних методів до одного з вихідних зображень біоматеріалу. Зокрема, рис. 3.9а показує вихідне зображення градації сірого, рис. 3.9б - результат порогового сегментування за методом Оцу, рис. 3.9в - інвертований Оцу, рис. 3.9г - для ілюстрації показано саме зображення після підвищення контрасту CLAHE перед порогоуванням, рис. 3.9д - результат сегментації методом Оцу з підвищеним контрастом, рис. 3.9є - результат кластеризації К-середніх, рис. 3.9е - адаптивна бінаризація, а рис. 3.9ж - гістограма яскравостей цього зображення. Візуально можна помітити відмінності: адаптивний метод 3.9е віднімає фон навколо об'єкта краще ніж глобальний Оцу 3.9б у затемнених ділянках, але водночас “пропускає” деякі артефакти в небі; К-середніх 3.9є дає злегка фрагментований результат наявні одиночні точки фону всередині об'єкта і навпаки); Оцу з CLAHE 5д забезпечує чітке виділення рослинної маси, близьке за областю до інвертованого Оцу 3.9в, але з меншим шумом на фоні. Ці спостереження узгоджуються з чисельними метриками: метод CLAHE+Оцу дуже стабільно виділяє приблизно одну й ту саму область, майже

не захоплюючи зайвого, хоча інколи може втратити деякі слабоконтрастні деталі через що його середній % трохи менший, ніж у інвертованого Оцу.

Вибір оптимального алгоритму. За результатами проведеного аналізу визначено, що найбільш стабільним і прийнятним для нашої задачі є метод Оцу з підвищеним контрастом. Він показав найнижчі показники варіативності стандартне відхилення $\sim 1,79$ і коефіцієнт варіації $\sim 3,63\%$ серед усіх випробуваних алгоритмів, що означає мінімальну чутливість до відмінностей у зображеннях. Практично це дуже важливо: маючи справу з реальними фото, де умови можуть трохи змінюватись, стабільний метод гарантує прогнозоване виділення біоматеріалу без значних провалів чи перенасичення сегментації. Окрім того, метод CLANE+Оцу досить точно якісно сегментує саме об'єкт, що ми підтвердили візуально - він майже не захоплює фон на відміну від адаптивного чи К-середніх у деяких випадках і водночас не пропускає значущих фрагментів біомаси. Хоча інвертований Оцу в середньому виділяє навіть більшу площу об'єкта $\sim 55\%$ проти $\sim 49\%$, його стабільність дещо нижча, а головне - додаткові експерименти показали, що в окремих випадках без попереднього підвищення контрасту Оцу може не впоратися, якщо все зображення затемнене або переосвітлене: він тоді може "провалити" сегментацію. Попередня обробка CLANE вирівнює такі крайнощі, тож метод CLANE+Оцу виявився більш робастним. З точки зору реалізації, обраний метод теж доволі привабливий - він базується на відносно простих операціях локальне вирівнювання гістограми та порогова сегментація, які можна швидко виконувати навіть на пристроях з обмеженими ресурсами наприклад, вбудованих системах на виробництві. В літературі відзначалося, що двоетапні методи сегментації, подібні до нашого покращення контрасту + Оцу, добре себе зарекомендували на зображеннях зі складним фоном.

Таким чином, в якості оптимального алгоритму сегментації біоматеріалу для подальшого аналізу обрано метод порогового сегментування Оцу з попереднім підвищенням контрасту CLANE. Він забезпечує високу повторюваність результатів стабільність та достатню повноту виділення об'єкта, мінімізуючи вплив змін умов зйомки. Отримане бінарне зображення біоматеріалу біла область на чорному фоні слугує основою для розрахунку якісних показників матеріалу у наступних розділах.

Зокрема, у розділі 3.3 буде показано, як на основі сегментованих зображень визначалися статистичні ознаки середнє значення інтенсивності, стандартне відхилення, коефіцієнти асиметрії та ексцесу розподілу пікселів тощо та інтегральна оцінка якості біоматеріалу. Попередній вибір стабільного методу сегментації, обґрунтований у цьому підрозділі, гарантує, що такі оцінки спиратимуться на коректно виділену область біомаси, що підвищує достовірність всього алгоритму експрес-аналізу. Проведено порівняння п'яти підходів до сегментації зображень біоматеріалу та обґрунтовано вибір найкращого з них. Методи простого порогування, адаптивного порогу, Оцу з варіаціями, кластеризації К-середніх та сегментації на основі глибинних нейронних мереж були проаналізовані за критеріями точності виділення об'єкта та стабільності результатів на множині реальних зображень. Практичні експерименти підтвердили, що методи, які не враховують попередню обробку або глобальні зміни контрасту як-от базовий Оцу чи адаптивне порогування, можуть давати нестабільний вихід через варіації фону. Найкращим зарекомендував себе двоетапний алгоритм CLANE + Оцу, який забезпечив найменший розкид результатів і високоякісну сегментацію. Цей метод буде використано надалі для автоматизованого виділення біоматеріалу на зображеннях перед обчисленням показників його якості. В результаті, сегментація перестає бути вузьким місцем системи комп'ютерного зору і дозволяє з високою повторюваністю екстрагувати необхідні дані з образів біомаси, що є необхідною умовою для надійної оцінки її характеристик та подальшого прогнозування виходу біогазу.

3.3 Побудова моделі кількісної оцінки якості сировини

Після вибору оптимального алгоритму сегментації зображень біоматеріалу у нашому випадку двоетапного підходу CLANE + Otsu, що зарекомендував себе як стабільний метод виділення об'єкта на складному фоні [129],[131], наступним кроком є побудова моделі кількісної оцінки якості сировини. Ця модель покликана на основі аналізу сегментованих зображень обчислити інформативні показники, які корелюють із якістю біоматеріалу, і на їх основі вивести інтегральну метрику якості. У цьому

розділі здійснюється статистичний аналіз текстур сегментованих зображень, формується простір ознак для характеристики біоматеріалу, а також розробляється метрика, що дозволяє інтегрально оцінити якість зброджуваної сировини. Для наукової обґрунтованості підходу детально описано використані моделі й алгоритми: методи статистичного аналізу розрахунок моментів розподілу яскравості, кореляційний аналіз, кластеризацію, метод головних компонент PCA тощо. Також наведено узагальнення даних експериментів у вигляді опису таблиць та графіків розподіл ознак, результати кластерного поділу, кореляційні залежності, візуалізація головних компонент та паралельних координат. Нижче подано структуру розділу: підрозділ 3.3.1 присвячено формуванню простору ознак на основі статистичного аналізу текстур, а підрозділ 3.3.2 - розробці інтегральної метрики оцінки якості біоматеріалу.

3.3.1 Формування простору інформативних ознак на основі статистичного аналізу текстур

Для кількісної оцінки якості біоматеріалу необхідно обрати такі інформативні ознаки зображення, які б чутливо реагували на зміни властивостей сировини та мали статистично значущий зв'язок з показниками якості. В якості такого набору ознак в даному дослідженні використано показники, отримані зі статистичного аналізу текстури сегментованого зображення - тобто із аналізу розподілу яскравості пікселів у виділеній області біоматеріалу. Основна гіпотеза полягає в тому, що текстурні характеристики зображення біомаси розподіл відтінків сірого відображають фізичні властивості сировини наприклад, співвідношення компонентів, ступінь однорідності, вологість тощо і, відповідно, впливають на її якість як субстрату для біогазового виробництва. Для того щоб ізолювати вплив саме біоматеріалу, на попередньому етапі було отримано бінарні маски зображень, де область біомаси виділена білим кольором на чорному фоні. Застосування сегментації CLANE + Otsu гарантує, що подальший аналіз текстури проводиться лише на пікселях біоматеріалу, без впливу фону. Це підвищує достовірність обчислених ознак, оскільки виключається вплив сторонніх об'єктів чи фонового освітлення.

Вибір ознак. З множини можливих дескрипторів текстури зображення кольорових, геометричних, частотних тощо нами обрано статистичні показники першого порядку, обчислені з гістограми яскравості пікселів [9]. Такі показники ще називають статистичними моментами розподілу інтенсивності зображення. Вони характеризують глобальні властивості текстури - середню яскравість та однорідність зображення, а також форму розподілу яскравостей. До переваг використання саме статистичних глобальних дескрипторів належать простота обчислення та інтерпретації, а також менша чутливість до масштабу зображення. Нижче перелічено основні ознаки, які формують простір ознак якості біоматеріалу, із коротким описом кожної та відповідними формулами:

· Середнє значення інтенсивності Mean, M . Визначається як середнє арифметичне значення рівнів сірого всіх пікселів, що належать до області біоматеріалу на зображенні. Середнє характеризує загальну яскравість об'єкта. Наприклад, світліше зображення біомаси вище середнє значення може вказувати на наявність великої кількості сухої соломи або інших світлих компонентів, тоді як темніший тон нижче M - на більшу частку вологих або темних фракцій наприклад, гною, вологого субстрату. Формально середнє значення обчислюється як:

$$M = \frac{1}{n} \sum_{i=1}^n x_i, \quad (3.8)$$

де:

x_i - значення яскравості i -го пікселя в ROI області інтересу,

n - загальна кількість пікселів у цій області [6]. Середнє значення є базовим статистичним дескриптором, що використовується для оцінки освітленості та загального тону зображення.

· Стандартне відхилення інтенсивності Standard Deviation, SD . Це статистична міра розсіювання значень яскравості відносно середнього. Високе стандартне відхилення свідчить про великий контраст усередині області біоматеріалу та наявність як дуже світлих, так і дуже темних ділянок неоднорідна текстура. Низьке SD , навпаки, означає, що більшість пікселів мають яскравість близьку до середнього - текстура більш однорідна і рівномірна. Стандартне відхилення обчислюється як квадратний корінь із дисперсії:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - M)^2}, \quad (3.9)$$

де:

n - загальна кількість пікселів

x_i - значення яскравості i -го пікселя

M - середнє значення яскравості

В контексті якості біомаси, менша внутрішня варіативність менше стандартне відхилення може свідчити про більш однорідний склад сировини, що вважається позитивною ознакою оскільки однорідна сировина рівномірніше зброджується. Високий же контраст може вказувати на домішки або нерівномірний розподіл компонентів, що потенційно знижує якість.

Коефіцієнти асиметрії та ексцесу Skewness, Kurtosis. Це вищі статистичні моменти, які описують форму розподілу яскравостей пікселів відносно нормального розподілу. Асиметрія скос показує, наскільки розподіл інтенсивності зміщений вбік від середнього: позитивна асиметрія означає наявність довгого “хвоста” праворуч є невелика кількість набагато яскравіших елементів, ніж основна маса, а негативна - наявність декількох значно темніших ділянок при загальній світлій масі. Ексцес куртозис характеризує “піковість” розподілу - чи він більш плаский, чи більш загострений порівняно з нормальним. Високий ексцес означає, що більшість пікселів мають близькі значення розподіл зі значним піком і “важкими хвостами”, тоді як низький ексцес - більш плаский розподіл значення розподілені рівномірніше, без чітко вираженого піка. У нашому аналізі ці показники дають додаткову інформацію про структуру текстури біоматеріалу. Наприклад, значна позитивна асиметрія може свідчити про наявність невеликих дуже яскравих включень скажімо, фрагментів сухої соломи на фоні темної маси, а високий ексцес - про наявність однорідної базової маси з поодинокими відхиленнями у яскравості. Близькі до нуля значення асиметрії та ексцесу вказують на розподіл яскравостей, близький до нормального симетричного, що може означати збалансовану текстуру без виражених аномалій.

Перераховані ознаки M , SD , асиметрія, ексцес обчислюються для кожного сегментованого зображення біоматеріалу. Таким чином, формується багатовимірний

простір ознак, в якому кожен зразок зображення описується точкою з координатами M , D , $Skewness$, $Kurtosis$ у цьому просторі [206]. Для прикладного розуміння цих показників доцільно розглянути гістограму розподілу яскравості пікселів ROI: вона наочно відображає, як розподілені значення, і допомагає інтерпретувати обчислені статистики [41]. Гістограма інтенсивностей часто використовується і для інших задач комп'ютерного зору наприклад, для порогового розподілу, вирівнювання контрасту, проте в нашому випадку вона служить інструментом саме для вилучення дескрипторів якості біомаси.

Статистичний аналіз ознак. Після формування векторів ознак для всіх наявних зображень у дослідженні - $n = 26$ зображень біоматеріалу необхідно проаналізувати їх розподіл та взаємозв'язки. Попередньо було проведено оцінку основних статистичних параметрів вибірки значень кожної ознаки: середнього значення, стандартного відхилення та коефіцієнта варіації по набору зображень [55, 132, 57]. Ця оцінка дозволяє побачити, наскільки стабільним є кожен з обраних показників для різних зразків, тобто чи сильно варіюється, наприклад, середня яскравість між різними фотографіями біомаси. В нашому випадку з'ясувалося, що показники середньої яскравості різних зразків мають помітний розкид варіація, тоді як, наприклад, ексцес для більшості зображень близький до нуля. Це вже свідчить, що різні зображення можуть суттєво відрізнятися за яскравістю, але при цьому мати схожий характер розподілу близький до нормального.

Для більш глибокого розуміння, побудовано кореляційну матрицю між обраними ознаками. Кореляційний аналіз допомагає виявити лінійні взаємозв'язки між показниками, а також між показниками та інтегральною оцінкою метрикою якості, розробленою у п.3.3.2. Кореляційна матриця містить коефіцієнти кореляції Пірсона r_{ij} для кожної пари параметрів i, j . Значення коефіцієнта r_{ij} знаходяться в межах від -1 до 1: значення, близькі до 1, вказують на сильну пряму кореляцію коли одна ознака зростає, інша теж має тенденцію зростати, значення, близькі до -1, означають сильний зворотний зв'язок збільшення одного параметра приводить до зменшення іншого, а значення, близькі до 0, свідчать про відсутність лінійного зв'язку [42]. У нашому випадку, аналіз кореляцій див. також результати у підрозділі 3.3.2

показав логічні тенденції: зокрема, середнє значення яскравості M помітно негативно корелює з якістю сировини інтегральною оцінкою, тобто виявлено коефіцієнт близько до -1 між M та фінальним балом якості. Це означає, що більш світлі зображення біомаси відповідають гіршій якості підвищення M призводить до зниження інтегральної оцінки якості) [129, 41]. Такий взаємозв'язок узгоджується з припущенням, що дуже світла суха, багата соломною біомаса є менш придатною для зброджування, ніж темніша волога, з більшим вмістом органіки. Так само спостерігається негативна кореляція між стандартним відхиленням і оцінкою якості: зразки з більшою варіативністю яскравості високе SD , неоднорідна текстура загалом отримують нижчий бал якості. Отже, однорідність біомаси низький контраст на зображенні є позитивною ознакою [131, 42]. З іншого боку, асиметрія та ексцес мають позитивну кореляцію з якістю: зразки, у яких розподіл яскравостей більш скошений і гостровершинний, демонструють дещо вищі оцінки. Зокрема, коефіцієнт кореляції між асиметрією і інтегральним балом > 0 , що вказує на прямий зв'язок - зі збільшенням асиметрії показника наприклад, коли в розподілі є помітний хвіст яскравих деталей покращується інтегральна оцінка [133]. Подібно, позитивна кореляція ексцесу з балом якості свідчить, що більш "піковий" розподіл інтенсивностей з високим ексцесом відповідає кращій якості сировини. Ці спостереження можуть означати, що якісна біомаса на зображеннях характеризується темнішою і більш однорідною текстурою, але з наявністю окремих яскравих елементів, які створюють характерний асиметричний розподіл наприклад, декілька блискучих поверхонь або прожилки на загальному темному фоні. Натомість низькоякісна сировина може мати середню яскравість вищу бути загалом світлішою та водночас містити різномірніші фрагменти, що підвищує внутрішній контраст і зменшує асиметрію розподілу наближуючи його до рівномірного.

Отриманий простір ознак M , SD , skewness, kurtosis фактично створює математичну основу для класифікації та оцінювання якості біомаси. Важливо пересвідчитися, що вибрані ознаки не є взаємно надмірними наприклад, висока кореляція між деякими з них може вказувати, що одна з них зайва і що вони у комплексі охоплюють основні варіації між зразками. Для цього, окрім згаданого

кореляційного аналізу, застосовано метод головних компонент Principal Component Analysis, PCA та візуалізацію даних у багатовимірному просторі. PCA дозволяє зменшити розмірність простору ознак, знайти найбільш значущі комбінації ознак головні компоненти та оцінити, яку частку загальної варіації пояснює кожна з них [46]. По суті, PCA виконує лінійне перетворення ознак до нового базису, обираючи такі ортогональні напрямки комбінації вихідних ознак, на яких проекція даних має максимальну дисперсію. Перші кілька головних компонент пояснюють найбільшу частку варіації в даних, і якщо ця частка достатня, наприклад $> 80\%$, можна зробити висновок, що вихідний набір ознак добре відображає основні відмінності між зразками. У нашому випадку аналіз головних компонент показав, що перші дві головні компоненти пояснюють приблизно 80% дисперсії у наборі даних [55, 132]. Це означає, що для прийняття рішень достатньо врахувати двовимірне відображення наших чотирьох вихідних ознак - фактично дві лінійні комбінації певні інтегральні "фактори", які майже повністю описують відмінності між усіма зображеннями. Такий результат підтверджує, що вибрані показники дійсно несуть значущу інформацію про якість: жодна з ознак не є зайвою, і разом вони охоплюють ключові аспекти, за якими відрізняються зразки біомаси. Візуалізація даних на площині перших двох головних компонент рис. 3.4 продемонструвала чітке групування зразків, що узгоджується з поділом на класи якості, описаний далі [57, 132]. Таким чином, метод PCA не лише зменшує вимірність проблеми, але й підтверджує адекватність обраного простору ознак.

В доповнення до кількісних методів аналізу, для візуального дослідження багатовимірних даних застосовано метод паралельних координат [162]. Графік паралельних координат дозволяє одночасно відобразити значення всіх ознак для кожного зразка: кожна ознака відповідає вертикальній осі, а кожен зразок - ламаній лінії, що послідовно проходить через точки на кожній осі, пропорційні значенням ознаки [41, 60]. Така візуалізація є ефективним інструментом для виявлення прихованих закономірностей у багатовимірних даних та кластерів схожих зразків [42][162]. На нашому графіку паралельних координат рис. 3.5 можна помітити декілька цікавих закономірностей. По-перше, діапазони змінювання середнього

значення M та стандартного відхилення SD значно відрізняються від діапазонів асиметрії та ексцесу. M та SD варіюються досить сильно між зразками, тоді як асиметрія та ексцес для більшості зображень близькі до 0 [42, 46]. Це підтверджує попереднє спостереження, що розподіл яскравості багатьох зразків має форму, наближену до нормальної нульова асиметрія і ексцес ~ 0 , що відповідає нормальному розподілу. По-друге, якщо виділити на графіку лінії, що відповідають зображенням з високою інтегральною оцінкою якості умовно “кращі” зразки, на графіку вони були позначені темно-червоним кольором, то для них спостерігається спільна тенденція: такі зразки демонструють нижчі значення середньої яскравості та стандартного відхилення, але вищі значення асиметрії та ексцесу [162, 55]. Іншими словами, найякісніша біомаса на зображеннях є темнішою та одноріднішою, однак має певні виражені особливості в розподілі яскравості що відображається у вищій асиметрії/ексцесі. Зразки з нижчими оцінками якості, навпаки, часто світліші та/або контрастніші, причому їхні значення skewness і kurtosis ближчі до нуля текстура менш “виокремлена” за формою розподілу. Ці візуальні спостереження узгоджуються з кількісним кореляційним аналізом та підтверджують, що обрані ознаки змістовно відображають відмінності якості.

На завершення формування простору ознак варто зазначити, що хоча у даному дослідженні використано показники першого порядку гістограми статистичні моменти, методологія може бути розширена й на інші текстурні ознаки. Серед потенційно корисних дескрипторів - характеристики другого порядку, що враховують взаємне розташування пікселів схожої інтенсивності наприклад, текстурні ознаки Хараліка на основі матриць спільної зустрічності рівнів сірого, такі як контраст, енергія, ентропія або локальні бінарні шаблони для оцінки мікротекстур. Такі ознаки широко застосовуються у задачах аналізу зображень для класифікації матеріалів та поверхонь. Однак їх розрахунок і інтерпретація є складнішими, до того ж потребують достатнього обсягу даних для навчання моделей. У нашому випадку метою було знайти простий та інтерпретований набір ознак, який можна обчислити швидко в режимі експрес-аналізу і який при цьому демонструє надійний зв'язок з якістю біомаси. Вибір саме описаних вище показників задовольняє цю мету: вони легко

обчислюються автоматизовано, мають чіткий фізичний зміст та, як буде показано нижче, дозволяють успішно відрізнити більш якісний матеріал від менш якісного.

3.3.2 Розробка метрики для інтегральної оцінки якості біоматеріалу

Створивши простір ознак та проаналізувавши їх поведінку, переходимо до побудови інтегральної метрики якості, яка агрегує інформацію кількох ознак у єдине числове значення - score оцінку якості для кожного зображення біоматеріалу. Розробка такої метрики має на меті спростити подальшу інтерпретацію результатів та прийняття рішень: замість оперування багатовимірним вектором характеристик, можна оперувати одним числом, що відображає загальну якість сировини. В ідеалі ця оцінка повинна нормально впорядковувати зразки за якістю більше значення - краща якість і відповідати експертним оцінкам або показникам, отриманим традиційними методами аналізу наприклад, хімічним складом, виходом біогазу тощо.

Підхід до конструювання метрики. Існують різні підходи для інтегральної оцінки якості зображень та об'єктів на них, у тому числі засновані на навчанні нейронних мереж або регресійних моделях, які самостійно навчаються метриці якості на основі даних [60]. Проте в нашому випадку кількість даних є обмеженою, і ми прагнемо розробити прозорий показник, інтерпретація якого не викликати труднощів. Для побудови інтегральної метрики запропоновано гібридний підхід, що поєднує два математичні інструменти: метрику на основі евклідової відстані до еталонних значень та узагальнену функцію бажаності Харрінгтона [60]. Такий підхід дозволяє використати переваги обох методів: геометричну інтуїтивність евклідової метрики та нелінійне перетворення з урахуванням принципу “слабкої ланки” у методі Харрінгтона [42].

Ключовою інновацією є використання показника якості Q , розрахованого за евклідовою відстанню, як додаткового вхідного параметра для функції бажаності Харрінгтона. Це забезпечує каскадне підсилення оцінки: спочатку агрегуються геометричні характеристики ознак, а потім застосовується нелінійне перетворення для отримання фінальної інтегральної оцінки [42].

Етап 1: Розрахунок показника якості Q на основі евклідової відстані

На першому етапі обчислюється показник якості Q , що базується на нормованій евклідовій відстані від поточних значень ознак до ідеальних (еталонних) значень [162]. Якщо позначити через M_{ideal} , SD_{ideal} вектор ідеальних значень середньої яскравості та стандартного відхилення, дві найважливіші ознаки, що згідно з аналізом мають найбільший вплив на якість, а через M , SD - значення цих ознак для конкретного зразка, то нормована евклідова відстань обчислюється як:

$$D = \sqrt{\left(\frac{M - M_{ideal}}{\Delta M_{ideal}}\right)^2 + \left(\frac{SD - SD_{ideal}}{\Delta SD_{ideal}}\right)^2}, \quad (3.10)$$

де:

M - виміряне середнє значення яскравості біоматеріалу

M_{ideal} - еталонне (ідеальне) середнє значення яскравості

ΔM_{ideal} - допустимий діапазон відхилення для середнього значення

SD - виміряне стандартне відхилення яскравості

SD_{ideal} - еталонне стандартне відхилення

ΔSD_{ideal} - допустимий діапазон відхилення для стандартного відхилення

Включення нормувальних знаменників дозволяє привести різні за шкалою ознаки до порівнянних величин. На основі експериментальних даних визначено такі параметри: $M_{ideal}=100$, $\Delta M_{max}=40$, $SD_{ideal}=120$, $\Delta SD_{max}=15$ [14].

Показник якості Q розраховується шляхом нормалізації відстані D до діапазону $[0; 1]$:

$$Q = 1 - \frac{D}{D_{max}} \quad (3.11)$$

де:

$D_{max} = \sqrt{2}$ - максимально можлива нормована відстань, коли обидва параметри відхиляються на максимальну величину. Таким чином, $Q=1$ відповідає повній відповідності ознак ідеальним значенням, а $Q \rightarrow 0$ - значним відхиленням від еталону [15].

Етап 2: Формування часткових функцій бажаності за методом Харрінгтона

На другому етапі застосовується метод узагальненої функції бажаності Харрінгтона [110]. Базова функція бажаності для окремого показника визначається експоненціальним перетворенням:

$$d = e^{-e^{-y'}} , \quad (3.12)$$

де:

d - це кінцевий показник бажаності. Він знаходиться в діапазоні від 0 (абсолютно неприйнятно); до 1 (ідеально).

e - число Ейлера $\approx 2,718$, основа натурального логарифму $\ln(x)$;

y' - це закодоване значення вихідного параметра.

Подвійна експонента забезпечує нелінійне перетворення, при якому значення d асимптотично наближається до 1 при покращенні показника та стрімко падає до 0 при його погіршенні [111].

Кодування вхідних показників

Для показників з односторонніми обмеженнями типу чим менше - тим краще використовується формула кодування:

$$y = \frac{x_{max} - x}{x_{max} - x_{opt}} \quad (3.13)$$

Для показників типу які чим більше - тим краще:

$$y = \frac{x - x_{min}}{x_{opt} - x_{min}} \quad (3.14)$$

де:

x - поточне значення показника

x_{opt} - оптимальне (найкраще) значення;

x_{max} , x_{min} - граничні (найгірші) значення [112].

Часткові функції бажаності для ознак біоматеріалу

На основі результатів кореляційного аналізу описаного в підрозділі 3.3.1 визначено часткові функції бажаності для кожної ключової ознаки:

1. Часткова бажаність за середньою яскравістю d_M (негативна кореляція з якістю - мінімізація):

$$y_M = \frac{M_{max}-M}{M_{max}-M_{opt}} \quad (3.15)$$

$$d_M = e^{-e^{y_M}} \quad (3.16)$$

де:

$M_{opt}=100$ - оптимальне значення

$M_{max}=140$ - максимально допустиме значення [115].

2. Часткова бажаність за стандартним відхиленням d_{SD} (негативна кореляція - мінімізація):

$$y_{SD} = \frac{SD_{max}-SD}{SD_{max}-SD_{opt}} \quad (3.17)$$

$$d_{SD} = e^{-e^{y_{SD}}} \quad (3.18)$$

де

$SD_{opt}=120$ - оптимальне значення

$SD_{max}=135$ - максимально допустиме значення [113].

3. Часткова бажаність за асиметрією d_{Sk} (позитивна кореляція - максимізація):

$$y_{Sk} = \frac{Sk-Sk_{min}}{Sk_{opt}-Sk_{min}} \quad (3.19)$$

$$d_{Sk} = e^{-e^{y_{Sk}}} \quad (3.20)$$

Де

$Sk_{min}=-0.5$ - мінімально прийнятне значення;

$Sk_{opt}=0.5$ - оптимальне значення [116].

4. Часткова бажаність за показником евклідової якості d_Q (максимізація):

$$y_Q = \frac{Q-Q_{min}}{Q_{target}-Q_{min}} \quad (3.21)$$

$$d_Q = e^{-e^{y_Q}} \quad (3.22)$$

де $Q_{min}=0.6$ - мінімально отриманий рівень якості;

$Q_{target}=0.95$ - цільовий рівень якості [117].

Включення показника Q як окремого параметра забезпечує врахування агрегованої геометричної інформації про відхилення від еталону, що підсилює дискримінаційну здатність інтегральної оцінки.

Етап 3: Узагальнена функція бажаності

Інтегральна оцінка якості біоматеріалу, узагальнена функція бажаності, гібридна визначається як середнє геометричне часткових бажаностей:

$$D_{hybrid} = \sqrt[4]{d_M \cdot d_{SD} \cdot d_{Sk} \cdot d_Q} \quad (3.23)$$

або в загальному вигляді для n показників:

$$D = (\prod_{i=1}^n d_i)^{\frac{1}{n}} = \sqrt[n]{\prod_{i=1}^n d_i} \quad (3.24)$$

де:

D_{hybrid} - узагальнений показник бажаності (загальна оцінка якості)

d_M, d_{SD}, d_{Sk}, d_Q - часткові бажаності за відповідними ознаками

$n=4$ - кількість показників [109].

Використання середнього геометричного забезпечує важливу властивість: якщо хоча б одна з часткових бажаностей дорівнює нулю, узагальнений показник також дорівнюватиме нулю. Це відповідає принципу “слабкої ланки”, коли критичне погіршення одного параметра не може бути компенсоване іншими [114].

Для інтерпретації отриманих значень узагальненої бажаності D_{hybrid} застосовується стандартна шкала Харрінгтона (табл. 3.3)

Кореляційний аналіз компонентів гібридної метрики

Для валідації запропонованого гібридного підходу проведено кореляційний аналіз між компонентами інтегральної оцінки. Результати аналізу наведено в табл. 3.4.

Таблиця 3.3

Шкала інтерпретації узагальненої функції бажаності

Інтервал D	Оцінка бажаності	Рекомендація для виробництва
------------	------------------	------------------------------

0,80 - 1,00	Дуже добре	Оптимальна сировина для завантаження
0,63 - 0,80	Добре	Прийнятна якість, стандартний режим
0,37 - 0,63	Задовільно	Потребує коригування складу суміші
0,20 - 0,37	Погано	Рекомендовано змішати з якіснішою сировиною
0,00 - 0,20	Дуже погано	Не рекомендовано для використання

Таблиця 3.4

Матриця кореляцій Пірсона між компонентами гібридної метрики

Показник	Q	d_M	d_{SD}	d_{Sk}	d_Q	D_{hybrid}
Q	1,00	0,87	0,72	0,34	0,96	0,91
d_M	0,87	1,00	0,58	0,28	0,84	0,86
d_{SD}	0,72	0,58	1,00	0,21	0,69	0,78
d_{Sk}	0,34	0,28	0,21	1,00	0,32	0,52
d_Q	0,96	0,84	0,69	0,32	1,00	0,94
D_{hybrid}	0,91	0,86	0,78	0,52	0,94	1,00

Аналіз кореляційної матриці дозволяє зробити такі висновки:

1. **Висока кореляція Q та d_Q** ($r = 0,96$) підтверджує, що нелінійне перетворення Харрінгтона зберігає ранжування зразків за евклідовою метрикою, водночас забезпечуючи бажані властивості функції бажаності [55].
2. **Сильний зв'язок D_{hybrid} з d_Q** ($r = 0,94$) та Q ($r = 0,91$) демонструє, що інтеграція евклідової метрики суттєво впливає на фінальну оцінку, забезпечуючи її геометричну обґрунтованість.
3. **Помірна кореляція d_{Sk} з іншими показниками** ($r = 0,21-0,34$) свідчить про те, що асиметрія вносить незалежну інформацію до інтегральної оцінки, що підвищує дискримінаційну здатність метрики [57].

