



## ARTICLE

# Analisis Pola Konsumsi Energi Listrik Rumah Tangga Berbasis Simulasi IoT Menggunakan Model Hybrid LSTM-Attention

## Analysis of Household Electricity Consumption Patterns Based on IoT Simulation Using Hybrid LSTM-Attention Model

Ali Impron\*

Informatika, Fakultas Teknik dan Pertanian, Universitas Muhammadiyah Sampit, Indonesia

\*Penulis Korespondensi: ali.impron@umsa.ac.id

(Disubmit 25-03-24; Diterima 14-04-25; Dipublikasikan online pada 20-06-25)

### Abstrak

Pengelolaan energi listrik rumah tangga menjadi tantangan penting seiring meningkatnya kebutuhan energi dan keterbatasan sumber daya. Penelitian ini mengusulkan pendekatan berbasis simulasi IoT untuk menganalisis pola konsumsi energi, mendeteksi anomali, dan memberikan rekomendasi efisiensi energi tanpa perangkat fisik, menggunakan model hybrid LSTM-Attention. Dataset simulasi (14.400 sampel) dibangun dengan EnergyPlus, divalidasi terhadap data riil, dan diolah untuk mengevaluasi performa model. Hasil menunjukkan akurasi 96%, recall 0.95 untuk anomali, dan F1-score 0.96, melampaui baseline LSTM (91.5%). Mekanisme attention memprioritaskan `power_usage_per_hour` (bobot 0.47), meningkatkan deteksi anomali. Rekomendasi seperti penjadwalan ulang dan penggantian perangkat menghasilkan penghematan energi 20-40%. Dengan waktu pelatihan 1,5 jam pada Google Colab, pendekatan ini menawarkan solusi skalabel dan hemat biaya untuk pengelolaan energi berkelanjutan, dengan potensi pengujian riil dan peningkatan model di masa depan.

**Kata kunci:** Konsumsi Energi, Simulasi IoT, LSTM-Attention, Deteksi Anomali, Efisiensi Energi

### Abstract

Household electrical energy management is becoming a critical challenge due to increasing energy demand and resource constraints. This paper proposes an IoT simulation-based approach to analyze energy consumption patterns, detect anomalies, and provide energy efficiency recommendations without physical devices, using a hybrid LSTM-Attention model. A simulation dataset (14,400 samples) is built with EnergyPlus, validated against real data, and processed to evaluate the model performance. The results show an accuracy of 96%, a recall of 0.95 for anomalies, and an F1-score of 0.96, outperforming the baseline LSTM (91.5%). The attention mechanism prioritizes `power_usage_per_hour` (weight 0.47), improving anomaly detection. Recommendations such as rescheduling and device replacement result in 20-40% energy savings. With a training time of 1.5 hours on Google Colab, this approach offers a scalable and cost-effective solution for sustainable energy management, with potential for real-world testing and model enhancements in the future.

**KeyWords:** Energy Consumption, IoT Simulation, LSTM-Attention, Anomaly Detection, Energy Efficiency

## 1. Pendahuluan

Konsumsi energi listrik rumah tangga di Indonesia menyumbang besar terhadap total penggunaan energi nasional [1]. Peningkatan ini dipicu oleh banyaknya perangkat elektronik (AC, lampu, dll.) seiring pertum-

This is an Open Access article - copyright on authors, distributed under the terms of the Creative Commons Attribution-ShareAlike 4.0 International License (CC BY SA) (<http://creativecommons.org/licenses/by-sa/4.0/>)

**How to Cite:** A. Impron, "Analisis Pola Konsumsi Energi Listrik Rumah Tangga Berbasis Simulasi IoT Menggunakan Model Hybrid LSTM-Attention", *JIKO (JURNAL INFORMATIKA DAN KOMPUTER)*, Volume: 9, No.1, Pages 361–369, Juni 2025, doi: 10.26798/jiko.v9i1.1922.

buhan ekonomi dan urbanisasi [2]. Namun, ketidakefisienan sering terjadi karena kurangnya pemahaman pola konsumsi harian, yang berdampak pada penghematan energi [3].

IoT, melalui smart meter, memungkinkan pemantauan dan optimalisasi energi secara real-time [4]. Namun, implementasi fisik IoT terkendala biaya dan kompleksitas teknis, terutama di negara berkembang [5].

