

PENERAPAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK ANALISIS PRODUKSI BIOGAS DALAM PENGOLAHAN SAMPAH ORGANIK BERBASIS IOT

(Application of Convolutional Neural Network (CNN) Method for Biogas Production Analysis in IoT Based Organic Waste Treatment)

Endro Ariyanto^[1], M. Hadist^[2], Hilal Hudan Nuha^[1]

^[1]School of Computing, Telkom University
Bandung, Indonesia

^[2]PT. Meysha Syafiyah Gemilang
Subang, Indonesia

Email : end@teluapp.org, muhammadhadistno3@gmail.com, hilalnuha@ieee.org

Abstract

The development of biogas technology in Indonesia faces challenges in production monitoring and prediction accuracy due to the non-linear complexity of data. This study aims to implement a Convolutional Neural Network (CNN) method integrated with Internet of Things (IoT) technology to analyze and predict biogas production parameters. The system utilizes an ESP32 microcontroller with MQ-4, DHT11, and pH sensors for real-time data acquisition sent to a cloud service. The prediction model was developed using a 1D-CNN architecture trained on 2,400 sensor data points collected at 30-second intervals. Results demonstrate that the CNN model is highly effective in predicting methane gas concentration, achieving an R^2 of 0.99661 and a MAPE of 1.3888%. Temperature and pH predictions yielded R^2 values of 0.8982 and 0.6633, respectively, with MAPE remaining below the 10% threshold. Overall, the integration of IoT and CNN provides accurate and stable predictions, serving as an intelligent reference for optimizing biogas production from household organic waste.

Keywords: Biogas, Organic Waste, IoT, Convolutional Neural Network, Prediction

1. PENDAHULUAN

Indonesia, sebagai negara agraris, memiliki potensi besar dalam pengembangan sumber energi terbarukan termasuk biogas. Pemerintah Indonesia telah menetapkan target ambisius mencapai 23% pemanfaatan energi terbarukan dalam bauran energi nasional pada tahun 2025 [1]. Namun, perkembangan teknologi biogas di Indonesia masih dalam tahap awal, terutama dalam pemanfaatan langsung biogas untuk produksi energi.

Sebagai alternatif, kotoran hewan, limbah dapur seperti sisa buah dan sayuran, serta berbagai jenis sampah organik lainnya dapat diubah menjadi biogas [2]. Biogas yang dihasilkan ini bisa dimanfaatkan sebagai energi alternatif yang bermanfaat bagi berbagai sektor, seperti energi, pertanian, industri, dan rumah tangga. Pemanfaatan sampah organik untuk produksi biogas juga dapat membantu mengurangi masalah sampah di Indonesia.

Biogas dihasilkan melalui proses fermentasi bahan organik yang melibatkan bakteri anaerob, yaitu bakteri yang dapat hidup di lingkungan tanpa oksigen. Dalam proses produksi biogas, terdapat beberapa faktor yang dapat memengaruhi hasil biogas, seperti Tingkat keasaman (pH) dan suhu [3]. Untuk memastikan pH, suhu, dan kelembapan tetap stabil, dikembangkan sebuah sistem pemantauan.

Penelitian ini juga akan melakukan prediksi produksi biogas. Prediksi produksi biogas dapat membantu dalam perencanaan penggunaan energi [4]. Dengan mengetahui seberapa banyak gas metana yang dihasilkan, pengelola biogas dapat merencanakan penggunaannya untuk memenuhi kebutuhan energi. Selain itu, hasil prediksi produksi gas metana juga memungkinkan untuk melakukan evaluasi kinerja sistem biogas. Dengan membandingkan hasil prediksi dengan produksi sebenarnya, pengelola dapat mengidentifikasi area di mana peningkatan atau perbaikan diperlukan.

