

УДК 004.85:662.63

ПАВЛОВ С. Г.\*, ЛИСЕНКО В. П., ЛЕНДЄЛ Т. І., НАКОНЕЧНА К. В.  
Національний університет біоресурсів і природокористування України

## МЕТОДОЛОГІЯ ПОБУДОВИ АВТОМАТИЗОВАНОЇ СИСТЕМИ ОПЕРАТИВНОГО МОНІТОРИНГУ ОКРЕМИХ ПАРАМЕТРІВ ВИРОБНИЦТВА БІОГАЗУ

Запропоновано методологію побудови автоматизованої системи оперативного моніторингу окремих параметрів виробництва біогазу - температурного режиму та візуально-статистичних ознак субстрату (середнє значення пікселів, стандартне відхилення, асиметрія, ексцес). Система інтегрує чотири функціональні підсистеми: мобільний IoT-моніторинг середовища на базі мікроконтролера ESP32 із передачею даних через протокол MQTT, технології комп'ютерного зору для експрес-оцінки якості біосировини методом Otsu з попереднім застосуванням CLAHE, ансамбль алгоритмів машинного навчання (XGBoost, LSTM, ResNet-50) для прогнозування виходу біогазу та узагальнену функцію бажаності Харрінгтона для формування рекомендацій оператору. Систематизовано математичний апарат системи: формули обчислення статистичних ознак зображення, метод кількісної оцінки якості на основі нормалізованої відстані від референсних значень, подвійну експоненціальну функцію бажаності з лінійною нормалізацією та метрики регресійного аналізу. Оперативність системи забезпечується передачею даних від IoT-пристрою до хмарної інфраструктури Amazon Web Services менш ніж за 5 секунд та повним циклом обробки - від отримання зображення до видачі рекомендації оператору - за 3,2 хвилини, що суттєво менше характерних часових констант процесу анаеробного зброджування. Архітектура реалізована за розімкненою схемою, де результатом роботи є не безпосередній вплив на виконавчі механізми, а формування рекомендацій для оператора з класифікацією стану біосировини за п'ятьма рівнями якості. Порівняльний аналіз п'яти методів сегментації на наборі з 26 зображень підтвердив перевагу методу CLAHE + Otsu з найнижчим коефіцієнтом варіації 3,63 %. Аналіз важливості параметрів методом Random Forest показав, що візуальна оцінка якості є найбільш впливовим предиктором із відносною важливістю 0,301. Результати 6-місячного тестування на пілотній установці підтвердили ефективність підходу: збір 98,6 % запланованих вимірювань, коефіцієнт детермінації прогностичної моделі  $R^2 = 0,91$  після циклу донавчання на 100 валідованих записах, зменшення RMSE на 42,6 % - з 0,61 до 0,35 м<sup>3</sup>/добу.

**Ключові слова:** біогазова установка, оперативний моніторинг, комп'ютерний зір, машинне навчання, IoT, функція бажаності Харрінгтона, хмарні сервіси, підтримка прийняття рішень

DOI: 10.20535/2617-9741.1.2026.354346

\*Corresponding author: [sergpavlov89@gmail.com](mailto:sergpavlov89@gmail.com)

Received 12 February 2026; Accepted 03 March 2026

Біогазова енергетика є одним з ключових напрямків відновлювальної енергетики, що забезпечує ефективну утилізацію органічних відходів сільськогосподарського виробництва та генерацію біогазу як альтернативного енергоносія. За даними Європейської біогазової асоціації, кількість біогазових установок у Європі постійно зростає, що створює потребу в розробці ефективних систем оперативного моніторингу їхніх параметрів [1]. Анаеробне зброджування є складним біологічним процесом, що включає серію послідовних біохімічних реакцій і вимагає систематичного спостереження за параметрами середовища для запобігання можливим втратам та максимального використання потенціалу сировини [2]. Основними джерелами біомаси для біогазових установок можуть бути органічні відходи, зернові культури, сіно, гній, різноманітні рослинні матеріали тощо. Якість цієї біосировини безпосередньо впливає на ефективність виробництва біогазу, тому оперативне відстеження її стану є критично важливим завданням. У попередніх дослідженнях нами було розглянуто можливість розробки мобільного блоку для моніторингу параметрів рослинного середовища під час виробництва біогазу зі збереженням даних та їх використанням для побудови математичної моделі прогнозування газовіддачі [2]. Запропоновано архітектуру мобільної системи моніторингу на основі принципів нечіткої логіки та структури нейронних мереж. Також досліджено технології комп'ютерного зору

для швидкого аналізу якості біоматеріалу для зброджування [3], що забезпечує кількісний повторюваний метод оцінки якості матеріалу. Проведено аналіз алгоритмів машинного навчання для прогнозування виходу біогазу та розроблено метод комплексної оцінки якості біосировини на основі узагальненої функції бажаності Харрінгтона [4]. Однак усі ці розробки розглядалися як окремі підсистеми, що не були об'єднані в єдину методологію побудови автоматизованої системи моніторингу. Тому метою даної роботи є розробка цілісної методології, що інтегрує всі зазначені компоненти – від мобільного збору даних до підтримки прийняття управлінських рішень – у єдину автоматизовану систему оперативного моніторингу окремих параметрів виробництва біогазу [2].