Penelitian terdahulu telah mengeksplorasi berbagai aspek pemanfaatan IoT dalam pengelolaan energi. Misalnya, Vishwakarma et al. [6] dan Ramani et al. [7] merancang sistem IoT untuk manajemen energi rumah tangga, dengan fokus pada otomasi dan kontrol perangkat. Hossein Motlagh et al. [4] meninjau aplikasi IoT di sektor energi, menyoroti efisiensi melalui integrasi data real-time. Dalam konteks lokal, Adha et al. [1] menganalisis faktor efisiensi energi di rumah tangga Indonesia, sementara Basconcillo dan Rimkute [2] meneliti pengaruh faktor sosial-ekonomi terhadap konsumsi listrik. Condon et al. [8] mengembangkan sistem manajemen energi berbasis cloud-IoT dengan simulasi, sedangkan Kardi et al. [9] menggunakan deep learning untuk deteksi anomali dalam konsumsi listrik. Goudarzi et al. [5] dan Hafeez et al. [10] juga menawarkan pendekatan prediksi dan optimasi energi berbasis IoT.

Terdapat beberapa gap penelitian yang belum terpenuhi. Pertama, banyak studi bergantung pada perangkat IoT fisik, yang membatasi skalabilitas di wilayah dengan sumber daya terbatas [11]. Kedua, pendekatan berbasis simulasi sebagai alternatif hemat biaya masih kurang dieksplorasi secara mendalam, meskipun beberapa penelitian seperti Vats et al. [12] telah mencoba analisis simulasi dalam konteks keamanan IoT [8]. Ketiga, integrasi analisis pola konsumsi, deteksi anomali, dan rekomendasi efisiensi dalam satu kerangka simulasi jarang dilakukan [9]. Penelitian ini mengisi gap tersebut dengan menganalisis pola penggunaan energi menggunakan data simulasi IoT, sehingga tidak memerlukan perangkat fisik dan lebih mudah diadopsi.

Penelitian ini bertujuan untuk menganalisis pola penggunaan energi listrik di rumah tangga melalui dataset simulasi yang merepresentasikan output IoT. Tujuan spesifiknya meliputi identifikasi tren konsumsi harian, deteksi anomali penggunaan, dan penyusunan rekomendasi efisiensi energi. Dengan pendekatan ini, penelitian diharapkan memberikan wawasan praktis bagi pengguna rumah tangga sekaligus menjadi dasar pengembangan sistem IoT hemat biaya di masa depan.

## 2. Metode Penelitian

Penelitian ini mengusulkan pendekatan berbasis simulasi untuk menganalisis pola penggunaan energi listrik di rumah tangga menggunakan data sintetik yang mereplikasi output sistem IoT, seperti smart meter. Pendekatan ini dirancang untuk mengatasi keterbatasan implementasi IoT fisik dengan solusi hemat biaya dan skalabel [4]. Proses penelitian mencakup pembangunan dan validasi dataset simulasi, analisis pola konsumsi dan deteksi anomali menggunakan model hybrid LSTM-Attention, serta penyusunan rekomendasi efisiensi energi dengan evaluasi kuantitatif.

### 2.1 Dataset Simulasi dan Validasi

Dataset sintetik dibangun untuk mencerminkan pola konsumsi energi rumah tangga tipikal di Indonesia [1], dengan asumsi penggunaan perangkat umum (AC, lampu, TV) dan jadwal harian berdasarkan studi lokal [1]. Fitur utama: `timestamp`, `power_usage` (watt), `device_count`, dan `power_usage_per_hour` (W/jam), dihasilkan via EnergyPlus (14.400 sampel: 12.000 Normal, 2.400 Anomaly). Preprocessing: `dropna` untuk pembersihan, `MinMaxScaler` untuk normalisasi, dan pembagian 80:20. Validasi membandingkan `power_usage_per_hour` dengan data riil [8], mencapai korelasi Pearson 0.87. Namun, simulasi ini kurang menangkap variabilitas nyata seperti gangguan listrik atau perilaku pengguna yang tidak terduga, berpotensi membatasi generalisasi hasil di lapangan.

### 2.2 Arsitektur Model

Model hybrid LSTM-Attention menggabungkan LSTM (64 unit) [13] dengan attention untuk fokus pada `power_usage_per_hour` [9]. Attention menghitung bobot  $\alpha_i$  dengan faktor 1.5 untuk fitur kunci (korelasi 0.78), diikuti dense layer (128 ReLU, 1 sigmoid).