Alat biogas yang dilengkapi dengan sistem pemantauan pH, suhu, dan kelembapan sudah ada sebelumnya. Namun, penelitian lain menunjukkan kelemahan, yaitu proses pengiriman data masih menggunakan kartu SD sebagai media penyimpanan, sehingga monitoring data harus dilakukan secara offline [5]. Dalam penelitian ini, proses pengiriman dan penyimpanan data dilakukan melalui *Internet of Things* (IoT). Dengan menggunakan penyimpanan *database cloud* dan *Esp32* untuk pengambilan data dari sensor lalu dikirim ke internet, maka pemantauan produksi biogas dapat dilakukan dengan mudah dan dapat mempermudah analisis produksi biogas.

Pengolahan sampah organik adalah proses penting karena kemampuannya untuk menghasilkan biogas dari sampah rumah tangga. Oleh karena itu, perkiraan yang akurat dapat meningkatkan produksi biogas. Akan tetapi, karena data yang diperoleh biasanya memiliki struktur yang kompleks dan tidak linear, prediksi produksi biogas secara matematis atau teoritis secara keseluruhan merupakan hal yang menantang [6]. Oleh karena itu, pendekatan berbasis *Deep Learning* mungkin lebih unggul daripada pendekatan teoritis atau matematis ketika sistem target (produksi biogas) memiliki kompleksitas yang lebih tinggi karena terdapat beberapa parameter. Dengan mengusulkan algoritma *Deep Learning* berbasis *Convolutional Neural Network* (CNN), penelitian ini dapat memprediksi kadar gas metana, nilai pH, suhu dan kelembapan yang kemudian dapat dijadikan acuan untuk meningkatkan produksi biogas.

Penelitian ini menggunakan algoritma CNN karena berdasarkan penelitian sebelumnya, algoritma ini menghasilkan akurasi yang lebih tinggi dibandingkan dengan algoritma lain seperti Naïve Bayes, RNN, DCNN, dan RCNN, dengan tingkat akurasi mencapai 90% [7]. Dari segi kecepatan prediksi produksi biogas, algoritma Naïve Bayes lebih cepat dibandingkan CNN. Namun, karena penelitian ini lebih memprioritaskan ketepatan analisis, algoritma CNN dianggap lebih sesuai untuk digunakan dalam memprediksi produksi biogas [8].

Kontribusi utama dari studi ini adalah pengembangan model prediksi parameter produksi biogas (metana, pH, suhu, dan kelembapan) yang mengintegrasikan teknologi IoT dengan arsitektur *Deep Learning* CNN untuk menangani kompleksitas data non-linear. Selain itu, penelitian ini memberikan studi perbandingan mengenai efektivitas algoritma CNN dalam memproses data pemantauan biogas dibandingkan dengan metode tradisional, guna memberikan acuan yang lebih akurat dalam optimalisasi produksi biogas dari sampah organik.

2. TINJAUAN PUSTAKA

2.1. Sistem Pemantauan Biogas Berbasis IoT

Integrasi teknologi *Internet of Things* (IoT) dalam operasional pembangkit biogas menandai era baru dalam pencapaian efisiensi optimal dan keberlanjutan pemanfaatan sumber daya. Penggunaan IoT memungkinkan pengumpulan dan pemrosesan data secara *real-time*, yang sangat krusial untuk pengambilan keputusan terkait pemilihan bahan baku dan pengendalian proses fermentasi anaerobik [9]. Melalui pemantauan parameter teknis seperti kualitas bahan baku, tingkat kelembapan, dan komposisi kimia substrat, sistem dapat menyempurnakan operasi untuk produksi gas yang maksimal.

Implementasi sensor yang terhubung dengan mikrokontroler seperti ESP32 telah terbukti efektif dalam memantau parameter kritis reaktor anaerobik secara jarak jauh. Penelitian terbaru menunjukkan bahwa sistem akuisisi data berbasis IoT mampu mentransmisikan data volume biogas, tekanan, dan suhu ke platform *cloud* dengan tingkat akurasi tinggi, di mana deviasi pembacaan sensor hanya berkisar antara 5–6% dibandingkan pengamatan aktual [10]. Kemampuan ini menghilangkan kebutuhan untuk inspeksi di lokasi secara terus-menerus dan memungkinkan deteksi dini terhadap kegagalan sistem.

