

АВТОМАТИЗАЦІЯ ТЕХНОЛОГІЧНИХ ПРОЦЕСІВ

УДК 004.85:662.63

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

ІНТЕЛЕКТУАЛЬНА СИСТЕМА АВТОМАТИЗОВАНОГО МОНІТОРИНГУ ЯКОСТІ БІОМАТЕРІАЛУ ДЛЯ ЗБРОДЖУВАННЯ В БІОГАЗОВІЙ УСТАНОВЦІ

Для вирішення проблеми неефективного та неоперативного контролю біогазових установок розроблено інтелектуальну систему автоматизованого моніторингу. Метою є підвищення стабільності та продуктивності анаеробного зброджування шляхом впровадження проактивного аналізу даних та адаптивного управління.

Дослідження проводилося на пілотній біогазовій установці з використанням ферментованого біоматеріалу. Для збору даних застосовано IoT-пристрій на базі ESP32 з датчиками температури та камерою. Аналіз даних реалізовано на хмарній інфраструктурі AWS з використанням сервісів S3, DynamoDB та Fargate, а також ансамблю моделей машинного навчання (XGBoost, LSTM) та комп'ютерного зору (ResNet-50).

Протягом 6-місячного тестування система продемонструвала високу надійність, забезпечивши збір 98,6 % запланованих вимірювань, та оперативність із середнім часом обробки даних 3,2 хвилини. Для аналізу зображень субстрату валідовано та обрано метод сегментації Оцу з підвищенням контрастності (CLAHE), який показав найнижчий коефіцієнт варіації 3,63 %, що свідчить про його стабільність.

Початкова прогностична модель машинного навчання демонструвала коефіцієнт детермінації (R^2) 0,85 та кореневу середньоквадратичну помилку (RMSE) 0,61 м³/добу. Ключовим результатом є ефективність адаптивного механізму 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 та, як наслідок, якість управлінських рекомендацій.

Ключові слова: комп'ютерний зір, зображення, біоматеріал, хмарні сервіси, розімкнута система, відновлювальна енергетика

DOI: 10.20535/2617-9741.3.2025.340376

* Corresponding author: sergpavlov89@gmail.com

Received 31 July 2025; Accepted 04 September 2025

Анаеробне зброджування (АЗ) біомаси є ключовою технологією у сфері відновлюваної енергетики, що забезпечує екологічно безпечну переробку органічних відходів в біогазових установках (БУ). БУ відіграють важливу роль у досягненні кліматичних цілей ЄС, забезпечуючи сталий цикл вуглецю та енергетичну незалежність [1]. Однак ефективність цього процесу істотно залежить від низки змінних факторів, таких як температура, якість сировини, мікробна активність та стабільність середовища. Традиційні підходи до моніторингу, що базуються на періодичному відборі проб і лабораторному аналізі, є трудомісткими, неоперативними та економічно обтяжливими [2]. Сучасні дослідження свідчать про зростаючу актуальність використання Інтернету речей (IoT), комп'ютерного зору (CV) та методів машинного навчання (МН) для автоматизованого контролю технологічних процесів у сільському господарстві та енергетиці [3, 5, 7]. Зокрема, хмарна інфраструктура, така як Amazon Web Services (AWS), у поєднанні з мікроконтролерами ESP32 та сенсорною мережею, дозволяє створити гнучкі та масштабовані системи реального часу з можливістю адаптації до змінних умов [4, 13]. Однак більшість існуючих рішень обмежуються лише збором та візуалізацією даних, без реалізації повного аналітичного циклу, включаючи адаптивне навчання моделей

на основі експлуатаційної інформації. Окрім того, якість субстрату істотно впливає на вихід біогазу й часто залишається поза увагою через відсутність відповідних сенсорів. Зважаючи на зазначене, комп'ютерний зір відкриває нові можливості для кількісного аналізу фізичних характеристик біомаси, які раніше оцінювалися виключно візуально, суб'єктивно з низькою надійністю [16].