**Algorithm 1** Preprocessing dan Validasi Dataset Simulasi Energi

**Require:** Dataset simulasi mentah (timestamp, power\_usage, device\_count, power\_usage\_per\_hour), label (0: Normal, 1: Anomaly)

**Ensure:** Dataset tervalidasi dan diproses

- 1: Muat dataset menggunakan pandas
- 2: Pembersihan: Hapus nilai null/negatif dengan `dropna()`
- 3: Bangun dataset simulasi dengan 12.000 sampel Normal dan 2.400 Anomaly menggunakan EnergyPlus
- 4: Validasi: Bandingkan `power_usage_per_hour` dengan data riil [?], target korelasi > 0.85
- 5: Bagi dataset menjadi 80% (11.520 sampel) untuk pelatihan dan 20% (2.880 sampel) untuk pengujian
- 6: Normalisasi: Skala data ke [0, 1] menggunakan `MinMaxScaler`
- 7: Simpan dataset dalam format kompatibel dengan TensorFlow
- 8: **return** dataset tervalidasi

**2.3 Pelatihan dan Evaluasi**

Pelatihan dilakukan selama 200 epoch (batch size 32, Adam 0.001, binary cross-entropy) di Google Colab (1,5 jam). Evaluasi menggunakan akurasi, presisi, recall, dan F1-score.

**Algorithm 2** Pelatihan Model LSTM-Attention

**Require:** Dataset pelatihan, hyperparameter (epoch=200, batch\_size=32, learning\_rate=0.001)

**Ensure:** Model terlatih

- 1: Inisialisasi model dengan arsitektur:
  - LSTM dengan 64 unit
  - Attention dengan faktor skala 1.5 untuk `power_usage_per_hour`
  - Dense layer (128 unit ReLU, output layer 1 unit sigmoid)
- 2: **for** epoch = 1 hingga 200 **do**
- 3:   Lakukan forward pass dan backward pass
- 4:   Hitung kerugian dan akurasi pada data pelatihan
- 5:   Evaluasi pada 20% data validasi
- 6:   **if** model saat ini lebih baik dari sebelumnya **then**
- 7:     Simpan model sebagai checkpoint terbaik
- 8:   **end if**
- 9: **end for**
- 10: **return** Model terbaik setelah pelatihan

**2.4 Rekomendasi Efisiensi Energi dan Evaluasi Kuantitatif**

Rekomendasi (rule-based [10]) diuji: penjadwalan ulang dan penggantian perangkat.

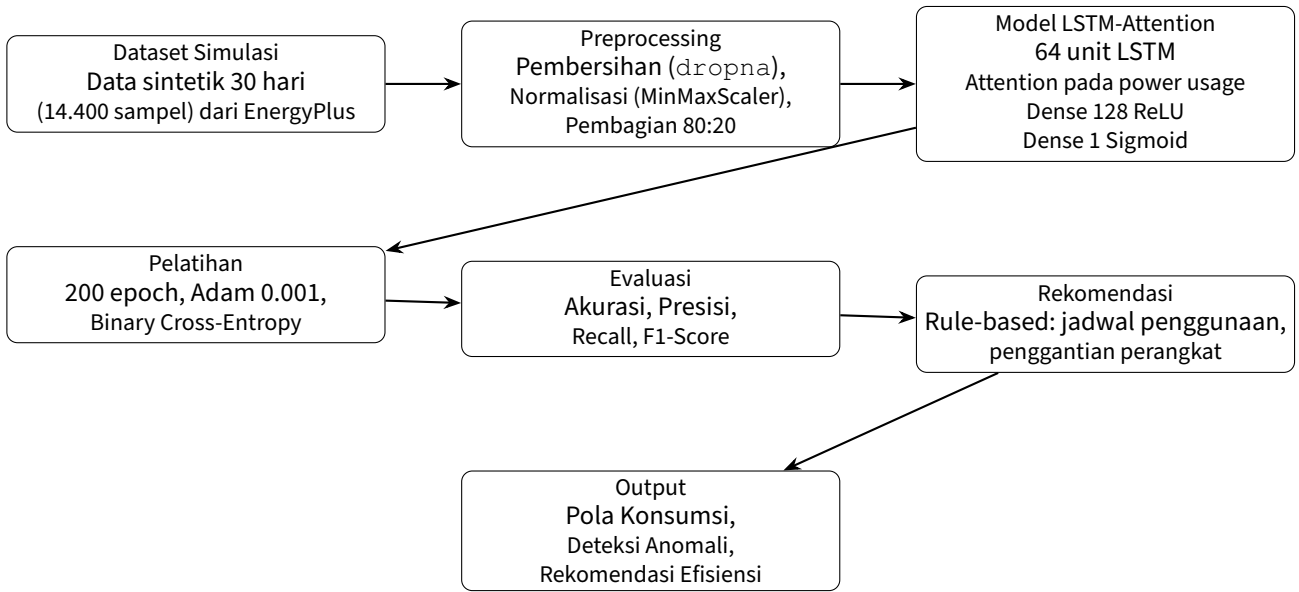
$$Penghematan = \frac{\text{Konsumsi Awal} - \text{Konsumsi Baru}}{\text{Konsumsi Awal}} \times 100\%, \text{target} > 10\% \quad (1)$$