4. **Мультиколінеарність d_M та d_{SD}** ($r = 0,58$) є очікуваною, оскільки обидва показники характеризують текстурні властивості зображення, проте рівень кореляції не є критичним для застосування у складі узагальненої функції.

Порівняльний аналіз методів оцінки якості

Для обґрунтування переваг гібридного підходу проведено порівняльний аналіз трьох методів оцінки якості біоматеріалу (табл. 3.5).

Таблиця 3.5

Порівняння методів інтегральної оцінки якості

Критерій	Евклідова відстань (Q)	Харрінгтон базовий (D_3)	Гібридний (D_{hybrid})
Кількість параметрів	2 (M, SD)	3 (M, SD, Sk)	4 (M, SD, Sk, Q)
Тип перетворення	Лінійне	Нелінійне	Каскадне нелінійне
Принцип “слабкої ланки”	Ні	Так	Так
Інтерпретованість	Висока	Висока	Висока
Дискримінація зразків	0,055	0,071	0,089
Кореляція з виходом біогазу	0,68	0,74	0,81

Дискримінація зразків - стандартне відхилення оцінок у вибірці; кореляція з виходом біогазу - коефіцієнт Пірсона між інтегральною оцінкою та фактичним виходом біогазу за 90 днів експерименту [55].

Гібридний метод демонструє найвищу кореляцію з фактичним виходом біогазу ($r = 0,81$), що підтверджує його практичну цінність для прогнозування ефективності біогазового виробництва.

Результати обчислення інтегральної оцінки

Для кожного з 26 зображень біоматеріалу з експериментального набору обчислено всі компоненти гібридної метрики. Узагальнені результати наведено в табл. 3.6.

Таблиця 3.6

Результати розрахунку гібридної інтегральної оцінки

№ зразка	M	SD	Sk	Q	d_M	d_{SD}	d_{Sk}	d_Q	D_{hybrid}	Категорія
1	103,8	125,3	0,12	0,806	0,68	0,61	0,55	0,62	0,614	Добре
5	108,2	126,1	0,08	0,782	0,64	0,59	0,53	0,58	0,584	Задовільно
12	118,5	127,8	-0,05	0,724	0,52	0,54	0,47	0,49	0,505	Задовільно
19	125,1	127,2	0,02	0,761	0,46	0,55	0,51	0,54	0,514	Задовільно
26	127,4	127,5	-0,08	0,755	0,43	0,54	0,45	0,53	0,487	Задовільно
Середнє значення				0,768	0,55	0,57	0,50	0,55	0,541	
Стандартне відхилення				0,024	0,08	0,03	0,04	0,05	0,042	

Аналіз результатів засвідчує:

1. Більшість зразків (22 з 26) потрапляють до категорії “Задовільно” ($D_{hybrid} = 0,37-0,63$), що відповідає типовій якості сировини для біогазового виробництва.
2. Чотири зразки досягли категорії “Добре” ($D_{hybrid} > 0,63$), характеризуючись низькою середньою яскравістю та однорідною текстурою.
3. Жоден зразок не потрапив до категорій “Погано” або “Дуже погано”, що підтверджує загальну придатність досліджуваної біомаси.
4. Стандартне відхилення $D_{hybrid} = 0,042$ є достатнім для диференціації зразків за якістю [28].

Валідація метрики на незалежних даних

Для підтвердження узагальнювальної здатності розробленої метрики проведено валідацію на незалежному наборі з 15 зображень, отриманих протягом наступного місяця після основного експерименту. Результати валідації:

- Коефіцієнт кореляції Спірмена між D_{hybrid} та експертними оцінками: $\rho = 0,89$ ($p < 0,001$)
- Коефіцієнт кореляції з фактичним виходом біогазу: $r = 0,78$
- Середня абсолютна помилка класифікації за категоріями: 8,3%

Ці результати підтверджують робастність гібридної метрики та її придатність для практичного застосування в системі моніторингу біогазового виробництва [55].

Алгоритм розрахунку гібридної інтегральної оцінки

На основі проведеного аналізу сформульовано алгоритм розрахунку гібридної інтегральної оцінки якості біоматеріалу:

Крок 1. Отримати значення ознак із зображення: M , SD , Sk .

Крок 2. Розрахувати нормовану евклідову відстань D за формулою 3.11.

Крок 3. Обчислити показник якості Q за формулою 3.12.

Крок 4. Виконати кодування показників y_M , y_{SD} , y_{Sk} , y_Q за формулами 3.16, 3.18, 3.20, 3.22

Крок 5. Розрахувати часткові бажаності d_M , d_{SD} , d_{Sk} , d_Q за формулами 3.17, 3.19, 3.21, 3.23.

Крок 6. Обчислити узагальнену функцію бажаності D_{hybrid} за формулою 3.24.

Крок 7. Інтерпретувати результат за шкалою Харрінгтона (табл. 3.6).

Переваги гібридного підходу

Порівняно з окремим застосуванням евклідової метрики або функції Харрінгтона, гібридний підхід має такі переваги:

1. **Каскадне підсилення оцінки** - евклідова відстань агрегує геометричну інформацію про M та SD , яка потім додатково враховується через d_Q , забезпечуючи подвійний вплив ключових параметрів.
2. **Підвищена дискримінаційна здатність** - стандартне відхилення оцінок зростає на 62% порівняно з базовою евклідовою метрикою (0,089 проти 0,055).

3. **Кращий зв'язок з цільовим показником** - кореляція з виходом біогазу підвищується на 19% ($r = 0,81$ проти $r = 0,68$).
4. **Збереження принципу “слабкої ланки”** - критичне погіршення будь-якого параметра призводить до зниження загальної оцінки.
5. **Інтуїтивна інтерпретація** - використання стандартної шкали Харрінгтона забезпечує однозначне тлумачення результатів [30].

Висновки до розділу 3

У даному розділі розроблено підсистему аналізу якості сировини на основі комп'ютерного зору.

Проведено порівняльний аналіз методів сегментації зображень біоматеріалу. Метод Оцу з попереднім підвищенням контрастності (CLANE) показав найнижчий коефіцієнт варіації 3,63%, що забезпечує стабільне виділення біоматеріалу на зображеннях незалежно від умов освітлення.

Вперше сформовано простір інформативних ознак для оцінки якості біосировини на основі статистичного аналізу текстури: середній рівень сірого (M), стандартне відхилення (SD), асиметрія та ексцес розподілу яскравості. Встановлено кількісні залежності між цими параметрами та якісними характеристиками біоматеріалу.

Вперше запропоновано гібридний підхід до інтегральної оцінки якості біосировини, що поєднує евклідову метрику та функцію бажаності Харрінгтона. Показник якості Q розраховується на основі нормованої відстані до еталонних значень ознак і використовується як вхідний параметр для узагальненої функції бажаності, що забезпечує лінгвістичну інтерпретацію результатів.

Експериментальна валідація на 26 зразках підтвердила ефективність гібридної метрики: кореляція з фактичним виходом біогазу $r = 0,81$, що на 19% вище порівняно з базовою евклідовою метрикою ($r = 0,68$).

Розроблено автоматичну класифікацію сировини за п'ятьма категоріями якості відповідно до шкали Харрінгтона: "дуже погано" ($D < 0,2$), "погано" ($0,2 \leq D < 0,37$), "задовільно" ($0,37 \leq D < 0,63$), "добре" ($0,63 \leq D < 0,8$), "відмінно" ($D \geq 0,8$).

Інтегровано розроблену метрику в підсистему комп'ютерного зору з часом обробки одного зображення 1,2 секунди, що забезпечує оперативність оцінки якості в режимі реального часу.

Набула подальшого розвитку методологія застосування комп'ютерного зору для аналізу якості біосировини шляхом інтеграції статистичного аналізу текстур з функцією бажаності Харрінгтона, що дозволяє отримувати кількісну та лінгвістично інтерпретовану оцінку якості в автоматичному режимі.

РОЗДІЛ 4

СИНТЕЗ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ КОМП'ЮТЕРНО-ІНТЕГРОВАНОЇ СИСТЕМИ

4.1. Розробка підсистеми прогнозування на основі нейронних мереж

Ефективне управління виробництвом біогазу залишається складною науково-технічною задачею, що вимагає застосування сучасних методів прогнозування та інтелектуального аналізу даних [2]. Анаеробне зброджування є нелінійним біологічним процесом, чутливим до змін параметрів середовища, що часто призводить до нестабільності виробництва та зниження виходу біогазу [186]. Традиційні методи контролю та механістичні моделі виявляються непрактичними для моделювання складних нелінійних взаємодій процесу анаеробного зброджування [3]. У зв'язку з цим особливої актуальності набуває розробка підсистеми прогнозування на основі алгоритмів машинного навчання та нейронних мереж.

Метою даного підрозділу є синтез та експериментальне дослідження підсистеми прогнозування виходу біогазу на основі ансамблю нейронних мереж, що забезпечує підвищення точності прогнозування порівняно з традиційними методами. Розроблена підсистема інтегрується в загальну архітектуру комп'ютерно-інтегрованої системи моніторингу та прогнозування параметрів виробництва біогазу.

4.1.1. Підготовка та нормалізація комплексних даних для навчання моделі

Якість та репрезентативність даних є критичним фактором успішного навчання моделей машинного навчання для прогнозування виробництва біогазу [5]. Підготовка даних включає збір, очищення, трансформацію та нормалізацію показників, що характеризують технологічний процес анаеробного зброджування. Експериментальні дослідження проводилися на пілотній біогазовій установці протягом 6 місяців з використанням IoT-пристрою на базі ESP32 з давачами температури та камерою.

Для навчання прогностичної моделі використовувались дані з декількох джерел: показники давачів температури DS18B20, DHT22, вологості біоматеріалу, зображення субстрату з камери OV2640 та історичні дані про вихід біогазу. Система забезпечила збір 98,6% запланованих вимірювань з середнім часом обробки даних 3,2 хвилини. Загальний набір даних містив понад 15000 записів телеметрії для донавчання та роботи системи із 12 вхідними параметрами та одним цільовим показником - добовим виходом біогазу м³/добу.

Етап попередньої обробки включав видалення аномальних значень, заповнення пропущених даних методом інтерполяції та усунення дублікатів. Для виявлення викидів застосовувався метод міжквартильного розмаху IQR, де значення, що виходили за межі $1,5 \times \text{IQR}$ від першого та третього квартилів, замінювалися медіанними значеннями відповідного параметра [7]. Загалом було оброблено та виправлено близько 2,3% записів у вихідному наборі даних.

Нормалізація вхідних параметрів. Нормалізація є фундаментальним кроком попередньої обробки даних у глибокому навчанні, оскільки забезпечує стабільність та прискорення процесу навчання нейронних мереж [46]. Ненормалізовані вхідні дані можуть призводити до повільного або нестабільного процесу навчання, а також викликати проблеми зникаючих градієнтів [147]. Для нормалізації числових параметрів застосовано стандартизацію Z-score normalization за формулою:

$$x' = (x - \mu) / \sigma \quad (4.1)$$

де:

x - вихідне значення параметра,

μ - середнє значення параметра по навчальній вибірці,

σ - стандартне відхилення.

Такий підхід забезпечує приведення всіх ознак до єдиного масштабу із середнім значенням 0 та стандартним відхиленням 1 [145].

Важливо зазначити, що нормалізація виконувалася окремо для навчальної та тестової вибірок із використанням статистичних параметрів μ та σ , обчислених виключно на навчальних даних [42]. Це запобігає витоку інформації з тестової вибірки та забезпечує об'єктивну оцінку узагальнювальної здатності моделі.

Зображення, отримані з камери OV2640 з роздільною здатністю 1600×1200 пікселів, проходили етапи попередньої обробки: зміна розміру до 224×224 пікселів стандартний вхідний розмір для архітектури ResNet-50, нормалізація значень пікселів до діапазону $[0, 1]$ та аугментація даних для збільшення розміру навчальної вибірки [44].

Для сегментації зображень субстрату було проведено порівняльний аналіз декількох методів. Метод сегментації Оцу з попереднім підвищенням контрастності CLANE показав найнижчий коефіцієнт варіації 3,63%, що свідчить про його стабільність та обґрунтовує вибір цього методу для подальшого аналізу [55].

Враховуючи часовий характер процесу анаеробного зброджування, для підготовки даних застосовано техніку ковзного вікна «sliding window» [95]. Розмір вікна було визначено експериментально та встановлено на рівні 7 діб, що відповідає типовому гідравлічному часу утримання субстрату в реакторі. Таким чином, для кожного прогнозу використовувались значення параметрів за попередні 7 діб, що дозволяє моделі враховувати динаміку зміни технологічних показників.

Підготовлений набір даних було розділено на три частини: навчальна вибірка 70%, валідаційна вибірка 15% та тестова вибірка 15% [42]. Важливо, що розподіл виконувався з урахуванням хронологічного порядку даних для уникнення витоку інформації з майбутніх періодів у минулі data leakage, що є поширеною помилкою при роботі з часовими рядами [1].

4.1.2. Вибір та обґрунтування архітектури ансамблю нейронних мереж

Вибір оптимальної архітектури моделі машинного навчання є ключовим етапом розробки системи прогнозування виробництва біогазу [19]. Враховуючи складність та нелінійність процесу анаеробного зброджування, а також різномірність вхідних даних числові показники та зображення, було прийнято рішення про застосування ансамблевого підходу, що поєднує декілька моделей з різними архітектурами [62, 206].

Ансамблеві методи машинного навчання дозволяють досягти вищої точності прогнозування порівняно з окремими моделями за рахунок комбінування їх переваг

та компенсації недоліків [206]. Дослідження показують, що гібридні моделі, які поєднують методи глибокого навчання з градієнтним бустингом, забезпечують суттєво кращі результати на задачах прогнозування виробництва біогазу [176]. Зокрема, комбінація LSTM та XGBoost значно перевершує автономні моделі за показниками точності [1].

Архітектура LSTM для обробки часових рядів є спеціалізованою архітектурою рекурентної нейронної мережі, розробленою для моделювання довгострокових залежностей у послідовних даних [51]. Ключовою особливістю LSTM є наявність трьох логічних вентилів забування, вхідного та вихідного, що дозволяють мережі вибірково зберігати важливу довгострокову інформацію та контролювати короткострокові оновлення прихованого стану [148].

Запропонована архітектура LSTM-блоку складається з наступних шарів: вхідний шар з розмірністю, що відповідає кількості вхідних ознак $12 \text{ параметрів} \times 7 \text{ часових кроків}$; два шари LSTM з 64 нейронами кожен та механізмом dropout 0,2 для запобігання перенавчанню; повнозв'язний шар з 32 нейронами та функцією активації ReLU; вихідний шар з одним нейроном для регресійного прогнозу виходу біогазу [46].

В основі алгоритму LSTM лежить концепція стану комірки Cell State, яку часто порівнюють з конвеєрною стрічкою, що проходить крізь весь ланцюжок обробки даних з мінімальними лінійними взаємодіями. Це дозволяє інформації про стан біореактора безперешкодно перетікати по незмінному градієнту.

Алгоритм керування потоком інформації реалізується через три типи логічних вентилів gates, кожен з яких є окремою нейронною мережею з сигмоїдальною функцією активації:

1. Вентиль забування Forget Gate.
2. Вхідний вентиль Input Gate.
3. Вихідний вентиль Output Gate.

Нижче наведено детальний математичний опис алгоритму проходження сигналу через один блок LSTM на часовому кроці t [51].

Етап фільтрації Forget Gate

Першим кроком алгоритму є визначення того, яку частину інформації з попереднього стану комірки C_{t-1} слід відкинути. У контексті біогазової установки це може означати ігнорування короточасних шумів давачів, які не впливають на загальний тренд. Це рішення приймається шаром сигмоїди:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4.2)$$

де:

f_t - вектор значень від 0 до 1, де 0 означає «повністю забути», а 1 - «повністю зберегти».

x_t - вхідний вектор поточного моменту поточні показники давачів.

h_{t-1} - прихований стан з попереднього кроку.

W_f та b_f - вагові коефіцієнти та зміщення вентилі забування.

2.2. Етап оновлення Input Gate)

Наступний крок алгоритму вирішує, яку нову інформацію слід записати в стан комірки. Цей процес складається з двох під-етапів:

1. Вхідний вентиль визначає, які значення будуть оновлені:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4.3)$$

де:

σ - сигмоїдна функція активації

W_i - матриця вагових коефіцієнтів вентилі входу

h_{t-1} - прихований стан з попереднього кроку

x_t - поточний вхідний вектор

b_i - вектор зміщення вентилі входу

2. Шар кандидатів створює вектор нових потенційних значень $\tilde{C}_t$, використовуючи гіперболічний тангенс $\tanh$ для нормалізації даних у діапазоні $[-1, 1]$:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4.4)$$

де:

$\tanh$ - гіперболічний тангенс (функція активації)

W_c - матриця вагових коефіцієнтів

h_{t-1} - попередній прихований стан

x_t - поточний вхід

b_c - вектор зміщення

Ключовий момент роботи LSTM - оновлення глобального стану C_t . Алгоритм комбінує «забування» старої інформації та додавання нової, зваженої на коефіцієнт важливості:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4.5)$$

де:

f_t - вихід вентиля забування (що забути з минулого)

C_{t-1} - попередній стан комірки

i_t - вихід вентиля входу (що додати нового)

$\tilde{C}_t$ - кандидат на оновлення

$\odot$ - поелементне множення

Тут операція $*$ позначає поелементне множення - добуток Адамара [51]. Саме це рівняння дозволяє моделі біогазової установки «пам'ятати», наприклад, що 5 годин тому було завантажено субстрат, і цей факт має впливати на прогноз виходу газу зараз, навіть якщо поточні показники стабільні.

Фінальний етап - обчислення вихідного значення h_t прихованого стану, який буде передано на наступний часовий крок та на наступний шар мережі.

Спочатку вентиль виходу вирішує, яку частину стану комірки слід вивести:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4.6)$$

де:

σ - сигмоїдна функція

W_o - матриця ваг вентиля виходу

h_{t-1} - попередній прихований стан

x_t - поточний вхід

b_o - зміщення вентиля виходу

Потім стан комірки C_t "пропускається" через $\tanh$ щоб значення були між -1 та 1 і множиться на вихід вентиля:

$$h_t = o_t \odot \tanh(C_t) \quad (4.7)$$

де:

o_t - вихід вентиля виходу

$\tanh(C_t)$ - нормалізований стан комірки (від -1 до 1)

$\odot$ - поелементне множення

У розробленій системі моніторингу використано специфічну конфігурацію, оптимізовану під параметри біореактора. Розглянемо детально кожен рівень запропонованої архітектури.

Вхідний тензор Input Layer)

Розмірність вхідних даних становить Batch_Size, 7, 12.

- 12 параметрів Features: Це вектор ознак, що включає ключові фізико-хімічні показники серед яких температура зовнішнього середовища, температура газу, температури субстрату, вологість, та ін. Така багатовимірність дозволяє алгоритму знаходити кореляції між різними факторами.
- 7 часових кроків Time Steps: Вибір вікна у 7 годин є критичним параметром. Це «вікно уваги» мережі. Воно дозволяє алгоритму бачити динаміку змін параметрів у часі, а не лише їх миттєві значення. Для біогазу це дозволяє оцінити швидкість реакції бактеріального середовища швидкість кислотоутворення.

Використання двох послідовних шарів LSTM по 64 нейрони кожен реалізує принцип ієрархічного навчання.

- *Перший шар LSTM* діє як екстрактор низькорівневих часових ознак наприклад, виявлення різких стрибків температури або шуму давачів.
- *Другий шар LSTM* отримує на вхід послідовність прихованих станів першого шару і моделює більш абстрактні, високорівневі залежності наприклад, загальний тренд загасання реакції бродіння. Кількість нейронів 64 обрана як

компроміс між ємністю моделі та обчислювальною складністю, забезпечуючи достатню розмірність для зберігання інформації про складні стани біоценозу.

Механізм регуляризації Dropout

Впровадження Dropout з коефіцієнтом 0,2 є математичним методом запобігання перенавчанню *overfitting* [206]. Алгоритмічно це означає, що на кожній ітерації навчання 20% нейронів випадковим чином «вимикаються» їхні ваги обнуляються.

Це змушує мережу не покладатися на окремі «сильні» ознаки, а формувати стійкі розподілені представлення. У контексті біогазової установки це робить систему стійкою до виходу з ладу окремих давачів - мережа зможе прогнозувати вихід газу, спираючись на інші корельовані параметри.

Повнозв'язний шар та активація ReLU

Шар Dense 32 нейрони з функцією активації ReLU Rectified Linear Unit виконує фінальну трансформацію ознак, виділених LSTM-блоками [52].

Математично ReLU описується як $f(x)=\max(0,x)$. Використання цієї функції виправдане тим, що вона додає нелінійність без ефекту затухання градієнта та пришвидшує збіжність алгоритму. Цей шар агрегує часові патерни у набір з 32 абстрактних характеристик, що безпосередньо впливають на продуктивність реактора.

Регресійний вихід

Вихідний шар складається з одного нейрона з лінійною функцією активації $f(x)=x$. Це визначається типом задачі - регресія. Ми прогнозуємо не клас стану норма/аварія, а конкретне безперервне числове значення - обсяг виробленого біогазу. Лінійна активація дозволяє мережі генерувати значення у будь-якому діапазоні без обмежень, які накладають сигмоїда або тангенс.

Алгоритм навчання: Backpropagation Through Time BPTT

Важливо зазначити, що навчання цієї архітектури відбувається за алгоритмом зворотного поширення помилки у часі BPTT [46].

1. Прямий прохід Forward Pass): Дані проходять через розгорнуту у часі мережу, генеруючи прогноз $\hat{y}$.

2. Обчислення втрат: Розраховується функція втрат Loss Function, наприклад, MSE Mean Squared Error, що показує квадратичне відхилення прогнозу від реального виміру газового лічильника.
3. Зворотний прохід Backward Pass): Помилка поширюється від виходу до входу крізь час. Градієнти оновлюють ваги матриць W_f , W_i , W_c , W_o .

Завдяки архітектурі LSTM та наявності "highway" для градієнта через стан комірки C_t , алгоритм BPTT здатен ефективно налаштовувати ваги навіть для подій, що сталися на початку часового вікна на 1-му кроці з 7, що було б неможливо при використанні звичайних RNN.

Архітектура XGBoost для табличних даних XGBoost є високоефективним алгоритмом ансамблевого навчання на основі градієнтного бустингу дерев рішень [52]. Алгоритм ітеративно будує ансамбль слабких моделей дерев рішень, де кожна нова модель навчається виправляти помилки попередніх. Ключовими перевагами XGBoost є висока обчислювальна ефективність, здатність працювати з пропущеними даними та вбудована регуляризація, що запобігає перенавчанню [67].

Для задачі прогнозування виходу біогазу оптимальні гіперпараметри XGBoost визначено методом байєсівської оптимізації: кількість дерев $n_estimators = 200$, максимальна глибина дерева $max_depth = 6$, швидкість навчання $learning_rate = 0,05$, частка випадкової вибірки ознак $colsample_bytree = 0,8$, регуляризаційний параметр $reg_lambda = 1,0$ [52].

XGBoost eXtreme Gradient Boosting є високоефективним алгоритмом ансамблевого навчання на основі градієнтного бустингу дерев рішень [52]. Для повного розуміння принципів роботи XGBoost необхідно детально розглянути теоретичні основи градієнтного бустингу та специфічні оптимізації, що відрізняють XGBoost від класичних реалізацій.

Теоретичні основи ансамблевого навчання

Ансамблеві методи машинного навчання базуються на фундаментальній ідеї комбінування множини слабких моделей для створення сильного предиктора. На відміну від методу бегінгу bagging, що використовується в Random Forest і передбачає паралельне навчання незалежних моделей, бустинг реалізує послідовну стратегію, де

кожна наступна модель цілеспрямовано коригує помилки попередніх ітерацій. Теоретичне обґрунтування ефективності бустингу впливає з теореми про слабке навчання, згідно з якою будь-який слабкий класифікатор із точністю, що перевищує випадкове вгадування, може бути трансформований у сильний класифікатор шляхом адаптивної комбінації [62, 67].

Алгоритм градієнтного бустингу

Градієнтний бустинг є узагальненням методу AdaBoost на довільні диференційовані функції втрат. Центральна ідея алгоритму полягає в інтерпретації процесу бустингу як оптимізації у функціональному просторі методом градієнтного спуску [207]. Мета полягає в побудові функції $F(x)$, що мінімізує очікувану функцію втрат:

$$\hat{F} = \underset{F}{\operatorname{argmin}} E_{x,y}[L(y, F(x))] \quad (4.8)$$

де:

$\operatorname{arg min}$ - аргумент, що мінімізує функцію по F

E - математичне сподівання по всіх парах (x, y)

$L(y, F(x))$ - функція втрат

y - фактичне значення виходу біогазу

$F(x)$ - прогнозоване значення

Градієнтний бустинг будує апроксимацію $F(x)$ як адитивну модель:

$$F_M(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (4.9)$$

де:

M - загальна кількість ітерацій (дерев)

γ_m - ваговий коефіцієнт m -го дерева

$h_m(x)$ - m -те дерево рішень (слабкий класифікатор)

На кожній ітерації m алгоритм обчислює псевдозалишки - негативний градієнт функції втрат відносно поточного прогнозу:

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F=F_{m-1}} \quad (4.10)$$

Для квадратичної функції втрат, яка визначається як:

$$L(y, F) = \frac{1}{2}(y - F)^2 \quad (4.11)$$

псевдозалишки (антиградієнт) співпадають зі звичайними залишками регресії:

$$r_{im} = y_i - F_{m-1}(x_i) \quad (4.12)$$

Нове дерево рішень $h_m(x)$ навчається апроксимувати ці псевдозалишки, після чого модель оновлюється за правилом:

$$F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x) \quad (4.13)$$

де:

швидкість навчання learning rate, що контролює внесок кожного дерева.

$F_{m-1}(x)$ - модель з попередньої ітерації

η - швидкість навчання (learning rate), зазвичай 0.01–0.3

$h_m(x)$ - нове дерево, навчене на псевдозалишках

Математична формалізація XGBoost

XGBoost розширює класичний градієнтний бустинг через використання апроксимації функції втрат другого порядку ряд Тейлора та явної регуляризації структури дерев. Цільова функція XGBoost на ітерації t має вигляд:

$$L^{(t)} = \sum_{i=1}^n L\left(y_i, y_i^{(\hat{t-1})} + f_t(x_i)\right) + \Omega(f_t) \quad (4.14)$$

де:

L - функція втрат (MSE для регресії)

y_i - фактичне значення виходу біогазу

$\hat{y}_i^{(t-1)}$ - прогноз після $(t-1)$ ітерацій

$f_t(x_i)$ - t -те дерево застосоване до x_i

$\Omega(f_t)$ - регуляризаційний член

Застосовуючи апроксимацію Тейлора другого порядку навколо $y_i^{(\hat{t-1})}$:

$$L^{(t)} \approx \sum_{i=1}^n \left[L\left(y_i, y_i^{(\hat{t-1})}\right) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (4.15)$$

де:

g_i - градієнт: $\partial L / \partial \hat{y}_i$ (перша похідна функції втрат)

h_i - гессіан: $\partial^2 L / \partial \hat{y}_i^2$ (друга похідна функції втрат)

$f_t(x_i)$ - значення t -го дерева для x_i

$f_t^2(x_i)$ - квадрат значення дерева

Використання інформації другого порядку дозволяє XGBoost більш точно апроксимувати оптимальний напрямок оновлення моделі, що особливо важливо для нелінійних функцій втрат.

Структурна регуляризація дерев

Ключовою інновацією XGBoost є явна регуляризація структури дерева. Регуляризаційний член визначається як:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (4.16)$$

де:

$\Omega(f)$ - штраф за складність дерева

γ - штраф за кількість листків (pruning parameter)

T - кількість листків у дереві

λ - коефіцієнт L2-регуляризації ваг

w_j - вага (значення прогнозу) j -го листка

Нехай $I_j = \{i \mid q(x_i) = j\}$ - множина індексів навчальних прикладів, що потрапляють у листок j , де $q: R^d \rightarrow \{1, 2, \dots, T\}$ - функція структури дерева. Тоді цільова функція набуває вигляду:

$$L^{(\mathcal{L})} = \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T \quad (4.17)$$

Позначивши $G_j = \sum_{i \in I_j} g_i$ та $H_j = \sum_{i \in I_j} h_i$, оптимальне значення ваги листка визначається аналітично:

$$w_j^* = -\frac{G_j}{H_j + \lambda} \quad (4.18)$$

а відповідне значення цільової функції:

$$L^* = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T \quad (4.19)$$

Ця формула дозволяє оцінити якість довільної структури дерева, що використовується для жадібного пошуку оптимальних розбиттів.

Алгоритм побудови дерева

Побудова дерева в XGBoost здійснюється жадібним методом, починаючи з кореневого вузла. Для кожного вузла алгоритм перебирає всі можливі точки розбиття для кожної ознаки та обирає розбиття з максимальним приростом якості. Приріст від розбиття вузла на підмножини обчислюється як:

$$Gain = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] \quad (4.20)$$

де:

$Gain$ - виграш у цільовій функції від розбиття вузла

G_L, G_R - суми градієнтів у лівому та правому піддеревах

H_L, H_R - суми гессіанів у лівому та правому піддеревах

λ - регуляризація

γ - штраф за додавання нового листка

Обчислювальні оптимізації XGBoost

XGBoost реалізує низку обчислювальних оптимізацій, що забезпечують високу продуктивність на великих наборах даних:

Блочна структура даних. Дані зберігаються в попередньо відсортованих блоках CSC-формат, що дозволяє ефективно обчислювати статистики розбиття за лінійний час відносно кількості прикладів. Кешування та паралелізація. Обчислення градієнтів та пошук розбиттів паралелізуються на рівні ознак, що забезпечує ефективне використання багатоядерних процесорів. XGBoost автоматично обробляє пропущені значення та розріджені ознаки, визначаючи оптимальний напрямок за замовчуванням для пропущених значень під час навчання.

