



Household Electricity Waste Detection Model Based on Autoencoder Algorithm with Internet of Things Concept

Model Deteksi Pemborosan Energi Listrik Rumah Tangga Berbasis Algoritma Autoencoder dengan Konsep *Internet of Things*

Sriwahyuningsih Piu A^{1*}, Muhammad Rizal², Maya Itasari³

¹Program Studi Teknik Informatika, Universitas Dipa Makassar, Indonesia

²Program Studi Teknik Komputer dan Jaringan, Politeknik Negeri Ujung Pandang, Indonesia

³Program Studi Teknik Elektronika, Politeknik Negeri Ujung Pandang, Indonesia

E-Mail: ¹sri.wahyuningsih@undipa.ac.id,

²muhammad.rizal@poliupg.ac.id, ³mayaitasari@poliupg.ac.id

Received Oct 24th 2025; Revised Dec 25th 2025; Accepted Dec 31th 2025; Available Online Jan 17th 2026

Corresponding Author: Sriwahyuningsih Piu A

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

This paper presents an unsupervised approach to detect household electricity waste from IoT-derived windowed features using an Autoencoder (AE). The pipeline comprises median imputation, RobustScaler normalization, time-aware splitting (70/15/15), AE training with AdamW and early stopping, and adaptive per-home thresholds from the 99.5th percentile of reconstruction error. We evaluate dataset (23,028 windows; two homes, two channels) engineered with voltage, current, power, and power-factor statistics (mean/std/p95), slopes, and transients. Grid search selects a shallow AE (depth=1, width=128, bottleneck=16, dropout=0, ReLU, lr=1e-4, wd=1e-5). On the held-out test set (n=3,455) the mean reconstruction error is 3.17×10^{-3} . Using per-home thresholds (homeA=0.0634, homeB=0.0859), the system flags ~0.52% of windows as waste/anomalies, with a higher incidence in homeA (0.81%) than homeB (0.23%). Feature-level error attribution highlights power-factor metrics and voltage/current/power slopes and variability, patterns consistent with inefficient or abruptly switching loads. The method is production-ready for IoT deployment and yields interpretable indicators for energy-saving actions without labels.

Keywords: Autoencoder, Energy Waste, Household Electricity, Internet of Things, Unsupervised

Abstrak

Penelitian ini menyajikan pendekatan *unsupervised* untuk mendeteksi pemborosan energi listrik rumah tangga dari fitur jendela waktu berbasis IoT menggunakan Autoencoder (AE). Pipeline meliputi imputasi median, normalisasi RobustScaler, pemisahan berbasis waktu (70/15/15), pelatihan AE dengan AdamW dan *early stopping*, serta ambang adaptif per-rumah dari persentil 99,5% *error* rekonstruksi. Evaluasi dilakukan pada *dataset* energi listrik (23.028 window; dua rumah, dua kanal) dengan fitur statistik tegangan, arus, daya, faktor daya (rata-rata/deviasi standar/p95), *slope*, dan transien. *Grid search* memilih AE dangkal (depth=1, width=128, bottleneck=16, dropout=0, ReLU, lr=1e-4, wd=1e-5). Pada *test set* (n=3.455), rerata *error* rekonstruksi sebesar $3,17 \times 10^{-3}$. Dengan treshhold per-rumah (homeA=0,0634, homeB=0,0859), sistem menandai ~0,52% window sebagai pemborosan/anomali, dengan insidensi lebih tinggi pada homeA (0,81%) dibanding homeB (0,23%). Atribusi *error* per-fitur menonjolkan metrik faktor daya serta *slope*/variabilitas tegangan, arus, dan daya, pola yang konsisten dengan beban tidak efisien atau *switching* mendadak. Metode ini siap dioperasikan pada ekosistem IoT dan memberikan indikator yang dapat ditafsirkan untuk tindakan penghematan tanpa memerlukan label.

Kata Kunci: Autoencoder, Internet of Things, Listrik Rumah Tangga, Pemborosan Energi, Unsupervised

1. PENDAHULUAN

Efisiensi energi merupakan agenda global yang semakin mendesak karena pertumbuhan permintaan listrik tidak sebanding dengan ketersediaan sumber daya[1]. Di Indonesia, konsumsi energi pada sektor rumah tangga dan industri relatif tinggi dan kerap tidak diimbangi oleh praktik pemakaian yang efisien [2]. Kondisi ini menyebabkan potensi pemborosan energi yang sulit diidentifikasi secara dini, khususnya pada

level penggunaan listrik harian, sehingga diperlukan pendekatan yang mampu memantau dan mengevaluasi pola konsumsi energi secara sistematis.