З огляду на зазначене, метою даного дослідження є розробка архітектури та експериментальна перевірка інтелектуальної автоматизованої системи моніторингу та прогнозування ефективності біогазових установок. Запропонована система поєднає IoT-технології, алгоритми комп'ютерного зору, хмарні обчислення та модулі машинного навчання з можливістю адаптивного до навчання моделей.

Розроблена система базується на багаторівневій архітектурі, що включає периферійні пристрої збору даних, хмарну інфраструктуру обробки та зберігання інформації, а також компоненти комп'ютерного зору та машинного навчання для аналізу та оптимізації процесів.

На периферійному рівні використовується спеціально розроблений IoT-модуль на базі плати ESP8266, що використовує процесор Xtensa L106, який базується на архітектурі RISC. Він працює на частоті від 80 до 160 МГц, що дозволяє виконувати обчислення та обробку даних, а також розроблений з урахуванням оптимізації споживаної потужності [3]. Фотомодуль побудований на базі плати ESP32 [4], в яку інтегровано двоядерний процесор Tensilica LX6, 4 МБ PSRAM та модуль камери OV2640 (2MP) [3]. Для моніторингу температури застосовуються високоточні водонепроникні давачі DS18B20, підключені до мікроконтролера через інтерфейс 1-Wire з використанням підтягуючого резистора 4,7 кΩ. Для захисту електроніки від агресивного середовища біореактора розроблено герметичний корпус, надрукований на 3D-принтері з PLA+, з кабельними входами стандарту IP67 та вентиляційною мембраною для вирівнювання тиску [3].

Програмне забезпечення для ESP32 розроблено в середовищі Arduino IDE з використанням бібліотек PubSubClient для Message Queue Telemetry Transport MQTT [10], ArduinoJson для обробки даних, та DallasTemperature і esp_camera для взаємодії з сенсорами. Алгоритм роботи пристрою передбачає ініціалізацію камери з налаштуванням формату JPEG та 12-бітної точності для датчиків температури. Для забезпечення надійності при втраті інтернет-з'єднання реалізовано механізм буферизації: дані тимчасово зберігаються у файловій системі SPIFFS на борту пристрою і відправляються до хмари після відновлення зв'язку [3].

Хмарна частина системи побудована на керованих сервісах AWS, що забезпечує високу надійність, масштабованість та безпеку, детальніше зображена на рис 1. При цьому:

AWS IoT Core - сервіс виступає як безпечний центральний шлюз для підключення IoT-пристроїв [11]. Він надійно приймає мільйони повідомлень за протоколом MQTT, автентифікує пристрої шляхом використання цифрових сертифікатів та використовує вбудований механізм правил (Rules Engine) для миттєвої фільтрації та маршрутизації вхідних даних телеметрії до інших сервісів AWS.

Amazon API Gateway - керований сервіс для створення, публікації та захисту API. У нашій архітектурі він використовується для створення стабільної та захищеної HTTPS-кінцевої точки, яка приймає великі бінарні файли (зображення) від IoT-пристроїв. API Gateway обробляє вхідні POST-запити та передає дані для подальшого збереження, виступаючи надійним фасадом для серверної логіки [12].

Amazon S3 (Simple Storage Service) – високмасштабоване та довговічне об'єктне сховище, що слугує центральним "озером даних" розробки. Всі «сирі» дані, як-от зображення та телеметрія, надійно зберігаються в бакетах S3. Завдяки ієрархічній структурі та політиці життєвого циклу, сервіс дозволяє оптимізувати витрати шляхом автоматичного переміщення старих даних у дешевші класи зберігання [3].

AWS Lambda – це безсерверний, керований подіями обчислювальний сервіс, який виконує роль "клею" між різними компонентами архітектури [13]. Функції Lambda запускаються автоматично у відповідь на події, наприклад, завантаження нового фото в S3. Вони виконують легковагові завдання, такі як синхронізація даних або запуск більш складних обчислювальних процесів на інших сервісах, не вимагаючи управління серверами.

AWS Fargate – безсерверне обчислювальне оточення для запуску Docker-контейнерів [14, 15]. Воно дозволяє запускати контейнеризовані додатки без необхідності керувати базовими віртуальними машинами EC2. У нашій системі Fargate використовується для виконання завдань аналізу даних та донавчання моделей. Такий підхід спрощує розгортання, масштабування та управління обчислювальними ресурсами, оскільки потрібно лише підготувати Docker-образ.