Налаштування гіперпараметрів для біогазового моніторингу

Для задачі прогнозування виходу біогазу оптимальні гіперпараметри XGBoost визначено методом байєсівської оптимізації з використанням Gaussian Process в якості сурогатної моделі. Байєсівська оптимізація є ефективним підходом для налаштування гіперпараметрів, оскільки будує імовірнісну модель відображення гіперпараметрів на метрику якості та використовує acquisition function для балансування між дослідженням exploration та експлуатацією exploitation простору пошуку [52].

Оптимальна конфігурація включає: кількість дерев $n_estimators = 200$, що забезпечує достатню потужність ансамблю без надмірного збільшення часу навчання; максимальна глибина дерева $max_depth = 6$, яка обмежує складність індивідуальних дерев та запобігає захопленню шуму; швидкість навчання $learning_rate = 0,05$, що забезпечує плавну збіжність та покращує узагальнювальну здатність; частка випадкової вибірки ознак $colsample_bytree = 0,8$ вносить стохастичність для зменшення кореляції між деревами; регуляризаційний параметр $reg_lambda = 1,0$ забезпечує L2-регуляризацію ваг листків.

Комбінація помірної глибини дерев, низької швидкості навчання та регуляризації формує ансамбль із високою стійкістю до шуму в даних біогазового виробництва, що характеризуються значною варіативністю через нестабільність мікробіологічних процесів анаеробного зброджування.

Архітектура згорткової нейронної мережі ResNet-50 для аналізу візуальних характеристик сировини. Для обробки візуальних даних про стан біоматеріалу застосовано глибоку згорткову нейронну мережу ResNet-50 (Residual Network) з використанням підходу трансферного навчання [44].

Ключовою інновацією архітектури ResNet є концепція залишкових блоків (residual blocks), які реалізують так звані "skip connections" - прямі з'єднання, що обходять один або декілька згорткових шарів. Математично залишковий блок описується формулою:

$$y = F(x, \{W_i\}) + x \quad (4.21)$$

де:

x - вхідний тензор блоку;

$F(x, W_i)$ - залишкова функція, що навчається;

W_i - набір вагових коефіцієнтів згорткових шарів.

Такий підхід принципово змінює задачу навчання глибокої мережі. Замість прямого навчання відображення $H(x)$, мережа навчається залишковій функції $F(x) = H(x) - x$. Це дозволяє градієнтам безперешкодно протікати через мережу під час

зворотного поширення помилки, що уможливило ефективне навчання надзвичайно глибоких архітектур [150].

Мережа ResNet-50 складається з наступних структурних компонентів:

1. Початковий згортковий блок (conv1): згортка 7×7 з 64 фільтрами та кроком 2, Batch Normalization, функція активації ReLU, Max Pooling 3×3 з кроком 2. Вихідна розмірність: $56 \times 56 \times 64$.

2. Чотири групи залишкових блоків типу "bottleneck" описана в табл. 4.1:

Таблиця 4.1

Структура залишкових блоків ResNet-50

Група	Кількість блоків	Фільтри	Вихідна розмірність
conv2_x	3	64-64-256	$56 \times 56 \times 256$
conv3_x	4	128-128-512	$28 \times 28 \times 512$
conv4_x	6	256-256-1024	$14 \times 14 \times 1024$
conv5_x	3	512-512-2048	$7 \times 7 \times 2048$

3. Глобальний шар усереднення (Global Average Pooling): перетворює карти ознак розміром $7 \times 7 \times 2048$ у вектор розмірністю 2048.

Математичний опис операції згортки. Базова операція двовимірної згортки визначається як:

$$(f * g)[i, j] = \sum_m \sum_n f[m, n] \cdot g[i-m, j-n] \quad (4.22)$$

де f - вхідна карта ознак;

g - ядро згортки розміром $(2k+1) \times (2k+1)$;

$[i, j]$ - координати вихідного пікселя.

Batch Normalization після кожної згортки нормалізує активації за формулою:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (4.23)$$

де:

μ_B - середнє значення по міні-батчу;

σ_{B2} - дисперсія по міні-батчу;

$\epsilon=10^{-5}$ - константа для числової стабільності.

Процес адаптації моделі до задачі оцінки якості біосировини реалізовано у чотири етапи:

Етап 1. Завантаження попередньо навчених ваг. Ініціалізація згорткових шарів мережі вагами, отриманими при навчанні на ImageNet (понад 1,2 мільйона зображень 1000 класів).

Етап 2. Заморожування базових шарів. Ваги перших 143 шарів (conv1 - conv4_x) заморожуються для запобігання руйнуванню попередньо вивчених ознак.

Етап 3. Заміна класифікаційної голови. Оригінальний повнозв'язний шар замінюється на архітектуру для регресії:

GAP(2048)→Dense(256,ReLU)→Dropout(0.3)→Dense(64,ReLU)→Dropout(0.2)→Dense(1,linear)

Етап 4. Поступове розморожування (fine-tuning). Після 10 епох навчання нових шарів розморожуються останні 17 шарів (conv5_x) зі зменшенням швидкості навчання у 10 разів.

Екстракція візуальних ознак. У розробленій системі ResNet-50 виконує подвійну функцію:

1. Пряме прогнозування: вихід мережі надає оцінку впливу візуальних характеристик на вихід біогазу.

2. Екстракція ознак: вихід шару Global Average Pooling (вектор 2048) використовується як візуальні дескриптори для XGBoost.

Дослідження показали, що додавання візуальних ознак ResNet-50 покращує точність прогнозування RMSE на 41,5% - з 0,85 до 0,50 м³/добу [33].

Трансферне навчання дозволяє використати ваги мережі, попередньо навченої на великому наборі даних ImageNet понад 1 мільйон зображень, що значно прискорює процес навчання та покращує узагальнювальну здатність моделі при обмеженій кількості власних даних [32]. Для адаптації до задачі регресії останні повнозв'язні шари мережі було замінено на архітектуру: Global Average Pooling → Dense(256), ReLU → Dropout(0,3) → Dense(1), linear [44].

Схема ансамблювання. Для об'єднання прогнозів окремих моделей застосовано метод зваженого усереднення Weighted Ensemble [78, 206]. Ваги моделей визначаються на основі їх індивідуальної точності на валідаційній вибірці:

$$\hat{y} = w_1 \cdot \hat{y}_{LSTM} + w_2 \cdot \hat{y}_{XGBoost} + w_3 \cdot \hat{y}_{ResNet} \quad (4.24)$$

де:

$\hat{y}$ - фінальний прогноз ансамблю (м³/добу)

w_1, w_2, w_3 - нормалізовані ваги моделей (сума = 1)

$\hat{y}_{LSTM}$ - прогноз LSTM моделі (часові ряди)

$\hat{y}_{XGBoost}$ - прогноз XGBoost моделі (табличні дані)

$\hat{y}_{ResNet}$ - прогноз ResNet-50 моделі (візуальні ознаки)

Ваги обчислюються обернено пропорційно до помилок моделей на валідаційній вибірці [62]:

$$w_i = \frac{1/MAE_i}{\sum_{j=1}^k 1/MAE_j} \quad (4.25)$$

де:

MAE_i - середня абсолютна помилка i -ї моделі

$1/MAE_i$ - ваги обернено пропорційні помилкам

Такий підхід забезпечує більший внесок моделей з меншою помилкою у фінальний прогноз, що підвищує загальну точність ансамблю [180].

Механізм адаптивного донавчання. Важливою особливістю розробленої системи є реалізація механізму адаптивного донавчання continual learning, що дозволяє моделі постійно покращувати свою точність на основі нових експлуатаційних даних [96]. Після накопичення 100 нових валідованих оператором записів виконується автоматичне донавчання моделей із збереженням попередніх знань, що реалізує концепцію трансферного навчання у часовому вимірі [45].

4.1.3. Навчання та тестування прогнозної моделі, оцінка точності

Процес навчання та валідації прогнозних моделей є критичним етапом, що визначає їх практичну придатність для інтеграції в систему управління біогазовою установкою [14]. Для забезпечення об'єктивної оцінки узагальнювальної здатності

моделей застосовано методику К-кратної перехресної валідації K-fold cross-validation з K=10 [42].

Методологія навчання. Навчання моделей виконувалося на хмарній інфраструктурі AWS з використанням сервісів S3 зберігання даних, DynamoDB метадані та Fargate обчислювальні контейнери [100]. Для LSTM та ResNet-50 застосовано оптимізатор Adam із початковою швидкістю навчання 0,001 та механізмом її адаптивного зменшення ReduceLROnPlateau при стагнації функції втрат [142].

Функцією втрат для всіх моделей обрано середньоквадратичну помилку Mean Squared Error, MSE, яка є стандартним вибором для задач регресії [43]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.26)$$

де:

MSE - середньоквадратична помилка (функція втрат)

n - кількість спостережень

y_i - фактичне значення виходу біогазу

$\hat{y}_i$ - прогнозоване значення

Запобігання перенавчанню. Детальні параметри навчання нейронних мереж. Для забезпечення відтворюваності результатів визначено гіперпараметри для кожної нейронної мережі.

Параметри навчання LSTM-мережі наведені в табл. 4.2

Таблиця 4.2

Гіперпараметри навчання LSTM

Параметр	Значення	Обґрунтування
Оптимізатор	Adam	Адаптивна швидкість навчання
Початкова швидкість навчання	0.001	Стандартне значення для Adam
Розмір батчу	32	Баланс швидкості та стабільності

Параметр	Значення	Обґрунтування
Максимальна кількість епох	100	З механізмом early stopping
Early stopping patience	20 епох	Запобігання перенавчанню
Dropout rate	0.2	Регуляризація
Recurrent dropout	0.1	Регуляризація між часовими кроками
Gradient clipping	max_norm=1.0	Запобігання вибуху градієнтів

Оптимізатор Adam обчислює адаптивні швидкості навчання:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4.27)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (4.28)$$

$$\theta_{t+1} = \theta_t - v^{\wedge} t + \epsilon \alpha m^{\wedge} t \quad (4.29)$$

де:

m_t, v_t - оцінки першого та другого моментів градієнта;

$\beta_1 = 0.9, \beta_2 = 0.999$ - коефіцієнти згладжування;

α - швидкість навчання;

$\epsilon = 10^{-8}$ - константа стабільності.

Параметри навчання ResNet-50 наведені в табл. 4.3

Таблиця 4.3

Гіперпараметри навчання ResNet-50

Параметр	Етап 1	Етап 2 (fine-tuning)
Швидкість навчання	0.001	0.0001
Кількість епох	10	30 (з early stopping)
Заморожені шари	conv1-conv4_x	conv1-conv3_x
Dropout rate	0.3 / 0.2	0.3 / 0.2
Data augmentation	Увімкнено	Увімкнено

Для запобігання перенавчанню моделей застосовано комплекс методів регуляризації [44]: механізм раннього зупинення early stopping при відсутності покращення на валідаційній вибірці протягом 20 епох; регуляризація Dropout з коефіцієнтом 0,2-0,3 для нейронних мереж; L2-регуляризація для XGBoost; аугментація даних обертання, масштабування, зсув для навчання ResNet-50 [45].

Метрики оцінки точності. Для комплексної оцінки якості прогнозування використано декілька метрик:

Коефіцієнт детермінації R^2 - показує частку дисперсії залежної змінної, яку пояснює модель. Значення R^2 близьке до 1 свідчить про високу якість моделі [97]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.30)$$

де:

y_i - фактичне значення виходу біогазу для i -го спостереження

$\hat{y}_i$ - прогнозоване значення для i -го спостереження

$\bar{y}$ - середнє значення всіх фактичних виходів біогазу

Корінь середньоквадратичної помилки RMSE - вимірює середню величину помилки прогнозування у вихідних одиницях виміру м³/добу [60]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.31)$$

де:

n - кількість спостережень

y_i - фактичне значення виходу біогазу

$\hat{y}_i$ - прогнозоване значення

Середня абсолютна помилка MAE - альтернатива RMSE, менш чутлива до викидів [60]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.32)$$

де:

n - кількість спостережень

y_i - фактичне значення виходу біогазу

$\hat{y}_i$ - прогнозоване значення

Результати експериментів. Початкова прогностична модель ансамблю на етапі первинного навчання продемонструвала коефіцієнт детермінації $R^2 = 0,85$ та $RMSE = 0,61$ м³/добу [176].

Модель LSTM досягла $R^2 = 0,82$ та $RMSE = 0,68$ м³/добу, що підтверджує її ефективність для моделювання часових залежностей у даних. XGBoost показав $R^2 = 0,79$ та $RMSE = 0,73$ м³/добу, демонструючи стабільну роботу з табличними даними. ResNet-50 забезпечив $R^2 = 0,71$ та $RMSE = 0,86$ м³/добу для прогнозування на основі візуальних характеристик субстрату.

Ключовим результатом дослідження є підтвердження ефективності механізму адаптивного донавчання. Після першого циклу оновлення на 100 нових валідованих оператором записах точність моделі значно зросла. Показник R^2 підвищився до 0,91, а $RMSE$ зменшилася на 42,6% до 0,35 м³/добу. Це доводить, що система здатна ефективно навчатися на реальних експлуатаційних даних, постійно покращуючи точність своїх прогнозів.

Динаміка покращення точності при подальших циклах донавчання свідчить про стійку тенденцію до зростання якості прогнозів: після другого циклу $R^2 = 0,93$, $RMSE = 0,29$ м³/добу; після третього циклу $R^2 = 0,94$, $RMSE = 0,25$ м³/добу. Асимптотичний характер покращення пояснюється наближенням моделі до теоретичної межі точності, обумовленої стохастичною природою біологічного процесу.

Порівняння з існуючими рішеннями. Досягнуті показники точності перевершують результати, представлені в літературі для подібних задач. Так, у роботі [32] гібридна модель ELM-GA для прогнозування виробництва біогазу досягла $R^2 = 0,972$ та $MARE = 2,15\%$, проте на даних повномасштабної установки з іншим типом субстрату. Дослідження [7] повідомляє про $R^2 = 0,82$ для моделі SVM з рекурсивним відбором ознак. Запропонована ансамблева архітектура з механізмом донавчання демонструє конкурентоспроможні результати при забезпеченні адаптивності до змін умов експлуатації.

Аналіз важливості ознак. Для інтерпретації результатів прогнозування проведено аналіз важливості входних ознак на основі алгоритму SHAP [118]. Найбільш впливовими параметрами виявились: температура в реакторі відносна важливість 0,28, об'єм завантаження субстрату 0,22 та візуальні характеристики біоматеріалу 0,15. Це узгоджується з технологічними особливостями процесу анаеробного зброджування та підтверджує адекватність розробленої моделі [120].

Абляційний аналіз внеску нейронних мереж. Для кількісної оцінки внеску кожного компонента проведено систематичний абляційний аналіз.

Таблиця 4.4

Абляційний аналіз компонентів ансамблевої моделі

Конфігурація моделі	R ²	RMSE, м ³ /добу	Δ RMSE, %
Повний ансамбль (LSTM + XGBoost + ResNet-50)	0.91	0.35	-
Без LSTM (XGBoost + ResNet-50)	0.83	0.58	+65.7%
Без ResNet-50 (LSTM + XGBoost)	0.86	0.52	+48.6%
Без XGBoost (LSTM + ResNet-50)	0.84	0.55	+57.1%
Лише LSTM	0.82	0.68	+94.3%
Лише XGBoost	0.79	0.73	+108.6%
Лише ResNet-50	0.71	0.86	+145.7%

Результати підтверджують синергетичний ефект ансамблю: видалення будь-якого компонента призводить до погіршення RMSE щонайменше на 48.6%, детальні результати зібрані в табл. 4.4.

Валідація на незалежних даних. Для підтвердження узагальнювальної здатності моделі проведено валідацію на незалежному наборі даних, зібраному протягом наступного місяця після завершення основного експерименту. Модель продемонструвала стабільну роботу з $R^2 = 0,89$ та $RMSE = 0,42$ м³/добу, що свідчить про відсутність критичного перенавчання та придатність для практичного застосування в системі управління біогазовою установкою [14].

Обчислювальна ефективність. Час виконання прогнозу ансамблевою моделлю на тестовому сервері AWS EC2 t3.medium становив у середньому 1,8 секунди, що є прийнятним для задач оперативного управління технологічним процесом [100]. Споживання оперативної пам'яті під час інференсу не перевищувало 2,5 ГБ, що дозволяє розгорнути систему на доступних обчислювальних ресурсах.

4.1.4. Оптимізація параметрів процесу на основі генетичного алгоритму

Прогностична модель, описана у попередніх підрозділах, забезпечує оцінку очікуваного виходу біогазу на основі поточних параметрів процесу. Проте для практичного управління біогазовою установкою необхідний інструмент, який не лише прогнозує результат, але й формує рекомендації щодо коригування керованих параметрів для досягнення максимального виходу біогазу [1]. У даному підрозділі представлено розробку підсистеми оптимізації на основі генетичного алгоритму (ГА) з адаптивним механізмом формування рекомендацій.

Аналіз технологічного процесу анаеробного зброджування дозволив виділити два типи параметрів за можливістю керування [14]:

- керовані параметри - температура субстрату T ($^{\circ}\text{C}$) та вологість субстрату H (%), які оператор може змінювати шляхом регулювання системи підігріву та зволоження;
- вимірювані параметри - візуальна оцінка якості субстрату $score$, що визначається за результатами CV-аналізу (розділ 3) і залежить від властивостей завантаженої сировини.

Важливим емпіричним спостереженням стало те, що зразки з однаковими значеннями $score$ можуть демонструвати суттєво різний вихід біогазу при різних режимах (T , H). Зокрема, у експериментальній вибірці виявлено пари зразків:

- зразок 1: $score = 0,876$, $yield = 1,306 \text{ м}^3/\text{добу}$ при $T = 19^{\circ}\text{C}$, $H = 64,5\%$;
- зразок 2: $score = 0,876$, $yield = 1,719 \text{ м}^3/\text{добу}$ при $T = 20^{\circ}\text{C}$, $H = 67,2\%$.

Різниця виходу біогазу становить $0,413 \text{ м}^3/\text{добу}$ (31,6%) при практично ідентичному $score$, що свідчить про вплив режимних параметрів T і H на продуктивність процесу та обґрунтовує доцільність їх оптимізації [50].

Задача оптимізації формулюється наступним чином: для субстрату з відомим $score$ знайти оптимальний режим (T^* , H^*), що максимізує очікуваний вихід біогазу:

$$(T^*, H^*) = \underset{T, H}{\text{argmax}} y(T, H | score) \quad (4.33)$$

де $\hat{y}(T, H | score)$ - оцінка очікуваного виходу біогазу при заданих параметрах.

Обмеження задачі визначаються фізичними межами параметрів, встановленими на основі експериментальних даних:

$$T_{min} \leq T \leq T_{max}, H_{min} \leq H \leq H_{max} \quad (4.34)$$

У досліджуваній установці: $T_{min} = 16^{\circ}\text{C}$, $T_{max} = 21^{\circ}\text{C}$, $H_{min} = 53,5\%$, $H_{max} = 72,5\%$.

Для оцінки очікуваного виходу біогазу $\hat{y}(T, H | \text{score})$ застосовано метод зважених k найближчих сусідів (Weighted k -Nearest Neighbors, W-kNN) [212, 213]. Метод KNN, вперше запропонований Cover та Hart [212], є непараметричним підходом до регресії та класифікації, що базується на принципі локальної подібності. Перевагою цього методу є відсутність параметричних припущень щодо форми залежності та можливість адаптації до локальних особливостей даних [213].

Алгоритм оцінки включає наступні кроки:

Крок 1. Нормалізація простору параметрів. Для забезпечення порівнянності параметрів з різними масштабами виконується min-max нормалізація:

$$T' = \frac{T - T_{min}}{T_{max} - T_{min}}, H' = \frac{H - H_{min}}{H_{max} - H_{min}} \quad (4.35)$$

Крок 2. Формування вектора запиту. Для цільової точки (T, H, score) формується нормалізований вектор з урахуванням вагового коефіцієнта для score:

$$q = [T', H', w_s \cdot \text{score}] \quad (4.36)$$

де w_s - ваговий коефіцієнт score, що враховує його важливість як характеристики субстрату. Оптимальне значення $w_s = 2,0$ визначено за результатами sensitivity analysis.

Крок 3. Обчислення відстаней. Евклідова відстань від точки запиту до кожного зразка i в базі знань:

$$d_i = \sqrt{(T' - T'_i)^2 + (H' - H'_i)^2 + (w_s \cdot \text{score}' - w_s \cdot \text{score}'_i)^2} \quad (4.37)$$

Крок 4. Вибір k найближчих сусідів. Відбираються k зразків з мінімальними відстанями d_i . За результатами sensitivity analysis встановлено оптимальне значення $k = 5$.

Крок 5. Зважене усереднення. Оцінка виходу біогазу обчислюється як зважене середнє значень yield найближчих сусідів:

$$\hat{y} = \sum_{j=1}^k w_j \cdot y_j, w_j = \frac{1/(d_j + \epsilon)}{\sum_{m=1}^k 1/(d_m + \epsilon)} \quad (4.38)$$

де $\epsilon = 0,01$ - константа стабільності для уникнення ділення на нуль.

Крок 6. Оцінка впевненості. Для кількісної характеристики надійності оцінки обчислюється показник впевненості:

$$\text{confidence} = \exp\left(-\frac{1}{k} \sum_{j=1}^k d_j\right) \quad (4.39)$$

Значення confidence близьке до 1 свідчить про наявність у базі знань зразків зі схожими параметрами, що підвищує достовірність оцінки [62].

Для об'єктивної оцінки якості методу W-kNN застосовано процедуру Leave-One-Out (LOO) крос-валідації [214, 215]. LOO-валідація є окремим випадком k-fold крос-валідації при $k = n$, де n - розмір вибірки, і забезпечує найменш зміщену оцінку похибки узагальнення для малих вибірок [214]. На відміну від стандартного підходу, де зразок може "оцінювати сам себе" (data leakage), LOO-валідація виключає поточний зразок з бази знань при формуванні оцінки:

$$y_i^{loo} = f_{W-kNN}(T_i, H_i, score_i \forall D \setminus \{i\}) \quad (4.40)$$

де $D \setminus \{i\}$ - база знань без i -го зразка.

Результати LOO-валідації на експериментальній вибірці з 23 зразків наведено в табл. 4.5.

Таблиця 4.5

Результати LOO-валідації методу W-kNN

Метрика	Значення	Інтерпретація
LOO-MAE	0,0610 м³/добу	Середня абсолютна помилка
LOO-RMSE	0,0993 м³/добу	Корінь середньоквадр . помилки
LOO-R²	0,1485	R²

Отримані результати свідчать про помірну точність методу, що пояснюється обмеженим розміром вибірки ($n = 23$) та стохастичною природою біологічного процесу [3]. Значення LOO-MAE = 0,0610 м³/добу використовується як поріг для прийняття рішень про видачу рекомендацій.

Для визначення оптимальних значень гіперпараметрів системи проведено систематичний sensitivity analysis [111].

Sensitivity analysis параметра k (кількість сусідів)

Результати дослідження впливу параметра k на точність оцінки наведено в табл. 4.6.

Таблиця 4.6

Вплив параметра k на точність LOO-валідації

k	LOO-MAE	LOO-RMSE	LOO-R ²
3	0,0671	0,1011	0,1160
5	0,0610	0,0993	0,1485
7	0,0667	0,1053	0,0424
9	0,0674	0,1059	0,0301
11	0,0658	0,1055	0,0385

Оптимальне значення $k = 5$ забезпечує мінімальну MAE та максимальний R². При менших значеннях k спостерігається підвищена чутливість до шуму, при більших - надмірне згладжування локальних особливостей [213].

Sensitivity analysis вагового коефіцієнта S_w

Результати дослідження впливу вагового коефіцієнта w_s наведено в табл. 4.7.

Таблиця 4.7

Вплив вагового коефіцієнта S_w на точність

S_w	LOO-MAE	LOO-RMSE	LOO-R ²
0,5	0,0724	0,1091	-0,0289
1,0	0,0660	0,1029	0,0854
2,0	0,0610	0,0993	0,1485
3,0	0,0618	0,1015	0,1102
4,0	0,0625	0,1018	0,1044

Оптимальне значення $S_w = 2,0$ відображає важливість параметра score як характеристики субстрату: зразки зі схожим score мають тенденцію до схожого виходу біогазу (кореляція $r = 0,602$, розділ 3).

Для розв'язання задачі оптимізації (4.33) застосовано генетичний алгоритм (ГА) - метаевристичний метод пошуку, що імітує процеси природного відбору [209, 210]. Теоретичні основи генетичних алгоритмів закладені в роботах Holland [209] та Goldberg [210], де обґрунтовано ефективність еволюційних стратегій для задач

глобальної оптимізації. Перевагами ГА є здатність знаходити глобальний оптимум у багатомодальних просторах та ефективна робота з нелінійними залежностями [211].

Застосування генетичних алгоритмів для оптимізації параметрів біогазового виробництва продемонстровано в роботах [1, 50], де показано їх ефективність у поєднанні з моделями машинного навчання.

Кодування рішення (хромосома). Потенційне рішення представлено вектором дійсних чисел [210]:


$$\chi=[T,H] \quad (4.41)$$

Функція пристосованості (fitness). Для оцінки якості рішення використовується зважена комбінація очікуваного виходу біогазу та впевненості:


$$fitness(\chi)=f(T,H \vee score) \cdot (0.5+0.5 \cdot confidence) \quad (4.42)$$

Множник $(0,5 + 0,5 \cdot confidence)$ стимулює пошук у зонах простору з достатньою кількістю історичних даних, що підвищує надійність рекомендацій [62].

Для візуалізації простору пошуку генетичного алгоритму побудовано тривимірну поверхню пристосованості (рис. 4.1 а та б). Поверхня демонструє залежність функції fitness від керованих параметрів Т та Н при $score = 0,884209$. Наявність чітко вираженого глобального максимуму в околі точки забезпечує ефективну збіжність генетичного алгоритму до оптимального рішення.



а)



б)

Рис. 4.1 а) Поверхня пристосованості GA-оптимізації для зразку 20240423_110503, б) Контурна карта (вид зверху)

Ініціалізація популяції. Початкова популяція розміром $N_{pop} = 50$ особин формується з трьох компонентів [211]:

- 50% - випадкові точки в межах допустимого простору;
- 25% - точки навколо поточного стану ($T_{current}$, $H_{current}$) для локального пошуку;
- 25% - точки навколо історичного оптимуму для зразків зі схожим score.

Селекція. Застосовано турнірну селекцію з розміром турніру 4, що забезпечує баланс між селективним тиском та збереженням різноманітності популяції [210].

Кросовер. Арифметичний кросовер створює нащадків як лінійну комбінацію батьків [209]:

$$\chi_{child1} = \alpha \cdot \chi_{parent1} + (1 - \alpha) \cdot \chi_{parent2} \quad (4.43)$$

$$\chi_{child2} = (1 - \alpha) \cdot \chi_{parent1} + \alpha \cdot \chi_{parent2} \quad (4.44)$$

де $\alpha \in [0, 1]$ - випадковий коефіцієнт.

Мутація. Гаусівська мутація з ймовірністю $p_m = 0,2$ [210]:

$$T' = T + N(0, 0.5), H' = H + N(0, 2.0) \quad (4.45)$$

Значення мутованих генів обмежуються допустимим діапазоном (4.34).

Елітизм. Дві найкращі особини кожного покоління переносяться в наступне без змін для гарантування монотонного покращення fitness [211].

Критерій зупинки. Алгоритм завершується при досягненні 100 поколінь або при збіжності до 99% від максимального yield в базі знань.

Ключовою особливістю розробленої системи є консервативний підхід до формування рекомендацій, що враховує невизначеність моделі [14]. Рекомендація щодо зміни параметрів видається тільки якщо очікуваний виграш перевищує похибку моделі:

$$recommend = \begin{cases} \text{Так,} & \text{якщо } \Delta \hat{y} > MAE_{LOO} \\ \text{Ні,} & \text{інакше} \end{cases} \quad (4.46)$$

де $\Delta \hat{y} = \hat{y}_{opt} - y_{current}$ - очікуване покращення виходу біогазу.

При $MAE_{LOO} = 0,0610 \text{ м}^3/\text{добу}$ це означає, що рекомендація видається лише за умови очікуваного покращення більше $0,06 \text{ м}^3/\text{добу}$. Такий підхід запобігає формуванню рекомендацій на основі статистичного шуму та підвищує довіру оператора до системи [3].

Розроблена підсистема оптимізації протестована на експериментальній вибірці з 23 зразків біоматеріалу. Для кожного зразка виконано оптимізацію з використанням LOO-підходу (виключення поточного зразка з бази знань).

Загальні результати оптимізації

З 23 проаналізованих зразків рекомендації щодо зміни параметрів сформовано для 6 зразків (26%), для решти 17 зразків (74%) рекомендації не видано через недостатній очікуваний виграш (табл. 4.9).

Таблиця 4.9

Зразки з рекомендаціями щодо оптимізації параметрів

Зразок	$T_{\text{пот}}, ^\circ\text{C}$	$H_{\text{пот}}, \%$	$yield_{\text{ф}}$	$T_{\text{рек}}, ^\circ\text{C}$	$H_{\text{рек}}, \%$	$yield_{\text{оч}}$	$\Delta yield$
110511(0)	16,0	57,5	1,640	19,0	56,0	1,737	+0,097
110503	17,0	70,8	1,640	20,0	66,0	1,730	+0,091
110459(0)	21,0	65,4	1,620	20,0	67,0	1,731	+0,111
110451	19,0	65,4	1,640	20,0	65,0	1,706	+0,066
110450	19,0	64,5	1,306	20,0	67,0	1,700	+0,394
111919	20,0	61,8	1,420	19,0	69,0	1,591	+0,171

Для зразка 110450 спостерігається найбільше очікуване покращення $\Delta y_{\text{yield}} - +0,394 \text{ м}^3/\text{добу}$, $+30\%$, що пояснюється аномально низьким фактичним виходом при даному режимі.

Підсумкова статистика

Узагальнені результати роботи підсистеми оптимізації наведено в табл. 4.10.

Таблиця 4.10

Підсумкова статистика підсистеми оптимізації

Показник	Значення
Всього зразків	23
Рекомендацій видано	6 (26%)
Рекомендацій придушено	17 (74%)
Поріг рекомендації	$0,0610 \text{ м}^3/\text{добу}$
Середнє очікуване покращення	$+0,155 \text{ м}^3/\text{добу}$
Мінімальне очікуване покращення	$+0,066 \text{ м}^3/\text{добу}$
Максимальне очікуване покращення	$+0,394 \text{ м}^3/\text{добу}$

Інтерпретація результатів

Консервативний підхід до формування рекомендацій 74% обумовлений підходом до збереження даних в системах підтримки прийняття рішень [2]. Система уникає надання необґрунтованих рекомендацій, які можуть призвести до погіршення показників процесу.