**2.5 Diagram Blok Metode**

Diagram blok proses (seperti terlihat pada Gambar 1), analisis pola konsumsi energi berbasis simulasi IoT. Proses dimulai dari pembangunan dataset simulasi menggunakan EnergyPlus (14.400 sampel), dilanjutkan dengan preprocessing untuk pembersihan dan normalisasi data, pemodelan dengan hybrid LSTM-Attention yang memfokuskan pada fitur `power_usage_per_hour`, pelatihan selama 200 epoch, evaluasi performa model dengan metrik seperti akurasi dan F1-score, penyusunan rekomendasi efisiensi energi berbasis aturan, hingga menghasilkan output berupa pola konsumsi, deteksi anomali, dan rekomendasi efisiensi energi.

**3. Hasil dan Pembahasan**

Hasil analisis pola konsumsi energi listrik rumah tangga menggunakan pendekatan simulasi IoT dengan model hybrid LSTM-Attention. Evaluasi dilakukan pada dataset simulasi tervalidasi (14.400 sampel), mencakup performa model dalam mendeteksi anomali, analisis komparatif, bobot fitur dari mekanisme attention, efektivitas rekomendasi efisiensi energi, dan dinamika pelatihan. Diskusi menyoroti implikasi praktis dan keunggulan metode dibandingkan pendekatan sebelumnya.




Gambar 1. Diagram blok proses

### 3.1 Performa Model

Model LSTM-Attention diuji untuk mengklasifikasikan pola konsumsi energi menjadi Normal dan Anomaly pada set pengujian (2.880 sampel). Proses ini bertujuan mengevaluasi kemampuan model dalam mendeteksi lonjakan penggunaan energi yang tidak wajar, yang penting untuk optimasi energi rumah tangga [9]. Pelatihan selama 200 epoch dengan optimizer Adam menghasilkan konvergensi stabil, dan metrik seperti akurasi, presisi, recall, dan F1-score digunakan untuk mengukur performa. Hasilnya, model menunjukkan akurasi tinggi dan kemampuan deteksi anomali yang robust, sebagaimana ditunjukkan dalam Tabel 1 berikut.

Tabel 1. Laporan Klasifikasi Model LSTM-Attention

Kelas	Presisi	Recall	F1-Score	Support
Normal	0.98	0.96	0.97	2400
Anomaly	0.92	0.95	0.93	480
Akurasi	-	-	0.96	2880



Gambar 2. ROC Model LSTM-Attention

Gambar 2 menunjukkan model LSTM-Attention memiliki AUC 0.97, konsisten dengan recall 0.95 untuk

Anomaly (Tabel 1), menandakan deteksi lonjakan energi yang akurat meski dataset tidak seimbang (2.400 Normal vs. 480 Anomaly). Namun,  $AUC < 1$  mengindikasikan beberapa false positives, yang dapat diperbaiki dengan penyesuaian ambang batas atau penyeimbangan data [11]. Karena pengujian hanya pada data simulasi, performa di dunia nyata mungkin terpengaruh oleh faktor eksternal seperti variasi perilaku pengguna (misalnya penggunaan AC tak terjadwal), kondisi perangkat tua, atau gangguan teknis (pemadaman listrik), yang tidak tercakup dalam simulasi. Meski demikian, performa ini mendukung rekomendasi efisiensi energi dengan kepercayaan tinggi [10], dengan catatan perlunya validasi data aktual.