DynamoDB – це повністю керована NoSQL база даних, яка доступна в оточенні AWS. Вона підтримує моделі даних "ключ-значення" та "документ", і дозволяє створювати масштабовані додатки, що працюють без супроводжуючого сервера [13].




Рис. 1 – Спрощена схема архітектури системи

Кожен IoT-модуль реєструється як унікальний об'єкт (Thing) в AWS IoT Core, що дозволяє керувати його політиками безпеки та доступом. Передача даних відбувається за структурованою схемою MQTT-каналів. Правило маршрутизації (IoT Rule) в AWS IoT Core, написане на SQL-подібній мові, автоматично обробляє вхідні повідомлення і виконує дві дії: зберігає дані в Amazon S3 та викликає функцію AWS Lambda для запуску процесу аналізу.

Спочатку IoT-модуль активується та отримує дані з датчиків температури і фотофіксує стану біоматеріалу. Для забезпечення надійності, у разі невдалого збору даних або подальших проблем зі з'єднанням, пристрій використовує механізм повторних спроб з експоненційною затримкою (Exponential Backoff). Після успішного збору даних, пристрій підключається до Wi-Fi, а потім до хмарної інфраструктури AWS. Дані передаються двома окремими потоками для оптимізації процесу: показники температури надсилаються через легковаговий протокол MQTT, тоді як об'ємні файли зображень передаються через захищений HTTPS POST-запит до Amazon API Gateway.

В інфраструктурі AWS сервіс IoT Core приймає дані температури та зберігає їх у сховищі S3, тоді як API Gateway обробляє запит із зображенням і також зберігає його в S3. **Amazon S3** використовується як центральне **"озеро даних"** (Data Lake) для зберігання великих, переважно неструктурованих об'єктів. Дані тут організовані за принципом файлової системи для довготривалого зберігання, архівування та доступу для обчислювальних завдань. Структура даних в S3 включає:

Фотографії з фотомодуля, збережені у форматі .jpg. Вони є первинним джерелом візуальної інформації про стан біоматеріалу.

Дані телеметрії отримані з датчиків температури та вологості. Це забезпечує повний історичний архів необроблених даних для можливого повторного аналізу або аудиту.

Збережені файли навчених моделей у форматі .pkl. Це дозволяє версіювати моделі, повертатися до попередніх версій та розгортати їх для аналізу.

Ключовим етапом є синхронізація: завантаження нового фото в S3 запускає функцію AWS Lambda, що перевіряє наявність відповідного файлу з даними температури. Якщо обидва файли на місці, Lambda ініціює запуск завдання у сервісі AWS Fargate, передаючи йому інформацію про нові дані. Якщо файл температури ще не надійшов, Lambda завершує роботу, запобігаючи аналізу неповних даних.