Selain itu, penggunaan platform visualisasi data seperti ThingSpeak, Grafana, atau Blynk mempermudah pemantauan interaktif dan mendukung pengambilan keputusan yang lebih cepat [11]. Dalam sistem skala kecil maupun rumah tangga, penggunaan sensor biaya rendah seperti MQ-4 untuk deteksi metana dan DS18B20 untuk suhu terbukti memberikan hasil yang linear dan presisi, selama proses kalibrasi dilakukan dengan standar yang tepat [12], [13], [14].

2.2. Karakteristik dan Keunggulan *Convolutional Neural Networks* (CNN)

Convolutional Neural Networks (CNN) merupakan jenis model *neural network* dengan struktur *fully connected* yang neuronnya terhubung dengan *layer* sebelumnya. Keunggulan utama CNN dibandingkan model biasa adalah kemampuannya menangkap informasi kontekstual yang mendalam, seperti hubungan antar piksel pada gambar atau kedekatan kata dalam teks. Dalam perkembangannya, metode *deep learning* ini telah terbukti sangat efektif untuk prosedur pengenalan dan validasi objek yang kompleks [15].

2.3. Implementasi Arsitektur 1D-CNN untuk Prediksi Data Time Series

Penggunaan model hibrida seperti Catboost-CNN-LSTM telah diterapkan untuk menganalisis variabel produksi biogas, seperti limbah dapur dan sisa organik lainnya. Arsitektur CNN mampu memodelkan dataset topologi *grid* dan kompatibel dengan berbagai format input, mulai dari 1D hingga nD. Secara khusus, arsitektur 1D-CNN memberikan hasil yang kuat dalam menangani masalah seri waktu (*time series*) [16].

2.4. Perbandingan Performa Algoritma Prediksi

Dalam analisis ketepatan prediksi, algoritma 1D-CNN menunjukkan tingkat akurasi yang unggul mencapai 90%. Jika dibandingkan dengan algoritma lain seperti *Naïve Bayes*, RNN, DCNN, dan RCNN, 1D-CNN dinilai lebih sesuai untuk penelitian yang memprioritaskan ketepatan analisis data, meskipun metode *Naïve Bayes* memiliki keunggulan dari segi kecepatan prediksi. Berikut adalah ringkasan perbandingannya [17], [18], [19].

TABEL I. PERBANDINGAN PERFORMA ALGORITMA PREDIKSI

Metode	Akuras i	Substrat	Referens i
CNN	92%	Sugarcane Bagasse	[9]
SVM	95%	Wastewater	[10]
RF	91%	Food Waste	[10]
1D-CNN	90%	Sentiment/Gener al Data	[11]
Catboost -CNN- LSTM	High	Industrial Biogas	[10]

3. METODE PENELITIAN

Tahapan penelitian ini dirancang secara sistematis untuk mencakup seluruh siklus hidup pengembangan sistem, mulai dari perancangan fisik biodigester hingga optimalisasi model prediksi berbasis *Deep Learning*. Pendekatan ini memastikan bahwa data yang dihasilkan oleh sensor memiliki integritas yang tinggi sehingga layak digunakan sebagai masukan model CNN. Penelitian ini mengikuti alur kerja yang dimulai dari akuisisi data hingga evaluasi model.

Struktur dataset yang digunakan terdiri dari setidaknya 2400 baris data sensor, dimana didapat dari pola pengambilan data yang diambil setiap 30 detik (2 data per menit) selama 20 jam (1.200 menit). Fitur input meliputi:

1. Timestamp (Waktu pengukuran).

2. Kadar Metana (ppm) dari sensor MQ-4.
3. Suhu (°C) dan Kelembapan (%) dari sensor DHT11.
4. Tingkat Keasaman (pH) dari sensor Depoinovasi.

Metrik Evaluasi: Model dievaluasi menggunakan empat metrik utama: RMSE, MAE, MAPE, dan R² Nilai-nilai ini akan dipaparkan secara lengkap pada bagian hasil untuk menunjukkan konsistensi prediksi

3.1. Perancangan Biodigester dan Integrasi Perangkat Keras

Biodigester digunakan dalam penelitian ini adalah tipe *batch* dengan kapasitas operasional sekitar 60 liter. Struktur utama terbuat dari material polimer yang tahan terhadap korosi asam hasil fermentasi. Digester dilengkapi dengan dua saluran utama, saluran *inlet* untuk memasukkan sampah organik dan saluran *outlet* gas yang terhubung ke sistem penampungan melalui katup kontrol elektrik (*solenoid valve*).