Методологія побудови автоматизованої системи оперативного моніторингу окремих параметрів виробництва біогазу базується на системному підході і передбачає поетапну інтеграцію кількох функціональних підсистем: підсистеми збору даних (IoT-моніторинг), підсистеми візуального аналізу якості біосировини (комп'ютерний зір), підсистеми прогнозування виходу біогазу (машинне навчання), підсистеми комплексної оцінки (функція бажаності Харрінгтона) та підсистеми формування рекомендацій для оператора. Під «окремими параметрами» в рамках даної методології розуміються дві групи показників, що підлягають оперативному моніторингу. Перша група – температурний режим середовища зброджування, який реєструється апаратними давачами IoT-пристрою. Друга група – візуально-статистичні ознаки субстрату, що розраховуються засобами комп'ютерного зору на основі зображень біоматеріалу: середнє значення пікселів, стандартне відхилення пікселів, асиметрія (skewness) та ексцес (kurtosis) розподілу інтенсивностей. Саме ці параметри було обрано на підставі попередніх досліджень [3], які підтвердили їх інформативність для оцінки якості біосировини та прогнозування видобутку газу. Загальна архітектура системи реалізована за розімкненою схемою, де результатом роботи системи є не безпосередній вплив на виконавчі механізми, а формування рекомендацій для оператора. Тому коректно говорити саме про систему моніторингу та підтримки прийняття рішень, а не про систему автоматичного керування. Такий підхід обґрунтований складністю біологічних процесів анаеробного зброджування та необхідністю врахування експертних знань на етапі впровадження. Загальну архітектуру системи оперативного моніторингу представлено на рис. 1.

Після сегментації зображення методом Оцу з попереднім застосуванням CLAHE для кожного зображення обчислюються чотири статистичні ознаки розподілу інтенсивностей пікселів. Нехай  $I = \{x_1, x_2, \dots, x_n\}$  - множина значень інтенсивності  $N$  пікселів сегментованого зображення [3].

Середнє значення пікселів характеризує загальну яскравість субстрату

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

де:

$x_i$  – окреме значення в наборі даних,

$n$  – кількість значень в наборі даних.

Стандартне відхилення пікселів відображає однорідність текстури

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

де:

$\sigma$  – стандартне відхилення,

$x_i$  – окреме значення в наборі даних,

$\mu$  – середнє значення набору даних,

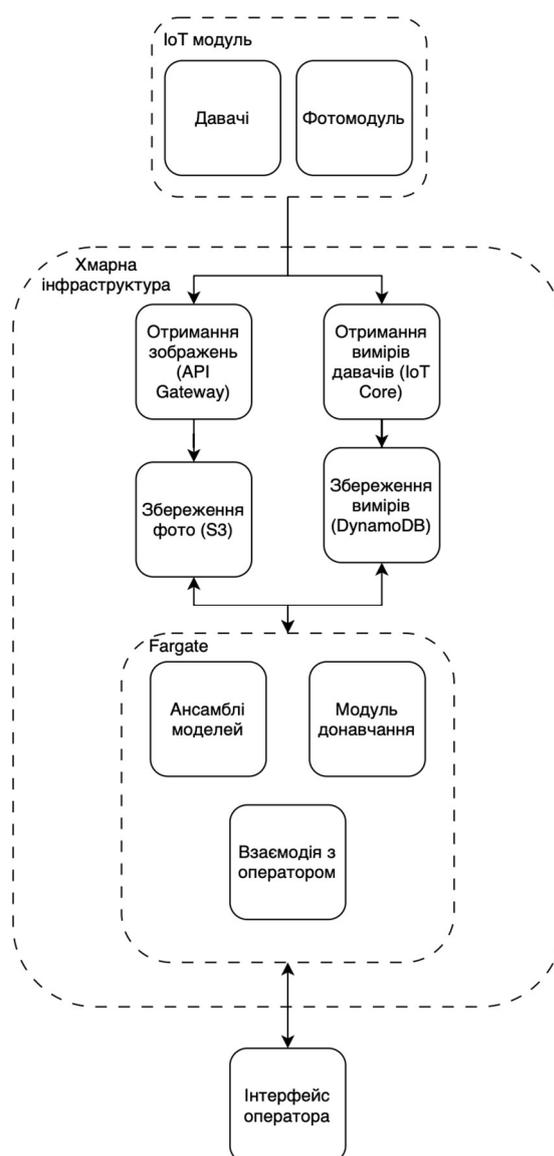
$n$  – кількість значень в наборі даних.