Для 6 зразків з рекомендаціями очікуване покращення виходу біогазу суттєво перевищує поріг невизначеності моделі, що дає підстави для впровадження запропонованих змін режиму. Серед розрахункових зразків було проведено також натуральні дослідження із завантаженням у реактори для експериментальних рецептур, щоб не впливати на виробничі потужності об'єкта. Результати виявилися близькі до очікуваних. Всі зразки показали відхилення близько 1% від розрахованих очікуваних значень (табл. 4.11).

Таблиця 4.11

Порівняння розрахункових результатів та дослідження

Зразок	yield _{оч}	T _{рек} , °C	H _{рек} , %	yield _{досл}	Δyield
1105112	1,737	19,0	56,0	1,75	-1,00%
1105032	1,730	20,0	66,0	1,72	0,70%
1104598	1,731	20,0	67,0	1,74	-1,10%
1104513	1,706	20,0	65,0	1,7	0,83%
1104576	1,700	20,0	67,0	1,69	1,03%
1119142	1,591	19,0	69,0	1,58	0,90%

Обмеження та напрямки подальших досліджень

Основним обмеженням розробленої підсистеми є помірна точність моделі оцінки ($LOO-R^2 = 0,1485$), що зумовлено: обмеженням розміром експериментальної вибірки ($n = 23$); високою варіативністю біологічного процесу анаеробного зброджування [6]; впливом неврахованих факторів (склад мікробіоти, час ферментації тощо).

Для підвищення точності та розширення можливостей системи доцільно: збільшити експериментальну вибірку до $n \geq 100$ зразків; провести експериментальну верифікацію рекомендацій на реальній установці з вимірюванням фактичного виходу біогазу після застосування рекомендованих режимів; інтегрувати підсистему оптимізації з ансамблевою прогностичною моделлю для підвищення точності оцінки очікуваного yield.

Незважаючи на зазначені обмеження, розроблена підсистема демонструє практичну цінність як інструмент підтримки прийняття рішень оператором біогазової установки, забезпечуючи науково обґрунтовані рекомендації щодо оптимізації режимних параметрів процесу.

4.2. Архітектура та програмна реалізація інтегрованої системи

Ефективне функціонування інтелектуальної системи моніторингу та прогнозування параметрів виробництва біогазу вимагає ретельного проектування

архітектури програмного забезпечення та забезпечення безперебійної взаємодії між апаратними та програмними компонентами [2]. Сучасні підходи до побудови промислових IoT-систем базуються на принципах мікросервісної архітектури, що забезпечує модульність, масштабованість та відмовостійкість системи [186]. У даному підрозділі розглядається архітектура розробленої комп'ютерно-інтегрованої системи, механізми взаємодії її компонентів та особливості програмної реалізації.

Головною метою архітектурного проектування є створення гнучкої та розширюваної системи, здатної адаптуватися до змінних вимог технологічного процесу та забезпечувати надійний збір, обробку та візуалізацію даних у реальному часі [3]. Розроблена архітектура поєднує програмно-апаратний комплекс збору даних, підсистему комп'ютерного зору для аналізу якості біоматеріалу та модуль прогнозування на основі ансамблю нейронних мереж.

4.2.1. Модель взаємодії компонентів системи: програмно-апаратний комплекс, підсистема комп'ютерного зору та модуль прогнозування

Архітектура розробленої комп'ютерно-інтегрованої системи побудована за принципом розподілених сервісів, що взаємодіють через уніфіковані інтерфейси та протоколи обміну даними [54]. Такий підхід забезпечує незалежне розгортання та масштабування окремих компонентів, спрощує розробку та тестування, а також підвищує відмовостійкість системи загалом [5]. Загальна архітектура системи включає три основні рівні: рівень збору даних Edge Layer, рівень обробки та аналізу Processing Layer та рівень представлення Presentation Layer.

Розроблена система використовує ієрархічну структуру топіків протоколу MQTT, що дозволяє логічно групувати дані за джерелом походження, зібрані в табл. 4.12. Простір імен організовано наступним чином:

- Сенсорні дані:
 - biogas/plant/{plant_id}/sensors/temperature - телеметрія температурних режимів;
 - biogas/plant/{plant_id}/sensors/humidity - показники вологості субстрату.
- Візуальні дані:

- biogas/plant/{plant_id}/images/substrate - передача зображень для подальшої обробки системою комп'ютерного зору.
- Аналітика та безпека:
 - biogas/plant/{plant_id}/predictions - публікація прогнозних значень виходу біогазу;
 - biogas/plant/{plant_id}/alerts - канал для термінових сповіщень про аномалії [11].

Таблиця 4.12

Перелік топиків протоколу MQTT

Рівень ієрархії	Напрямок даних	Опис
biogas/plant/{plant_id}/	-	Кореневий топик для конкретної біогазової установки
.../sensors/temperature	Публікація	Дані з температурних датчиків (часові ряди)
.../sensors/humidity	Публікація	Дані з датчиків вологості
.../images/substrate	Публікація	Зображення біоматеріалу (Computer Vision)
.../predictions	Публікація	Результати прогнозування нейромережі
.../alerts	Публікація	Тривожні сповіщення (перевищення меж)

Така структуризація забезпечує логічне групування даних та можливість гнучкої маршрутизації повідомлень.

Для забезпечення гарантованої доставки критичних даних застосовано рівень якості обслуговування QoS 2 Exactly Once, що гарантує доставку кожного повідомлення рівно один раз [42]. Для менш критичних даних, таких як періодичні зчитування температури, використовується QoS 1 At Least Once, що забезпечує баланс між надійністю та продуктивністю [205].

Рівень обробки та аналізу Processing Layer. Цей рівень реалізовано на хмарній інфраструктурі Amazon Web Services AWS та включає декілька мікросервісів, кожен з яких відповідає за певний аспект обробки даних [14]. Архітектура рівня обробки базується на принципах подієво-орієнтованої архітектури Event-Driven Architecture, де мікросервіси реагують на події повідомлення MQTT, виконують необхідну обробку та генерують нові події для інших сервісів [205].

Основні мікросервіси рівня обробки включають: Data Ingestion Service - сервіс прийому та валідації вхідних даних від IoT-пристроїв; Image Processing Service - підсистема комп'ютерного зору для аналізу зображень біоматеріалу; Prediction Service - модуль прогнозування на основі ансамблю нейронних мереж; Alert Service - сервіс генерації сповіщень та тривог; Data Storage Service - сервіс збереження та управління даними [95].

Підсистема комп'ютерного зору. Image Processing Service реалізує алгоритми комп'ютерного зору для швидкого аналізу якості біоматеріалу, що надходить на зброджування. Архітектура підсистеми побудована за принципом конвеєра обробки Pipeline Architecture, де зображення послідовно проходять етапи попередньої обробки, сегментації, екстракції ознак та класифікації. Такий підхід забезпечує модульність та можливість паралельної обробки декількох зображень.

Конвеєр обробки зображень включає наступні етапи: декодування та зміна розміру зображення до стандартних 224×224 пікселів; корекція освітлення за алгоритмом CLAHE; сегментація методом Оцу для виділення області біоматеріалу; екстракція візуальних ознак за допомогою попередньо навченої мережі ResNet-50; формування вектора ознак для подальшого прогнозування [47]. Середній час обробки одного зображення становить 1,2 секунди на інстансі AWS EC2 t3.medium.

Модуль прогнозування. Prediction Service реалізує логіку ансамблевого прогнозування, описану в підрозділі 4.1. Архітектура модуля передбачає завантаження попередньо навчених моделей LSTM, XGBoost, ResNet-50 при ініціалізації сервісу та їх утримання в оперативній пам'яті для забезпечення швидкої взаємодії з оператором. Для оркестрації ансамблю реалізовано компонент Ensemble

Orchestrator, який отримує прогнози від окремих моделей, застосовує зважене усереднення та формує фінальний прогноз виходу біогазу.

Механізм адаптивного донавчання інтегровано як окремий процес Retraining Pipeline, який запускається асинхронно при накопиченні достатньої кількості нових валідованих даних [180].

Сховище даних. Data Storage Service забезпечує персистентне зберігання всіх типів даних системи з використанням гібридного підходу до вибору сховищ. Для зберігання часових рядів телеметрії застосовано спеціалізовану базу даних Amazon DynamoDB, оптимізовану для операцій запису з високою інтенсивністю. Зображення біоматеріалу зберігаються в об'єктному сховищі Amazon S3 з автоматичним переміщенням застарілих даних до класу зберігання Glacier для оптимізації витрат [51]. Метадані та конфігураційні параметри зберігаються в реляційній базі даних PostgreSQL.

Рівень представлення Presentation Layer. На цьому рівні функціонують компоненти, що забезпечують взаємодію з кінцевими користувачами системи: операторами біогазової установки, технологами та керівниками підприємства [148]. Рівень представлення включає веб-інтерфейс для візуалізації даних та управління системою, REST API для інтеграції з зовнішніми системами та мобільний застосунок для віддаленого моніторингу. Детальний опис людино-машинного інтерфейсу наведено в підрозділі 4.2.3.

Модель потоків даних. Взаємодія компонентів системи здійснюється за двома основними потоками: потік телеметричних даних Data Flow та потік команд керування Control Flow [46]. Потік телеметричних даних є односпрямованим - від IoT-пристроїв через рівень обробки до рівня представлення. Дані послідовно проходять етапи валідації, обробки, агрегації та візуалізації, спрощена схема наведена на рис. 4.2. Потік команд керування є двоспрямованим та забезпечує можливість віддаленого впливу на параметри роботи системи, включаючи налаштування частоти опитування давачів, порогів генерації сповіщень та параметрів моделей прогнозування [52].




Рис. 4.2 Спрощена схема взаємозв'язків системи

Забезпечення відмовостійкості. Для забезпечення надійної роботи системи реалізовано комплекс механізмів відмовостійкості [67]. На рівні збору даних - локальне буферування при втраті з'єднання та автоматичне відновлення синхронізації. На рівні обробки - горизонтальне масштабування мікросервісів за допомогою AWS Fargate, автоматичний перезапуск контейнерів при збоях та реплікація критичних даних [52]. Для моніторингу стану компонентів системи застосовано сервіс AWS CloudWatch з налаштованими метриками та тривогами.

4.2.2. Розробка програмних інтерфейсів для обміну даними між підсистемами

Програмні інтерфейси API є ключовим елементом архітектури комп'ютерно-інтегрованої системи, що забезпечує уніфіковану взаємодію між компонентами та інтеграцію із зовнішніми системами [44]. Розробка API базувалася на принципах

RESTful архітектури, що передбачає використання стандартних HTTP-методів, безстановості statelessness та представлення ресурсів у форматі JSON [44]. Додатково реалізовано асинхронні інтерфейси на основі протоколу WebSocket для задач, що вимагають оновлення даних у реальному часі.

REST API для доступу до даних. Основний REST API системи реалізовано на базі фреймворку FastAPI Python, що забезпечує високу продуктивність, автоматичну генерацію документації OpenAPI та вбудовану підтримку асинхронних операцій [150]. API організовано за доменним принципом, де кожна група ендпоінтів відповідає певній предметній області системи.

Ендпоінти для роботи з телеметричними даними (/api/v1/telemetry): GET /api/v1/telemetry/current - отримання поточних значень параметрів; GET /api/v1/telemetry/history - отримання історичних даних за вказаний період; GET /api/v1/telemetry/aggregated - отримання агрегованих даних середні, мінімальні, максимальні значення [57]. Всі ендпоінти підтримують параметри фільтрації за типом параметра, діапазоном дат та ідентифікатором установки.

Ендпоінти для роботи з прогнозами (/api/v1/predictions): GET /api/v1/predictions/latest - отримання останнього прогнозу; POST /api/v1/predictions/request - запит нового прогнозу; GET /api/v1/predictions/history - історія прогнозів з метриками точності; GET /api/v1/predictions/model-info - інформація про поточну версію моделі [34]. Формат відповіді включає прогнозоване значення виходу біогазу, довірчий інтервал та перелік параметрів, що найбільше вплинули на прогноз.

Ендпоінти для роботи із зображеннями (/api/v1/images): GET /api/v1/images/latest - отримання останнього зображення субстрату; GET /api/v1/images/{image_id} - отримання зображення за ідентифікатором; GET /api/v1/images/{image_id}/analysis - результати аналізу зображення; POST /api/v1/images/upload - завантаження зображення для аналізу [62].

Ендпоінти для управління сповіщеннями (/api/v1/alerts): GET /api/v1/alerts - отримання списку активних сповіщень; POST /api/v1/alerts/{alert_id}/acknowledge - підтвердження сповіщення; GET /api/v1/alerts/rules - отримання правил генерації

сповіщень; PUT /api/v1/alerts/rules/{rule_id} - оновлення правила [180]. Детально описані в табл. 4.13

Таблиця 4.13

Перелік розроблених ендпоінтів в системі

Метод	URL (Endpoint)	Опис функції
Телеметрія		
<i>Базовий шлях: /api/v1/telemetry</i>		
GET	/current	Отримання поточних значень давачів
GET	/history	Історичні дані за вказаний період
GET	/aggregated	Агреговані метрики (min, max, avg)
Прогнози		
<i>Базовий шлях: /api/v1/predictions</i>		
GET	/latest	Останній доступний прогноз
POST	/request	Ініціювання нового розрахунку прогнозу
GET	/history	Архів прогнозів з оцінкою точності
GET	/model-info	Метадані поточної ML-моделі
Зображення		
<i>Базовий шлях: /api/v1/images</i>		
GET	/latest	Останнє завантажене фото субстрату
POST	/upload	Завантаження зображення для аналізу
GET	/ {id}	Отримання зображення за ID
GET	/ {id}/analysis	Результат CV-аналізу конкретного фото
Сповіщення		
<i>Базовий шлях: /api/v1/alerts</i>		
GET	/	Список активних сповіщень
GET	/rules	Перегляд правил генерації тривог
PUT	/rules/{id}	Редагування параметрів правила
POST	/ {id}/acknowledge	Підтвердження (квітування) сповіщення

Для забезпечення зворотної сумісності та можливості поступового оновлення клієнтських застосунків реалізовано версіонування API через URL-шлях `/api/v1/`, `/api/v2/` [96]. Кожна нова версія API підтримує попередню протягом щонайменше 6 місяців, що дозволяє клієнтам здійснити міграцію без втрати функціональності. Зміни в API документуються в CHANGELOG та автоматично відображаються в OpenAPI-специфікації.

Автентифікація та авторизація. Безпека API забезпечується за допомогою токенів JWT JSON Web Token, що передаються в заголовок `Authorization` кожного запиту [45]. Процес автентифікації передбачає отримання токена через ендпоінт `/api/v1/auth/login` з наданням облікових даних користувача. Термін дії `access`-токена становить 15 хвилин, після чого необхідно оновити його за допомогою `refresh`-токена з терміном дії 7 днів.

WebSocket API для реального часу. Для забезпечення оновлення даних у реальному часі без необхідності періодичного опитування сервера `polling` реалізовано WebSocket API [41]. Клієнт встановлює постійне з'єднання з сервером та отримує оновлення негайно при їх появі. Це особливо важливо для відображення поточних значень параметрів на дашбордах та миттєвого сповіщення операторів про критичні події.

WebSocket-канали системи: `/ws/telemetry` - потік телеметричних даних у реальному часі; `/ws/alerts` - потік сповіщень та тривог; `/ws/predictions` - оновлення прогнозів; `/ws/system-status` - стан компонентів системи [42]. Протокол обміну повідомленнями базується на JSON з обов'язковими полями: `type` тип повідомлення, `timestamp` часова мітка, `payload` корисне навантаження. Для підтримки з'єднання реалізовано механізм `heartbeat` з інтервалом 30 секунд.

Внутрішні API між мікросервісами. Для взаємодії між мікросервісами на рівні обробки застосовано комбінований підхід: синхронні виклики через `gRPC` для операцій з низькою латентністю та асинхронна комунікація через `MQTT` для подієво-орієнтованих взаємодій [61]. `gRPC` забезпечує ефективну бінарну серіалізацію даних за допомогою `Protocol Buffers` та підтримку двонаправленого потокового передавання.

Обробка помилок та логування. Стандартизована обробка помилок реалізована на рівні API Gateway, що перехоплює всі винятки та формує уніфіковані відповіді про помилки [149]. Формат відповіді про помилку включає: HTTP-статус код, унікальний код помилки системи, повідомлення для користувача та технічні деталі для розробників у режимі налагодження. Логування API-запитів здійснюється з використанням структурованого формату JSON, що включає: `timestamp`, `request_id`, `method`, `path`, `status_code`, `response_time_ms`, `user_id` [97].

Rate Limiting та захист від перевантажень. Для захисту системи від перевантажень та зловживань реалізовано механізм обмеження частоти запитів Rate Limiting на основі алгоритму Token Bucket [97]. Ліміти встановлено диференційовано для різних категорій ендпоінтів: загальні ендпоінти - 100 запитів/хвилину; ендпоінти прогнозування - 10 запитів/хвилину; ендпоінти завантаження зображень - 5 запитів/хвилину. При перевищенні ліміту повертається HTTP-статус 429 Too Many Requests з заголовком `Retry-After`, що вказує час до скидання ліміту [60].

Документування API. Документація API автоматично генерується з коду на основі анотацій та доступна через вбудований інтерфейс Swagger UI за адресою `/api/docs` [60]. Документація включає: опис всіх ендпоінтів з прикладами запитів та відповідей; схеми даних з описом полів та обмежень; інформацію про автентифікацію та авторизацію; приклади типових сценаріїв використання. Для розробників надано також колекцію Postman з готовими запитами для тестування API [176].

4.2.3. Створення людино-машинного інтерфейсу для візуалізації даних та результатів роботи системи

Людино-машинний інтерфейс HMI - Human-Machine Interface є ключовим компонентом комп'ютерно-інтегрованої системи, що забезпечує ефективну взаємодію операторів та технологів з системою моніторингу та прогнозування [208]. Сучасні веб-технології дозволяють створювати інтерактивні HMI-інтерфейси, що за своїми можливостями не поступаються традиційним SCADA-системам, але при цьому забезпечують кросплатформеність, гнучкість налаштування та зручність віддаленого доступу.

Архітектура веб-інтерфейсу. Веб-інтерфейс системи розроблено з використанням бібліотеки React.js, що забезпечує компонентний підхід до побудови інтерфейсу, ефективне оновлення DOM-дерева та широку екосистему готових компонентів [57]. Для управління станом застосунку використовується бібліотека Redux Toolkit, що реалізує патерн Flux та забезпечує передбачуваний потік даних між компонентами [37]. Стилзація інтерфейсу виконана за допомогою CSS-фреймворку Tailwind CSS з кастомною темою, адаптованою до вимог промислових HMI-застосунків.

Архітектура фронтенд-застосунку організована за модульним принципом з наступними основними модулями: головна панель з оглядом ключових показників, детальна візуалізація телеметричних даних, інтерфейс для роботи з прогнозами, відображення сповіщень та тривог, всі елементи зображено на рис. 4.3



Рис. 4.3 Головна панель оператора

Головна панель є точкою входу в систему та надає оператору миттєвий огляд стану біогазової установки. Блок ключових показників ефективності відображає: поточний вихід біогазу м³/год, температуру в реакторі °C, прогнозований вихід біогазу на наступну добу, кількість активних сповіщень. Кожен показник супроводжується індикатором тренду зростання/спадання та візуальною індикацією відхилення від норми зелений/жовтий/червоний кольори. Блок прогнозування відображає результати останнього прогнозу у вигляді графіка з довірчим інтервалом та рекомендаціями щодо оптимізації процесу.



Рис. 4.4 Динамічна зміна температур на екрані оператора

Детальна візуалізація телеметричних даних реалізована з використанням бібліотеки Recharts, що забезпечує побудову інтерактивних графіків з високою продуктивністю відображення великих обсягів даних. Модуль підтримує наступні типи візуалізацій: лінійні графіки часових рядів з можливістю масштабування та панорамування; гістограми розподілу значень параметрів; кореляційні діаграми для аналізу взаємозв'язків між параметрами; теплові карти для відображення просторового розподілу температури, приклад діаграми зі зміною температури субстрату зображено на рис. 4.4

Для забезпечення плавного відображення даних у реальному часі реалізовано механізм буферування та поступового оновлення графіків, приклад зміни температури на рис. 4.3. При надходженні нових даних через WebSocket вони додаються до буфера, а оновлення візуалізації відбувається з фіксованою частотою 1 раз на секунду для оптимізації використання ресурсів браузера. Користувач може

налаштувати часовий діапазон відображення остання година, доба, тиждень та вибрати параметри для порівняльного аналізу.

Спеціалізований модуль надає інтерфейс для перегляду та аналізу зображень біоматеріалу, отриманих з камери OV2640. Галерея зображень відображає мініатюри з часовими мітками та індикаторами результатів аналізу. При виборі зображення відкривається детальний вигляд з накладеними результатами сегментації та виявлених аномалій. Реалізовано можливість порівняння двох зображень для візуальної оцінки динаміки змін стану субстрату.

Результати аналізу зображень представлені у структурованому вигляді: оцінка якості субстрату шкала 1-10); виявлені аномалії сторонні включення, нерівномірність текстури); розраховані візуальні ознаки середня яскравість, текстурні дескриптори); прогноз впливу на вихід біогазу. Для кожного аналізу доступна деталізація з візуалізацією карти активацій нейронної мережі, що пояснює, на які області зображення звернула увагу модель .

Інтерфейс роботи з прогнозами дозволяє операторам переглядати результати прогнозування, аналізувати точність минулих прогнозів та ініціювати оновлення моделі. Головний графік відображає фактичний та прогнозований вихід біогазу з візуалізацією довірчого інтервалу. В цьому ж модулі доступний функціонал валідації прогнозу, приклад зображено на рис. 4.5




Рис. 4.5 Модуль валідації прогнозу виходу біогазу

Панель метрик демонструє поточну точність моделі R^2 , RMSE, MAE та її динаміку за останній місяць.




Рис. 4.6 Модуль донавчання моделі, а) модель містить 79 неопрацьованих записів, б) модель донавчилася на 79 записах

Блок аналізу важливості ознак відображає внесок кожного вхідного параметра в прогноз у вигляді горизонтальної гістограми. Це допомагає оператору зрозуміти, які фактори найбільше впливають на вихід біогазу, та прийняти обґрунтовані рішення щодо коригування технологічних параметрів. Також цей модуль містить дані про донавчання моделі, приклад наведено на рис. 4.6 а та б.

Модуль сповіщень забезпечує своєчасне інформування операторів про критичні події та відхилення параметрів від норми [194]. Сповіщення класифікуються за рівнями критичності: червоний - потребує негайної уваги; жовтий - потребує уваги найближчим часом; синій - інформаційне повідомлення, приклад роботи модуля зображено на рис. 4.7. При виникненні критичного сповіщення відображається модальне вікно з детальною інформацією та рекомендованими діями, а також активується звуковий сигнал [195].




Рис. 4.7 Модуль управління сповіщеннями

Панель активних сповіщень розташована у верхній частині інтерфейсу та відображає кількість непідтверджених сповіщень кожного рівня. Розгорнутий список сповіщень містить: час виникнення, опис події, поточне та порогове значення параметра.

Ключовим нововведенням інтерфейсу системи є модуль підтримки прийняття рішень (Decision Support Module, DSM), що базується на генетичному алгоритмі

оптимізації режимних параметрів процесу [209, 210]. На відміну від традиційних систем моніторингу, що лише відображають поточний стан установки, розроблений модуль активно аналізує можливості покращення виходу біогазу та формує обґрунтовані рекомендації для оператора.

Модуль DSM інтегровано в центральну частину головної панелі оператора та реалізовано з використанням наступних компонентів:

- База знань (Knowledge Base) - історичні дані про режими роботи установки та відповідний вихід біогазу;
- Оцінювач W-kNN - модуль зваженого методу k найближчих сусідів для оцінки очікуваного виходу біогазу [212, 213];
- GA-оптимізатор - генетичний алгоритм пошуку оптимального режиму (T^* , H^*) [211];
- Валідатор рекомендацій - модуль перевірки значущості рекомендації на основі порогу LOO-MAE [214]. Модуль автоматично запускає цикл оптимізації з періодичністю 30 секунд або при надходженні нових даних від давачів та підсистеми комп'ютерного зору. Модуль DSM може перебувати в одному з двох основних візуальних станів, кожен з яких має специфічне оформлення та функціональність.

Стан Рекомендація доступна активується, коли GA-оптимізатор знаходить режим (T^* , H^*), що забезпечує очікуване покращення виходу біогазу, яке перевищує поріг невизначеності моделі, приклад наведено на рис. 4.8.




Рис. 4.8 Інформування про доступну рекомендацію

Стан - Рекомендація не потрібна відображається (рис 4.9), коли поточний режим роботи є близьким до оптимального, і очікуване покращення не перевищує порогу невизначеності.

Такий консервативний підхід запобігає формуванню рекомендацій на основі статистичного шуму та підвищує довіру оператора до системи [3]. За експериментальними даними, 74% зразків потрапляють у цей стан, що свідчить про адекватність порогу та відсутність надмірної кількості рекомендацій.




Рис. 4.9 Інформування про відсутню доступну рекомендацію

Адаптивний дизайн та доступність. Веб-інтерфейс розроблено з урахуванням принципів адаптивного дизайну Responsive Design, що забезпечує коректне відображення на пристроях з різною роздільною здатністю екрана.

Для забезпечення доступності інтерфейсу реалізовано підтримку стандарту WCAG 2.1 рівня AA [159]: достатній контраст кольорів для читабельності тексту; можливість навігації за допомогою клавіатури; семантична розмітка для програм зчитування з екрана; альтернативний текст для всіх значущих зображень; можливість масштабування інтерфейсу без втрати функціональності.

Продуктивність та оптимізація. Для забезпечення швидкого завантаження та плавної роботи інтерфейсу реалізовано комплекс оптимізацій [174]: Code Splitting - розділення коду на модулі, що завантажуються за потребою; Lazy Loading - відкладене завантаження компонентів та зображень; Memoization - кешування результатів обчислень для запобігання повторних рендерів; Virtual Scrolling - віртуалізація довгих списків для оптимізації використання пам'яті [163].

Результати тестування продуктивності за методологією Lighthouse демонструють наступні показники: Performance Score - 92/100; First Contentful Paint - 1,2 с; Time to Interactive - 2,1 с; Cumulative Layout Shift - 0,05 [162]. Ці показники відповідають рекомендаціям для промислових веб-застосунків та забезпечують комфортну роботу оператора.

4.3. Організація та результати експериментального дослідження.

4.3.1. Валідація роботи системи в умовах роботи з оператором

Центральна гіпотеза експериментального дослідження полягала в тому, що ефективна інтелектуальна система для керування складним біопроцесом повинна бути динамічно адаптивною, а не статичною. Цю адаптивність реалізовано через механізм зворотного зв'язку з оператором, що базується на парадигмі HITL. Концепція HITL передбачає активне залучення людини-експерта до циклу функціонування інтелектуальної системи не як пасивного спостерігача [208], а як повноцінного учасника процесу валідації та вдосконалення моделі.

Замість традиційної фіксованої валідації, коли модель разово навчається на train-наборі і перевіряється на test-наборі без подальших модифікацій, застосовано підхід, за якого оператор активно бере участь у циклі роботи моделі як валідатор прогнозів і постачальник нових розмічених даних для донавчання. Такий підхід вирішує дві ключові проблеми, характерні для систем машинного навчання у промислових умовах.

Перша проблема з якою ми стикнулися це те, що початковий набір даних був надзвичайно обмеженим - лише близько 23 прикладів пар "вхідні параметри - вихід біогазу", зібраних під час попередніх лабораторних досліджень та короткострокових випробувань. Такий обсяг даних є недостатнім для повноцінного навчання складних ансамблевих моделей, тож початкова модель могла слугувати лише базовою оцінкою, яка потребувала подальшого вдосконалення.

Друга проблема - "дрейф концепції", тобто поступова зміна статистичних закономірностей у даних з плином часу. Характеристики біореактора не залишаються константними: змінюється склад мікробного консорціуму, накопичуються відкладення на стінках ферментера, зношуються компоненти обладнання, варіюється якість сировини залежно від постачальника та сезону. Внаслідок цього модель, навчена лише на історичних даних, може втратити точність уже через кілька місяців

експлуатації, оскільки закономірності, виявлені на старих даних, перестають відповідати поточному стану системи.

Динамічна валідація в режимі HITL перетворює експлуатацію системи на безперервний процес навчання. Оператор не пасивно спостерігає за роботою автоматизованої системи, а регулярно підтверджує або спростовує прогнози фактичними даними, отриманими з реальних вимірювань. Кожне таке підтвердження створює нову розмічену точку даних, яка використовується для ітеративного покращення моделі. Таким чином, система постійно адаптується до поточних умов функціонування конкретної біогазової установки, компенсуючи як початкову нестачу даних, так і поступові зміни в характеристиках процесу.

Експериментальну апробацію системи проведено на пілотних біогазових установках протягом шести місяців в умовах, максимально наближених до реальної промислової експлуатації. Вибір шестимісячного періоду тестування обумовлений необхідністю охопити різні сезонні умови роботи та забезпечити накопичення достатнього обсягу валідованих даних для кількох циклів донавчання моделі. Загальний процес включав декілька послідовних етапів, кожен з яких мав чітку визначені цілі та критерії успішності.

Розгортання системи. На пілотних установках було встановлено повний програмно-апаратний комплекс, що включав периферійні IoT-модулі збору даних та модулі комп'ютерного зору. Периферійні модулі на базі мікроконтролерів ESP32 забезпечували зчитування показників з аналогових та цифрових датчиків температури, тиску, рівня рН, окисно-відновного потенціалу та інших параметрів біореактора. Модулі комп'ютерного зору, обладнані камерами високої роздільної здатності, здійснювали періодичну фіксацію зображень вхідної сировини для подальшого аналізу її візуальних характеристик. Паралельно було розгорнуто хмарні сервіси, які забезпечували централізоване зберігання даних, виконання обчислювальних задач та надання веб-інтерфейсу для операторів. У хмарній інфраструктурі було запущено початкову версію прогностичної моделі, попередньо навченої на невеликому початковому датасеті. Операторам біогазових установок надали захищений доступ до

людино-машинного інтерфейсу НМІ для моніторингу поточного стану системи та виконання процедур валідації прогнозів.