Sistem akuisisi data dibangun di atas platform mikrokontroler ESP32. Pemilihan ESP32 didasarkan pada keberadaan modul Wi-Fi terintegrasi dan kemampuan pemrosesan yang cukup untuk menangani bebrapa sensor secara simultan. Arsitektur sensor yang diimplementasikan meliputi:

1. Sensor MQ-4: Berfungsi untuk mendeteksi konsentrasi gas metana.
2. Sensor DHT11: Mengukur suhu dan kelembapan udara di dalam ruang kepala (*headspace*) digester.
3. Sensor pH Depoinovasi: Mengukur tingkat keasaman lumpur organik.
4. *Solenoid Valve*: Digunakan sebagai mekanisme pelepasan gas otomatis jika konsentrasi gas metana mencapai ambang batas keamanan atau operasional tertentu.

Data sensor dibaca dengan interval setiap 30 detik untuk memastikan resolusi data yang cukup tinggi guna menangkap fluktuasi jangka pendek. Seluruh data kemudian ditransmisikan ke Layanan Google Spreadsheet yang bertindak sebagai database *cloud* sementara untuk mempermudah akses dan analisis data.

3.2. Arsitektur Model CNN

Model prediksi dikembangkan menggunakan arsitektur 1D-CNN. Tidak seperti 2D-CNN yang menggunakan filter berbentuk persegi untuk gambar, 1D-CNN menggunakan filter linier yang bergerak sepanjang sumbu waktu. Hal ini memungkinkan model

untuk mempelajari pola temporal, seperti bagaimana penurunan suhu pada malam hari dapat memengaruhi laju produksi gas.

Pelatihan model dilakukan dengan membagi dataset menjadi 80% data latih dan 20% data uji. Fungsi aktivasi yang digunakan adalah ReLU (*Rectified Linear Unit*) untuk lapisan tersembunyi guna memperkenalkan non-linearitas, dan Adam *optimizer* digunakan untuk menyesuaikan bobot jaringan secara efisien.

3.3. Metrik Evaluasi Performa

Untuk mengukur sejauh mana model dapat memprediksi nilai aktual dengan benar, digunakan beberapa metrik statistik, yaitu: [20], [21], [22]

- *Root Mean Square Error* (RMSE): Memberikan penalti lebih besar pada kesalahan yang besar. Semakin rendah nilai RMSE, semakin baik model menangkap pola data. Persamaan RMSE yang digunakan dapat dilihat pada persamaan (1)

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

- *Mean Absolute Error* (MAE): Menunjukkan rata-rata selisih absolut antara prediksi dan nilai actual.
- *Mean Absolute Percentage Error* (MAPE): Memberikan Gambaran persentase kesalahan relatif terhadap skala data yang diprediksi.
- *R-Squared* (R^2): Menunjukkan seberapa baik variabilitas data dapat dijelaskan oleh model. Nilai mendekati 1 menandakan model yang sangat akurat.

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan data hasil pengujian sistem IoT dan analisis performansi model CNN. Diskusi difokuskan pada interpretasi metrik akurasi dan implikasi fisik dari tren data yang diamati selama periode fermentasi sampah organik.

4.1. Evaluasi Skenario Pelatihan Model CNN

Penentuan jumlah *epoch* yang optimal sangat penting untuk mencegah *underfitting* atau *overfitting*. Dalam penelitian ini dilakukan eksperimen dengan variasi *epoch* dari 1 hingga 500.

Hasil eksperimen menunjukkan bahwa:

- *Epoch* 1-100: Terjadi penurunan drastis pada nilai *loss* RMSE. Ini menandakan model sedang belajar

dengan cepat untuk mengenali pola-pola dasar dalam data sensor.