Асиметрія (skewness) характеризує ступінь несиметричності розподілу інтенсивностей відносно середнього значення

$$S = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - M}{\sigma} \right)^3 \quad (3)$$

Ексцес (kurtosis) визначає гостроту піку розподілу відносно нормального розподілу

$$K = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - M}{\sigma} \right)^4 - 3 \quad (4)$$



**Рис. 1 – Загальна архітектура системи оперативного моніторингу параметрів виробництва біогазу**

Від’ємне значення ексцесу ( $K < 0$ ) свідчить про плосковершинний розподіл, що є характерним для якісного біоматеріалу з однорідною текстурою [3].

Для формування кількісної оцінки якості зображення біоматеріалу застосовано метод нормалізованої відстані від ідеальних значень параметрів. Часткові оцінки за середнім значенням та стандартним відхиленням обчислюються як [3]:

$$q_M = 1 - \frac{|M - M_0|}{255} \quad (5)$$

$$q_\sigma = 1 - \frac{|\sigma - \sigma_0|}{255} \quad (6)$$

де  $M_0 = 100$ ,

$\sigma_0 = 30$  референсні значення параметрів, визначені експертно на основі зразків високоякісної біоматеріалу; 255 - максимально можливе значення інтенсивності пікселя (8-бітне зображення).

Інтегральна оцінка якості обчислюється як середнє арифметичне часткових оцінок

$$Q = \frac{qM + q\sigma}{2} \quad (7)$$

Значення  $Q$  знаходиться в діапазоні  $[0; 1]$ , де більше значення відповідає вищій якості біоматеріалу. Для набору з 26 зображень отримано діапазон оцінок від  $Q = 0,762$  (найгірший зразок) до  $Q = 0,805$  (найкращий зразок), з середнім значенням  $Q = 0,802$  [3].

Для комплексної оцінки стану біосировини з урахуванням як візуально-статистичних ознак, так і параметрів середовища (температура, вологість) застосовано узагальнену функцію бажаності Харрінгтона [4]. Метод передбачає перетворення кожного натурального показника у у безрозмірну шкалу бажаності  $d \in [0; 1]$  за допомогою подвійної експоненціальної функції. Спочатку виконується лінійна нормалізація

$$y' = \frac{1,5 \cdot (y - y_{min})}{y_{max} - y_{min}} \quad (8)$$

де  $y_{min}$  – нижня межа прийнятного діапазону показника

$y_{max}$  – верхня межа прийнятного діапазону показника.

Для виходу біогазу в рамках експерименту визначено  $y_{min} = 1,5$  м<sup>3</sup>/добу та  $y_{max} = 1,8$  м<sup>3</sup>/добу. Часткова бажаність обчислюється як

$$d = \exp(-\exp(-y')) \quad (9)$$

Узагальнена функція бажаності для  $n$  параметрів розраховується як середнє геометричне часткових бажаностей

$$D = \left( \prod_{i=1}^n d_i \right)^{\frac{1}{n}} \quad (10)$$

Властивістю середнього геометричного є те, що критично низьке значення будь-якого параметра суттєво знижує загальну оцінку  $D$ , що адекватно відображає реальну ситуацію у виробництві біогазу. На основі значення  $D$  виконується класифікація стану біосировини за п'ятьма рівнями якості (табл. 1).

**Таблиця 1 – Класифікація стану біосировини за функцією бажаності Харрінгтона**

Рівень якості	Діапазон $D$	Рекомендація оператору
Дуже добре	$D > 0,80$	Продовжити процес
Добре	$0,63 < D \leq 0,80$	Контрольна перевірка
Задовільно	$0,37 < D \leq 0,63$	Коригування параметрів
Погано	$0,20 < D \leq 0,37$	Негайне втручання
Дуже погано	$D \leq 0,20$	Зупинка та заміна сировини

Для оцінки точності прогнозування виходу біогазу ансамблем моделей машинного навчання застосовано стандартні метрики регресійного аналізу. Коефіцієнт детермінації  $R^2$  характеризує частку дисперсії цільової змінної, що пояснюється моделлю

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

де  $y_i$  – це реальне, спостережуване значення для  $i$ -го виміру.

$n$  – це загальна кількість точок даних у наборі, на якому проводиться оцінка

$\hat{y}_i$  – це значення, яке спрогнозувала наша модель машинного навчання для  $i$ -го виміру на основі вхідних даних.

Коефіцієнт детермінації ( $R^2$ ) розраховується як

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (12)$$

де  $n$  – це загальна кількість точок даних у наборі

$y_i$  – це реальне, спостережуване значення для  $i$ -го виміру

$\hat{y}_i$  – це значення, яке спрогнозувала наша модель машинного навчання для  $i$ -го виміру на основі вхідних даних

$\bar{y}$  – це середнє арифметичне всіх фактичних значень ( $y_i$ ) у наборі даних.