Запущене завдання Fargate розгортає Docker-контейнер, який завантажує фото та дані телеметрії з S3, проводить їх комплексний аналіз на основі використання моделей машинного навчання і зберігає отримані результати в базі даних DynamoDB, автоматично маркуючи їх як "не навчені", приклад запису даних наведено на рис 2.

```
{
  "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 – Приклад запису в базу даних DynamoDB

Підсистема оцінювання складається з модулів комп'ютерного зору та прогнозування. Для аналізу зображень використовується попередньо навчена модель на дата-сеті специфічних зображеннях матеріалу для зброджування, зроблених на полігоні для зберігання біоматеріалу. Перед подачею в модель зображення, проходить конвеєр попередньої обробки, що включає корекцію освітлення методом CLAHE [16], переведення в градацію сірого, видалення відблисків та нормалізацію. Модель виконує багатозадачне навчання, одночасно визначаючи аномалії кольору та загальну якість поверхні субстрату [16].

Модуль прогнозування підсистеми оцінювання, використовує ансамбль з моделей для передбачення виходу біогазу: градієнтний бустинг (XGBoost) [9] для врахування складних нелінійних залежностей, рекурентну нейронну мережу (LSTM) [17] для аналізу часових трендів у даних, та лінійну регресію як базову модель. Фінальний прогноз отримується шляхом зваженого усереднення результатів кожної моделі, що підвищує його стійкість та точність.

На основі результатів аналізу, система генерації рекомендацій, що працює на основі набору продукційних правил, формує поради для оператора. Правила враховують відхилення температури від оптимального діапазону, прогнозоване падіння продуктивності, візуальні індикатори проблем та довгострокові тренди. Рекомендації автоматично категоризуються за пріоритетом (критичні, важливі, інформаційні).

Ключовою особливістю системи є механізм додаткового навчання на реальних даних – підсистема донавчання. Завершальний етап це і є адаптивне покращення системи. Коли кількість записів, позначених спеціальним маркером, досягає порогового значення, система формує з них набір даних та надає його оператору через веб-сторінку, розміщену на S3. Оператор вводить фактичні дані про вихід біогазу за період, коли були отримані дані. На наступній ітерації, коли система виявляє ці нові валідовані дані, вона запускає окреме завдання Fargate для перенавчання моделей. Після успішного навчання та оцінки, покращена модель розгортається для подальшого використання, а використані дані маркуються в DynamoDB іншим маркером, завершуючи цикл. Процес використовує техніку transfer learning – існуючі ваги моделей не скидаються, а додатково навчаються на нових даних, що значно прискорює навчання [18]. Нова версія моделей розгортається лише у випадку, якщо її метрика RMSE [8] на тестовій вибірці покращується більше ніж на 5 % порівняно з поточною версією. Для забезпечення стабільності система зберігає останні 5 версій моделей з можливістю швидкого повернення до моделі з кращими показниками.



а)




Рис. 3 – Блок-схема алгоритму функціонування системи: а) – пристрою, б) – підсистеми оцінювання, в) – підсистеми донавчання

Реалізована архітектура системи автоматизованого моніторингу та оптимізації виробництва біогазу продемонструвала високу ефективність та надійність під час 6-місячного тестування на пілотних установках. На рис.3 зображена блок-схема алгоритму функціонування. Система успішно інтегрує компоненти збору даних, хмарну інфраструктуру AWS та модулі машинного навчання в єдиний функціональний комплекс, підтвердивши переваги модульності, масштабованості та економічної ефективності.

Протягом 6 місяців тестування система продемонструвала високі операційні показники. Надійність збору даних склала 98,6 %, де основні втрати були пов'язані з перебоями в електропостачанні (0,8 %) та інтернет-з'єднанні (0,6 %). Успішно отримано та проаналізовано 97,5 % запланованих фотознімків, з яких 89 % мали достатню якість для автоматичного аналізу. Середній час від збору даних до генерації рекомендацій становив 3,2 хвилини, що свідчить про високу оперативність системи.