Збір даних і прогнозування. Після завершення етапу розгортання система перейшла до штатного режиму функціонування. Периферійні модулі автоматично збирали телеметричні дані базових параметрів з налаштованою періодичністю. Зображення сировини захоплювалися при кожному завантаженні нової порції субстрату в біореактор. Зібрані дані передавалися у хмару через захищені канали зв'язку з використанням протоколу MQTT over TLS. У хмарній інфраструктурі відбувалася багатоетапна обробка: модулі комп'ютерного зору на основі згорткових нейронних мереж аналізували зображення сировини та визначали візуальні показники якості ступінь подрібнення, наявність сторонніх включень, оцінку вологості. Ці візуальні ознаки об'єднувалися з телеметричними даними у єдиний вектор ознак, який подавався на вхід ансамблевої прогностичної моделі. Модель генерувала прогноз добового виходу біогазу разом з оцінкою невизначеності прогнозу. Розраховані прогнози відображалися на НМІ в режимі реального часу, що дозволяло оператору оперативно ознайомлюватися з очікуваними результатами та планувати виробничі операції.

Валідація оператором НІТЛ. Ключовим елементом експерименту була процедура валідації прогнозів оператором. Після появи фактичних даних про вихід біогазу - зазвичай за результатами добових замірів витратоміра або періодичного лабораторного аналізу складу газу - оператор виконував процедуру підтвердження. Для цього він знаходив у НМІ відповідний прогноз за датою та часом, переглядав прогнозоване значення виходу газу та вводив реальне виміряне значення у спеціальне поле форми. Інтерфейс також дозволяв оператору залишати текстові коментарі щодо особливих умов, які могли вплинути на результат наприклад, нештатні ситуації, зміна типу сировини, технічне обслуговування обладнання. Після заповнення всіх необхідних полів оператор підтверджував введення натисканням кнопки "Підтвердити", після чого система фіксувала валідований приклад оператор має можливість ігнорувати рекомендації системи на власний розсуд у базі даних. Таким

чином, кожна нова валідована точка представляла собою повноцінну пару "прогноз-факт" з повним контекстом вхідних параметрів.

Маркування та накопичення даних. Кожне фактичне значення, введене оператором, автоматично пов'язувалося системою з відповідним вектором ознак та прогнозом у реляційній базі даних. Механізм зв'язування базувався на унікальних ідентифікаторах прогнозів та часових мітках. Нові записи позначалися спеціальним статусом "очікує донавчання", що сигналізувало про їх готовність до використання в наступному циклі оновлення моделі. Система безперервно накопичувала такі валідовані приклади у спеціалізованій таблиці бази даних, відстежуючи загальну кількість записів зі статусом очікування. Коли ця кількість досягала заздалегідь визначеного порогу - у нашому експерименті це було 100 нових записів - система генерувала сигнал готовності до донавчання.

Автоматичне донавчання моделі. У хмарній інфраструктурі було налаштовано автоматичний тригер на основі механізму планування задач, який періодично щодоби о 02:00 за місцевим часом перевіряв наявність достатньої кількості нових валідованих даних. При досягненні порогу автоматично запускалося окреме обчислювальне завдання на виділеному сервері з GPU-прискоренням. Процес донавчання включав декілька кроків: спочатку поточна версія моделі завантажувалася з репозиторію артефактів машинного навчання використовувався MLflow для версіонування моделей); далі з бази даних витягувалися нові валідовані приклади; потім модель донавчалася *fine-tuning* на цих прикладах методами трансферного навчання з використанням зниженої швидкості навчання для запобігання "катастрофічному забуванню". В процесі донавчання зберігалися накопичені знання - ваги нейромережових компонентів та параметри ансамблю не скидалися до початкових значень, а поступово коригувалися на нових даних. Після завершення навчання оновлену модель автоматично перевіряли на контрольному наборі даних, який був зафіксований на початку експерименту і не змінювався. Якщо ключові метрики якості покращувалися порівняно з попередньою версією зокрема, якщо помилка RMSE знижувалася або залишалася стабільною, нова версія моделі автоматично розгорталася у продуктивному середовищі та ставала активною для генерації

прогнозів. Використані для донавчання записи позначалися статусом "навчені" і виключалися з розгляду в наступних циклах, що запобігало повторному використанню одних і тих самих даних.

Результати експлуатаційної валідації

Шестимісячний збір даних та тестування системи в умовах реальної експлуатації надало вичерпні дані для оцінки ефективності запропонованого підходу та підтвердило його високу надійність. Отримані результати можна структурувати за декількома ключовими напрямками.

По-перше, система продемонструвала високу надійність у зборі даних. За весь період експерименту було успішно зібрано приблизно 98,6% від запланованого обсягу телеметричних даних та зображень. Незначні втрати на рівні 1,4% були спричинені виключно зовнішніми факторами, такими як короткочасні перебої електропостачання на об'єктах, планові технічні роботи з обслуговування мережевого обладнання та поодинокі випадки апаратних збоїв давачів, які оперативно усувалися. Важливо зазначити, що архітектура системи з локальним буферуванням даних на периферійних модулях дозволяла мінімізувати втрати навіть при тимчасовій недоступності хмарних сервісів - дані накопичувалися локально та синхронізувалися після відновлення зв'язку.

По-друге, забезпечено достатню оперативність роботи для потреб операційного керування. Середній час від моменту фіксації даних сенсорами до відображення оновленого прогнозу на НМІ становив близько 3,2 хвилини. Цей показник включав час передачі даних по мережі у середньому 0,8 хв, час обробки зображень модулем комп'ютерного зору 1,2 секунди, час формування вектора ознак та виконання прогнозу ансамблевою моделлю 0,9 хв та час оновлення інтерфейсу 0,4 хв. Така швидкодія є цілком прийнятною для біогазового виробництва, де характерні часові константи процесів вимірюються годинами та добами.

Головним результатом експерименту стали кількісні докази ефективності адаптивного механізму HITL. Порівняння якості прогнозної моделі до і після декількох циклів донавчання на операторських даних показало суттєве та статистично значуще покращення точності. Початкова модель, навчена на початковому датасеті з

23 прикладів пар «вхідні параметри - фактичний вихід біогазу» повні цикли з валідованими результатами, демонструвала середньоквадратичну помилку RMSE на рівні приблизно $0,61 \text{ м}^3/\text{добу}$ та коефіцієнт детермінації R^2 близько $0,85$. Ці показники свідчили про загалом прийнятну, але недостатню для промислового застосування точність прогнозування. Після накопичення та включення у навчання приблизно 100 нових валідованих точок, отриманих від операторів за перші два місяці експлуатації, показники моделі суттєво покращилися: RMSE знизився до $0,35 \text{ м}^3/\text{добу}$, а R^2 підвищився до $0,91$. Таким чином, абсолютна помилка зменшилась на $0,26 \text{ м}^3/\text{добу}$, що у відносному вираженні становить покращення на $42,6\%$. Пояснювальна здатність моделі, яку характеризує коефіцієнт детермінації, зросла приблизно на 7 відсоткових пунктів.

Ці результати є прямим емпіричним доказом того, що система успішно навчається в процесі експлуатації, адаптуючись до специфічних умов конкретної біогазової установки. Модель поступово "вивчає" індивідуальні особливості кожного біореактора - характерні для нього затримки, нелінійності відгуку, типові режими роботи - та значно підвищує точність своїх прогнозів. Фактично підтверджено, що запропонований механізм "збагачення" даних оператором через парадигму HITL є життєздатною та ефективною стратегією для підтримання високої якості прогнозування у динамічному середовищі біогазового виробництва, де умови постійно змінюються і жодна статична модель не може залишатися точною протягом тривалого часу.

4.3.2. Аналіз впливу інтеграції підсистем на загальну точність прогнозування

Другою ключовою гіпотезою дослідження було припущення, що інтеграція підсистеми комп'ютерного зору КЗ для аналізу сировини забезпечує відчутний синергетичний ефект та є критично важливою для досягнення високої точності прогнозування. Іншими словами, прогнозна модель, яка поєднує традиційні сенсорні дані з візуальними ознаками сировини, повинна давати кращі результати, ніж модель, що використовує лише параметри давачів. Крім того, очікувалося, що адаптивний

механізм донавчання HITL ще більше підвищить точність. Для перевірки цих гіпотез було проведено спеціальний експеримент - абляційний аналіз, що дозволяє кількісно оцінити внесок кожної підсистеми в загальну ефективність.

Методика абляційного аналізу. Порівнювалися показники точності трьох різних конфігурацій прогнозової моделі. Всі моделі навчалися і тестувалися на одному і тому ж підсумковому валідованому наборі даних зібраному протягом експерименту 4.3.1 для забезпечення коректної співставності. Конфігурації були такі:

1. Модель А - тільки сенсорні дані SCADA. Ця модель слугує базовим орієнтиром baseline, що імітує традиційний підхід до моніторингу реактора. Вона отримує на вхід лише дані від звичайних сенсорів: агреговані часові ряди температури, тиску, вологості тощо. Жодних ознак з підсистеми комп'ютерного зору тут не використовується. Таким чином, Модель А покладається виключно на стандартну телеметрію для прогнозу виходу біогазу.
2. Модель Б - інтегрована сенсори + комп'ютерний зір. Ця конфігурація відповідає початковій версії розробленої системи до етапу адаптації. Модель отримує повний набір ознак, що включає і традиційні сенсорні показники, і ключові ознаки з комп'ютерного зору - такі, як узагальнена візуальна оцінка якості сировини score та оцінка її вологості humidity, отримані шляхом аналізу зображень. Таким чином, Модель Б поєднує обидва типи даних і дозволяє оцінити вплив додавання комп'ютерного зору на точність прогнозу.
3. Модель В - інтегрована адаптована сенсори + КЗ + HITL. Ця конфігурація відповідає фінальній версії моделі після повного циклу навчання. За архітектурою вона ідентична Моделі Б отримує ті самі сенсорні та візуальні ознаки, але досягла свого стану шляхом додаткових циклів донавчання на реальних даних, валідованих оператором тобто ця модель враховує результати експериментальної валідації з підрозділу 4.3.1. Модель В репрезентує повнофункціональну систему, здатну не тільки інтегрувати різні підсистеми, але й адаптуватися до умов шляхом HITL.

Формулювання гіпотез. Очікувані результати від цих трьох конфігурацій можна узагальнити двома гіпотезами:

- Гіпотеза 1: Точність Модель Б > Точність Модель А. Додавання підсистеми комп'ютерного зору суттєво підвищить точність прогнозування. Обґрунтування: Попередній аналіз важливості ознак показав, що візуальні показники сировини score, humidity є доміантними предикторами виходу біогазу статистично значущі, $p < 0.001$, тоді як традиційні температурні показники самі по собі мають низьку прогностичну значущість. Інтуїтивно зрозуміло, що хімічний склад і якість біомаси опосередковано виміряні через комп'ютерний зір прямо впливають на вихід газу, тоді як одні лише фізичні параметри температура тощо не дають повної картини. Отже, Модель А, що спирається тільки на сенсори, ймовірно продемонструє обмежену точність, а інтеграція ознак комп'ютерного зору в Моделі Б повинна забезпечити істотне покращення прогнозу. Такий стрибок точності при додаванні інформативних ознак узгоджується і з відомими результатами в галузі машинного навчання: ретельна інженерія ознак суттєво підвищує якість моделей.
- Гіпотеза 2: Точність Модель В > Точність Модель Б. Механізм HITL адаптивне донавчання на нових даних дасть додатковий вигравш у точності порівняно з початковою інтегрованою моделлю. Обґрунтування: Ця гіпотеза фактично ґрунтується на результатах попереднього підрозділу: експеримент 4.3.1 вже продемонстрував, що після кількох циклів донавчання на реальних даних похибка моделі значно знижується. Тому очікується, що Модель В з функцією HITL перевершить Модель Б, яка ще не мала змоги адаптуватися до специфіки середовища. Адаптивність через HITL повинна додатково зменшити помилку прогнозу за рахунок врахування нових зразків, отриманих у процесі експлуатації.

Результати абляційного аналізу. Порівняння трьох описаних моделей повністю підтвердило висунуті гіпотези і продемонструвало кількісно, наскільки саме кожна підсистема впливає на точність. Ключові метрики точності RMSE - середньоквадратична помилка, R^2 - коефіцієнт детермінації, MAE - середня абсолютна помилка для кожної конфігурації:

- Модель А тільки сенсори): $RMSE \approx 0,85$ м³/добу, $R^2 \approx 0,62$, $MAE \approx 0,71$ м³/добу. Це базовий рівень точності, досягнутий без використання комп'ютерного зору. Помітно, що прогностична спроможність моделі досить низька: коефіцієнт детермінації 0,62 означає слабе пояснення варіативності виходу біогазу лише сенсорними показниками.
- Модель Б сенсори + КЗ): $RMSE \approx 0,61$ м³/добу, $R^2 \approx 0,85$, $MAE \approx 0,51$ м³/добу. Додавання ознак комп'ютерного зору різко покращує результати: $RMSE$ зменшилась майже на третину на $\sim 28\%$, а R^2 піднявся до 0,85, що вказує на значно кращу відповідність моделі реальним даним. Цей результат підтверджує гіпотезу 1: традиційних параметрів недостатньо для точного прогнозу, інтеграція візуального аналізу сировини істотно підвищує якість моделі. Отримані цифри кількісно доводять критичну важливість підсистеми комп'ютерного зору: без неї модель пропускала важливу інформацію про якість біомаси, через що помилка була високою.
- Модель В сенсори + КЗ + НІТЛ): $RMSE \approx 0,35$ м³/добу, $R^2 \approx 0,91$, $MAE \approx 0,29$ м³/добу. Фінальна адаптована модель демонструє ще кращу точність. У порівнянні з Моделлю Б, середньоквадратична помилка знизилась більш ніж на 40%, до рівня 0,35, а коефіцієнт детермінації досяг 0,91. Це означає, що більше 90% варіації цільового показника пояснюється моделлю - відмінний результат для такої складної системи. Таким чином, гіпотеза 2 також повністю підтверджена: адаптивне донавчання НІТЛ приносить додатковий вагомий виграш у точності понад ефект від простої інтеграції підсистем.

Аналіз і висновки. Наведені результати наочно демонструють синергетичний ефект інтеграції підсистем комп'ютерного зору та адаптивного навчання. Перехід від суто сенсорної моделі А до інтегрованої Б зменшує похибку майже на третину, а подальший перехід до повністю адаптованої системи В знижує її ще майже вдвічі. Загалом, повнофункціональна система Модель В перевершила базову Модель А за точністю прогнозу у 2,4 рази за показником $RMSE$ 0,35 проти 0,85, що є разючим покращенням. Коефіцієнт детермінації зріс з 0,62 до 0,91, тобто модель почала пояснювати переважну частину варіацій виходу газу, тоді як базова модель давала

мало корисної інформації. Такий прорив у продуктивності став можливим лише завдяки поєднанню всіх розроблених компонентів: розширення вхідних даних за рахунок комп'ютерного зору значно підняло стелю можливої точності, а вбудований цикл HITL-адаптації дозволив цю точність поступово довести до максимальної для даних конкретної установки. Отже, проведений абляційний аналіз кількісно підтвердив наукову новизну інтегрованого підходу: саме синергія підсистем комп'ютерний зір + класичні сенсори + машинне навчання з механізмом донавчання забезпечує істотне підвищення ефективності прогнозування, недосяжне при використанні кожної з підсистем окремо.

Висновки до розділу 4

У результаті проведених досліджень розроблено та експериментально валідовано підсистему прогнозування виходу біогазу.

Розроблено методику підготовки комплексних даних для навчання моделей: збір 15 000+ записів телеметрії з 12 вхідними параметрами, видалення аномалій методом IQR (оброблено 2,3% записів), Z-score нормалізація, формування часових вікон розміром 7 діб.

Вперше обґрунтовано архітектуру ансамблю нейронних мереж для прогнозування виходу біогазу, що поєднує: LSTM (2 шари по 64 нейрони, dropout 0,2) для часових рядів з $R^2 = 0,82$; XGBoost (200 дерев, глибина 6) для табличних даних з $R^2 = 0,79$; ResNet-50 з трансферним навчанням для візуальних ознак з $R^2 = 0,71$.

Вперше запропоновано механізм зваженого ансамблювання з динамічним розрахунком ваг, обернено пропорційних до MAE кожної моделі на валідаційній вибірці. Початкова точність ансамблю: $R^2 = 0,85$, RMSE = 0,61 м³/добу.

Вперше розроблено та впроваджено механізм адаптивного донавчання Human-in-the-Loop для системи прогнозування виробництва біогазу: автоматичне перенавчання після накопичення 100 валідованих оператором записів, збереження попередніх знань через трансферне навчання, період адаптації 30 днів при зміні субстрату.

Експериментально підтверджено ефективність донавчання: після першого циклу $R^2 = 0,91$, RMSE = 0,35 м³/добу (покращення на 42,6%); після третього циклу

$R^2 = 0,94$, $RMSE = 0,25$ м³/добу. Абляційний аналіз показав, що видалення будь-якого компонента погіршує $RMSE$ на 48-146%.

Досягнуто обчислювальну ефективність: час прогнозу 1,8 секунди на EC2 t3.medium, споживання пам'яті до 2,5 ГБ, валідація на незалежних даних підтвердила $R^2 = 0,89$ без ознак перенавчання.

Набула подальшого розвитку методологія ансамблевого машинного навчання для прогнозування нелінійних біотехнологічних процесів шляхом інтеграції рекурентних мереж, градієнтного бустингу та згорткових мереж з механізмом адаптивного донавчання на основі зворотного зв'язку від оператора.

РОЗДІЛ 5

ОЦІНКА ЕФЕКТИВНОСТІ ТА ПЕРСПЕКТИВИ ВПРОВАДЖЕННЯ СИСТЕМИ

Завершальним етапом дослідження є комплексна оцінка ефективності розробленої комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу. Даний розділ містить технічну оцінку результатів впровадження, економічне обґрунтування доцільності застосування системи, аналіз ризиків та обмежень, а також рекомендації щодо масштабування та перспективних напрямів розвитку.

5.1. Технічна оцінка результатів впровадження системи

Результати експериментальної валідації розробленої комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу підтвердили її технічну ефективність та практичну придатність для промислового застосування. Комплексна оцінка технічних характеристик системи проводилася за кількома ключовими критеріями: точність вимірювань, надійність функціонування, продуктивність обробки даних та масштабованість рішення .

Точність вимірювань апаратної підсистеми. Давачі температури DS18B20 забезпечили точність вимірювань $\pm 0,5^{\circ}\text{C}$ в робочому діапазоні температур мезофільного процесу $30\text{--}40^{\circ}\text{C}$, що повністю відповідає технологічним вимогам контролю анаеробного зброджування. Порівняльна калібрування з еталонним обладнанням підтвердила стабільність показників протягом 90-денного періоду тестування з дрейфом не більше $0,1^{\circ}\text{C}$ [25]. Давачі вологості DHT22 продемонстрували точність $\pm 2\%$ у діапазоні 20-90% відносної вологості, що є достатнім для оцінки мікрокліматичних умов у зоні завантаження субстрату. Ємнісні давачі вологості ґрунту забезпечили відносну точність оцінки вологості субстрату на рівні $\pm 5\%$, що дозволяє виявляти суттєві відхилення від оптимальних значень.

Продуктивність підсистеми комп'ютерного зору. Аналіз зображень за допомогою мережі ResNet-50 дозволив досягти середнього часу обробки одного

знімку 1,2 секунди на хмарній інфраструктурі сервер EC2 t3.medium. Класифікація якості біомаси за візуальними ознаками показала точність 89,7% при перевірці на незалежній тестовій вибірці з 500 зображень. Автоматизований контроль якості сировини суттєво знизив вплив людського фактору у процесі оцінки та забезпечив об'єктивність аналізу [55]. Метод сегментації Оцу з попереднім підвищенням контрасту продемонстрував найвищу стабільність серед досліджених методів із коефіцієнтом варіації 3,63%.

Ефективність прогнозної моделі. Ансамблевий підхід із використанням LSTM, XGBoost та ResNet-50 забезпечив коефіцієнт детермінації $R^2 = 0,91$ після адаптивного донавчання в режимі HITL. Середньоквадратична помилка прогнозування (RMSE) становить $0,35 \text{ м}^3/\text{добу}$, що на 58,8% краще за базову модель без візуальних ознак. Абляційний аналіз підтвердив критичну важливість інтеграції підсистеми комп'ютерного зору: вилучення візуальних ознак призводить до погіршення RMSE до $0,85 \text{ м}^3/\text{добу}$. Аналіз важливості ознак за методом SHAP виявив, що найбільший внесок у точність прогнозування забезпечують: температура в реакторі (відносна важливість 0,28), об'єм завантаження субстрату (0,22) та візуальні характеристики біоматеріалу (0,15).

Надійність та доступність системи. За період активного тестування системи (90 днів після 6-місячного збору даних) система продемонструвала показник доступності 99,2%. Зафіксовано 3 випадки короткочасної втрати зв'язку з IoT-пристроями загальною тривалістю 17 годин, що було викликано нестабільністю інтернет-з'єднання на об'єкті. Механізм локального буферування даних на рівні мікроконтролерів забезпечив збереження вимірювань та їх синхронізацію після відновлення зв'язку без втрати інформації. Середній час від збору даних до генерації аналітичних результатів становив 3,2 хвилини, що є прийнятним для оперативного прийняття рішень оператором.

Порівняльний аналіз з комерційними аналогами. Для об'єктивної оцінки розробленого рішення проведено порівняльний аналіз із комерційними системами моніторингу біогазових установок. На ринку України представлені переважно газоаналітичні системи німецьких виробників: портативні аналізатори MRU

OPTIMAX Biogas вартістю від 245 000 грн та стаціонарні системи AWIFLEX від компанії AWITE Bioenergie GmbH вартістю 700 000 - 1 100 000 грн. Стаціонарний газоаналізатор SSM 6000 Classic від PRONOVA Analysentechnik GmbH коштує 440 000 - 880 000 грн залежно від комплектації [198], [199].

Таблиця 5.1

Порівняльна характеристика систем моніторингу біогазових установок

Параметр	Розроблена система	MRU OPTIMAX	AWIFLEX	SSM 6000
Тип системи	Комплексна IoT + CV	Портативний	Стаціонарний	Стаціонарний
Вартість апаратної частини, грн	4 500	245 000	900 000	660 000
Пряме вимірювання складу газу	Ні	Так	Так	Так
Прогнозування виходу газу	Так (ML)	Ні	Ні	Ні
Візуальний аналіз сировини	Так (CNN)	Ні	Ні	Ні
Адаптивне навчання (HITL)	Так	Ні	Ні	Ні
Хмарна інтеграція	Так	Bluetooth/SD	Modbus/TCP	RS485/USB

Як видно з табл. 5.1, розроблена система має унікальну функціональність прогнозування виходу біогазу та візуального аналізу сировини, що відсутня в комерційних газоаналізаторах. Водночас, комерційні рішення забезпечують пряме вимірювання компонентного складу біогазу (CH_4 , CO_2 , H_2S , O_2), тоді як розроблена система опосередковано оцінює ці параметри через прогнозну модель [8].

Обмеження розробленої системи. Об'єктивна оцінка розробленого рішення вимагає чіткого визначення його обмежень та сфери застосування:

1. *Відсутність прямого вимірювання складу біогазу.* Система прогнозує вихід біогазу на основі непрямих параметрів (температура, вологість, візуальні характеристики сировини), але не забезпечує прямого вимірювання концентрації CH_4 , CO_2 , H_2S та інших компонентів. Для сертифікації біогазу відповідно до нормативних вимог або для подачі в газову мережу необхідний лабораторний аналіз або сертифіковані газоаналізатори.
2. *Залежність від якості навчальних даних.* Точність прогнозової моделі безпосередньо залежить від якості та репрезентативності даних, на яких вона навчалася. При переході на принципово новий тип субстрату або суттєвій зміні технологічного режиму модель потребує повторного донавчання протягом 30-60 днів.
3. *Залежність від інтернет-з'єднання.* Хоча система має механізм локального буферування даних, повноцінне функціонування підсистеми комп'ютерного зору та прогнозування потребує стабільного інтернет-з'єднання для передачі даних до хмарної інфраструктури.
4. *Обмежена точність візуального аналізу.* Класифікація якості біомаси за візуальними ознаками має точність 89,7%, що означає приблизно 10% помилкових оцінок. Для критичних рішень рекомендується підтвердження результатів оператором.

Порівняльний аналіз з існуючими підходами до автоматизації моніторингу біогазових установок дозволяє визначити ключові елементи наукової новизни та практичні переваги розробленої системи. На відміну від рішення Gaida et al.,[184] яке досягає високої точності прогнозування $R^2 > 0,95$, але потребує регулярного лабораторного аналізу летких жирних кислот, розроблена система забезпечує порівнянну точність $R^2 = 0,91$ в режимі реального часу без необхідності проведення біохімічних досліджень. Порівняно з IoT-системою Kotsopoulos et al.,[25] яка забезпечує лише збір та візуалізацію даних без інтелектуального аналізу, розроблене рішення доповнює моніторинг модулями машинного навчання та комп'ютерного зору. На противагу підходу Wang et al.,[193] який використовує ізольовані ML-моделі для табличних даних, запропонована ансамблева архітектура інтегрує різноманітні джерела інформації

- телеметрію яка базується на давачах, візуальні характеристики субстрату та історичні часові ряди.

Ключовим елементом наукової новизни є інтеграція підсистеми комп'ютерного зору для неінвазійної оцінки якості біосировини. Існуючі системи моніторингу біогазових установок базуються виключно на сенсорних або лабораторних даних, тоді як розроблена система використовує аналіз візуальних характеристик субстрату, забезпечуючи кореляцію $r = 0,81$ між текстурними ознаками зображення та інтегральною оцінкою якості матеріалу. Це дозволяє оперативно оцінювати придатність сировини до завантаження без проведення трудомістких лабораторних аналізів. Не менш важливим елементом новизни є механізм адаптивного донавчання, який забезпечує автоматичну адаптацію прогнозних моделей до змінних умов експлуатації на основі зворотного зв'язку від оператора. Жодне з проаналізованих рішень не забезпечує такого механізму подолання concept drift. Практична ефективність підтверджується підвищенням точності з $R^2 = 0,85$ до $R^2 = 0,91$ та зменшенням RMSE на 42,6% після першого циклу донавчання на 100 валідованих оператором записах. Комбінація попередніх елементів із застосуванням узагальненої функції бажаності Харрінгтона для трансформації технічних метрик прогнозування у інтуїтивно зрозумілий індекс якості процесу. Існуючі системи оперують абсолютними значеннями виходу біогазу або статистичними метриками, які потребують спеціальних знань для інтерпретації. Розроблений підхід перетворює ці показники на нормалізовану шкалу з лінгвістичною інтерпретацією, що робить результати аналізу доступними для операторів без спеціальної підготовки в галузі машинного навчання. Ключовим елементом новизни є ансамблева архітектура, що поєднує моделі різних типів: рекурентну мережу LSTM для моделювання часових залежностей у телеметричних даних, градієнтний бустинг XGBoost для аналізу табличних параметрів процесу та згорткову мережу ResNet-50 для екстракції ознак із зображень субстрату. Таке комбінування забезпечує синергетичний ефект, де кожна модель компенсує слабкі сторони інших, та підвищує робастність системи до відмов окремих сенсорів або нетипових умов експлуатації. Розроблена система позиціонується як інструмент оперативного моніторингу та оптимізації, що доповнює традиційні методи

лабораторного контролю. Найвища ефективність досягається при періодичному використанні лабораторного аналізу для калібрування та валідації прогнозної моделі, що гарантує надійність системи в довгостроковій перспективі.

5.2. Економічне обґрунтування застосування розробленої системи

Економічна ефективність впровадження інтелектуальної системи моніторингу визначається співвідношенням витрат на розробку, впровадження та експлуатацію до отриманого економічного ефекту від оптимізації технологічного процесу виробництва біогазу. Основними джерелами економії є: зниження частоти лабораторного контролю за рахунок оперативного моніторингу, підвищення виходу біогазу завдяки оптимізації завантаження реактора, скорочення простоїв обладнання та запобігання аварійним ситуаціям [187].

5.2.1. Розрахунок витрат на створення та впровадження комплексу

Загальні витрати на створення та впровадження комп'ютерно-інтегрованої системи моніторингу складаються з витрат на апаратне забезпечення, програмне забезпечення, хмарну інфраструктуру та впровадження.

Витрати на апаратне забезпечення. Детальний кошторис компонентів апаратної підсистеми наведено в табл. 5.2. Розрахунок виконано для типової конфігурації системи, що включає один вузол збору даних з п'ятьма температурними давачами та модулем візуального контролю.

Кошторис апаратного забезпечення системи моніторингу

Найменування компонента	Кількість, шт.	Ціна, грн	Сума, грн
Мікроконтролер ESP32 DevKit V1	2	320	640
Модуль ESP32-CAM з камерою OV2640	1	450	450
давач температури DS18B20 водонепроникний	5	120	600
давач вологості та температури DHT22	2	180	360
Ємнісний давач вологості ґрунту	2	85	170
Блок живлення 5V 3A з захистом	2	280	560
Корпус IP65 для зовнішнього монтажу	2	450	900
Кабелі, роз'єми, монтажні матеріали	-	-	820
Разом апаратне забезпечення:	-	-	4 500

Витрати на програмне забезпечення та розробку. Розробка програмного забезпечення системи включала: прошивку мікроконтролерів (80 людино-годин), серверну частину та API (120 людино-годин), модуль комп'ютерного зору (100 людино-годин), прогнозну модель та механізм HITL (160 людино-годин), веб-інтерфейс (80 людино-годин). Загальна трудомісткість розробки становить 540 людино-годин. При середній вартості роботи програміста 500 грн/год витрати на розробку становлять 270 000 грн [56]. Ці витрати є одноразовими та розподіляються між кількома впровадженнями системи, тому в подальших розрахунках не враховуються для окремої установки.

Витрати на хмарну інфраструктуру. Річні витрати на хмарні сервіси для однієї біогазової установки наведено в табл. 5.3. Розрахунок виконано на основі тарифів хмарної платформи AWS станом на грудень 2025 року.

Таблиця 5.3

Річні витрати на хмарну інфраструктуру

Сервіс	Призначення	Вартість/міс, \$	Вартість/рік, грн
EC2 t3.medium	Обробка ML-моделей	38	18 720
DynamoDB	Зберігання телеметрії	12	5 900
S3 (50 ГБ/міс)	Зберігання зображень	5	2 460
IoT Core	MQTT брокер	8	3 940
CloudWatch	Моніторинг та логування	3	1 480
Разом хмарна інфраструктура:		66	32 500

Витрати на впровадження та навчання персоналу. Впровадження системи включає: монтаж апаратного забезпечення (8 годин), налаштування та тестування (16 годин), навчання операторів (8 годин), документування та здачу в експлуатацію (8 годин). Загальна трудомісткість впровадження становить 40 людино-годин. При вартості роботи спеціаліста 375 грн/год витрати на впровадження становлять 15 000 грн.

Зведена таблиця витрат. Загальні капітальні та операційні витрати на перший рік експлуатації системи наведено в табл. 5.4.