Першим етапом методології є побудова підсистеми оперативного збору даних. Для цього було розроблено IoT-пристрій на базі мікроконтролера ESP32, який забезпечує реєстрацію температурного режиму та візуальну фіксацію стану біоматеріалу [2]. Вибір ESP32 обумовлений не лише його широкими можливостями бездротового зв'язку та низьким енергоспоживанням, а й високою швидкістю, що є критичною для забезпечення оперативності моніторингу в польових умовах сільськогосподарського виробництва. Було підключено датчики температури та вологості (DS18B20, DHT22) [2]. Архітектура мобільної системи моніторингу передбачає циклічний збір даних із заданою періодичністю та їх передачу через протокол MQTT до хмарної інфраструктури. Протокол MQTT обрано завдяки його легковагості та мінімальній затримці при роботі з обмеженими каналами зв'язку, що є типовим для сільськогосподарських виробництв [5]. Час передачі даних від IoT-пристрою до хмари становить менше 5 секунд, що забезпечує практично миттєву доставку вимірювань для подальшої обробки. Фотофіксація біоматеріалу відбувається в однакових умовах освітленості для забезпечення повторюваності результатів візуального аналізу. За результатами 6-місячного тестування на пілотній установці підсистема продемонструвала високу надійність, забезпечивши збір 98,6 % запланованих вимірювань [2]. Такий рівень безвідмовності є достатнім для оперативного моніторингу процесу анаеробного збродження, де характерні часові константи зміни стану системи вимірюються годинами.

Другим ключовим компонентом методології є підсистема комп'ютерного зору для оперативної експрес-оцінки якості біоматеріалу [3]. Розроблений підхід базується на послідовній обробці зображень та включає такі етапи: збір зображень, конвертація в градації сірого, сегментація, розрахунок статистичних ознак за формулами (1)–(4) та оцінка якості за формулою (7).

Конвертація зображень у градації сірого виконується для уніфікації та спрощення подальшої обробки, оскільки це зменшує розмір даних і знижує обчислювальну складність за рахунок зменшення кількості каналів. Для сегментації було досліджено п'ять методів: порогове сегментування (Thresholding), адаптивне порогове сегментування (Adaptive Thresholding), метод Оцу, метод Оцу з попереднім застосуванням CLAHE та кластеризацію K-середніх. Результати порівняльного аналізу на наборі з 26 зображень біоматеріалу наведено в таблиці 2.

**Таблиця 2 – Порівняльний аналіз методів сегментації**

Метод сегментації	Mean, %	SD, %	CV, %
Оригінальний Оцу	44,59	2,59	5,80
Інвертований Оцу	55,41	2,59	4,67
CLAHE + Оцу	49,42	1,79	3,63
Адаптивне порогове	53,94	4,90	9,08
K-means	50,76	6,11	12,03

Метод Оцу з підвищеним контрастом (CLAHE + Otsu) є найбільш стабільним: його коефіцієнт варіації склав лише 3,63 %, стандартне відхилення - 1,79 %, що є найнижчими серед досліджених методів (табл. 2). Окрім стабільності, вибір методу CLAHE + Otsu обумовлений також його обчислювальною ефективністю: алгоритм не вимагає ітеративних обчислень (на відміну від кластеризації K-середніх з CV = 12,03 %), що забезпечує оперативність експрес-оцінки в реальному часі. Після сегментації для кожного зображення розраховуються чотири ознаки за формулами (1)–(4). Аналіз головних компонент (PCA) підтвердив, що перші два компоненти пояснюють близько 80 % дисперсії даних, що свідчить про достатність обраного набору ознак (табл. 3).

**Таблиця 3 – Навантаження головних компонент на статистичні ознаки**

Компонента	М (середнє)	$\sigma$ (стд. відх.)	S (асиметрія)	K (ексцес)
PC1	-0,500	-0,500	0,500	0,500
PC2	-0,509	0,499	0,491	-0,501

Рівномірний розподіл навантажень у PC1 (табл. 3) свідчить про те, що всі чотири ознаки вносять приблизно однаковий вклад у першу головну компоненту, підтверджуючи їх рівнозначну інформативність для оцінки якості біосировини. Кореляційний аналіз показав сильний негативний зв'язок між середнім значенням пікселів та оцінкою якості, а також позитивну кореляцію між асиметрією, ексцесом та оцінкою. Це свідчить про те, що більш якісний біоматеріал має більш однорідну структуру з характерними особливостями розподілу інтенсивностей [3].