Для модуля комп'ютерного зору було проведено валідацію методів сегментації зображень, яка показала, що метод Оцу з підвищенням контрастності є найбільш стабільним [16], з найнижчим коефіцієнтом варіації 3,63 % (табл. 1).

Таблиця 1 – Порівняльні характеристики методів сегментації зображень

Метод	Коефіцієнт варіації (%)
Оригінальний Оцу	5,80
Інвертований Оцу	4,67
Оцу з підвищенням контрасту (CLAHE)	3,63
Адаптивний поріг	9,08
К-середніх	10,21

Для кількісної оцінки точності прогностичної моделі та ефективності її додаткового навчання були обрані дві стандартні для регресійних завдань метрики: коренева середньоквадратична помилка (RMSE) [8], [19] та коефіцієнт детермінації (R^2) [20]. Розрахунок проводився на тестовій вибірці, яка не використовувалася під час навчання, шляхом порівняння прогнозованих значень виходу біогазу ($\hat{y}_i$) з фактичними показниками, наданими оператором (y_i).

Коренева середньоквадратична помилка (RMSE) розраховується як:

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

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:

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

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.

Після першого циклу оновлення на 100 нових записах точність ансамблю моделей значно зросла (Таблиця 2).

Таблиця 2 – Порівняння метрик продуктивності моделі МН до та після циклу додаткового навчання

Метрика	Початкова модель	Модель після до навчання	Динаміка покращення
RMSE (м³/добу)	0,61	0,35	-42,6%
Коефіцієнт детермінації (R²)	0,85	0,91	+7,1%

Значне зниження помилки прогнозування та зростання R^2 до 0.91 свідчить про успішну адаптацію моделі до специфіки установки та підтверджує практичну цінність реалізованого підходу.

Запропонована система є значним кроком уперед у сфері автоматизації отримання біогазу. Порівнюючи наше рішення з іншими дослідженнями, можна виділити кілька ключових аспектів. Подібно до робіт Pandey et al. [5], Kalamaras et al., [7] ми доводимо, що використання доступної елементної бази та хмарних сервісів є економічно виправданим підходом. Однак, на відміну від систем, що фокусуються переважно на пасивному моніторингу (такі як в роботі Galon et al. [6]), наше рішення впроваджує практичний аналіз та генерує конкретні рекомендації. Головною ж науковою новизною є реалізація адаптивного механізму з керованим циклом зворотного зв'язку. Якщо інші автори лише пропонують використання МН в майбутньому, ми представляємо працюючу архітектуру, здатну до навчання на основі реальних експлуатаційних даних. Інтеграція комп'ютерного зору для аналізу якості субстрату також є особливістю, що дозволяє отримувати дані, недоступні для традиційних сенсорів.

Практична значущість системи є багатогранною. З економічної точки зору, підвищення виходу біогазу веде до прямого збільшення виробництва енергії та прибутковості. Зниження ризиків аварій та автоматизація рутинних операцій скорочують експлуатаційні витрати. Екологічні переваги полягають у більш повній переробці відходів та максимізації виробництва "зеленої" енергії. Для операторів система стає надійним помічником, що надає об'єктивні дані для прийняття рішень та допомагає виявляти помилки в експлуатації.

Незважаючи на успішні результати, система має певні обмеження, які окреслюють напрями для майбутніх досліджень. Залежність від інтернет-зв'язку у віддалених регіонах є викликом, який можна вирішити шляхом впровадження резервних GSM-каналів. Початкове навчання моделі вимагає значного обсягу даних. Подальший розвиток має бути спрямований на розширення сенсорного масиву для отримання більш повної картини процесів (рН, ОБП, амоній), а також на дослідження більш складних моделей МН, зокрема згорткових нейронних мереж (CNN) для глибшого аналізу зображень та моделей навчання з підкріпленням (Reinforcement Learning) для переходу від рекомендацій до повністю автономного управління. Також потрібно впровадити періодичну перевірку в лабораторії отриманих зразків для калібрування результатів після оцінки оператором.