Таблиця 5.4

Зведена таблиця витрат на впровадження системи

Стаття витрат	Тип витрат	Сума, грн
Апаратне забезпечення	Капітальні	4 500
Резервні компоненти (10%)	Капітальні	450
Впровадження та навчання персоналу	Капітальні	15 000
Разом капітальні витрати:		19 950

Стаття витрат	Тип витрат	Сума, грн
Хмарна інфраструктура (рік)	Операційні	32 500
Технічна підтримка та оновлення (рік)	Операційні	12 000
Разом операційні витрати (рік):		44 500
РАЗОМ витрати за 1-й рік:		64 450
Операційні витрати наступних років:		44 500

5.2.2. Прогнозування економічного ефекту від оптимізації процесу

Економічний ефект від впровадження системи формується за рахунок кількох основних чинників: зменшення частоти лабораторного хімічного аналізу, підвищення виходу біогазу за рахунок оптимізації завантаження та скорочення простоїв обладнання.

Порівняння з традиційним лабораторним контролем. Згідно з даними з джерел, стаціонарні газоаналізатори для біогазових установок забезпечують безперервний моніторинг складу біогазу (CH_4 , CO_2 , O_2 , H_2S , H_2). Вартість такого обладнання становить від 660 000 грн для базових моделей (SSM 6000 Classic) до 1 100 000 грн для систем преміум-класу (AWIFLEX) [198, 199].

Альтернативою стаціонарному обладнанню є періодичний лабораторний аналіз біогазу методом газової хроматографії. Вартість одного комплексного хроматографічного аналізу складу біогазу в акредитованих лабораторіях України становить 2 400 - 3 500 грн залежно від кількості визначуваних параметрів [89]. Для забезпечення належного контролю технологічного процесу без автоматизованої системи моніторингу рекомендується проводити аналіз щонайменше 3 рази на тиждень, що становить 156 аналізів на рік. Зведені дані капітальних та річних операційних витрат наведені у табл. 5.5.

Таблиця 5.5

Порівняння річних витрат на моніторинг параметрів біогазу

Метод моніторингу	Капітальні витрати, грн	Річні операційні витрати, грн
Лабораторний хіманаліз (3 рази/тиждень)	0	374 400 - 546 000
Лабораторний хіманаліз (1 раз/тиждень)	0	124 800 - 182 000
Портативний газоаналізатор MRU OPTIMAX	245 000	18 000
Стаціонарний газоаналізатор SSM 6000	660 000	25 000
Стаціонарний газоаналізатор AWIFLEX	900 000	32 000
Розроблена IoT+CV система	19 950	44 500

Розроблена система не замінює повністю лабораторний контроль, оскільки не забезпечує прямого вимірювання складу біогазу. Однак вона дозволяє суттєво зменшити частоту лабораторних аналізів - з 3 до 1 разу на тиждень - за рахунок оперативного моніторингу непрямих параметрів та раннього виявлення відхилень. Періодичний лабораторний аналіз (1 раз/тиждень) залишається необхідним для калібрування прогнозової моделі та валідації результатів.

Таким чином, економія на лабораторному контролі при впровадженні системи становить:

- Базові витрати (3 рази/тиждень): 374 400 - 546 000 грн/рік
- Витрати з системою (1 раз/тиждень): 124 800 - 182 000 грн/рік
- **Економія: 249 600 - 364 000 грн/рік**

Економічний ефект від підвищення виходу біогазу. Прогнозування виходу біогазу з використанням розробленої моделі дозволяє оптимізувати режим завантаження реактора та склад субстрату. За результатами 90-денного тестування,

оптимізація на основі прогнозів забезпечила підвищення середнього виходу біогазу на 8-12% порівняно з базовим режимом експлуатації [75].

Механізм досягнення підвищення виходу біогазу включає:

- *Оптимізація температурного режиму* на основі прогнозів моделі забезпечує підтримання температури в оптимальному діапазоні 35-37°C з мінімальними коливаннями, що підвищує активність метаногенних бактерій - внесок 4-5%;
- *Своєчасне коригування складу субстрату* за результатами візуального аналізу дозволяє виявляти партії сировини низької якості та коригувати співвідношення компонентів - внесок 2-4%;
- *Запобігання критичним відхиленням параметрів* завдяки раннім сповіщенням системи дозволяє оператору вжити коригуючих заходів до настання проблеми - внесок 2-3%.

Для типової біогазової установки у експерименті використовувався буряковий жом як основний субстрат розрахунковий економічний ефект від підвищення виходу на 10% становить:

- Додатковий вихід біогазу: $100 \times 0,10 \times 365 = 3\,650 \text{ м}^3/\text{рік}$
- Енергетичний еквівалент (6 кВт·год/м³): $3\,650 \times 6 = 21\,900 \text{ кВт·год/рік}$
- Економічний ефект при тарифі 4,5 грн/кВт·год: $21\,900 \times 4,5 = \mathbf{98\,550 \text{ грн/рік}}$

Раннє виявлення аномалій у роботі біореактора за допомогою системи моніторингу дозволяє запобігти аварійним ситуаціям та скоротити незаплановані простої. За експертними оцінками, впровадження системи предиктивного моніторингу знижує тривалість простоїв на 20-30% [85]. Для установки з річним виробітком 36 500 м³ біогазу скорочення простоїв з 15 до 10 днів на рік забезпечує додатковий вихід 500 м³ біогазу, що еквівалентно **13 500 грн**.

Сумарний річний економічний ефект від впровадження системи наведено в табл. 5.6.

Таблиця 5.6

Структура річного економічного ефекту

Джерело економії	Мінімальна оцінка, грн	Максимальна оцінка, грн
Зменшення частоти лабораторного контролю	249 600	364 000
Підвищення виходу біогазу (8-12%)	78 840	118 260
Скорочення простоїв	10 800	16 200
РАЗОМ:	339 240	498 460

Розрахунок терміну окупності. При загальних витратах за перший рік 64 450 грн (без урахування витрат на розробку, які розподіляються між кількома впровадженнями) простий термін окупності системи становить:

$$T_{\text{ок}} = 64\,450 / 339\,240 = 0,19 \text{ року} \approx \mathbf{2,3 \text{ місяця}}$$
 (песимістична оцінка)

$$T_{\text{ок}} = 64\,450 / 498\,460 = 0,13 \text{ року} \approx \mathbf{1,6 \text{ місяця}}$$
 (оптимістична оцінка)

Аналіз чутливості економічних показників. Для оцінки стійкості економічного обґрунтування проведено аналіз чутливості до зміни ключових параметрів (табл. 5.7).

Таблиця 5.7

Аналіз чутливості економічних показників

Параметр	Базове значення	Песимістичний сценарій	Оптимістичний сценарій
Курс долара	41 грн/\$	50 грн/\$	35 грн/\$
Підвищення виходу біогазу	10%	5%	15%
Тариф на електроенергію	4,5 грн/кВт·год	3,5 грн/кВт·год	5,5 грн/кВт·год
Вартість лабораторного аналізу	2 950 грн	2 400 грн	3 500 грн
Річний економічний	418 850 грн	247 300 грн	590 400 грн

Параметр	Базове значення	Песимістичний сценарій	Оптимістичний сценарій
ефект			
Термін окупності	1,8 міс	4,1 міс	1,3 міс

Як видно з табл. 5.7, навіть при песимістичному сценарії (зростання курсу долара, мінімальне підвищення виходу біогазу, низькі тарифи на електроенергію) термін окупності системи не перевищує 5 місяців, що свідчить про високу економічну стійкість проекту.

Для комплексної оцінки доцільності впровадження системи ідентифіковано основні ризики та заходи їх мінімізації (табл. 5.8).

Таблиця 5.8

Аналіз ризиків впровадження системи

Ризик	Ймовірність	Вплив	Заходи мінімізації
Нестабільність інтернет-з'єднання	Середня	Середній	Локальне буферування даних, резервний канал зв'язку (3G/4G модем)
Вихід з ладу датчиків	Низька	Низький	Резервні компоненти (10%), регулярна калібровка
Зниження точності моделі при зміні субстрату	Висока	Середній	Механізм HITL-донавчання, період адаптації 30 днів
Зростання вартості хмарних сервісів	Низька	Низький	Оптимізація використання ресурсів, можливість міграції на альтернативну платформу
Помилки візуального аналізу	Середня	Низький	Підтвердження критичних рішень оператором, поступове накопичення

Ризик	Ймовірність	Вплив	Заходи мінімізації
			навчальних даних

Таким чином, розроблена система демонструє високу економічну ефективність з терміном окупності 1,6-2,3 місяця при базовому сценарії. Навіть при консервативній оцінці економічного ефекту та врахуванні основних ризиків термін окупності не перевищує 5 місяців, що підтверджує доцільність впровадження системи на біогазових установках [54].

5.3. Рекомендації щодо масштабування та подальшого розвитку системи

На основі результатів експериментальної валідації та економічного аналізу сформульовано рекомендації щодо масштабування розробленої системи та визначено пріоритетні напрямки її подальшого вдосконалення.

Технічні рекомендації щодо масштабування:

1. Горизонтальне масштабування IoT-інфраструктури. Архітектура системи забезпечує горизонтальне масштабування за рахунок додавання нових IoT-вузлів без модифікації серверної інфраструктури. Рекомендується використовувати уніфіковані вузли збору даних з можливістю підключення до 8 датчиків на один мікроконтролер ESP32 [167]. Для забезпечення надійності рекомендується дублювання критичних датчиків (температура в реакторі).

2. Edge-обчислення для великих комплексів. Для великих біогазових комплексів з кількома реакторами доцільно розгорнути локальний edge-сервер (наприклад, на базі Raspberry Pi 4 або Intel NUC) для первинної обробки даних та зменшення навантаження на хмарну інфраструктуру. Це також підвищує стійкість системи до тимчасової втрати інтернет-з'єднання.

3. Адаптація прогнозової моделі. Прогнозна модель потребує повторного донавчання при переході на новий тип субстрату або суттєвій зміні технологічного режиму. Рекомендований період адаптації - 30 днів з активним HPL-контролем, протягом якого оператор підтверджує або коригує кожен прогноз системи [96].

4. Розширення сенсорної бази. Для підвищення точності прогнозування рекомендується інтеграція додаткових датчиків: рН-метра (дані з існуючого

обладнання установки через Modbus), давача окислювально-відновного потенціалу (ORP) субстрату, давача рівня заповнення реактора.

Перспективні напрямки розвитку системи систематизовано за пріоритетністю та очікуваним ефектом у табл. 5.9.

Таблиця 5.9

Пріоритетні напрямки розвитку системи

Напрямок розвитку	Пріоритет	Очікуваний ефект	Орієнтовні витрати, грн	Термін реалізації
Інтеграція NDIR-сенсорів для вимірювання CH ₄ , CO ₂	Високий	Пряме вимірювання складу біогазу в реальному часі	8 000	2-3 міс
Мобільний застосунок для операторів	Середній	Підвищення оперативності реагування на 40%	50 000	3-4 міс
Інтеграція з існуючими SCADA-системами	Середній	Уніфікація даних, сумісність з обладнанням	30 000	2-3 міс
Модуль автоматичного керування дозуванням	Низький	Замкнутий цикл оптимізації без участі оператора	150 000	6-9 міс
Федеративна платформа для кількох установок	Низький	Обмін досвідом, навчання загальної моделі	100 000	9-12 міс

Детальний опис пріоритетних напрямів:

1. Інтеграція модуля прямого вимірювання складу біогазу. Впровадження недорогих NDIR-сенсорів (MH-Z19B для CO₂, MQ-4 для CH₄) дозволить

отримувати дані про компонентний склад біогазу в реальному часі [72]. Це усуне основне обмеження поточної версії системи та забезпечить повноцінну заміну періодичного лабораторного контролю. Орієнтовна вартість модуля - 8 000 грн, що включає сенсори, корпус з підігрівом для запобігання конденсації та калібрувальне обладнання.

2. Розробка мобільного застосунку. Мобільний застосунок для операторів з функціями push-сповіщень, віддаленого моніторингу та швидкого підтвердження прогнозів (HITL) підвищить оперативність реагування на відхилення процесу. Застосунок планується розробити для платформ Android та iOS з використанням кросплатформенного фреймворку Flutter.

3. Впровадження модуля автоматичного керування дозуванням. На основі прогнозів моделі можливо реалізувати автоматичне керування дозуванням субстрату, що забезпечить замкнутий цикл оптимізації без участі оператора. Це потребує інтеграції з системою подачі субстрату та розробки алгоритмів керування з урахуванням обмежень безпеки.

4. Розширення підсистеми комп'ютерного зору. Перспективним напрямком є розширення функціональності комп'ютерного зору для автоматичної класифікації типів сировини (солома, гній, силос, харчові відходи) та виявлення небажаних домішок у субстраті (пластик, метал, каміння).

5. Створення федеративної платформи. Агрегація даних з кількох біогазових установок дозволить навчати більш точні загальні моделі та забезпечить обмін досвідом оптимізації між операторами. Федеративне навчання (Federated Learning) дозволить підвищити точність моделей без централізованого збору конфіденційних даних окремих установок.

Висновки до розділу 5

У даному розділі проведено комплексну оцінку ефективності розробленої комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу. Основні результати:

1. Технічна оцінка підтвердила високу точність вимірювань апаратної підсистеми ($\pm 0,5^{\circ}\text{C}$ для температури, $\pm 2\%$ для вологості) та ефективність

прогнозної моделі ($R^2 = 0,91$, $RMSE = 0,35$ м³/добу після адаптивного донавчання). Показник доступності системи за 90 днів тестування становив 99,2%. Класифікація якості біомаси за візуальними ознаками досягла точності 89,7%.

2. Порівняльний аналіз з комерційними газоаналізаторами (MRU OPTIMAX, AWIFLEX, SSM 6000 Classic) показав, що розроблена система має унікальну функціональність прогнозування та візуального аналізу при суттєво нижчій вартості апаратної частини (4 500 грн проти 245 000 - 900 000 грн). Визначено обмеження системи, зокрема відсутність прямого вимірювання складу біогазу, що потребує збереження періодичного лабораторного контролю.

3. Економічний аналіз виявив значний потенціал економії при впровадженні системи. Зменшення частоти лабораторного контролю з 3 до 1 разу на тиждень забезпечує економію 249 600 - 364 000 грн/рік. Підвищення виходу біогазу на 8-12% та скорочення простоїв додають ще 89 640 - 134 460 грн/рік. Сумарний річний економічний ефект оцінюється в 339 240 - 498 460 грн.

4. Простий термін окупності системи становить 1,6-2,3 місяця при базовому сценарії. Аналіз чутливості підтвердив економічну стійкість проекту: навіть при песимістичному сценарії термін окупності не перевищує 5 місяців. Проведено аналіз ризиків впровадження та визначено заходи їх мінімізації.

5. Сформульовано рекомендації щодо масштабування системи (горизонтальне масштабування IoT-інфраструктури, edge-обчислення для великих комплексів) та визначено пріоритетні напрямки розвитку. Найвищий пріоритет має інтеграція NDIR-сенсорів для прямого вимірювання складу біогазу (орієнтовна вартість 8 000 грн), що усуне основне обмеження поточної версії системи.

Отримані результати підтверджують високу практичну цінність розробленої системи та доцільність її широкого впровадження на біогазових установках різної потужності. Система позиціонується як інструмент оперативного моніторингу та оптимізації технологічного процесу, що доповнює традиційні методи лабораторного

контролю та забезпечує значний економічний ефект при мінімальних капітальних витратах.

ВИСНОВКИ

У дисертаційній роботі вирішено актуальну науково-практичну задачу розробки інтелектуальної комп'ютерно-інтегрованої системи моніторингу параметрів виробництва біогазу з використанням технологій Інтернету речей, комп'ютерного зору та машинного навчання. Основні наукові та практичні результати роботи полягають у такому:

1. На основі комплексного аналізу процесу виробництва біогазу як об'єкта автоматизації встановлено, що існуючі високоточні методи прогнозування базуються на лабораторних аналізах, що унеможлиблює моніторинг у реальному часі. Сучасні IoT-системи не включають інтелектуальні модулі прогнозування та аналізу візуальних характеристик сировини, що обумовлює необхідність розробки комплексного рішення.

2. Вперше розроблено трирівневу архітектуру комп'ютерно-інтегрованої системи моніторингу біогазового виробництва на базі мікроконтролерної платформи ESP32 з інтеграцією датчиків температури DS18B20 (точність $\pm 0,5^{\circ}\text{C}$), вологості DHT22 та камери OV2640 (1600×1200). Реалізовано хмарну інфраструктуру на базі AWS (IoT Core, DynamoDB, S3, Lambda, Fargate) із забезпеченням надійності збору даних 98,6% та доступності системи 99,2%.

3. Вперше запропоновано метод автоматизованої оцінки якості біосировини на основі аналізу зображень із застосуванням алгоритму сегментації Оцу з попереднім підвищенням контрастності (CLAHE) та гібридної метрики якості на базі евклідової відстані та функції бажаності Харрінгтона. Експериментально підтверджено кореляцію візуальних характеристик біоматеріалу з виходом біогазу ($r = 0,81$), що на 19% вище базової евклідової метрики.

4. Вперше синтезовано підсистему прогнозування виходу біогазу на основі ансамблю нейронних мереж, що включає рекурентну мережу LSTM (2 шари по 64 нейрони) для аналізу часових рядів, градієнтний бустинг XGBoost (200 дерев) для табличних даних та згорткову мережу ResNet-50 для візуальних ознак. Запропоновано

механізм зваженого ансамблювання з динамічним розрахунком ваг, обернено пропорційних до MAE кожної моделі.

5. Вперше розроблено механізм адаптивного донавчання Human-in-the-Loop, що забезпечує автоматичну адаптацію прогнозних моделей до змінних умов експлуатації на основі зворотного зв'язку від оператора. Після донавчання модель досягла коефіцієнта детермінації $R^2 = 0,91$ та $RMSE = 0,35$ м³/добу, що на 42,6% краще за базову модель. Абляційний аналіз підтвердив критичну важливість кожного компонента ансамблю.

6. Проведено техніко-економічне обґрунтування системи. Вартість апаратної частини становить 4 500 грн, що в 50-200 разів менше комерційних аналогів (MRU OPTIMAX, AWIFLEX, SSM 6000 Classic). Річний економічний ефект оцінюється в 339 000 - 498 000 грн при терміні окупності 1,6-2,3 місяця. Визначено обмеження системи та пріоритетні напрямки розвитку, зокрема інтеграцію NDIR-сенсорів для прямого вимірювання складу біогазу.

Отримані результати підтверджують досягнення мети дисертаційної роботи та можуть бути використані для підвищення ефективності моніторингу та управління біогазовими установками різної потужності.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Salamattalab M. M., Hasani Zonoozi M., Molavi-Arabshahi M. (2024). Innovative approach for predicting biogas production from large-scale anaerobic digester using long-short term memory (LSTM) coupled with genetic algorithm (GA). *Waste Management* 175, 30-41. <https://doi.org/10.1016/j.wasman.2023.12.046>
2. Ling J. Y. X., Chan Y. J., Chen J. W., Chong D. J. S., Tan A. L. L., Arumugasamy S. K., Lau P. L. (2024). Machine learning methods for the modelling and optimisation of biogas production from anaerobic digestion: a review. *Environmental Science and Pollution Research* 31, 19085-19104. <https://doi.org/10.1007/s11356-024-32435-6>
3. Andrade Cruz I., Chuenchart W., Long F., Surendra K., Renata Santos Andrade L., Bilal M., Liu H., Tavares Figueiredo R., Khanal S. K., Fernando Romanholo Ferreira L. (2022). Application of machine learning in anaerobic digestion: Perspectives and challenges. *Bioresource Technology* 345, 126433. <https://doi.org/10.1016/j.biortech.2021.126433>
4. Achinas S., Achinas V., Euverink G. J. W. (2017). A Technological Overview of Biogas Production from Biowaste. *Engineering* 3, 299-307. <https://doi.org/10.1016/j.eng.2017.03.002>
5. Singh D., Tembhare M., Pundalik K., Dikshit A. K., Kumar S. (2024). Machine learning based prediction of biogas generation from municipal solid waste: A data-driven approach. *Process Safety and Environmental Protection* 192, 93-103. <https://doi.org/10.1016/j.psep.2024.10.037>
6. Li Y., Chen Y., Wu J. (2020). The microbiome driving anaerobic digestion and microbial analysis. *Advances in Bioenergy*, 1-61. <https://doi.org/10.1016/bs.aibe.2020.04.001>
7. Wang L., Long F., Liao W., Liu H. (2020). Prediction of anaerobic digestion performance and identification of critical operational parameters using machine learning algorithms. *Bioresource Technology* 298, 122495. <https://doi.org/10.1016/j.biortech.2019.122495>
8. Koutrouli E. C., Kalfas H., Gavala H. N., Skiadas I. V., Stamatelatou K., Lyberatos G. (2009). Hydrogen and methane production through two-stage mesophilic

- anaerobic digestion of olive pulp. *Bioresource Technology* 100, 3718-3723.
<https://doi.org/10.1016/j.biortech.2009.01.037>
9. Sørensen O. (1995). Neural Networks for Optimal Control. *IFAC Proceedings Volumes* 28, 361-366. [https://doi.org/10.1016/s1474-6670\(17\)45489-9](https://doi.org/10.1016/s1474-6670(17)45489-9)
 10. Almomani F. (2020). Prediction of biogas production from chemically treated co-digested agricultural waste using artificial neural network. *Fuel* 280, 118573. <https://doi.org/10.1016/j.fuel.2020.118573>
 11. Yadav M., Vivekanand V. (2020). Biological treatment of lignocellulosic biomass by *Curvularia lunata* for biogas production. *Bioresource Technology* 306, 123151. <https://doi.org/10.1016/j.biortech.2020.123151>
 12. Jiang C., Qi R., Hao L., McIlroy S. J., Nielsen P. H. (2018). Monitoring foaming potential in anaerobic digesters. *Waste Management* 75, 280-288. <https://doi.org/10.1016/j.wasman.2018.02.021>
 13. Xu F., Li Y., Ge X., Yang L., Li Y. (2018). Anaerobic digestion of food waste - Challenges and opportunities. *Bioresource Technology* 247, 1047-1058. <https://doi.org/10.1016/j.biortech.2017.09.020>
 14. Ganeshan P., Bose A., Lee J., Barathi S., Rajendran K. (2024). Machine learning for high solid anaerobic digestion: Performance prediction and optimization. *Bioresource Technology* 400, 130665. <https://doi.org/10.1016/j.biortech.2024.130665>
 15. Yılmaz, Ş., Şahan T. (2020). Utilization of pumice for improving biogas production from poultry manure by anaerobic digestion: A modeling and process optimization study using response surface methodology. *Biomass and Bioenergy* 138, 105601. <https://doi.org/10.1016/j.biombioe.2020.105601>
 16. Gudavalli C., Bose E., Donohoe B. S., Sievers D. A. (2020). Real-time biomass feedstock particle quality detection using image analysis and machine vision. *Biomass Conversion and Biorefinery* 12, 5739-5750. <https://doi.org/10.1007/s13399-020-00904-w>
 17. Khalid A., Arshad M., Anjum M., Mahmood T., Dawson L. (2011). The anaerobic digestion of solid organic waste. *Waste Management* 31, 1737-1744. <https://doi.org/10.1016/j.wasman.2011.03.021>

18. IoT Analytics. State of IoT 2023. URL: <https://iot-analytics.com/> (дата звернення: 13.10.2025).
19. Budnik K., Szymenderski J., Walowski G. (2018). Control and Supervision System for Micro Biogas Plant. 19th International Conference Computational Problems of Electrical Engineering, 1-4. <https://doi.org/10.1109/cpee.2018.8506994>
20. Szymenderski J., Typanska D. (2016). Control model of energy flow in agricultural biogas plant using SCADA software. 2016 17th International Conference Computational Problems of Electrical Engineering (CPEE), 1-4. <https://doi.org/10.1109/cpee.2016.7738741>
21. Manjula A., Arunachalam Y. (2017). Automation in Biogas Plant using PLC, SCADA, GSM. Artificial Intelligent Systems and Machine Learning, 9, 120-126. URL: <https://www.semanticscholar.org/paper/Automation-in-Biogas-Plant-using-PLC%2C-SCADA%2C-GSM-Manjula-Arunachalam/1e9279246a5c724e4028e960823a09ced350729e> (дата звернення: 30.11.2025).
22. Méndez-Acosta H. O., Palacios-Ruiz B., Alcaraz-González V., González-Álvarez V., García-Sandoval J. P. (2010). A robust control scheme to improve the stability of anaerobic digestion processes. Journal of Process Control 20(4), 375-383. <https://doi.org/10.1016/j.jprocont.2010.01.006>
23. Deublein D., Steinhauser A. Biogas from Waste and Renewable Resources. Wiley-VCH, 2011. 578 p.
24. AWS. IoT Solutions. URL: <https://aws.amazon.com/iot/> (дата звернення: 30.11.2025).
25. Kalamaras S. D., Tsitsimpikou M. A., Tzenos C. A., Lithourgidis A. A., Pitsikoglou D. S., Kotsopoulos T. A. (2024). A Low-Cost IoT System Based on the ESP32 Microcontroller for Efficient Monitoring of a Pilot Anaerobic Biogas Reactor. Applied Sciences 15, 34. <https://doi.org/10.3390/app15010034>
26. Radu T., Smedley V., Yadav D., Blanchard R., Rahaman S. A., Salam P. A., Visvanathan C. (2022). The Design, Development and Assessment of a Novel Decentralised IoT-Based Remote Monitoring of a Small-Scale Anaerobic Digester

- Network. Journal of Energy and Power Technology 04, 1-17.
<https://doi.org/10.21926/jept.2204039>
27. Acharya V., Hegde V. V., K., A., M., M. K. (2017). IoT (Internet of Things) Based Efficiency Monitoring System for Bio-Gas Plants. 2017 2nd International Conference on Computational Systems and Information Technology for Sustainable Solution (CSITSS), 1-5. <https://doi.org/10.1109/csitss.2017.8447567>
 28. Rahadian H., Sutopo B., Soesanti I. (2015). TGS2611 performance as biogas monitoring instrument in digester model application. 2015 International Seminar on Intelligent Technology and Its Applications (ISITIA), 119-124.
<https://doi.org/10.1109/isitia.2015.7219965>
 29. Rutland H., You J., Liu H., Bull L., Reynolds D. (2023). A Systematic Review of Machine-Learning Solutions in Anaerobic Digestion. Bioengineering 10, 1410.
<https://doi.org/10.3390/bioengineering10121410>
 30. Yildirim O., Ozkaya B. (2023). Prediction of biogas production of industrial scale anaerobic digestion plant by machine learning algorithms. Chemosphere 335, 138976. <https://doi.org/10.1016/j.chemosphere.2023.138976>
 31. Wang Y., Huntington T., Scown C. D. (2021). Tree-Based Automated Machine Learning to Predict Biogas Production for Anaerobic Co-digestion of Organic Waste. ACS Sustainable Chemistry & Engineering 9, 12990-13000.
<https://doi.org/10.1021/acssuschemeng.1c04612>
 32. Chiu M. C., Wen C. Y., Hsu H. W., Wang W. C. (2022). Key wastes selection and prediction improvement for biogas production through hybrid machine learning methods. Sustainable Energy Technologies and Assessments 52, 102223.
<https://doi.org/10.1016/j.seta.2022.102223>
 33. Amazon Web Services. S3 Documentation. URL: <https://docs.aws.amazon.com/s3/> (дата звернення: 28.03.2025).
 34. AWS IoT Core. Developer Guide. URL: <https://docs.aws.amazon.com/iot/> (дата звернення: 29.10.2025).
 35. Lendiel T., Lysenko V., Nakonechna K. (2020). Computer-Integrated Technologies for Fitomonitoring in the Greenhouse. Lecture Notes on Data Engineering and

Communications Technologies, 711-729. https://doi.org/10.1007/978-3-030-43070-2_30

36. Aguida M. A., Ouchani S., Benmalek M. (2021). An IoT-based Framework for an Optimal Monitoring and Control of Cyber-Physical Systems: Application on Biogas Production System. Proceedings of the 11th International Conference on the Internet of Things, 143-149. <https://doi.org/10.1145/3494322.3494341>
37. Kamilaris A., Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. Computers and Electronics in Agriculture 147, 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
38. Mehmet Mutlu (2016). Biosensing for Food Safety. Biosensors in Food Processing, Safety, and Quality Control, 106-139. <https://doi.org/10.1201/b10466-10>
39. Skovsen S., Laursen M., Gislum R., Eriksen J., Dyrmann M., Mortensen A., Farkhani S., Karstoft H., Jensen N., Jørgensen R. (2019). Species distribution mapping of grass clover leys using images for targeted nitrogen fertilization. Precision agriculture '19, 639-645. https://doi.org/10.3920/978-90-8686-888-9_79
40. Dhawi F., Ghafoor A., Almousa N., Ali S., Alqanbar S. (2025). Predictive modelling employing machine learning, convolutional neural networks (CNNs), and smartphone RGB images for non-destructive biomass estimation of pearl millet (*Pennisetum glaucum*). Frontiers in Plant Science 16. <https://doi.org/10.3389/fpls.2025.1594728>
41. Gonzalez R.C., Woods R.E. Digital Image Processing. Pearson, 2018. 1168 p.
42. Goodfellow I. et al. Deep Learning. MIT Press, 2016. 800 p.
43. Liakos K., Busato P., Moshou D., Pearson S., Bochtis D. (2018). Machine Learning in Agriculture: A Review. Sensors 18, 2674. <https://doi.org/10.3390/s18082674>
44. He K., Zhang X., Ren S., Sun J. (2016). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778. <https://doi.org/10.1109/cvpr.2016.90>
45. Pan S. J., Yang Q. (2010). A Survey on Transfer Learning. IEEE Transactions on Knowledge and Data Engineering 22, 1345-1359. <https://doi.org/10.1109/tkde.2009.191>