- *Epoch* 100-300: Penurunan error mulai konvergen. Pada titik ini, model mulai menyempurnakan prediksi pada detail-detail kecil.
- *Epoch* 300+: Nilai RMSE pada data latih terus menurun, namun data pada validasi mulai terlihat peningkatan sedikit, yang merupakan indikasi awal *overfitting*.

Berdasarkan data diatas, pelatihan optimal tercapai pada 300 *Epoch*, di mana model memiliki keseimbangan terbaik antara akurasi dan kemampuan generalisasi.

4.2. Akurasi Prediksi Parameter Biogas

Model CNN yang telah dilatih kemudian diuji menggunakan data yang belum pernah dilihat sebelumnya (data uji). Berikut adalah analisis mendalam untuk setiap parameter utama.

4.2.1. Konsentrasi Gas Metana (ppm)



Gambar 1. Hasil Prediksi Modul terhadap data gas metana

Pada gambar 1 dapat dilihat garis merah mengikuti garis biru dengan cukup dekat, ini menunjukkan bahwa model CNN dapat menangkap pola utama dalam data ini.


Pada tabel II menunjukkan model dilatih selama 300 *Epoch*. Hasil pengujian menunjukkan bahwa CNN sangat mahir dalam memprediksi konsentrasi gas dengan nilai *R-Squared* mencapai 0.99661. Hal ini berarti model mampu menjelaskan lebih dari 99% variasi data dalam gas metana. Nilai MAE sebesar 9.1418 dan MAPE sebesar 1.3888% menunjukkan bahwa rata-rata kesalahan prediksi sangat kecil dibandingkan dengan skala pengukuran ppm yang ribuan. Keberhasilan ini didorong oleh karakteristik

data metana yang memiliki tren akumulasi yang relatif mulus dalam sistem biodigester tertutup.

TABEL II. PERFORMANSI AKURASI KONSENTRASI GAS METANA

Epoch	Iteration	Mini-batch RMSE	Mini-batch Loss	Base Learning Rate
1	1	108.88	5927.7	0.0010
50	50	32.56	530.2	0.0010
100	100	21.83	238.3	0.0010
150	150	15.49	120.0	0.0010
200	200	13.39	89.7	0.0010
250	250	12.67	80.3	0.0010
300	300	12.26	75.2	0.0010

4.2.2. Parameter Suhu



Gambar 2. Hasil Prediksi Modul Terhadap Data Suhu

Pada gambar 2 menunjukkan plot dari prediksi *time series* untuk suhu menggunakan CNN, terlihat plot mengalami tren turun ketika malam hari, dan tren naik ketika siang hari yang menandakan perubahan suhu di biodigester bergantung pada aktivitas matahari.

TABEL III. PERFORMANSI AKURASI DATA SUHU


Epoch	Iteration	Mini-batch RMSE	Mini-batch Loss	Base Learning Rate
1	1	43.10	929.0	0.0010
50	50	7.52	28.3	0.0010
100	100	6.19	19.2	0.0010
150	150	4.51	10.2	0.0010
200	200	3.10	4.8	0.0010
250	250	2.33	2.7	0.0010
300	300	2.08	2.2	0.0010

Berdasarkan tabel III model dilatih selama 300 *Epoch* yang mana pada akhir pelatihan terlihat RMSE bernilai 2.08 dan *R-Squared* sebesar 0.8982. Meskipun akurasi tinggi, variabilitas suhu mencapai 10% tidak dapat dijelaskan sepenuhnya oleh model, yang kemungkinan disebabkan oleh faktor lingkungan luar yang tidak terduga.

4.2.3. Parameter pH

Tingkat keasaman (pH) merupakan indikator kritis dalam fermentasi anaerobik. Untuk produksi biogas yang optimal dari sampah organik, pH harus dijaga pada rentang 6,8 hingga 7,5. Jika pH turun di bawah 6,0 (terlalu asam), bakteri metanogen akan terhambat, sehingga produksi metana menurun drastis.


Dalam pengujian ini, sampah organik rumah tangga cenderung mengalami asidifikasi di awal, namun model CNN berhasil menangkap tren kenaikan pH menuju angka 7,0 (netral) yang menunjukkan lingkungan biodigester telah stabil dan mendukung aktivitas mikroba.