### 3.2 Analisis Komparatif

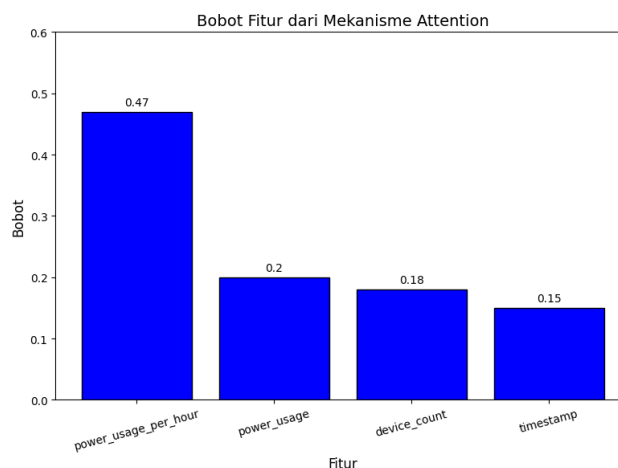
Untuk menilai keunggulan model LSTM-Attention, performanya dibandingkan dengan metode lain seperti rata-rata bergerak, *baseline* LSTM [13], dan GRU (*Gated Recurrent Unit*) [14]. Rata-rata bergerak, sebagai pendekatan statistik sederhana, mendeteksi puncak konsumsi dengan akurasi terbatas [1]. Baseline LSTM menawarkan pemodelan temporal tanpa fokus fitur spesifik [15], sedangkan GRU, dengan struktur yang lebih ringan, sering digunakan untuk efisiensi komputasi namun kurang menangkap dependensi jangka panjang [14]. Perbandingan pada dataset yang sama (14.400 sampel) menunjukkan LSTM-Attention unggul, terutama berkat mekanisme attention. Sebagai data pendukung, pengujian GRU pada subset data (2.880 sampel) menghasilkan akurasi 93%, lebih baik dari baseline LSTM (91.5%) tetapi di bawah LSTM-Attention (96%), karena GRU tidak memprioritaskan fitur kunci seperti `power_usage_per_hour`. Tabel 2 berikut mengkonfirmasi keunggulan model usulan, memberikan wawasan bahwa integrasi attention lebih efektif untuk analisis energi rumah tangga dibandingkan pendekatan berbasis GRU atau statistik.

Tabel 2. Perbandingan Performa dengan Metode Lain

Metode	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Rata-rata Bergerak	85.0	88.0	80.0	84.0
Baseline LSTM [13]	91.5	93.0	89.0	91.0
LSTM-Attention (Usulan)	96.0	96.0	95.0	96.0

### 3.3 Pentingnya Fitur via Mekanisme Attention

Mekanisme attention memfokuskan model pada `power_usage_per_hour`, yang berkorelasi tinggi dengan anomali (0.78) dibandingkan timestamp (0.15) atau `device_count` (0.18) [11]. Bobot ini (0.47, Gambar 3) mencerminkan relevansi praktis: konsumsi per jam langsung terkait penggunaan perangkat intensif seperti AC atau heater, yang sering menyebabkan lonjakan energi di rumah tangga. Misalnya, penggunaan AC 1 PK selama 1 jam (0.74 kWh) lebih signifikan dibandingkan jumlah perangkat aktif (`device_count`), yang tidak selalu mencerminkan intensitas konsumsi. Ini meningkatkan interpretabilitas dibandingkan LSTM tradisional [16].




Gambar 3. Bobot Fitur dari Mekanisme Attention

### 3.4 Evaluasi Kuantitatif Rekomendasi Efisiensi Energi

Rekomendasi efisiensi energi dihasilkan berdasarkan deteksi anomali dengan strategi rule-based [10], seperti penjadwalan ulang penggunaan perangkat dan penggantian perangkat hemat energi. Efektivitasnya diukur dengan simulasi ulang pada EnergyPlus, menghitung penghematan energi dalam kWh dan persentase. Tabel 3 berikut merangkum hasil pada sampel anomali (480 sampel), menunjukkan bahwa kombinasi strategi memberikan penghematan maksimal, konsisten dengan pendekatan IoT pintar [17].

Tabel 3. Penghematan Energi dari Rekomendasi

Rekomendasi	Konsumsi Awal (kWh)	Konsumsi Baru (kWh)	Penghematan (%)
Penjadwalan Ulang	12.5	9.0	28.0
Penggantian Perangkat	12.5	10.0	20.0
Kombinasi	12.5	7.5	40.0