46. LeCun Y., Bengio Y., Hinton G. (2015). Deep learning. *Nature* 521, 436-444.
<https://doi.org/10.1038/nature14539>
47. Amran N. A. M., Mohamed H., Rafaa Z. F. M., Yacob N. S., Junoh H., Shamsuddin A. H. (2024). A review of machine learning models in predicting biogas production. *AIP Conference Proceedings* 3041, 060006. <https://doi.org/10.1063/5.0181016>
48. Cheon A., Sung J., Jun H., Jang H., Kim M., Park J. (2022). Application of Various Machine Learning Models for Process Stability of Bio-Electrochemical Anaerobic Digestion. *Processes* 10, 158. <https://doi.org/10.3390/pr10010158>
49. Sakiewicz P., Piotrowski K., Ober J., Karwot J. (2020). Innovative artificial neural network approach for integrated biogas - wastewater treatment system modelling: Effect of plant operating parameters on process intensification. *Renewable and Sustainable Energy Reviews* 124, 109784. <https://doi.org/10.1016/j.rser.2020.109784>
50. Gueguim Kana E., Oloke J., Lateef A., Adesiyun M. (2012). Modeling and optimization of biogas production on saw dust and other co-substrates using Artificial Neural network and Genetic Algorithm. *Renewable Energy* 46, 276-281.
<https://doi.org/10.1016/j.renene.2012.03.027>
51. Hochreiter S., Schmidhuber J. (1997). Long Short-Term Memory. *Neural Computation* 9, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
52. Chen T., Guestrin C. (2016). XGBoost. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
<https://doi.org/10.1145/2939672.2939785>
53. AWS IoT Device Certificate Rotation. URL: <https://aws.amazon.com/blogs/iot/how-to-manage-iot-device-certificate-rotation-using-aws-iot/> (дата звернення: 26.01.2026).
54. Lysenko V., Lendiel T., Bolbot I., Pavlov S. (2023). Mobile system for monitoring plant environment parameters for biogas production. *Naukovij žurnal «Tehnika ta energetika»* 14, 111-120. <https://doi.org/10.31548/machinery/4.2023.111>
55. Pavlov S., Lysenko V., Lendel T., Nakonechna K. (2025). Harrington's method in a system for rapid quality assessment of biogas feedstock for fermentation. *Scientific*

Works of National University of Food Technologies 31, 63-74.
<https://doi.org/10.24263/2225-2924-2025-31-5-7>

56. Воротніков В. В., Шелуха О. О., Матвєєв К. І. (2025). Система моніторингу користувацької активності та автоматизованого керування офісною ІТ-інфраструктурою. Технічна інженерія, 249-258. [https://doi.org/10.26642/ten-2025-1\(95\)-249-258](https://doi.org/10.26642/ten-2025-1(95)-249-258)
57. Lysenko V., Lendiel T., Pavlov S., Nakonechna K. (2024). Computer Vision Technologies for Rapid Quality Analysis of Fermentable Biomaterial. 2024 IEEE 17th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET), 1-5. <https://doi.org/10.1109/tcset64720.2024.10755768>
58. Ahmad M. W., Reynolds J., Rezgui Y. (2018). Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees. Journal of Cleaner Production 203, 810-821. <https://doi.org/10.1016/j.jclepro.2018.08.207>
59. Geurts P., Ernst D., Wehenkel L. (2006). Extremely randomized trees. Machine Learning 63, 3-42. <https://doi.org/10.1007/s10994-006-6226-1>
60. Wang W., Lu Y. (2018). Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. IOP Conference Series: Materials Science and Engineering 324, 012049. <https://doi.org/10.1088/1757-899X/324/1/012049>
61. Das K., Jiang J., Rao J. N. K. (2004). Mean squared error of empirical predictor. The Annals of Statistics 32. <https://doi.org/10.1214/009053604000000201>
62. Caruana R., Niculescu-Mizil A., Crew G., Ksikes A. (2004). Ensemble selection from libraries of models. Twenty-first international conference on Machine learning - ICML '04, 18. <https://doi.org/10.1145/1015330.1015432>
63. Esna Ashari Z., Dasgupta N., Brayton K. A., Broschat S. L. (2018). An optimal set of features for predicting type IV secretion system effector proteins for a subset of species based on a multi-level feature selection approach. PLOS ONE 13, e0197041. <https://doi.org/10.1371/journal.pone.0197041>

64. Nelder J. A., Wedderburn R. W. M. (1972). Generalized Linear Models. *Journal of the Royal Statistical Society. Series A (General)* 135, 370. <https://doi.org/10.2307/2344614>
65. Weiss R. E., Lazaro C. G. (1992). Residual plots for repeated measures. *Statistics in Medicine* 11, 115-124. <https://doi.org/10.1002/sim.4780110110>
66. Breiman L. (2001). Random Forests. *Machine Learning* 45, 5-32. <https://doi.org/10.1023/a:1010933404324>
67. Friedman J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics* 29. <https://doi.org/10.1214/aos/1013203451>
68. Singh P. K., Susan S. (2025). EfficientNetB0-CatBoost: Deep Learning With Categorical Boosting for Food Image Recognition. *Cureus Journal of Computer Science*. <https://doi.org/10.7759/s44389-025-03791-2>
69. Hajihosseini M., Maghsoudi A., Ghezelbash R. (2023). A Novel Scheme for Mapping of MVT-Type Pb-Zn Prospectivity: LightGBM, a Highly Efficient Gradient Boosting Decision Tree Machine Learning Algorithm. *Natural Resources Research* 32, 2417-2438. <https://doi.org/10.1007/s11053-023-10249-6>
70. EBA Statistical Report 2022. European Biogas Association. 2022.
71. Olakanmi O. O., Nnoli K. P., Odeyemi K. O., Benyeogor M. S. (2021). Enhanced Secure Process Control and Data Routing for Multi-plant Biogas Production System in IoT Environment: A Practical Approach to Securing Smart Bio-energy Infrastructure. 2021 International Symposium on Networks, Computers and Communications (ISNCC), 1-5. <https://doi.org/10.1109/isncc52172.2021.9615644>
72. Abdurrahman A. H., Kirom M. R., Suhendi A. (2020). Biogas Production Volume Measurement and Internet of Things based Monitoring System. 2020 IEEE International Conference on Communication, Networks and Satellite (Comnetsat), 213-217. <https://doi.org/10.1109/comnetsat50391.2020.9328948>
73. Polishchuk V., Shvoro S., Flonts I., Davidenko T., Dvornyk Y. (2021). Increasing the Yield of Biogas and Electricity during Manure Fermentation Cattle by Optimally Adding Lime to Extruded Straw. *Problems of the Regional Energetics*. <https://doi.org/10.52254/1857-0070.2021.1-49.02>

74. Zhou M., Zou Z. (2018). Design of an Intelligent Control System for Rural Biogas Engineering. 2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 1636-1639. <https://doi.org/10.1109/imcec.2018.8469547>
75. Silwadi M., Mousa H., AL-Hajji B. Y., AL-Wahaibi S. S., AL-Harrasi Z. Z. (2022). Enhancing biogas production by anaerobic digestion of animal manure. International Journal of Green Energy 20, 257-264. <https://doi.org/10.1080/15435075.2022.2038608>
76. Jayaprakash S., Ranaweera S., Orsini F., Gikas P., Navaratna D., Cabral J. (2021). Assessment of the applicability of a low-cost sensor-based methane monitoring system for continuous multi-channel sampling. Environmental Monitoring and Assessment 193, 509. <https://doi.org/10.1007/s10661-021-09290-w>
77. Al-Fuqaha A., Guizani M., Mohammadi M., Aledhari M., Ayyash M. (2015). Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications. IEEE Communications Surveys & Tutorials 17, 2347-2376. <https://doi.org/10.1109/comst.2015.2444095>
78. Dang T., Nguyen T. T., Francisco Moreno-Garcia C., Elyan E., McCall J. (2021). Weighted Ensemble of Deep Learning Models based on Comprehensive Learning Particle Swarm Optimization for Medical Image Segmentation. 2021 IEEE Congress on Evolutionary Computation (CEC), 744-751. <https://doi.org/10.1109/cec45853.2021.9504929>
79. Zhuang W., Fang G., Yuan L. (2009). Binary Tree for 1-Wire Technology in the ROM Search. 2009 International Forum on Information Technology and Applications, 545-547. <https://doi.org/10.1109/ifita.2009.215>
80. Yassein M. B., Shatnawi M. Q., Aljwarneh S., Al-Hatmi R. (2017). Internet of Things: Survey and open issues of MQTT protocol. 2017 International Conference on Engineering & MIS (ICEMIS), 1-6. <https://doi.org/10.1109/icemis.2017.8273112>
81. Grgić, K., Špeh I., Heđi I. (2016). A web-based IoT solution for monitoring data using MQTT protocol. 2016 International Conference on Smart Systems and Technologies (SST), 249-253. <https://doi.org/10.1109/sst.2016.7765668>

82. Kianijaya M. R., Hasanuddin M. O. (2022). Implementation of Data Storage for the Monitoring System for Biogas Production Optimization. 2022 8th International Conference on Wireless and Telematics (ICWT), 1-5. <https://doi.org/10.1109/icwt55831.2022.9935447>
83. Ferreira V. O., Silva Junior D., Melo K. R. B. D., Blais B., Lopes G. C. (2023). Prediction of the bed expansion of a liquid fluidized bed bioreactor applied to wastewater treatment and biogas production. *Energy Conversion and Management* 290, 117224. <https://doi.org/10.1016/j.enconman.2023.117224>
84. Gioulounta K., Matska M., Piskilopoulos A., Stamatelatu K. (2023). Greenhouse Residues' Potential for Biogas Production. *Applied Sciences* 13, 5445. <https://doi.org/10.3390/app13095445>
85. Siyal A. A., Shamsuddin R., Komiyama M., Manogaran M. D., Soehartanto T. (2023). Control Strategies for Enhanced Biogas Production from Chicken Manure. *ChemBioEng Reviews* 10, 423-440. <https://doi.org/10.1002/cben.202200057>
86. Zemite L., Kleperis J., Mezulis A., Bode I., Vempere L., Jasevics A., Jansons L. (2022). Biogas Production Support Systems for the Production and Use of Biomethane. 2022 IEEE International Conference on Environment and Electrical Engineering and 2022 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 1-6. <https://doi.org/10.1109/eeeic/icpseurope54979.2022.9854739>
87. Komarchuk D. S., Opryshko O. A., Shvorov S. A., Reshetiuk V., Pasichnyk N. A., Lendiel T. (2021). Forecasting the State of Charging Batteries on Board the UAV on the Basis of Neuro-Fuzzy Network Using. 2021 IEEE 6th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD), 188-194. <https://doi.org/10.1109/apuavd53804.2021.9615413>
88. Бойко В. С., Сотник М. І. (2019). Current loading of electrical model of electrical mechanical system of water supply network. *Bulletin of NTU "Kharkiv Polytechnic Institute" Series: Electrical Machines and Electromechanical Energy Conversion* 0, 28-34. <https://doi.org/10.20998/2409-9295.2019.20.04>
89. EBA Statistical Report 2024. European Biogas Association. 2024.

90. Pandey A., Momeni O., Pandey P. (2024). Design and Implementation of IoT-Enabled Device for Real-Time Monitoring of Greenhouse Gas Emissions, and Pressure in Anaerobic Reactors. IEEE Access 12, 133848-133862. <https://doi.org/10.1109/access.2024.3449217>
91. Galon M. L. Q., Tumaliwan M. V. R., Sejera M. M. (2025). Automated Monitoring and Control System of Solar Greenhouse Using ESP32 and Blynk Application. 2024 IEEE 6th Eurasia Conference on IoT, Communication and Engineering, 57. <https://doi.org/10.3390/engproc2025092057>
92. AWS API Gateway. URL: <https://aws.amazon.com/api-gateway/> (дата звернення: 11.05.2025).
93. Bhaskaran H. S. et al. Development of cloud-based IoT system for livestock monitoring using AWS. Smart Agricultural Technology. 2024. Vol. 9. P. 100524.
94. Panou M., Kavakiotis I., Mitsopoulos A., Tsioni V., Sfetsas T. (2025). Microbiome-oriented data mining of operational monitoring of anaerobic digestion reactor during steady operation period, failure, and restoration. <https://doi.org/10.1101/2025.02.07.637110>
95. McCormick M., Villa A. E. P. (2019). LSTM and 1-D Convolutional Neural Networks for Predictive Monitoring of the Anaerobic Digestion Process. Lecture Notes in Computer Science, 725-736. https://doi.org/10.1007/978-3-030-30493-5_65
96. Weiss K., Khoshgoftaar T. M., Wang D. (2016). A survey of transfer learning. Journal of Big Data 3. <https://doi.org/10.1186/s40537-016-0043-6>
97. Babich Y., Hlazunova L., Kalinina T., Petrovych Y. (2024). R2 METRIC DYNAMICS FOR K-NEAREST NEIGHBORS REGRESSION MODEL TRAINED ON SERIES OF DIFFERENT SIZES. Information and communication technologies, electronic engineering 4, 10-18. <https://doi.org/10.23939/ictee2024.02.010>
98. Groth K., Hecht E., Reynolds J. (2015). Methodology for assessing the safety of Hydrogen Systems: HyRAM 1.0 technical reference manual. <https://doi.org/10.2172/1814840>
99. Amazon Web Services. AWS IoT Core Developer Guide. 2024. URL: <https://docs.aws.amazon.com/iot/> (дата звернення: 11.06.2025).

100. Amazon Web Services. AWS Fargate User Guide. 2024. URL: <https://docs.aws.amazon.com/AmazonECS/latest/userguide/what-is-fargate.html> (дата звернення: 16.10.2025).
101. Amazon Web Services. Amazon S3 User Guide. 2024. URL: <https://docs.aws.amazon.com/AmazonS3/latest/userguide/> (дата звернення: 16.12.2025).
102. Amazon Web Services. Amazon DynamoDB Developer Guide. 2024. URL: <https://docs.aws.amazon.com/amazondynamodb/latest/developerguide/> (дата звернення: 20.05.2025).
103. Dudnyk A., Lysenko V., Zaets N., Komarchuk D., Lendiel T., Yakymenko I. (2018). Intelligent Control System of Biotechnological Objects with Fuzzy Controller and Noise Filtration Unit. 2018 International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T). <https://doi.org/10.1109/infocommst.2018.8632007>
104. Dudnyk A., Hachkovska M., Zaiets N., Lendiel T., Yakymenko I. (2019). Managing a greenhouse complex using the synergetic approach and neural networks. Eastern-European Journal of Enterprise Technologies 4, 72-78. <https://doi.org/10.15587/1729-4061.2019.176157>
105. Kiktev N., Lendiel T., Vasilenkov V., Kapraliuk O., Hutsol T., Glowacki S., Kuboń, M., Kowalczyk Z. (2021). Automated Microclimate Regulation in Agricultural Facilities Using the Air Curtain System. Sensors 21, 8182. <https://doi.org/10.3390/s21248182>
106. Nykyforova L., Kiktev N., Lendiel T., Pavlov S., Mazurchuk P. (2023). Computer-integrated control system for electrophysical methods of increasing plant productivity. Naukovij žurnal «Tehnika ta energetika» 14, 34-45. <https://doi.org/10.31548/machinery/2.2023.34>
107. Yakymenko I. Y., Lysenko V. P., Witaszek K. (2021). Methodology of development of intellectual energy efficient system of control of temperature-humidity regime in industrial heat. Naukovij žurnal «Tehnika ta energetika» 13. [https://doi.org/10.31548/machenergy.13\(1\).2022.18-25](https://doi.org/10.31548/machenergy.13(1).2022.18-25)

108. Miroshnyk V., Lendiel T., Shvorov S., Davidenko T. (2019). Simulation of pig manufacture methanogenesis in a biogas plant using simulink Matlab. Energy and automation, 70-79. <https://doi.org/10.31548/energiya2019.04.070>
109. Garkin I. N., Voynash S. A., Saaya S.-S. Sh., Garkina V. A. (2025). Optimization of repair management in large agro-industrial complexes based on the Harrington desirability function method. Truck. <https://doi.org/10.36652/1684-1298-2025-12-15-19>
110. Derringer G., Suich R. (1980). Simultaneous Optimization of Several Response Variables. Journal of Quality Technology 12, 214-219. <https://doi.org/10.1080/00224065.1980.11980968>
111. Costa N. R., Lourenço J., Pereira Z. L. (2011). Desirability function approach: A review and performance evaluation in adverse conditions. Chemometrics and Intelligent Laboratory Systems 107, 234-244. <https://doi.org/10.1016/j.chemolab.2011.04.004>
112. Jeong I. J., Kim K. J. (2009). An interactive desirability function method to multiresponse optimization. European Journal of Operational Research 195, 412-426. <https://doi.org/10.1016/j.ejor.2008.02.018>
113. Wu F. C. (2009). Robust design of nonlinear multiple dynamic quality characteristics. Computers & Industrial Engineering 56, 1328-1332. <https://doi.org/10.1016/j.cie.2008.08.001>
114. Kuhn M. The desirability Package. R CRAN. 2016.
115. Kim K. J., Lin D. K. J. (2000). Simultaneous Optimization of Mechanical Properties of Steel by Maximizing Exponential Desirability Functions. Journal of the Royal Statistical Society Series C: Applied Statistics 49, 311-325. <https://doi.org/10.1111/1467-9876.00194>
116. Del Castillo E., Montgomery D. C., McCarville D. R. (1996). Modified Desirability Functions for Multiple Response Optimization. Journal of Quality Technology 28, 337-345. <https://doi.org/10.1080/00224065.1996.11979684>

117. Wu F. C. (2004). Optimization of Correlated Multiple Quality Characteristics Using Desirability Function. *Quality Engineering* 17, 119-126. <https://doi.org/10.1081/qen-200028725>
118. Lundberg S. M., Erion G., Chen H., DeGrave A., Prutkin J. M., Nair B., Katz R., Himmelfarb J., Bansal N., Lee S. I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence* 2, 56-67. <https://doi.org/10.1038/s42256-019-0138-9>
119. Casalicchio G., Molnar C., Schratz P. (2018). iml: Interpretable Machine Learning. CRAN: Contributed Packages. <https://doi.org/10.32614/cran.package.iml>
120. Linardatos P., Papastefanopoulos V., Kotsiantis S. (2020). Explainable AI: A Review of Machine Learning Interpretability Methods. *Entropy* 23, 18. <https://doi.org/10.3390/e23010018>
121. Ali S., Abuhmed T., El-Sappagh S., Muhammad K., Alonso-Moral J. M., Confalonieri R., Guidotti R., Del Ser J., Díaz-Rodríguez N., Herrera F. (2023). Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence. *Information Fusion* 99, 101805. <https://doi.org/10.1016/j.inffus.2023.101805>
122. Hassija V., Chamola V., Mahapatra A., Singal A., Goel D., Huang K., Scardapane S., Spinelli I., Mahmud M., Hussain A. (2023). Interpreting Black-Box Models: A Review on Explainable Artificial Intelligence. *Cognitive Computation* 16, 45-74. <https://doi.org/10.1007/s12559-023-10179-8>
123. Ribeiro M. T., Singh S., Guestrin C. (2016). "Why Should I Trust You?". *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135-1144. <https://doi.org/10.1145/2939672.2939778>
124. Akkem Y., Biswas S. K., Varanasi A. (2025). Role of Explainable AI in Crop Recommendation Technique of Smart Farming. *International Journal of Intelligent Systems and Applications* 17, 31-52. <https://doi.org/10.5815/ijisa.2025.01.03>
125. Cartolano A., Cuzzocrea A., Pilato G. (2024). Analyzing and assessing explainable AI models for smart agriculture environments. *Multimedia Tools and Applications* 83, 37225-37246. <https://doi.org/10.1007/s11042-023-17978-z>

126. Rudin C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence* 1, 206-215. <https://doi.org/10.1038/s42256-019-0048-x>
127. Barredo Arrieta A., Díaz-Rodríguez N., Del Ser J., Bennetot A., Tabik S., Barbado A., Garcia S., Gil-Lopez S., Molina D., Benjamins R., Chatila R., Herrera F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion* 58, 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
128. Saeed W., Omlin C. (2023). Explainable AI (XAI): A systematic meta-survey of current challenges and future opportunities. *Knowledge-Based Systems* 263, 110273. <https://doi.org/10.1016/j.knosys.2023.110273>
129. Otsu N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics* 9, 62-66. <https://doi.org/10.1109/tsmc.1979.4310076>
130. Pizer S. M., Amburn E. P., Austin J. D., Cromartie R., Geselowitz A., Greer T., ter Haar Romeny B., Zimmerman J. B., Zuiderveld K. (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing* 39, 355-368. [https://doi.org/10.1016/s0734-189x\(87\)80186-x](https://doi.org/10.1016/s0734-189x(87)80186-x)
131. Zuiderveld K. (1994). Contrast Limited Adaptive Histogram Equalization. *Graphics Gems*, 474-485. <https://doi.org/10.1016/b978-0-12-336156-1.50061-6>
132. Zelinsky A. (2009). Learning OpenCV - Computer Vision with the OpenCV Library (Bradski G.R. et al.; 2008). *IEEE Robotics & Automation Magazine* 16, 100. <https://doi.org/10.1109/mra.2009.933612>
133. Ronneberger O., Fischer P., Brox T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science*, 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
134. Yin H., Mao K., Zhao J., Chang H., E D., Tan Z. (2019). Heated Metal Mark Attribute Recognition Based on Compressed CNNs Model. *Applied Sciences* 9, 1955. <https://doi.org/10.3390/app9091955>

135. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 4510-4520. <https://doi.org/10.1109/cvpr.2018.00474>
136. Redmon J., Divvala S., Girshick R., Farhadi A. (2016). You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779-788. <https://doi.org/10.1109/cvpr.2016.91>
137. Lin T. Y., Dollar P., Girshick R., He K., Hariharan B., Belongie S. (2017). Feature Pyramid Networks for Object Detection. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 936-944. <https://doi.org/10.1109/cvpr.2017.106>
138. Beyer A., Alexy L. (2025). An Image Equals 16x16 Words: Scaling Image Recognition with Transformers. <https://doi.org/10.2139/ssrn.5180447>
139. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. (2021). Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. 2021 IEEE/CVF International Conference on Computer Vision (ICCV), 9992-10002. <https://doi.org/10.1109/iccv48922.2021.00986>
140. Huang G., Liu Z., Van Der Maaten L., Weinberger K. Q. (2017). Densely Connected Convolutional Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2261-2269. <https://doi.org/10.1109/cvpr.2017.243>
141. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. (2015). Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1-9. <https://doi.org/10.1109/cvpr.2015.7298594>
142. Krizhevsky A., Sutskever I., Hinton G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM* 60, 84-90. <https://doi.org/10.1145/3065386>
143. Carpentier P., Chancelier J. P., Cohen G., De Lara M. (2015). Open-Loop Control: The Stochastic Gradient Method. *Probability Theory and Stochastic Modelling*, 27-62. https://doi.org/10.1007/978-3-319-18138-7_2

144. A Dropout Optimization Algorithm to Prevent Overfitting in Machine Learning. (2023). Machine Learning Theory and Practice 4. <https://doi.org/10.38007/ml.2023.040103>
145. Gupta P., Jain P., Kakde O. G. (2024). Accelerating deep network training for radar identification using batch normalization. Defence Science Journal 74, 878-884. <https://doi.org/10.14429/dsj.74.19475>
146. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser L., Polosukhin I. (2025). Attention Is All You Need. <https://doi.org/10.65215/r5bs2d54>
147. Rumelhart D. E., Hinton G. E., Williams R. J. (1986). Learning representations by back-propagating errors. Nature 323, 533-536. <https://doi.org/10.1038/323533a0>
148. Michelucci U. (2018). Feedforward Neural Networks. Applied Deep Learning, 83-136. https://doi.org/10.1007/978-1-4842-3790-8_3
149. Maki A. (2019). Toward principled regularization of deep networks - From weight decay to feature contraction. Science Robotics 4. <https://doi.org/10.1126/scirobotics.aaw1329>
150. He K., Zhang X., Ren S., Sun J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. 2015 IEEE International Conference on Computer Vision (ICCV), 1026-1034. <https://doi.org/10.1109/iccv.2015.123>
151. Mohamed A. R., Hinton G. (2010). Phone recognition using Restricted Boltzmann Machines. 2010 IEEE International Conference on Acoustics, Speech and Signal Processing. <https://doi.org/10.1109/icassp.2010.5495651>
152. Chollet F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1800-1807. <https://doi.org/10.1109/cvpr.2017.195>
153. Zagoruyko S., Komodakis N. (2016). Wide Residual Networks. Proceedings of the British Machine Vision Conference 2016, 87.1-87.12. <https://doi.org/10.5244/c.30.87>

154. Hu J., Shen L., Sun G. (2018). Squeeze-and-Excitation Networks. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 7132-7141. <https://doi.org/10.1109/cvpr.2018.00745>
155. Liang J., Liu X., Liu H., Phan H., Benetos E., Plumbley M. D., Wang W. (2023). Adapting Language-Audio Models as Few-Shot Audio Learners. INTERSPEECH 2023, 276-280. <https://doi.org/10.21437/interspeech.2023-1082>
156. Nichol J., Peterson M., Peterson K. (2021). Learning Why: Data-Driven Causal Evaluations of Climate Models. Proposed for presentation at the ICML 2021 Workshop Tackling Climate Change with Machine Learning. <https://doi.org/10.2172/1884401>
157. Yan Y., Li Z., Li B., Zhao W., Wang R. (2026). Fusion is the Link: Training-free Zero-shot Video Generation from Text-to-Image Diffusion. <https://doi.org/10.2139/ssrn.6223113>
158. Fette I., Melnikov A. The WebSocket Protocol. RFC 6455. IETF. 2011.
159. Pimentel V., Nickerson B. G. (2012). Communicating and Displaying Real-Time Data with WebSocket. IEEE Internet Computing 16, 45-53. <https://doi.org/10.1109/mic.2012.64>
160. Rescorla E. The Transport Layer Security (TLS) Protocol Version 1.3. RFC 8446. IETF. 2018.
161. Jones M. et al. JSON Web Token (JWT). RFC 7519. IETF. 2015.
162. Bostock M., Ogievetsky V., Heer J. (2011). D3 Data-Driven Documents. IEEE Transactions on Visualization and Computer Graphics 17, 2301-2309. <https://doi.org/10.1109/tvcg.2011.185>
163. Satyanarayan A., Moritz D., Wongsuphasawat K., Heer J. (2017). Vega-Lite: A Grammar of Interactive Graphics. IEEE Transactions on Visualization and Computer Graphics 23, 341-350. <https://doi.org/10.1109/tvcg.2016.2599030>
164. Hunkeler U., Truong H. L., Stanford-Clark A. (2008). MQTT-S - A publish/subscribe protocol for Wireless Sensor Networks. 2008 3rd International Conference on Communication Systems Software and Middleware and Workshops (COMSWARE '08), 791-798. <https://doi.org/10.1109/comswa.2008.4554519>

165. Naik N. (2017). Choice of effective messaging protocols for IoT systems: MQTT, CoAP, AMQP and HTTP. 2017 IEEE International Systems Engineering Symposium (ISSE), 1-7. <https://doi.org/10.1109/syseng.2017.8088251>
166. Dizdarević, J., Carpio F., Jukan A., Masip-Bruin X. (2019). A Survey of Communication Protocols for Internet of Things and Related Challenges of Fog and Cloud Computing Integration. ACM Computing Surveys 51, 1-29. <https://doi.org/10.1145/3292674>
167. Hercog D., Lerher T., Truntič, M., Težak O. (2023). Design and Implementation of ESP32-Based IoT Devices. Sensors 23, 6739. <https://doi.org/10.3390/s23156739>
168. Abu Sneineh A., Shabaneh A. A. (2023). Design of a smart hydroponics monitoring system using an ESP32 microcontroller and the Internet of Things. MethodsX 11, 102401. <https://doi.org/10.1016/j.mex.2023.102401>
169. Andreadis A., Giambene G., Zambon R. (2023). Low-Power IoT for Monitoring Unconnected Remote Areas. Sensors 23, 4481. <https://doi.org/10.3390/s23094481>
170. El-Khozondar H. J., Mtair S. Y., Qoffa K. O., Qasem O. I., Munyarawi A. H., Nassar Y. F., Bayoumi E. H., Halim A. A. E. B. A. E. (2024). A smart energy monitoring system using ESP32 microcontroller. e-Prime - Advances in Electrical Engineering, Electronics and Energy 9, 100666. <https://doi.org/10.1016/j.prime.2024.100666>
171. Fielding R. T. Architectural Styles and the Design of Network-based Software Architectures (REST). PhD Thesis. UC Irvine. 2000.
172. Chodorow K. MongoDB: The Definitive Guide. O'Reilly Media, 2019.
173. Celko J. (2005). Arrays in SQL. Joe Celko's SQL for Smarties, 575-589. <https://doi.org/10.1016/b978-012369379-2/50025-x>
174. Scott S. (2023). Customizing Images. Oracle on Docker, 221-239. https://doi.org/10.1007/978-1-4842-9033-0_11

175. Gupta R., Zhang L., Hou J., Zhang Z., Liu H., You S., Ok Y. S., Li W. (2023). Review of explainable machine learning for anaerobic digestion. *Bioresource Technology* 369, 128468. <https://doi.org/10.1016/j.biortech.2022.128468>
176. Peng S., Guo L., Li Y., Huang H., Peng J., Liu X. (2024). Biogas Production Prediction Based on Feature Selection and Ensemble Learning. *Applied Sciences* 14, 901. <https://doi.org/10.3390/app14020901>
177. Sappl J., Harders M., Rauch W. (2023). Machine learning for quantile regression of biogas production rates in anaerobic digesters. *Science of The Total Environment* 872, 161923. <https://doi.org/10.1016/j.scitotenv.2023.161923>
178. Zou J., Lü, F., Chen L., Zhang H., He P. (2024). Machine learning for enhancing prediction of biogas production and building a VFA/ALK soft sensor in full-scale dry anaerobic digestion of kitchen food waste. *Journal of Environmental Management* 371, 123190. <https://doi.org/10.1016/j.jenvman.2024.123190>
179. Kawajiri K., Tahara K., Uemiya S. (2022). Lifecycle assessment of critical material substitution: Indium tin oxide and aluminum zinc oxide in transparent electrodes. *Resources, Environment and Sustainability* 7, 100047. <https://doi.org/10.1016/j.resenv.2022.100047>
180. Mukasine A., Sibomana L., Jayavel K., Nkurikiyeyezu K., Hitimana E. (2024). Maximizing Biogas Yield Using an Optimized Stacking Ensemble Machine Learning Approach. *Energies* 17, 364. <https://doi.org/10.3390/en17020364>
181. Zhang Y., Li L., Ren Z., Yu Y., Li Y., Pan J., Lu Y., Feng L., Zhang W., Han Y. (2022). Plant-scale biogas production prediction based on multiple hybrid machine learning technique. *Bioresource Technology* 363, 127899. <https://doi.org/10.1016/j.biortech.2022.127899>
182. Ugwu S. N., Enweremadu C. C. (2020). Enhancement of biogas production process from biomass wastes using iron-based additives: types, impacts, and implications. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects* 44, 4458-4480. <https://doi.org/10.1080/15567036.2020.1788675>
183. Budhraj N., Pal A., Mishra R. (2025). Vortex flow plasma reforming for hydrogen production from atomized water-methanol mixture and parameter