Perkembangan *Internet of Things* (IoT) memungkinkan pengumpulan data konsumsi listrik secara *real-time* melalui sensor dan smart meter, sehingga menyediakan data yang bersifat kontinu dan granular. Dalam konteks ini, pemodelan cerdas berbasis kecerdasan buatan (AI) menjadi pendekatan yang relevan untuk mendukung pemantauan dan pengambilan keputusan energi [3]. Khususnya, algoritma Autoencoder (AE) berpotensi digunakan untuk mempelajari pola konsumsi energi normal dan mendeteksi penyimpangan sebagai indikasi pemborosan, tanpa memerlukan data berlabel.


Penelitian terkait deteksi anomali konsumsi energi telah dilakukan dengan berbagai pendekatan. Shahid et al. menunjukkan bahwa keluarga AE, termasuk Variational Autoencoder (VAE), efektif dalam mempelajari manifold konsumsi energi normal dan mendeteksi anomali tanpa label eksplisit [4]. Copiaco et al. menerapkan pendekatan deep learning untuk mendeteksi anomali pada konsumsi energi bangunan berbasis data deret waktu [3]. Pendekatan lain seperti *Local Outlier Factor* (LOF) telah digunakan untuk mendeteksi konsumsi energi abnormal di lingkungan industri [5], sementara metode sekuensial seperti SDAR digunakan untuk membedakan outlier sesaat dan perubahan tren konsumsi energi [6]. Selain itu, ekosistem sensor dan smart meter *real-time* yang semakin matang mendukung penerapan analitik energi pada tingkat rumah tangga [7].

Meskipun berbagai pendekatan telah dikembangkan, sebagian besar penelitian sebelumnya masih menghadapi beberapa keterbatasan, antara lain ketergantungan pada model yang kompleks, kebutuhan sumber daya komputasi yang tinggi, serta penggunaan ambang keputusan global yang kurang adaptif terhadap variasi karakteristik konsumsi antar rumah tangga. Selain itu, kebutuhan data berlabel sering kali sulit dipenuhi dalam konteks rumah tangga. Penelitian ini menawarkan kebaruan dengan mengusulkan penggunaan AE standar yang ringan secara komputasi, dikombinasikan dengan mekanisme ambang adaptif per rumah yang dikalibrasi berdasarkan distribusi data masing-masing rumah.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model deteksi pemborosan energi listrik rumah tangga berbasis AE dan IoT yang mampu mendeteksi anomali konsumsi energi pada level jendela waktu tanpa memerlukan data berlabel, serta menghasilkan sistem deteksi yang adaptif terhadap karakteristik konsumsi masing-masing rumah tangga.

2. BAHAN DAN METODE

2.1. Riset Metodologi



Gambar 1. Diagram Alur system

Gambar 1 menunjukkan diagram alur sistem deteksi pemborosan energi listrik rumah tangga yang diusulkan dalam penelitian ini. Proses diawali dengan pengumpulan data energi listrik, yang diperoleh dari perangkat pengukuran energi berbasis IoT pada lingkungan rumah tangga. Data yang dikumpulkan meliputi parameter kelistrikan seperti tegangan, arus, daya, dan faktor daya. Data energi yang diperoleh disimpan pada cloud untuk keperluan pengolahan dan analisis lebih lanjut. Penyimpanan terpusat ini memungkinkan pengelolaan data secara terstruktur serta mendukung proses pemrosesan data secara efisien.

Pada tahap berikutnya, data diproses menggunakan model AE yang dikombinasikan dengan mekanisme ambang adaptif (*adaptive threshold*). AE digunakan untuk mempelajari pola konsumsi energi normal, sedangkan ambang adaptif diterapkan untuk menyesuaikan batas deteksi anomali berdasarkan karakteristik konsumsi energi masing-masing rumah tangga. Hasil keluaran model kemudian dievaluasi pada tahap evaluasi akurasi model, dengan menganalisis nilai *error* rekonstruksi dan tingkat anomali yang terdeteksi. Tahap akhir dari sistem ini adalah penyajian informasi deteksi pemborosan energi, yang dapat digunakan sebagai dasar pengambilan keputusan dalam upaya penghematan energi listrik rumah tangga.

2.2. *Internet of Things* (IoT)

IoT merupakan paradigma teknologi yang memungkinkan objek fisik dilengkapi sensor dan kemampuan komunikasi untuk mengumpulkan serta mentransmisikan data melalui jaringan internet. IoT membentuk infrastruktur yang menghubungkan perangkat fisik dengan sistem komputasi sehingga data dapat diproses dan dianalisis secara otomatis tanpa intervensi manusia secara langsung [8].

Dalam penelitian ini, IoT berperan sebagai penghubung antara dunia fisik dan sistem digital berbasis data. Pada pemantauan konsumsi energi listrik, IoT memungkinkan akuisisi data kelistrikan secara *real-time* dan berkelanjutan melalui smart meter dan sensor energi [9]. Data yang dihasilkan bersifat deret waktu, berdimensi tinggi, dan umumnya tidak berlabel. IoT dalam penelitian ini berfungsi sebagai infrastruktur pengumpulan data energi rumah tangga yang menjadi dasar penerapan algoritma pembelajaran mesin untuk mendeteksi pemborosan energi secara otomatis.