Висновки. У роботі представлено багаторівневу архітектуру для автоматизації моніторингу біогазових установок, що поєднує IoT-пристрої, хмарну інфраструктуру AWS та адаптивне машинне навчання з комп'ютерним зором. Ключовою інновацією є адаптивна система з циклом зворотного зв'язку для безперервного самовдосконалення.

Результати 6-місячного тестування підтвердили високу надійність системи (98,6% успішно зібраних даних) і швидкість обробки (середній час 3,2 хвилини). Система функціонує як окрема складова для формування дорадчих рішень у виробництві біогазу.

Впровадження подібних технологій позитивно впливає на виробництво біогазу, підвищуючи економічну ефективність та надійність, що сприятиме розкриттю потенціалу біогазу в глобальній сталій енергетиці.

Перспективи подальших досліджень. Перспективи подальших досліджень спрямовані на розширення функціоналу системи, підвищення її автономності та точності шляхом інтеграції нових технологій та поглиблення аналітичних можливостей шляхом безперервного донавчання.

Список використаної літератури

1. EBA Statistical Report 2024 / European Biogas Association [Електронний ресурс]. — 2024. — Режим доступу: <https://www.europeanbiogas.eu/eba-statistical-report-2024/> (дата звернення: 02.07.2025).
2. Polishchuk, V. M. Increasing the yield of biogas and electricity during manure fermentation cattle by optimally adding lime to extruded straw / V. M. Polishchuk, S. A. Shvoro, I. V. Flonts, T. S. Davidenko // *Problems of the Regional Energetics*. — 2021. — Vol. 49, No. 1. — P. 73–85. — DOI: 10.52254/1857-0070.2021.1-49.02.
3. Lysenko, V. Mobile system for monitoring plant environment parameters for biogas production / V. Lysenko, T. Lendiel, I. Bolbot, S. Pavlov // *Machinery & Energetics*. — 2023. — Vol. 14, No. 4. — P. 111–120. — DOI: 10.31548/machinery/4.2023.111.
4. Espressif Systems — ESP32 Overview [Електронний ресурс]. — [Б. м.], [б. р.]. — Режим доступу: <https://www.espressif.com/en/products/socs/esp32> (дата звернення: 12.07.2025).
5. Pandey, A. Design and implementation of IoT-enabled device for real-time monitoring of greenhouse gas emissions, and pressure in anaerobic reactors / A. Pandey, O. Momeni, P. Pandey // *IEEE Access*. — 2024. — Vol. 12. — P. 133848–133862. — DOI: 10.1109/ACCESS.2024.3449217.
6. Galon, M. L. Q. Automated monitoring and control system of solar greenhouse using ESP32 and Blynk application / M. L. Q. Galon, M. V. R. Tumaliwan, M. M. Sejera // *Engineering Proceedings*. — 2025. — Vol. 92, No. 1. — P. 57. — DOI: 10.3390/engproc2025092057.
7. Kalamaras, S. D. A low-cost IoT system based on the ESP32 microcontroller for efficient monitoring of a pilot anaerobic biogas reactor / S. D. Kalamaras, M.-A. Tsitsimpikou, C. A. Tzenos [та ін.] // *Applied Sciences*. — 2025. — Vol. 15, No. 1. — P. 34. — DOI: 10.3390/app15010034.
8. Wang, W. Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in assessing rounding model / W. Wang, Y. Lu // *IOP Conference Series: Materials Science and Engineering*. — 2018. — Vol. 324, No. 1. — P. 012049. — DOI: 10.1088/1757-899X/324/1/012049.
9. Al Daoud, E. Comparison between XGBoost, LightGBM and CatBoost using a Home Credit dataset / E. Al Daoud // *International Journal of Computer, Electrical, Automation, Control and Information Engineering*. — 2018. — Vol. 12, No. 6. — P. 518–522. — Режим доступу: <https://publications.waset.org/10009954/> (дата звернення: 15.07.2025).
10. Grgić, K. A web-based IoT solution for monitoring data using MQTT protocol / K. Grgić, I. Špeh, I. Heđi // *2016 International Conference on Smart Systems and Technologies (SST)*. — 2016. — P. 249–253. — DOI: 10.1109/SST.2016.7765668.
11. Kianijaya, M. R. Implementation of data storage for the monitoring system for biogas production optimization / M. R. Kianijaya, M. O. Hasanuddin // *2022 8th International Conference on Wireless and Telematics (ICWT)*. — 2022. — P. 1–5. — DOI: 10.1109/ICWT55831.2022.9935447.