Gambar 3. Hasil Prediksi Modul terhadap data pH

Gambar 3 menunjukkan plot dari prediksi *time series* untuk pH menggunakan CNN. Terlihat plot mengalami fluktuasi yang besar dan juga tidak menentu. Oleh sebab itu, untuk melihat tren dengan mudah dibuat *scatter plot* dan *linear regression* untuk pH.

Terlihat pada gambar 4 bahwa pH dalam biogester mengalami tren naik seiring waktu, pH di biogester rata-rata bernilai 7 yang berarti dalam keadaan netral.



Gambar 4. Scatter Plot dan pH

TABEL IV. PERFORMANSI AKURASI DATA pH

Epoch	Iteration	Mini-batch RMSE	Mini-batch Loss	Base Learning Rate
1	1	5.81	16.9	0.0010
50	50	1.65	1.4	0.0010
100	100	1.25	0.8	0.0010
150	150	1.05	0.6	0.0010
200	200	0.91	0.4	0.0010
250	250	0.85	0.4	0.0010
300	300	0.79	0.3	0.0010

Pada tabel IV dapat dilihat bahwa pelatihan untuk parameter data pH dilakukan hingga 300 *Epoch*. Karena adanya fluktuasi yang bising dari sensor Depoinovasi, nilai *R-Squared* hanya mencapai 0.66335. Meskipun demikian, RMSE sebesar 0.79 menunjukkan bahwa kesalahan absolut masih dalam batas yang dapat diterima untuk aplikasi praktis. Fluktuasi data pH yang terjadi kurang lebih setiap 20 titik data menunjukkan keterbatasan perangkat keras, namun secara makro, model CNN masih mampu menangkap tren kenaikan pH seiring berjalannya proses fermentasi.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pembahasan mengenai penerapan metode *Convolutional Neural Network* (CNN) berbasis IoT untuk analisis produksi biogas, dapat ditarik kesimpulan sebagai berikut:

1. Sistem IoT yang dirancang berhasil melakukan akuisisi data parameter biogas (metana, suhu, dan pH) secara real-time dengan interval 30 detik. Integrasi sensor MQ-4, DHT11, dan sensor pH dengan ESP32 memungkinkan pemantauan

kondisi biodigester secara kontinu yang disimpan langsung ke dalam *cloud*.

2. Performa Prediksi Metana sebagai Indikator Utama. Metode CNN menunjukkan efektivitas yang luar biasa dalam memprediksi konsentrasi gas metana, yang merupakan parameter paling krusial dalam produksi energi biogas. Validasi model menunjukkan nilai R^2 sebesar 0,9966, yang mengindikasikan bahwa model mampu merepresentasikan 99,66% varians data aktual dengan sangat presisi. Selain itu, tingkat kesalahan rata-rata (MAPE) yang hanya sebesar 1,38% berada jauh di bawah ambang batas 10%, sehingga secara statistik model ini masuk ke dalam kategori "Prediksi Sangat Akurat". Didukung dengan nilai RMSE sebesar 12,26 dan MAE sebesar 9,1418, model ini terbukti memiliki stabilitas yang tinggi dalam menghadapi fluktuasi produksi gas. Sebagaimana dinyatakan oleh Mukasine dkk., dalam pemodelan produksi biogas, metana sering kali menjadi fokus utama evaluasi performa karena nilai kalornya yang menentukan efektivitas sistem secara keseluruhan [18].
3. Pada parameter suhu biodigester, model CNN berhasil mencapai tingkat kepercayaan yang tinggi dengan nilai R^2 sebesar 0,8982. Efektivitas prediksi suhu didukung oleh nilai RMSE sebesar 2,08, MAE sebesar 1,85, dan MAPE sebesar 7,12%. Meskipun suhu lingkungan biodigester dipengaruhi oleh faktor eksternal, model tetap mampu menekan angka kesalahan di bawah 10%, yang membuktikan bahwa arsitektur CNN dapat mengenali pola termal yang diperlukan untuk menjaga stabilitas proses fermentasi anaerobik.
4. Parameter tingkat keasaman (pH) diuji secara ketat dan menghasilkan nilai RMSE sebesar 0,79, MAE sebesar 0,62, serta MAPE sebesar 8,85%. Walaupun nilai R^2 tercatat sebesar 0,6633 (lebih rendah dibanding metana karena sensitivitas sensor pH terhadap *noise* biologis dan interferensi kimia dalam limbah), nilai MAPE yang tetap berada di bawah 10% mengonfirmasi bahwa prediksi model masih dalam rentang toleransi operasional yang aman. Kemampuan model dalam