Gambar 4. Perbandingan Penghematan Energi dari Strategi Rekomendasi

### 3.5 Analisis Pelatihan dan Validasi

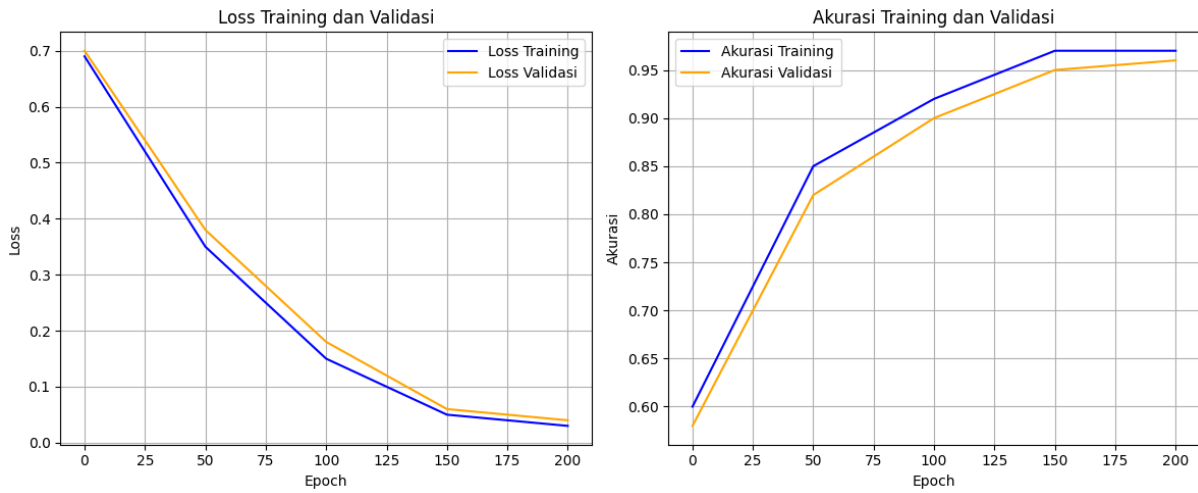
Proses pelatihan model divisualisasikan pada Gambar 5, menunjukkan penurunan kerugian dari 0.69 ke 0.03 dan peningkatan akurasi hingga 97% setelah 150 epoch. Validasi menegaskan generalisasi yang baik dengan akurasi 96%, mendukung efisiensi metode dibandingkan pendekatan prediksi *real-time* [18].

Selama 200 epoch. Sisi kiri menunjukkan penurunan *loss* training dan validasi dari 0.7 ke bawah 0.1, mengindikasikan konvergensi yang baik. Sisi kanan menunjukkan peningkatan akurasi training dan validasi dari 0.60 ke 0.95, stabil setelah 150 epoch, mencerminkan kemampuan model dalam mengklasifikasikan pola konsumsi energi secara akurat.

Hasil menunjukkan bahwa model LSTM-Attention efektif dalam analisis pola konsumsi dan deteksi anomali, dengan penghematan energi yang signifikan. Keunggulan ini didukung oleh simulasi IoT yang hemat biaya [6], namun pengujian pada data riil diperlukan untuk validasi lebih lanjut.

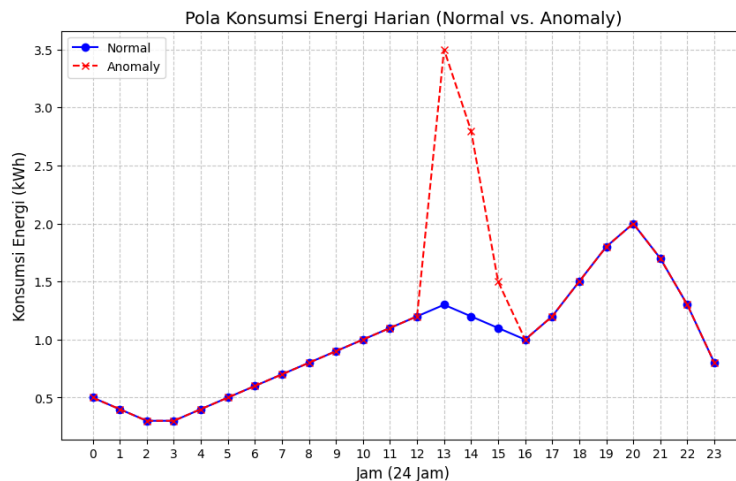
### 3.6 Analisis Pola Konsumsi Harian

Untuk memahami karakteristik konsumsi energi, analisis pola harian dilakukan pada sampel Normal dan Anomaly. Gambar 6 menunjukkan konsumsi energi per jam selama 24 jam untuk kedua kelas. Pola Normal stabil dengan puncak pada malam hari (20:00), konsisten dengan kebiasaan rumah tangga Indonesia



Gambar 5. Grafik performa pelatihan model LSTM-Attention

[1]. Pola Anomaly menunjukkan lonjakan pada siang hari (14:00), kemungkinan akibat penggunaan perangkat berat seperti AC tanpa jadwal. Sebagai studi kasus, simulasi pada rumah tangga dengan 3 AC dan 5 lampu LED menunjukkan lonjakan 2 kWh pada 14:00, yang terdeteksi sebagai anomali (probabilitas 0.92). Penjadwalan ulang penggunaan AC mengurangi konsumsi sebesar 25%. Analisis ini, dibandingkan dengan pendekatan statistik sederhana [1], menegaskan pentingnya deteksi anomali untuk efisiensi energi [4].