12. Amazon Web Services — API Gateway [Електронний ресурс]. — [Б. м.], [б. р.]. — Режим доступу: <https://aws.amazon.com/api-gateway/> (дата звернення: 15.07.2025).
13. Bhaskaran, H. S. Development of a cloud-based IoT system for livestock health monitoring using AWS and Python / H. S. Bhaskaran, M. Gordon, S. Neethirajan // *Smart Agricultural Technology*. — 2024. — Vol. 9. — P. 100524. — DOI: 10.1016/j.atech.2024.100524.
14. Amazon Web Services — AWS Fargate [Електронний ресурс]. — [Б. м.], [б. р.]. — Режим доступу: <https://aws.amazon.com/fargate/> (дата звернення: 15.07.2025).
15. Panou, M. Microbiome-oriented data mining of operational monitoring of anaerobic digestion reactor during steady operation period, failure, and restoration / M. Panou, I. Kavakiotis, A. Mitsopoulos [та ін.] // *bioRxiv*. — 2025. — DOI: 10.1101/2025.02.07.637110.
16. Lysenko, V. Computer vision technologies for rapid quality analysis of fermentable biomaterial / V. Lysenko, T. Lendiel, S. Pavlov, K. Nakonechna // *2024 IEEE 17th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*. — 2024. — P. 1–5. — DOI: 10.1109/TCSET64720.2024.10755768.

17. McCormick, M. LSTM and 1-D convolutional neural networks for predictive monitoring of the anaerobic digestion process / M. McCormick, A. E. Villa // Artificial Neural Networks and Machine Learning – ICANN 2019. — 2019. — P. 725–736. — DOI: 10.1007/978-3-030-30484-0_71.
 18. Weiss, K. A survey of transfer learning / K. Weiss, T. M. Khoshgoftaar, D. Wang // Journal of Big Data. — 2016. — Vol. 3. — P. 1–40. — DOI: 10.1186/s40537-016-0043-6.
 19. Лисенко, В. Аналіз алгоритмів машинного навчання для прогнозування виходу біогазу / В. Лисенко, Т. Лендієль, С. Павлов // Енергетика і автоматика. — 2023. — № 3. — С. 100–111. — DOI: 10.31548/energiya3(67).2023.100.
 20. Babich, Y. R2 metric dynamics for K-nearest neighbors regression model trained on series of different sizes / Y. Babich, L. Hlazunova, T. Kalinina, Y. Petrovych // Information and Communication Technologies, Electronic Engineering. — 2024. — Vol. 4. — P. 10–18. — DOI: 10.23939/ict2024.02.010.
-

Serhii Pavlov, Vitalii Lysenko, Taras Lendiel, Kateryna Nakonechna

INTELLIGENT SYSTEM FOR AUTOMATED MONITORING OF BIOMATERIAL QUALITY FOR DIGESTION IN A BIOGAS PLANT

To address the challenge of inefficient and non-real-time control of biogas plants, an intelligent automated monitoring system was developed. The objective is to enhance the stability and productivity of anaerobic digestion through the implementation of proactive data analysis and adaptive control.

The study was conducted on a pilot biogas plant using fermented biomaterial. An ESP32-based IoT device equipped with temperature sensors and a camera was used for data collection. Data analysis was performed on the AWS cloud infrastructure, utilizing S3, DynamoDB, and Fargate services, along with an ensemble of machine learning (XGBoost, LSTM) and computer vision (ResNet-50) models.

During a 6-month testing period, the system demonstrated high reliability, collecting 98.6 % of planned measurements, and efficiency, with an average data processing time of 3.2 minutes. For substrate image analysis, the Otsu segmentation method with Contrast Limited Adaptive Histogram Equalization (CLAHE) was validated and selected, showing the lowest coefficient of variation at 3.63 %, indicating its stability.

The initial predictive machine learning model achieved a coefficient of determination (R^2) of 0.85 and a Root Mean Square Error (RMSE) of 0.61 m³/day. A key result is the effectiveness of the adaptive retraining mechanism: after the first update cycle with 100 new, operator-validated records, the model's accuracy significantly increased. The R^2 score rose to 0.91, and the RMSE decreased by 42.6 % to 0.35 m³/day. This proves that the system can effectively learn from real operational data, continuously improving its predictive accuracy and, consequently, the quality of its management recommendations.

Keywords: computer vision, image, biomaterial, cloud services, open system, renewable energy