memprediksi pH sangat penting karena stabilitas pH di angka netral (6,8–7,5) merupakan syarat mutlak bagi aktivitas mikroba metanogen dalam mengurai sampah organik.

Secara keseluruhan, sistem ini dinyatakan berhasil memenuhi empat kriteria evaluasi statistik pada ketiga parameter utama secara konsisten. Keberhasilan menekan nilai MAPE di bawah 10% untuk seluruh parameter (Metana, Suhu, dan pH) membuktikan bahwa integrasi IoT dan CNN bukan hanya sekadar alat pemantau, melainkan sistem prediksi cerdas yang mampu meminimalisir risiko kegagalan produksi biogas akibat ketidakstabilan variabel biologis dalam pengolahan sampah organik. Hal ini sejalan dengan penelitian Kasulla dkk. yang menyatakan bahwa parameter biologis dalam biodigester memiliki sifat non-linearitas yang tinggi [17].

UCAPAN TERIMA KASIH

Ucapan terima kasih dapat diberikan kepada penyandang dana penelitian dan orang yang memberikan bio ilmiah pada penelitian namun bukan merupakan penulis artikel ini.

DAFTAR PUSTAKA

- [1] I. Febijanto *et al.*, "Techno-enviro-economic assessment of bio-CNG derived from Palm Oil Mill Effluent (POME) for public transportation in Pekanbaru City," *Renew. Energy Focus*, vol. 49, no. 100569, p. 100569, June 2024.
- [2] F. N. Rahmat, "Analisis Pemanfaatan Sampah Organik Menjadi Energi Alternatif Biogas," *J. En. Baru & Terbarukan*, vol. 4, no. 2, pp. 118–122, Sept. 2023.
- [3] P. Pamikatsih, G. D. Agcaya, and A. Mulyaningtyas, "Pengaruh Suhu dan pH Ekstraksi Pektin dari Limbah Kulit Buah," *Bioeksperimen J. Penelit. Biol.*, vol. 7, no. 2, pp. 112–120, Dec. 2021.
- [4] M. S. Rana, R. Nandi, and J.-Q. Ni, "Characteristic drivers of biochar and nanomaterials in anaerobic digestion across all stages for augmented methane-rich biogas production," *Fuel (Lond.)*, vol. 406, no. 137023, p. 137023, Feb. 2026.
- [5] S. Utami, P. Iriani, and Y. Suprianti, "Sistem Monitoring pH dan Volume Biogas Digester Dua Tahap menggunakan Mikrokontroler," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 7, no. 1, p. 126, Jan. 2019.
- [6] K. Jeong, A. Abbas, J. Shin, M. Son, Y. M. Kim, and K. H. Cho, "Prediction of biogas production in anaerobic co-digestion of organic wastes using deep learning models," *Water Res.*, vol. 205, no. 117697, p. 117697, Oct. 2021.
- [7] M. Rajwadi, C. Glackin, J. Wall, G. Chollet, and N. Cannings, "Explaining Sentiment Classification," in *Interspeech 2019*, ISCA: ISCA, Sept. 2019. doi: 10.21437/interspeech.2019-2743.
- [8] F. Fahry, T. C. Miswaty, and H. Harun, "Analyzing marketplace reviews using Word2Vec, CNN, and deep K-Means with sociolinguistic approaches," *J. Tek. Inform. (JUTIF)*, vol. 6, no. 6, pp. 5489–5502, Dec. 2025.
- [9] S. Swami, S. Suthar, S. R. Addula, V. Kumar Saini, Komal, and A. Lande, "IoT-Based Smart Solution for Biogas Plant Operation," in *2023 International Conference on Smart Devices (ICSD)*, IEEE, May 2024, pp. 1–5.
- [10] A. Li, A. Pandey, and P. Pandey, "Application of IoT in monitoring greenhouse gas emissions in anaerobic reactors," *Energies*, vol. 18, no. 23, p. 6191, Nov. 2025.
- [11] Asminar, A. Djohar, S. Rifaldi, Rifki, M. A. Raswadi, and A. Sadewa, "Smart biogas: An independent energy system based on organic waste integrated with IoT," *Applied Environmental Science*, vol. 3, no. 2, pp. 112–130, Dec. 2025.
- [12] K. Sharma, A. Singh, Arvind, D. Chawla, Sushant, and R. Kumar, "Monitoring system for biogas plant: An IOT based approach," in *2024 1st International Conference on Sustainability and Technological Advancements in Engineering Domain (SUSTAINED)*, IEEE, Dec. 2024, pp. 485–491.
- [13] I. G. A. Negara, D. S. Anakottapary, I. A. A. Arsani, I. N. L. Antara, and T. G. T. Nindhia, "Quantitative analysis of methane in a biogas reactor using an MQ-4 sensor for low-cost monitoring," in *Advances in Engineering Research*, in *Advances in Engineering Research*, Dordrecht: Atlantis Press International BV, 2025, pp. 175–183.
- [14] S. Dedgaonkar, A. Kaalay, N. Biyani, and M. Mohite, "Biogas monitoring system using DS18B20 temperature sensor and MQTT protocol," in *Intelligent Computing and Information and Communication*, in *Advances in Intelligent Systems and Computing*, Singapore: Springer Singapore, 2018, pp. 567–577.
- [15] J. Lubura *et al.*, "Food recognition and food waste estimation using convolutional neural network," *Electronics (Basel)*, vol. 11, no. 22, p. 3746, Nov. 2022.
- [16] S. Sukatmo, H. A. Nugroho, B. H. Rusanto, and S. Soekirno, "Performance comparison of 1D-CNN and LSTM deep learning models for time series-based electric power prediction," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 13, no. 1, p. 44, Feb. 2025.