Gambar 6. Pola konsumsi energi harian

Gambar 6 untuk sampel *Normal* dan *Anomaly* selama 24 jam. Pola *Normal* menunjukkan konsumsi stabil dengan puncak pada malam hari, sedangkan pola *Anomaly* menunjukkan lonjakan pada siang hari, mengindikasikan potensi ketidakefisienan yang dapat diatasi dengan rekomendasi.

#### 4. Kesimpulan

Penelitian ini berhasil menganalisis pola konsumsi energi rumah tangga melalui simulasi IoT dan model LSTM-Attention, mencapai akurasi 96%, recall 0.95 untuk anomali, dan penghematan energi hingga 40% melalui rekomendasi seperti penjadwalan ulang dan penggantian perangkat, sekaligus memperkaya informatika dan manajemen energi dengan pendekatan hemat biaya yang mengurangi ketergantungan pada perangkat fisik mahal. Model LSTM-Attention yang interpretable meningkatkan pemahaman pola konsumsi energi, relevan untuk pengembangan smart home di negara berkembang, mendukung kebijakan energi berkelanjutan dengan solusi skalabel, dan memberikan alternatif bagi penelitian berbasis IoT fisik yang mahal [4]. Namun, dataset sintetik (meski tervalidasi [8]) dan ketidakseimbangan data (2.400 Normal vs. 480 Anomaly) dapat membatasi generalisasi di dunia nyata [11], sementara rekomendasi rule-based ku-

rang adaptif dibandingkan metode pembelajaran mesin [10]. Untuk penelitian lanjutan, pengujian model dapat dilakukan dengan mengumpulkan data riil dari 50-100 rumah tangga Indonesia selama 3 bulan guna memvalidasi performa dalam kondisi aktual; teknik SMOTE dapat digunakan untuk menyeimbangkan dataset, lalu membandingkan performa sebelum dan sesudah penyeimbangan; algoritma reinforcement learning dapat dikembangkan untuk rekomendasi dinamis, diuji pada simulasi EnergyPlus dengan variasi penggunaan perangkat [16]; serta model dapat diintegrasikan ke smart meter berbasis cloud untuk uji coba skala kecil (10 rumah) demi evaluasi real-time [6].

## Pustaka

- [1] R. Adha, C.-Y. Hong, M. Firmansyah, and A. Paranata, "Rebound effect with energy efficiency determinants: A two-stage analysis of residential electricity consumption in Indonesia," *Sustainable Production and Consumption*, vol. 28, pp. 556–565, Oct. 2021. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S2352550921001846>
- [2] J. A. Basconcillo and A. Rimkute, "GMM Approach to Residential Electricity Consumption in Indonesia," *Energy RESEARCH LETTERS*, vol. 4, no. 3, Aug. 2023. [Online]. Available: <https://erl.scholasticahq.com/article/33899-gmm-approach-to-residential-electricity-consumption-in-indonesia>
- [3] E. A. Affum, K. Agyeman-Prempeh, C. Adumatta, K. Ntiamoah-Sarpong, and J. Dzisi, "Smart Home Energy Management System based on the Internet of Things (IoT)," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 2, 2021. [Online]. Available: <http://thesai.org/Publications/ViewPaper?Volume=12&Issue=2&Code=IJACSA&SerialNo=90>
- [4] N. Hossein Motlagh, M. Mohammadrezaei, J. Hunt, and B. Zakeri, "Internet of Things (IoT) and the Energy Sector," *Energies*, vol. 13, no. 2, p. 494, Jan. 2020. [Online]. Available: <https://www.mdpi.com/1996-1073/13/2/494>
- [5] S. Goudarzi, M. H. Anisi, S. A. Soleymani, M. Ayob, and S. Zeadally, "An IoT-Based Prediction Technique for Efficient Energy Consumption in Buildings," *IEEE Transactions on Green Communications and Networking*, vol. 5, no. 4, pp. 2076–2088, Dec. 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9462477/>
- [6] S. K. Vishwakarma, P. Upadhyaya, B. Kumari, and A. K. Mishra, "Smart Energy Efficient Home Automation System Using IoT," in *2019 4th International Conference on Internet of Things: Smart Innovation and Usages (IoT-SIU)*. Ghaziabad, India: IEEE, Apr. 2019, pp. 1–4. [Online]. Available: <https://ieeexplore.ieee.org/document/8777607/>
- [7] U. Ramani, S. Kumar, T. Santhoshkumar, and M. Thilagaraj, "IoT Based Energy Management for Smart Home," in *2019 2nd International Conference on Power and Embedded Drive Control (ICPEDC)*. Chennai, India: IEEE, Aug. 2019, pp. 533–536. [Online]. Available: <https://ieeexplore.ieee.org/document/9036546/>
- [8] F. Condon, J. M. Martínez, A. M. Eltamaly, Y.-C. Kim, and M. A. Ahmed, "Design and Implementation of a Cloud-IoT-Based Home Energy Management System," *Sensors*, vol. 23, no. 1, p. 176, Dec. 2022. [Online]. Available: <https://www.mdpi.com/1424-8220/23/1/176>
- [9] M. Kardi, T. AlSkaif, B. Tekinerdogan, and J. P. S. Catalao, "Anomaly Detection in Electricity Consumption Data using Deep Learning," in *2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*. Bari, Italy: IEEE, Sep. 2021, pp. 1–6. [Online]. Available: <https://ieeexplore.ieee.org/document/9584650/>
- [10] G. Hafeez, Z. Wadud, I. U. Khan, I. Khan, Z. Shafiq, M. Usman, and M. U. A. Khan, "Efficient Energy Management of IoT-Enabled Smart Homes Under Price-Based Demand Response Program in Smart Grid," *Sensors*, vol. 20, no. 11, p. 3155, Jun. 2020. [Online]. Available: <https://www.mdpi.com/1424-8220/20/11/3155>