References

1. EBA (2024) EBA Statistical Report 2024. Available at: <https://www.europeanbiogas.eu/eba-statistical-report-2024/> (Accessed: 02 July 2025).
2. Polishchuk, V.M., Shvoroov, S.A., Flonts, I.V. and Davidenko, T.S. (2021) 'Increasing the yield of biogas and electricity during manure fermentation cattle by optimally adding lime to extruded straw', Problems of the Regional Energetics, 49(1), pp. 73–85. doi: 10.52254/1857-0070.2021.1-49.02.
3. Lysenko, V., Lendiel, T., Bolbot, I. and Pavlov, S. (2023) 'Mobile system for monitoring plant environment parameters for biogas production', Machinery & Energetics, 14(4), pp. 111–120. doi: 10.31548/machinery/4.2023.111.

4. Espressif Systems (n.d.) ESP32 Overview. Available at: <https://www.espressif.com/en/products/socs/esp32> (Accessed: 12 July 2025).
5. Pandey, A., Momeni, O. and 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, pp. 133848–133862. doi: 10.1109/ACCESS.2024.3449217.
6. Galon, M.L.Q., Tumaliwan, M.V.R. and Sejera, M.M. (2025) 'Automated monitoring and control system of solar greenhouse using ESP32 and Blynk application', *Engineering Proceedings*, 92(1), p. 57. doi: 10.3390/engproc2025092057.
7. Kalamaras, S.D., Tsitsimpikou, M.-A., Tzenos, C.A. et al. (2025) 'A low-cost IoT system based on the ESP32 microcontroller for efficient monitoring of a pilot anaerobic biogas reactor', *Applied Sciences*, 15(1), p. 34. doi: 10.3390/app15010034.
8. Wang, W. and 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(1), p. 012049. doi: 10.1088/1757-899X/324/1/012049.
9. 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*, 12(6), pp. 518–522. Available at: <https://publications.waset.org/10009954/> (Accessed: 15 July 2025).
10. Grgić, K., Špeh, I. and Heđi, I. (2016) 'A web-based IoT solution for monitoring data using MQTT protocol', in *2016 International Conference on Smart Systems and Technologies (SST)*. IEEE, pp. 249–253. doi: 10.1109/SST.2016.7765668.
11. Kianijaya, M.R. and Hasanuddin, M.O. (2022) 'Implementation of data storage for the monitoring system for biogas production optimization', in *2022 8th International Conference on Wireless and Telematics (ICWT)*. IEEE, pp. 1–5. doi: 10.1109/ICWT55831.2022.9935447.
12. Amazon Web Services (n.d.) API Gateway. Available at: <https://aws.amazon.com/api-gateway/> (Accessed: 15 July 2025).
13. Bhaskaran, H.S., Gordon, M. and Neethirajan, S. (2024) 'Development of a cloud-based IoT system for livestock health monitoring using AWS and Python', *Smart Agricultural Technology*, 9, p. 100524. doi: 10.1016/j.atech.2024.100524.
14. Amazon Web Services (n.d.) AWS Fargate. Available at: <https://aws.amazon.com/tag/> (Accessed: 15 July 2025).
15. Panou, M., Kavakiotis, I., Mitsopoulos, A. et al. (2025) 'Microbiome-oriented data mining of operational monitoring of anaerobic digestion reactor during steady operation period, failure, and restoration', *bioRxiv*. doi: 10.1101/2025.02.07.637110.
16. Lysenko, V., Lendiel, T., Pavlov, S. and Nakonechna, K. (2024) 'Computer vision technologies for rapid quality analysis of fermentable biomaterial', in *2024 IEEE 17th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*. IEEE, pp. 1–5. doi: 10.1109/TCSET64720.2024.10755768.
17. McCormick, M. and Villa, A.E. (2019) 'LSTM and 1-D convolutional neural networks for predictive monitoring of the anaerobic digestion process', in *Artificial Neural Networks and Machine Learning – ICANN 2019*. Springer, pp. 725–736. doi: 10.1007/978-3-030-30484-0_71.
18. Weiss, K., Khoshgoftaar, T.M. and Wang, D. (2016) 'A survey of transfer learning', *Journal of Big Data*, 3, pp. 1–40. doi: 10.1186/s40537-016-0043-6.
19. Lysenko, V., Lendiel, T., Pavlov, S. (2023) 'Analysis of machine learning algorithms for biogas yield prediction', *Energy and automation*, 3, pp. 100–111. doi: 10.31548/energiya3(67).2023.100.
20. Babich, Y., Hlazunova, L., Kalinina, T. and 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, pp. 10–18. doi: 10.23939/ictee2024.02.010.