Третій компонент методології – підсистема прогнозування виходу біогазу на основі ансамблю моделей машинного навчання [2]. Проведений аналіз алгоритмів машинного навчання дозволив визначити найбільш ефективні підходи для задачі прогнозування обсягу виробництва біогазу. Принципово важливим є те, що підсистема прогнозування безпосередньо використовує результати роботи підсистеми комп'ютерного зору. Статистичні ознаки, розраховані на етапі візуального аналізу - середні значення пікселів, стандартне відхилення, асиметрія та ексцес - виступають вхідними предикторами для моделі XGBoost разом із даними температурного давача. Таким чином, дві підсистеми утворюють єдиний конвеєр обробки: від зображення субстрату через візуально-статистичні ознаки до прогнозу газовіддачі. В рамках методології застосовано комбінацію двох типів моделей: XGBoost для аналізу структурованих даних показників температурних давачів та візуально-статистичні ознаки субстрату та LSTM (Long Short-Term Memory) для врахування часових залежностей у процесі зброджування. Додатково для аналізу зображень субстрату використано згорткову нейронну мережу ResNet-50, попередньо навчену на ImageNet з подальшим донавчанням на спеціалізованому наборі даних біоматеріалу [2]. Також застосовано механізм адаптивного донавчання Human-in-the-Loop (HITL), що забезпечує автоматичну адаптацію прогнозних моделей до змінних умов експлуатації на основі зворотного зв'язку від оператора [6, 7]. Ключовою особливістю підсистеми є адаптивний механізм донавчання. Початкова модель демонструвала коефіцієнт детермінації  $R^2 = 0,85$  та  $RMSE = 0,61$  м<sup>3</sup>/добу. Після першого циклу оновлення на 100 нових записах, валідованих оператором, точність суттєво зросла:  $R^2$  підвищився до 0,91, а  $RMSE$  зменшилась на 42,6 % до 0,35 м<sup>3</sup>/добу [2]. Це доводить здатність системи ефективно навчатися на реальних експлуатаційних даних, поступово підвищуючи точність прогнозів.

Четвертим компонентом методології є підсистема комплексної оцінки якості біосировини на основі узагальненої функції бажаності Харрінгтона [4]. Цей метод дозволяє звести множину різнорідних параметрів моніторингу до єдиного інтегрального показника, що суттєво спрощує процес прийняття рішень оператором. Перевагою середнього геометричного є те, що критично низьке значення будь-якого параметра суттєво знижує загальну оцінку, що відповідає реальній ситуації у виробництві біогазу. Інтеграція методу Харрінгтона в автоматизовану систему моніторингу дозволяє класифікувати стан біосировини за п'ятьма рівнями якості: відмінний –  $D > 0,80$ , добрий –  $0,63 < D \leq 0,80$ , задовільний –  $0,37 < D \leq 0,63$ , поганий –  $0,20 < D \leq 0,37$  та неприйнятний –  $D \leq 0,20$ . На основі цієї класифікації система формує відповідні рекомендації для оператора [4].

Об'єднання всіх підсистем у цілісну автоматизовану систему оперативного моніторингу реалізовано на хмарній інфраструктурі Amazon Web Services (AWS) [2]. Архітектура включає такі сервіси: API Gateway для прийому даних від IoT-пристроїв, S3 для зберігання зображень, DynamoDB для зберігання структурованих даних вимірювань, Fargate для запуску контейнерів з моделями машинного навчання та модулем комп'ютерного зору. Детальну схему потоку даних та протоколів взаємодії між модулями представлено на рис. 2.

Потік даних у системі організовано як єдиний конвеєр оперативної обробки. IoT-пристрій здійснює вимірювання температури та фотофіксацію субстрату і передає дані через протокол MQTT до хмари (рис. 2). Зображення у форматі JPEG зберігаються в об'єктному сховищі S3 через REST API, числові дані (температура, часова мітка, ідентифікатор сесії) – в DynamoDB через AWS SDK. Сервіс Fargate запускає контейнеризований конвеєр обробки: спочатку модуль комп'ютерного зору отримує зображення з S3 через S3 API та обчислює чотири візуально-статистичні ознаки; потім ці ознаки разом із даними температурного давача з DynamoDB подаються як предиктори на вхід ансамблю ML-моделей передача відбувається в межах єдиної хмарної інфраструктури; далі прогноз видобутку газу та всі параметри агрегуються функцією бажаності Харрінгтона; на основі інтегральної оцінки генератор рекомендацій формує повідомлення для оператора, що доставляється через HTTPS.