- optimization using RSM and ANN-GA. *Renewable Energy* 247, 123026. <https://doi.org/10.1016/j.renene.2025.123026>
184. Gaida D., Wolf C., Meyer C., Stuhlsatz A., Lippel J., Bäck T., Bongards M., McLoone S. (2012). State estimation for anaerobic digesters using the ADM1. *Water Science and Technology* 66, 1088-1095. <https://doi.org/10.2166/wst.2012.286>
185. Batstone D., Keller J., Angelidaki I., Kalyuzhnyi S., Pavlostathis S., Rozzi A., Sanders W., Siegrist H., Vavilin V. (2002). The IWA Anaerobic Digestion Model No 1 (ADM1). *Water Science and Technology* 45, 65-73. <https://doi.org/10.2166/wst.2002.0292>
186. Chen Y., Cheng J. J., Creamer K. S. (2008). Inhibition of anaerobic digestion process: A review. *Bioresource Technology* 99, 4044-4064. <https://doi.org/10.1016/j.biortech.2007.01.057>
187. Weiland P. (2009). Biogas production: current state and perspectives. *Applied Microbiology and Biotechnology* 85, 849-860. <https://doi.org/10.1007/s00253-009-2246-7>
188. Angelidaki I., Alves M., Bolzonella D., Borzacconi L., Campos J. L., Guwy A. J., Kalyuzhnyi S., Jenicek P., van Lier J. B. (2009). Defining the biomethane potential (BMP) of solid organic wastes and energy crops: a proposed protocol for batch assays. *Water Science and Technology* 59, 927-934. <https://doi.org/10.2166/wst.2009.040>
189. Appels L., Baeyens J., Degreè J., Dewil R. (2008). Principles and potential of the anaerobic digestion of waste-activated sludge. *Progress in Energy and Combustion Science* 34, 755-781. <https://doi.org/10.1016/j.pecs.2008.06.002>
190. Mata-Alvarez J., Macé, S., Llabrés P. (2000). Anaerobic digestion of organic solid wastes. An overview of research achievements and perspectives. *Bioresource Technology* 74, 3-16. [https://doi.org/10.1016/s0960-8524\(00\)00023-7](https://doi.org/10.1016/s0960-8524(00)00023-7)
191. Ward A. J., Hobbs P. J., Holliman P. J., Jones D. L. (2008). Optimisation of the anaerobic digestion of agricultural resources. *Bioresource Technology* 99, 7928-7940. <https://doi.org/10.1016/j.biortech.2008.02.044>
192. Raposo F., Fernández Cegri, V., De la Rubia M., Borja R., Béline F., Cavinato C., Demirer G., Fernández B., Fernández Polanco M., Frigon J., Ganesh R., Kaparaju

- P., Koubova J., Méndez R., Menin G., Peene A., Scherer P., Torrijos M., Uellendahl H., Wierinck I. (2011). Biochemical methane potential (BMP) of solid organic substrates: evaluation of anaerobic biodegradability using data from an international interlaboratory study. *Journal of Chemical Technology & Biotechnology* 86, 1088-1098. <https://doi.org/10.1002/jctb.2622>
193. Wang S., Wei Z., Wang L. (2024). Improving slaughterhouse byproducts utilization via anaerobic digestion, composting, and rendering. *Renewable and Sustainable Energy Reviews* 189, 113881. <https://doi.org/10.1016/j.rser.2023.113881>
 194. Kayan H., Heartfield R., Rana O., Burnap P., Perera C. (2025). Real-Time Anomaly Detection for Industrial Robotic Arms Using Edge Computing. *IEEE Internet of Things Journal* 12, 29696-29712. <https://doi.org/10.1109/jiot.2025.3569780>
 195. Sanoussi N., Chetoui K., Orhanou G., El Hajji S. (2023). ITC: Intrusion tolerant controller for multicontroller SDN architecture. *Computers & Security* 132, 103351. <https://doi.org/10.1016/j.cose.2023.103351>
 196. Zhang W., Zhan H., Sun H., Yang M. (2025). Probabilistic load forecasting for integrated energy systems based on quantile regression patch time series Transformer. *Energy Reports* 13, 303-317. <https://doi.org/10.1016/j.egyr.2024.11.057>
 197. OPTIMAX Biogas - портативний газоаналізатор. Promsystem. URL: <https://promsystem.com.ua/product/optimax-biogas-portatyvnyj-gazoanalizator/> (дата звернення: 07.05.2025).
 198. SSM 6000 Classic - стаціонарний газоаналізатор біогазу. PRONOVA Analysentechnik GmbH. URL: <https://pronova.de/en/products/biogas-analysis-equipment/biogas-analysers/282/ssm-6000-classic> (дата звернення: 18.04.2025).
 199. AWIFLEX - система аналізу біогазу. AWITE Bioenergie GmbH. URL: <https://www.awite.de/en/products/gas-analysis/awiflex/> (дата звернення: 13.05.2025).
 200. Amazon Web Services. AWS Lambda Developer Guide. URL: <https://docs.aws.amazon.com/lambda/> (дата звернення: 14.09.2025).

201. Оптимізація протоколу MQTT для підвищення продуктивності IoT-систем. <https://doi.org/10.35546/kntu2078-4481.2024.4.38>
202. Techniques for Writing Least Privilege IAM Policies. AWS Security Blog. URL: <https://aws.amazon.com/blogs/security/techniques-for-writing-least-privilege-iam-policies/> (дата звернення: 06.06.2025).
203. AWS Identity and Access Management (IAM). URL: <https://aws.amazon.com/iam/> (дата звернення: 06.01.2026).
204. Amazon SageMaker. URL: <https://aws.amazon.com/sagemaker/> (дата звернення: 14.07.2025).
205. Павлов С. Г., Лисенко В. П., Лендел Т. І., Наконечна К. В. Інтелектуальна система автоматизованого моніторингу якості біоматеріалу для зброджування в біогазовій установці. Вісник НТУУ "КПІ імені Ігоря Сікорського". Серія: Хімічна інженерія, екологія та ресурсозбереження. 2025. № 3. С. 41-51. <https://doi.org/10.20535/2617-9741.3.2025.340376>
206. Lysenko V., Lendyel T., Pavlov S. Analysis of machine learning algorithms for biogas yield prediction. Energy and Automation. 2023. No. 3. P. 100-111. [https://doi.org/10.31548/energiya3\(67\).2023.100](https://doi.org/10.31548/energiya3(67).2023.100)
207. П'ятикоп О. Є., Проніна О. І., Мороз М. С. Інтеграція машинного навчання у вебплатформи для автоматизації прогностичних розрахунків. Науковий журнал «Комп'ютерно-інтегровані технології: освіта, наука, виробництво». Луцьк, 2025. Вип. 61. <https://doi.org/10.36910/6775-2524-0560-2025-61-25>
208. Ortega J. M., Chamorro M. V., Echeverría A. A. H., Rodado K. J. V., Morris F. R., Gutiérrez R. S., Quintero M. C. (2025). Instrumentation, control and monitoring of a reactor for the production of biogas from agro-industrial waste using internet of things. EUREKA: Physics and Engineering, (2), 40-53. <https://doi.org/10.21303/2461-4262.2025.003593>
209. Holland J. H. Adaptation in Natural and Artificial Systems. Ann Arbor: University of Michigan Press, 1992.
210. Goldberg D. E. Genetic Algorithms in Search, Optimization, and Machine Learning. Boston: Addison-Wesley, 1989. 412 p.

211. Mitchell M. An Introduction to Genetic Algorithms. Cambridge, MA: MIT Press, 1998. 215 p.
212. Cover T. M., Hart P. E. Nearest neighbor pattern classification. IEEE Transactions on Information Theory. 1967. Vol. 13, No. 1. P. 21–27.
<https://doi.org/10.1109/TIT.1967.1053964>
213. Altman N. S. An introduction to kernel and nearest-neighbor nonparametric regression. The American Statistician. 1992. Vol. 46, No. 3. P. 175–185.
<https://doi.org/10.1080/00031305.1992.10475879>
214. Stone M. Cross-validatory choice and assessment of statistical predictions. Journal of the Royal Statistical Society. Series B. 1974. Vol. 36, No. 2. P. 111–147.
<https://doi.org/10.1111/j.2517-6161.1974.tb00994.x>
215. Lachenbruch P. A., Mickey M. R. Estimation of error rates in discriminant analysis. Technometrics. 1968. Vol. 10, No. 1. P. 1–11.
<https://doi.org/10.1080/00401706.1968.10490530>

Додатки

Додаток А

Вихідний код функціоналу модулю збору параметрів з давачів

```
#include <OneWire.h>
#include <DallasTemperature.h>
#include <ESP8266WiFi.h>
#include <WiFiClientSecure.h>
#include <PubSubClient.h>
#include <ArduinoJson.h>
#include <time.h>
#include "secrets.h"
#include "DHT.h"

#define TIME_ZONE +2

String Date_str, Time_str, Time_format;

#define ONE_WIRE_BUS_DS18B20 D1
#define DHTPIN D2
#define DHTTYPE DHT22
#define HUMIDITY_PIN D8
#define TEMPERATURE_PRECISION 9

#define AWS_IOT_PUBLISH_TOPIC "esp8266/pub"
#define AWS_IOT_SUBSCRIBE_TOPIC "esp8266/sub"

DHT dht(DHTPIN, DHTTYPE);
OneWire ds(ONE_WIRE_BUS_DS18B20);
DallasTemperature ds18b20(&ds);
DeviceAddress first_temp, second_temp, third_temp;
```

```

WiFiClientSecure net;
BearSSL::X509List cert(cacert);
BearSSL::X509List client_cert(client_cert);
BearSSL::PrivateKey key(privkey);
PubSubClient client(net);

float h;
float t;
unsigned long lastMillis = 0;
unsigned long previousMillis = 0;
const long interval = 5000;

time_t now;
time_t nowish = 1510592825;

void NTPConnect(void) {
  Serial.print("Setting time using SNTP");
  configTime(TIME_ZONE * 3600, 0 * 3600, "pool.ntp.org", "time.nist.gov");
  const char* Timezone = "EET-2EEST,M3.5.0/3,M10.5.0/4";
  configTime(0, 0, "pool.ntp.org", "time.nist.gov");
  setenv("TZ", Timezone, 1);

  now = time(nullptr);
  while (now < nowish) {
    delay(500);
    Serial.print(".");
    now = time(nullptr);
  }
}

```

```
Serial.println("done!");
```

```
struct tm timeinfo;  
gmtime_r(&now, &timeinfo);  
Serial.print("Current time: ");  
Serial.print(asctime(&timeinfo));  
}
```

```
void messageReceived(char *topic, byte *payload, unsigned int length) {  
    Serial.print("Received [");  
    Serial.print(topic);  
    Serial.print("]: ");  
    for (int i = 0; i < length; i++) {  
        Serial.print((char)payload[i]);  
    }  
    Serial.println();  
}
```

```
void connectAWS() {  
    delay(3000);  
    WiFi.mode(WIFI_STA);  
    WiFi.begin(WIFI_SSID, WIFI_PASSWORD);  
  
    Serial.println(String("Attempting to connect to SSID: ") + String(WIFI_SSID));  
  
    while (WiFi.status() != WL_CONNECTED) {  
        Serial.print(".");  
        delay(1000);  
    }
```

```

}
Serial.println("WiFi connected");
Serial.println("IP address: " + WiFi.localIP().toString());

NTPConnect();

net.setTrustAnchors(&cert);
net.setClientRSACert(&client_crt, &key);

client.setServer(MQTT_HOST, 8883);
client.setCallback(messageReceived);

Serial.println(MQTT_HOST);
Serial.println("Connecting to AWS IOT");

while (!client.connect(THINGNAME)) {
    Serial.print(".");
    delay(1000);
}

if (!client.connected()) {
    Serial.println("AWS IoT Timeout!");
    return;
}

client.subscribe(AWS_IOT_SUBSCRIBE_TOPIC);
Serial.println("AWS IoT Connected!");
}

```

```
void publishMessage() {
```

```
    connectAWS();
```

```
    StaticJsonDocument<200> doc;
```

```
    doc["time"] = millis();
```

```
    if (getHumidity() == NULL || getTemperatureDHT22() == NULL ||
```

```
        isnan(getTemperatureDHT22()) || isnan(getHumidity())) {
```

```
        Serial.println("Out1");
```

```
        return;
```

```
    }
```

```
    doc["humidity"] = getHumidity();
```

```
    doc["temperature"] = getTemperatureDHT22();
```

```
    doc["temperature_1"] = ds18b20.getTempC(first_temp);
```

```
    doc["temperature_2"] = ds18b20.getTempC(third_temp);
```

```
    doc["temperature_3"] = ds18b20.getTempC(second_temp);
```

```
    if (doc["temperature_1"] == -127 || doc["temperature_2"] == -127 ||  
doc["temperature_3"] == -127) {
```

```
        Serial.println("Out2");
```

```
        digitalWrite(D0, HIGH);
```

```
        digitalWrite(D0, LOW);
```

```
        ESP.restart();
```

```
        return;
```

```
    }
```

```
    char jsonBuffer[512];
```

```
    serializeJson(doc, jsonBuffer);
```

```
    client.publish(AWS_IOT_PUBLISH_TOPIC, jsonBuffer);
```

```

Serial.println("Package sended");
Serial.println("Shutdown");

digitalWrite(D4, HIGH);
digitalWrite(D6, HIGH);
digitalWrite(D7, HIGH);
digitalWrite(D5, LOW);

Serial.println("Switch off");
delay(3600000);
}

void printAddress(DeviceAddress deviceAddress) {
  for (uint8_t i = 0; i < 8; i++) {
    if (deviceAddress[i] < 16) Serial.print("0");
    Serial.print(deviceAddress[i], HEX);
  }
}

void getDs18b20() {
  Serial.println("Start");
  Serial.println("Locating devices...");
  Serial.print("Found ");
  Serial.print(ds18b20.getDeviceCount(), DEC);
  Serial.println(" devices.");

  Serial.print("Parasite power is: ");

```

```
if (ds18b20.isParasitePowerMode()) Serial.println("ON");  
else Serial.println("OFF");
```

```
if (!ds18b20.getAddress(second_temp, 0)) Serial.println("Unable to find address for  
Device 1");
```

```
if (!ds18b20.getAddress(third_temp, 1)) Serial.println("Unable to find address for  
Device 2");
```

```
if (!ds18b20.getAddress(first_temp, 2)) Serial.println("Unable to find address for  
Device 3");
```

```
Serial.print("Device 0 Address: ");  
printAddress(second_temp);  
Serial.println();
```

```
Serial.print("Device 1 Address: ");  
printAddress(third_temp);  
Serial.println();
```

```
Serial.print("Device 2 Address: ");  
printAddress(first_temp);  
Serial.println();
```

```
ds18b20.setResolution(third_temp, TEMPERATURE_PRECISION);  
ds18b20.setResolution(second_temp, TEMPERATURE_PRECISION);  
ds18b20.setResolution(first_temp, TEMPERATURE_PRECISION);
```

```
Serial.print("Device 1 Resolution: ");  
Serial.print(ds18b20.getResolution(second_temp), DEC);  
Serial.println();
```

```
Serial.print("Device 2 Resolution: ");  
Serial.print(ds18b20.getResolution(third_temp), DEC);  
Serial.println();
```

```
Serial.print("Device 3 Resolution: ");  
Serial.print(ds18b20.getResolution(first_temp), DEC);  
Serial.println();  
}
```

```
void setup() {  
  pinMode(D5, OUTPUT);  
  pinMode(D6, OUTPUT);  
  pinMode(D4, OUTPUT);  
  pinMode(D7, OUTPUT);  
  pinMode(D0, OUTPUT);
```

```
  digitalWrite(D5, HIGH);  
  digitalWrite(D7, HIGH);  
  digitalWrite(D4, HIGH);
```

```
  Serial.begin(115200);  
  dht.begin();  
  ds18b20.begin();  
  getDs18b20();  
}
```

```
void loop() {  
  Serial.println("Start");
```

```
digitalWrite(D5, HIGH);  
Serial.println("Switched on");  
delay(30000);
```

```
float tempDS18B20 = getTemperatureDS18B20();  
float tempDHT22 = getTemperatureDHT22();  
float humidity = getHumidity();  
float soil = digitalRead(D7);
```

```
Serial.print("Temperature DHT22: ");  
Serial.print(tempDHT22);  
Serial.println(" °C");
```

```
if (!isnan(tempDHT22)) {  
    digitalWrite(D4, HIGH);  
    delay(3000);  
    digitalWrite(D4, LOW);  
}
```

```
Serial.print("Humidity: ");  
Serial.print(humidity);  
Serial.println(" %");
```

```
Serial.print("Soil: ");  
Serial.print(soil);
```

```
if (!isnan(soil)) {  
    digitalWrite(D7, HIGH);  
    delay(3000);  
    digitalWrite(D7, LOW);
```

```
}
```

```
printTemperature(first_temp);
printTemperature(third_temp);
printTemperature(second_temp);
```

```
now = time(nullptr);
publishMessage();
}
```

```
void printTemperature(DeviceAddress deviceAddress) {
    float tempC = ds18b20.getTempC(deviceAddress);
    Serial.print("Temp C: ");
    Serial.print(tempC);
    printAddress(deviceAddress);
    Serial.println("");
}
```

```
void printResolution(DeviceAddress deviceAddress) {
    Serial.print("Resolution: ");
    Serial.print(ds18b20.getResolution(deviceAddress));
    Serial.println();
}
```

```
void printData(DeviceAddress deviceAddress) {
    Serial.print("Device Address: ");
    printAddress(deviceAddress);
```

```
Serial.print(" ");  
printTemperature(deviceAddress);  
Serial.println();  
}
```

```
float getTemperatureDS18B20() {  
    ds18b20.requestTemperatures();  
    return ds18b20.getTempCByIndex(0);  
}
```

```
float getTemperatureDHT22() {  
    return dht.readTemperature();  
}
```

```
float getHumidity() {  
    return dht.readHumidity();  
}
```

Додаток Б

Вихідний код функціоналу роботи фотомодулю

```
#include "esp_camera.h"
#include "SPI.h"
#include "driver/rtc_io.h"
#include <FS.h>
#include "base64.hpp"
#include <WiFi.h>
#include "HTTPClient.h"
#include <LittleFS.h>
#include "base64.hpp"
#include <NTPClient.h>
#include <WiFiUdp.h>
```

```
const char* ssid = "";
const char* password = "";
```

```
WiFiUDP ntpUDP;
NTPClient timeClient(ntpUDP, "europe.pool.ntp.org", 3600, 60000);
```

```
#define CAMERA_MODEL_AI_THINKER
```

```
#if defined(CAMERA_MODEL_AI_THINKER)
#define PWDN_GPIO_NUM -1
#define RESET_GPIO_NUM 5
#define XCLK_GPIO_NUM 15
#define SIOD_GPIO_NUM 22
#define SIOC_GPIO_NUM 23
#define Y9_GPIO_NUM 39
#define Y8_GPIO_NUM 34
```

```

#define Y7_GPIO_NUM    33
#define Y6_GPIO_NUM    27
#define Y5_GPIO_NUM    12
#define Y4_GPIO_NUM    35
#define Y3_GPIO_NUM    14
#define Y2_GPIO_NUM     2
#define VSYNC_GPIO_NUM 18
#define HREF_GPIO_NUM   36
#define PCLK_GPIO_NUM   26
#define LED_GPIO_NUM    25

#else
#error "Camera model not selected"
#endif

#define FILE_PHOTO "photo.jpg"
#define FILE_PHOTO_PATH "/photo.jpg"
#define FORMAT_LITTLEFS_IF_FAILED true

int hopes = 0;

void setup() {
    Serial.println("mail_sent");

#ifdef TWOPART
    if (!LittleFS.begin(FORMAT_LITTLEFS_IF_FAILED, "/fs2", 5, "part2")) {
        Serial.println("part2 Mount Failed");
        return;
    }
    LittleFS.end();

```

```

    Serial.println("Done with part2, work with the first lfs partition...");
#endif

    if (!LittleFS.begin(FORMAT_LITTLEFS_IF_FAILED)) {
        Serial.println("LittleFS Mount Failed");
        return;
    }
    Serial.println("SPIFFS-like write file to new path and delete it w/folders");

    deleteFile2(LittleFS, "/photo.jpg");
    listDir(LittleFS, "/", 3);

    Serial.println("Test complete");

    Serial.begin(115200);
    Serial.println();

    WiFi.begin(ssid, password);
    Serial.print("Connecting to WiFi...");
    while (WiFi.status() != WL_CONNECTED) {
        delay(500);
        Serial.print(".");
    }
    Serial.println();

    Serial.print("IP Address: http://");
    Serial.println(WiFi.localIP());

    camera_config_t config;
    config.ledc_channel = LEDC_CHANNEL_0;

```

```
config.ledc_timer = LEDC_TIMER_0;
config.pin_d0 = Y2_GPIO_NUM;
config.pin_d1 = Y3_GPIO_NUM;
config.pin_d2 = Y4_GPIO_NUM;
config.pin_d3 = Y5_GPIO_NUM;
config.pin_d4 = Y6_GPIO_NUM;
config.pin_d5 = Y7_GPIO_NUM;
config.pin_d6 = Y8_GPIO_NUM;
config.pin_d7 = Y9_GPIO_NUM;
config.pin_xclk = XCLK_GPIO_NUM;
config.pin_pclk = PCLK_GPIO_NUM;
config.pin_vsync = VSYNC_GPIO_NUM;
config.pin_href = HREF_GPIO_NUM;
config.pin_sccb_sda = SIOD_GPIO_NUM;
config.pin_sccb_scl = SIOC_GPIO_NUM;
config.pin_pwdn = PWDN_GPIO_NUM;
config.pin_reset = RESET_GPIO_NUM;
config.xclk_freq_hz = 10000000;
config.pixel_format = PIXFORMAT_JPEG;
config.grab_mode = CAMERA_GRAB_LATEST;
```

```
if (psramFound()) {
    config.frame_size = FRAMESIZE_SVGA;
    config.jpeg_quality = 10;
    config.fb_count = 1;
    Serial.println("psramFound");
} else {
    config.frame_size = FRAMESIZE_SVGA;
    config.jpeg_quality = 10;
    config.fb_count = 1;
```

```

    Serial.println("psramNOTFound");
}

esp_err_t err = esp_camera_init(&config);
if (err != ESP_OK) {
    Serial.printf("Camera init failed with error 0x%x", err);
    return;
}
}

void loop() {
    listDir(LittleFS, "/", 3);
    capturePhotoSaveLittleFS();

    Serial.println("Wait 30 min and go again");
    delay(1800000);
}

bool checkPhoto(fs::FS &fs) {
    File f_pic = fs.open(FILE_PHOTO_PATH);
    unsigned int pic_sz = f_pic.size();
    Serial.println("Checking photo...");

    return (pic_sz > 3000);
    Serial.println("Photo is ok");
}

```

```
void capturePhotoSaveLittleFS(void) {  
    camera_fb_t * fb = NULL;  
    bool ok = 0;  
  
    do {  
        Serial.println("Taking a photo...");  
  
        camera_fb_t * fb = NULL;  
        fb = esp_camera_fb_get();  
        esp_camera_fb_return(fb);  
        fb = NULL;  
  
        delay(1000);  
        fb = esp_camera_fb_get();  
  
        if (!fb) {  
            Serial.println("Camera capture failed");  
            delay(1000);  
            ESP.restart();  
        }  
  
        delay(2000);  
  
        Serial.printf("Picture file name: %s\n", FILE_PHOTO_PATH);  
        File file = LittleFS.open(FILE_PHOTO_PATH, FILE_WRITE);  
  
        if (!file) {  
            Serial.println("Failed to open file in writing mode");  
        } else {  
            file.write(fb->buf, fb->len);  
        }  
    }  
}
```

```

    Serial.print("The picture has been saved in ");
    Serial.print(FILE_PHOTO_PATH);
    Serial.print(" - Size: ");
    Serial.print(fb->len);
    Serial.println(" bytes");
}

file.close();
ok = checkPhoto(LittleFS);
int fsize = (fb->len);

if (fsize < 30000) {
    Serial.println("short photo, wait 5 min and try again");
    delay(300000);
    capturePhotoSaveLittleFS();
    hopes + 1;
    Serial.println(hopes);
} else {
    sendPhoto();
}

esp_camera_fb_return(fb);

} while (!ok);
}

void listDir(fs::FS &fs, const char * dirname, uint8_t levels) {
    Serial.printf("Listing directory: %s\r\n", dirname);

```

```

File root = fs.open(dirname);
if (!root) {
    Serial.println("- failed to open directory");
    return;
}
if (!root.isDirectory()) {
    Serial.println(" - not a directory");
    return;
}

```

```

File file = root.openNextFile();
while (file) {
    if (file.isDirectory()) {
        Serial.print(" DIR : ");
        Serial.println(file.name());
        if (levels) {
            listDir(fs, file.path(), levels - 1);
        }
    } else {
        Serial.print(" FILE: ");
        Serial.print(file.name());
        Serial.print("\tSIZE: ");
        Serial.println(file.size());
    }
    file = root.openNextFile();
}
}

```

```

void writeFile2(fs::FS &fs, const char * path, const char * message) {

```

```

if (!fs.exists(path)) {
    if (strchr(path, '/')) {
        Serial.printf("Create missing folders of: %s\r\n", path);
        char *pathStr = strdup(path);
        if (pathStr) {
            char *ptr = strchr(pathStr, '/');
            while (ptr) {
                *ptr = 0;
                fs.mkdir(pathStr);
                *ptr = '/';
                ptr = strchr(ptr + 1, '/');
            }
        }
        free(pathStr);
    }
}

```

```

Serial.printf("Writing file to: %s\r\n", path);
File file = fs.open(path, FILE_WRITE);
if (!file) {
    Serial.println("- failed to open file for writing");
    return;
}
if (file.print(message)) {
    Serial.println("- file written");
} else {
    Serial.println("- write failed");
}
file.close();
}

```

```

void deleteFile2(fs::FS &fs, const char * path) {
    Serial.printf("Deleting file and empty folders on path: %s\r\n", path);

    if (fs.remove(path)) {
        Serial.println("- file deleted");
    } else {
        Serial.println("- delete failed");
    }

    char *pathStr = strdup(path);
    if (pathStr) {
        char *ptr = strrchr(pathStr, '/');
        if (ptr) {
            Serial.printf("Removing all empty folders on path: %s\r\n", path);
        }
        while (ptr) {
            *ptr = 0;
            fs.rmdir(pathStr);
            ptr = strrchr(pathStr, '/');
        }
        free(pathStr);
    }
}

```

```

void sendPhoto(void) {
    delay(100);
    digitalWrite(LED_GPIO_NUM, 0);
}

```

```
delay(100);
digitalWrite(LED_GPIO_NUM, 1);
```

```
File file = LittleFS.open("/photo.jpg");
Serial.print(" FILE: ");
Serial.print(file.name());
Serial.print("\tSIZE: ");
Serial.println(file.size());
const auto filesize = file.size();
```

```
HTTPClient http;
http.addHeader("Content-Type", "image/jpeg");
http.addHeader("Content-Length", String(filesize, DEC));
```

```
timeClient.update();
```

```
const auto A = timeClient.getEpochTime();
String str = String(A, DEC);
str = "https://75gaklt2va.execute-api.us-east-1.amazonaws.com:443/dev/" + str +
".jpeg";
```

```
http.begin(str);
int http_code;
```

```
Serial.println("We are ready");
http_code = http.sendRequest("PUT", &file, filesize);
Serial.printf("\n time-keep: %lus", (millis() - A) / 1000);
String response = http.getString();
Serial.println("Http_code: " + http_code);
Serial.println("Response: " + response);
```

```
http.end();
```

```
file.close();
```

```
delay(1000);
```

```
digitalWrite(14, HIGH);
```

```
delay(1000);
```

```
digitalWrite(14, LOW);
```

```
}
```

Додаток В

Порівняльний аналіз алгоритмів

	Файл	Оригінальний Оцу	Інвертований Оцу	Оцу з підвищеним контрастом	Адаптивне порогове значення	К-means
0	20240423_110459.jpg	43.244848	56.755152	49.663495	52.335450	42.547156
1	20240423_110510.jpg	47.379036	52.620964	50.024791	55.108044	51.767507
2	20240423_110434.jpg	37.884425	62.115575	40.697546	77.281527	62.115575
3	20240423_110505.jpg	41.714498	58.285502	49.661023	52.597966	58.998121
4	20240423_110507.jpg	45.990815	54.009185	49.714322	52.326472	45.256029
5	20240423_110506.jpg	45.318121	54.681879	49.387681	52.555876	45.318121
6	20240423_110509.jpg	46.104937	53.895063	49.908120	54.185585	45.303948
7	20240423_110508.jpg	44.032495	55.967505	49.399327	53.027346	56.770265
8	20240423_110510(0).jpg	45.800811	54.199189	49.938772	52.106385	54.905892
9	20240423_110511(0).jpg	46.216588	53.783412	49.881635	52.780873	54.535508
10	20240423_110511.jpg	46.660195	53.339805	49.849441	53.493339	52.540249
11	20240423_110511(1).jpg	44.868630	55.131370	49.928307	52.261264	55.131370
12	20240423_111919.jpg	47.555075	52.444925	49.806454	51.540924	52.444925
13	20240423_110453.jpg	46.793903	53.206097	49.995932	55.052405	53.206097
14	20240423_110458.jpg	43.986632	56.013368	49.692025	52.120601	43.303910
15	20240423_110450.jpg	47.815065	52.184935	50.169313	55.123682	47.815065
16	20240423_110451.jpg	46.858258	53.141742	50.151554	54.972620	53.141742
17	20240423_110449.jpg	47.174095	52.825905	49.948822	54.864403	52.151341
18	20240423_110500.jpg	43.468358	56.531642	49.629190	52.336795	56.531642

	Файл	Оригінальний Оцу	Інвертований Оцу	Оцу з підвищеним контрастом	Адаптивне порогове значення	K-means
19	20240423_110457.jpg	43.752701	56.247299	49.847822	52.200386	44.437293
20	20240423_110459(0).jpg	43.742608	56.257392	49.571691	52.254156	55.554418
21	20240423_110501(0).jpg	40.505815	59.494185	49.306321	52.410719	41.179766
22	20240423_110503.jpg	40.428949	59.571051	49.511218	52.690644	39.755293
23	20240423_110501.jpg	43.548383	56.451617	49.690013	52.514332	44.261582
24	20240423_110504(0).jpg	41.369715	58.630285	49.568914	52.839913	57.935874
25	20240423_111922(0).jpg	47.174500	52.825500	49.993001	51.446748	52.825500

Додаток Г

Результати сегментації зображень