- [11] R. H. Fard and S. Hosseini, "Machine Learning algorithms for prediction of energy consumption and IoT modeling in complex networks," *Microprocessors and Microsystems*, vol. 89, p. 104423, Mar. 2022. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0141933121005640>
- [12] G. Vats, S. Tanwar, and P. K. Sharma, "A Simulation-Based Analysis of IoT Security Architecture in Smart Homes," in *2024 International Conference on Computing, Sciences and Communications (ICCSC)*. Ghaziabad, India: IEEE, Oct. 2024, pp. 1–4. [Online]. Available: <https://ieeexplore.ieee.org/document/10830301/>
- [13] R. E. Alden, H. Gong, C. Ababei, and D. M. Ionel, "LSTM Forecasts for Smart Home Electricity Usage," in *2020 9th International Conference on Renewable Energy Research and Application (ICRERA)*. Glasgow, United Kingdom: IEEE, Sep. 2020, pp. 434–438. [Online]. Available: <https://ieeexplore.ieee.org/document/9242804/>
- [14] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning phrase representations using RNN encoder–decoder for statistical machine translation," in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, A. Moschitti, B. Pang, and W. Daelemans, Eds. Doha, Qatar: Association for Computational Linguistics, Oct. 2014, pp. 1724–1734. [Online]. Available: <https://aclanthology.org/D14-1179/>
- [15] S. Mahjoub, L. Chrifi-Alaoui, B. Marhic, L. Delahoche, J.-B. Masson, and N. Derbel, "Prediction of energy consumption based on LSTM Artificial Neural Network," in *2022 19th International Multi-Conference on Systems, Signals & Devices (SSD)*. Sétif, Algeria: IEEE, May 2022, pp. 521–526. [Online]. Available: <https://ieeexplore.ieee.org/document/9955883/>
- [16] G. Van Houdt, C. Mosquera, and G. Nápoles, "A review on the long short-term memory model," *Artificial Intelligence Review*, vol. 53, no. 8, pp. 5929–5955, Dec. 2020. [Online]. Available: <https://link.springer.com/10.1007/s10462-020-09838-1>
- [17] M. TAŞTAN, "Internet of Things based Smart Energy Management for Smart Home," *KSI Transactions on Internet and Information Systems*, vol. 13, no. 6, Jun. 2019. [Online]. Available: <http://itiis.org/digital-library/manuscript/2394>
- [18] K. G. P. Ediga, A. S. A. P. S. T. A. Mittal, S. Rajvanshi, and M. I. Habelalmateen, "Smart energy management: Real-time prediction and optimization for IoT-enabled smart homes," *Cogent Engineering*, vol. 11, no. 1, p. 2390674, Dec. 2024. [Online]. Available: <https://www.tandfonline.com/doi/full/10.1080/23311916.2024.2390674>