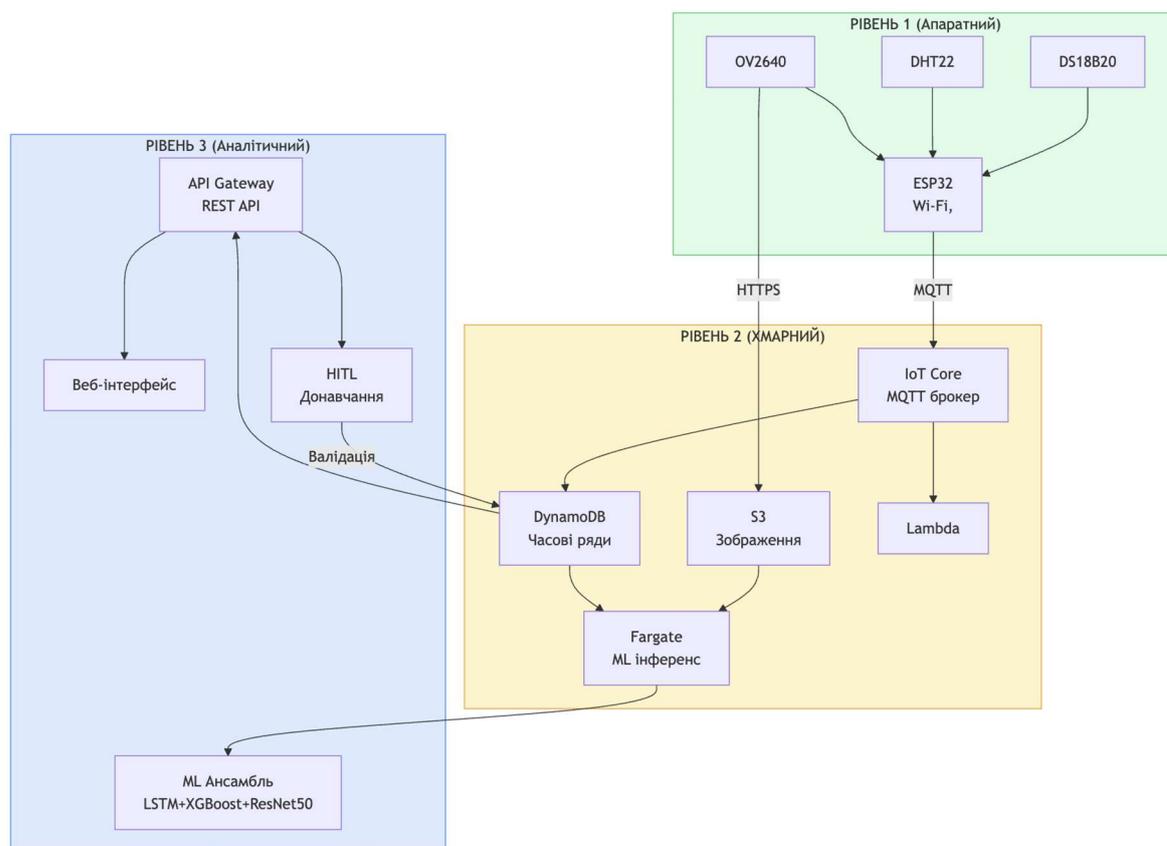


Рис. 2 – Потік даних та протоколи взаємодії між модулями системи оперативного моніторингу

Повний цикл обробки даних – від отримання зображення та показників температурного давача до видачі рекомендації оператору – займає в середньому 3,2 хвилини [2]. Враховуючи, що характерні часові константи процесу анаеробного зброджування вимірюються годинами, досягнутий час реакції системи є достатнім для забезпечення оперативності моніторингу та своєчасного втручання оператора за необхідності.

Запропонована методологія була реалізована та протестована на пілотній біогазовій установці протягом 6 місяців. Основні результати тестування підтвердили ефективність кожного компонента та системи в цілому. Підсистема IoT-моніторингу забезпечила надійний збір 98,6 % запланованих вимірювань температурного режиму та зображень субстрату. Підсистема комп'ютерного зору з використанням методу Оцу з CLANE показала найнижчий коефіцієнт варіації (3,63%) серед п'яти досліджених методів сегментації, що підтверджує стабільність обраного підходу для обчислення візуально-статистичних ознак біоматеріалу в умовах реального виробництва [2, 3]. Прогностична модель на основі ансамблю XGBoost та LSTM, яка використовує візуально-статистичні ознаки субстрату та дані температурного давача як предиктори, продемонструвала значне покращення точності після циклу донавчання:  $R^2$  зріс з 0,85 до 0,91, а RMSE зменшилась з 0,61 до 0,35 м<sup>3</sup>/добу отримане покращення на 42,6 %. Метод Харрінгтона дозволив ефективно класифікувати стан біосировини та генерувати рекомендації для оператора, підвищивши загальну ефективність прийняття рішень щодо управління процесом зброджування [2, 4]. Важливо відзначити, що методологія передбачає поетапне впровадження, де кожний компонент може функціонувати автономно та поступово інтегруватися в загальну систему моніторингу [8-13]. Це знижує ризики впровадження та дозволяє адаптувати систему до конкретних умов виробництва. Розімкнена схема – коли система лише рекомендує, а не діє автоматично – дозволяє оператору зберігати повний контроль над процесом на етапі валідації методології.