- [17] S. Kasulla, S. J. Malik, A. Yadav, G. Kathpal, and S. Zafar, "Harnessing convolutional neural networks for the optimization of anaerobic digestion of sugarcane bagasse: A novel approach to pretreatment strategies and microbial activity prediction," *African Journal of Biomedical Research*, vol. 28, no. 2S, pp. 601–618, Feb. 2025.
- [18] A. Mukasine, L. Sibomana, K. Jayavel, K. Nkurikiyeyezu, and E. Hitimana, "Maximizing biogas yield using an optimized stacking ensemble machine learning approach," *Energies*, vol. 17, no. 2, p. 364, Jan. 2024.
- [19] I. B. R. W. Manuaba, R. Dwiyanaputra, and M. Z. Hamidi, "PENDEKATAN SENTIMEN BERBASIS ASPEK PADA ULASAN SIRKUIT MANDALIKA MENGGUNAKAN CNN DAN REPRESENTASI FASTTEXT," *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTIKA)*, vol. 7, no. 1, pp. 132–141, Mar. 2025.
- [20] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput. Sci.*, vol. 7, no. e623, p. e623, July 2021.
- [21] S. Aree and S. Tooprakai, "Maintenance decision modeling for solar photovoltaic performance prediction using RMSE and MAPE methods," in *2025 International Technical Conference on Circuits/Systems, Computers, and Communications (ITC-CSCC)*, IEEE, July 2025, pp. 1–6.
- [22] A. N. A. Mahmad Azan, N. F. A. Mohd Zulkifly Mototo, and P. J. W. Mah, "The comparison between ARIMA and ARFIMA model to forecast Kijang Emas (gold) prices in Malaysia using MAE, RMSE and MAPE," *Journal of Computing Research and Innovation*, vol. 6, no. 3, pp. 22–33, Sept. 2021.