**Висновки.** Розроблено цілісну методологію побудови автоматизованої системи оперативного моніторингу окремих параметрів виробництва біогазу – температурного режиму та візуально-статистичних ознак субстрату. Методологія інтегрує чотири ключові підсистеми: IoT-моніторинг середовища на базі ESP32, комп'ютерний зір для експрес-оцінки якості біосировини (метод Оцу з CLANE), ансамбль моделей

машинного навчання (XGBoost, LSTM, ResNet-50) для прогнозування виходу біогазу та функцію бажаності Харрінгтона для комплексної оцінки та формування рекомендацій оператору.

Оперативність системи підтверджена часом повного циклу обробки 3,2 хвилини при передачі даних менш ніж за 5 секунд. Результати тестування на пілотній установці протягом 6 місяців підтвердили ефективність методології: збір 98,6 % вимірювань, коефіцієнт детермінації прогностичної моделі після донавчання  $R^2 = 0,91$ , зменшення RMSE на 42,6 % до 0,35 м<sup>3</sup>/добу.

Перспективними напрямками подальших досліджень є розширення набору параметрів моніторингу рН, вміст летких жирних кислот, вологість, перехід від розімкненої системи рекомендацій до замкненої системи з автоматичним коригуванням параметрів установки, а також валідація методології на промислових біогазових установках більшої потужності.

#### **Список використаної літератури**

1. EBA Statistical Report 2024 / European Biogas Association. 2024. URL: <https://www.europeanbiogas.eu/eba-statistical-report-2024/>
2. 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: <https://doi.org/10.20535/2617-9741.3.2025.340376>
3. 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: <https://doi.org/10.1109/TCSET64720.2024.10755768>
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. DOI: <https://doi.org/10.24263/2225-2924-2025-31-5>
5. Grgić K., Špeh I., Heđi I. A web-based IoT solution for monitoring data using MQTT protocol // 2016 International Conference on Smart Systems and Technologies (SST). 2016. P. 249–253. DOI: <https://doi.org/10.1109/SST.2016.7765668>
6. Kalamaras S. D. et al. A low-cost IoT system based on the ESP32 microcontroller for efficient monitoring of a pilot anaerobic biogas reactor // Applied Sciences. 2025. Vol. 15, No. 1. P. 34. DOI: <https://doi.org/10.3390/app15010034>
7. Pandey A., Momeni O., Pandey P. Design and implementation of IoT-enabled device for real-time monitoring of greenhouse gas emissions, and pressure in anaerobic reactors // IEEE Access. 2024. Vol. 12. P. 133848–133862. DOI: <https://doi.org/10.1109/ACCESS.2024.3449217>
8. Al Daoud E. Comparison between XGBoost, LightGBM and CatBoost using a Home Credit dataset // International Journal of Computer, Electrical, Automation, Control and Information Engineering. 2018. Vol. 12, No. 6. P. 518–522.
9. McCormick M., Villa A. E. LSTM and 1-D convolutional neural networks for predictive monitoring of the anaerobic digestion process // Artificial Neural Networks and Machine Learning – ICANN 2019. 2019. P. 725–736. DOI: [https://doi.org/10.1007/978-3-030-30484-0\\_71](https://doi.org/10.1007/978-3-030-30484-0_71)
10. Bradley D., Roth G. Adaptive Thresholding using the Integral Image // Journal of Graphics Tools. 2007. Vol. 12, No. 2. P. 13–21. DOI: <https://doi.org/10.1080/2151237X.2007.10129236>
11. Reza A. M. Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement // Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology. 2004. Vol. 38. P. 35–44.
12. Wang W., Lu Y. 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. 2018. Vol. 324, No. 1. Article 012049. DOI: <https://doi.org/10.1088/1757-899X/324/1/012049>
13. Weiss K., Khoshgoftaar T. M., Wang D. A survey of transfer learning // Journal of Big Data. 2016. Vol. 3. P. 1–40. DOI: <https://doi.org/10.1186/s40537-016-0043-6>

---

*Serhii Pavlov, Vitalii Lysenko, Taras Lendiel, Kateryna Nakonechna*

#### **METHODOLOGY FOR BUILDING AN AUTOMATED SYSTEM FOR OPERATIONAL MONITORING OF INDIVIDUAL BIOGAS PRODUCTION PARAMETERS**

*A methodology for building an automated system for real-time monitoring of selected biogas production parameters – temperature regime and visual-statistical features of the substrate (mean pixel value, standard deviation, skewness, kurtosis) - is proposed. The system integrates four functional subsystems: mobile IoT-based environmental monitoring using an ESP32 microcontroller with data transmission via the MQTT protocol, computer vision technologies for*

rapid biomass quality assessment using the Otsu method with prior application of CLAHE, an ensemble of machine learning algorithms (XGBoost, LSTM, ResNet-50) for biogas yield prediction, and the Harrington generalized desirability function for generating operator recommendations. The mathematical framework of the system is systematized, including formulas for computing image statistical features, a quality assessment method based on normalized distance from reference values, a double exponential desirability function with linear normalization, and regression analysis metrics. The system's responsiveness is ensured by data transmission from the IoT device to the Amazon Web Services cloud infrastructure in under 5 seconds and a complete processing cycle - from image acquisition to operator recommendation - in 3.2 minutes, which is substantially less than the characteristic time constants of the anaerobic digestion process. The architecture follows an open-loop scheme, where the system output is not a direct control action but rather operator recommendations with biomass condition classification across five quality levels. A comparative analysis of five segmentation methods on a set of 26 images confirmed the advantage of the CLAHE + Otsu method with the lowest coefficient of variation of 3.63 %. Feature importance analysis using Random Forest showed that the visual quality score is the most influential predictor with a relative importance of 0.301. The results of 6-month pilot plant testing confirmed the effectiveness of the approach: 98.6 % of scheduled measurements collected, predictive model coefficient of determination  $R^2 = 0.91$  after a retraining cycle on 100 validated records, and RMSE reduction of 42.6 % - from 0.61 to 0.35 m<sup>3</sup>/day.

**Keywords:** biogas plant, real-time monitoring, computer vision, machine learning, IoT, Harrington desirability function, cloud services, decision support

### References

1. EBA Statistical Report 2024 / European Biogas Association. (2024). URL: <https://www.europeanbiogas.eu/eba-statistical-report-2024>
2. Pavlov S. H., Lysenko V. P., Lendiel T. I., Nakonechna K. V. (2025). Intelektualna systema avtomatyzovanoho monitorynhu yakosti biomaterialu dlia zbrodzhuvannia v biohazovii ustanovtsi [Intelligent system for automated monitoring of biomaterial quality for digestion in a biogas plant] // *Bulletin of National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", Series "Chemical engineering, ecology and resource saving"*, no. 3. pp. 41–51. DOI: <https://doi.org/10.20535/2617-9741.3.2025.340376> (Ukr.)
3. 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), Lviv-Slavske, Ukraine, 2024. P. 1–5. DOI: <https://doi.org/10.1109/TCSET64720.2024.10755768>
4. Pavlov S. H., Lysenko V. P., Lendiel T. I. (2025). Metod Kharrinhntona v systemi ekspres-otsinky yakosti biosyrovyny dlia zbrodzhuvannia [Harrington's method in the system of rapid assessment of the quality of bioraw materials for fermentation] // *Scientific works of the National University of Food Technologies* Vol. 31, no. 5. DOI: <https://doi.org/10.24263/2225-2924-2025-31-5> (Ukr.)
5. 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). P. 249–253. DOI: <https://doi.org/10.1109/SST.2016.7765668>
6. Kalamaras S. D. et al. (2025). A low-cost IoT system based on the ESP32 microcontroller for efficient monitoring of a pilot anaerobic biogas reactor // *Applied Sciences*. Vol. 15, No. 1. P. 34. DOI: <https://doi.org/10.3390/app15010034>
7. 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*. Vol. 12. P. 133848–133862. DOI: <https://doi.org/10.1109/ACCESS.2024.3449217>
8. Al Daoud E. (2018). Comparison between XGBoost, LightGBM and CatBoost using a Home Credit dataset // *International Journal of Computer, Electrical, Automation, Control and Information Engineering*. Vol. 12, No. 6. P. 518–522.
9. McCormick M., Villa A. E. (2019). LSTM and 1-D convolutional neural networks for predictive monitoring of the anaerobic digestion process // *Artificial Neural Networks and Machine Learning – ICANN 2019*. P. 725–736. DOI: [https://doi.org/10.1007/978-3-030-30484-0\\_71](https://doi.org/10.1007/978-3-030-30484-0_71)
10. Bradley D., Roth G. (2007). Adaptive Thresholding using the Integral Image // *Journal of Graphics Tools*. Vol. 12, No. 2. P. 13–21. DOI: <https://doi.org/10.1080/2151237X.2007.10129236>
11. Reza A. M. (2004). Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement // *Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology*. Vol. 38. P. 35–44.
12. 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*. Vol. 324, No. 1. Article 012049. DOI: <https://doi.org/10.1088/1757-899X/324/1/012049>
13. Weiss K., Khoshgoftaar T. M., Wang D. (2016). A survey of transfer learning // *Journal of Big Data*. Vol. 3. P. 1–40. DOI: <https://doi.org/10.1186/s40537-016-0043-6>