2.3. Literature Review

Penelitian terkait deteksi anomali konsumsi energi rumah tangga berkembang seiring ketersediaan data smart meter beresolusi tinggi. Berbagai pendekatan machine learning seperti algoritma KNN[10] dan statistik digunakan untuk mengidentifikasi pola konsumsi abnormal yang mengindikasikan pemborosan energi maupun perilaku tidak wajar pada lingkungan rumah tangga [11], [12], [13],[14], [15]. Pendekatan outlier detection berbasis jarak dan kepadatan, seperti LOF, banyak diterapkan pada sistem energi dan lingkungan industri. Metode ini efektif untuk mendeteksi deviasi lokal, namun memiliki keterbatasan dalam menangani data berdimensi tinggi dan deret waktu panjang, serta kurang adaptif terhadap variasi pola konsumsi energi antar entitas [5]

Seiring meningkatnya kompleksitas data energi, pendekatan deep learning berbasis AE menjadi solusi yang banyak digunakan. AE mampu mempelajari representasi pola konsumsi energi normal dan mendeteksi anomali berdasarkan *error* rekonstruksi, terutama pada kondisi data tidak berlabel [16], [17]. Pengembangan lebih lanjut dilakukan melalui VAE untuk meningkatkan kemampuan generalisasi dan transfer knowledge antar domain energi. Pendekatan ini menunjukkan performa yang baik dalam mendeteksi anomali konsumsi listrik dan pemanas distrik, namun memiliki kompleksitas model dan biaya komputasi yang relatif lebih tinggi [4], [18], [19]. Penelitian lain mengusulkan modifikasi AE untuk meningkatkan akurasi dan lokalisasi anomali, seperti whitening-enhanced AE dan probabilistic AE. Meskipun memberikan peningkatan performa, pendekatan tersebut umumnya memerlukan konfigurasi model yang kompleks dan kurang efisien untuk implementasi IoT skala rumah tangga [20]. Integrasi IoT dengan machine learning memungkinkan deteksi anomali konsumsi energi dilakukan secara *real-time*. Beberapa studi berfokus pada deteksi pencurian listrik dan optimasi konsumsi energi berbasis IoT, namun sebagian besar masih menargetkan anomali ekstrem dan belum secara spesifik menangani pemborosan energi halus pada jendela waktu konsumsi rumah tangga [7].

Berdasarkan tinjauan tersebut, masih terdapat celah penelitian dalam pengembangan sistem deteksi pemborosan energi rumah tangga yang ringan secara komputasi, tidak bergantung pada data berlabel, serta adaptif terhadap karakteristik konsumsi masing-masing rumah. Penelitian ini mengisi celah tersebut dengan mengusulkan AE standar yang dikombinasikan dengan mekanisme ambang adaptif per rumah untuk deteksi pemborosan energi berbasis IoT.


2.4. Model Autoencoder

AE adalah model pembelajaran representasi tak berlabel yang mempelajari pola “normal” suatu data dengan cara mengompresi dan kemudian merekonstruksi kembali vektor fitur input. Diberikan vektor fitur jendela waktu ($x \in \mathbb{R}^d$) dalam hal ini statistik tegangan, arus, daya, faktor daya, slope, dan transien, AE terdiri dari encoder (g_ϕ) yang memetakan (x) ke representasi laten berdimensi rendah ($z = g_\phi(x)$) dan decoder (h_ψ) yang memetakan kembali ($\hat{x} = h_\psi(z)$). Parameter model ($\theta = \phi, \psi$) dipelajari dengan meminimalkan loss rekonstruksi berbasis rata-rata kuadrat kesalahan:

$$\mathcal{L}(\theta) = \frac{1}{N} \sum_{i=1}^N \frac{1}{d} \|x_i - \hat{x}_i\|_2^2, \quad (1)$$

$$\hat{x}_i = f_\theta(x_i). \quad (2)$$

Gambar 2 adalah diagram blok AE. Pola konsumsi normal akan direkonstruksi dengan kesalahan kecil, sedangkan perilaku tidak lazim/boros seperti faktor daya turun tajam, lonjakan/penurunan mendadak, atau variabilitas daya tidak wajar akan sulit direkonstruksi sehingga menghasilkan kesalahan lebih besar.



Gambar 2. Diagram AE

2.5. Protokol Train dan Tuning Hyperparameter

Data *train* dan validasi digunakan untuk pelatihan AE dengan AdamW, *learning rate* dalam himpunan $(1! \times 10^{-3}, 5! \times 10^{-4})$, *weight decay* (10^{-5}) , *batch size* (128), *depth* (1), *width* (64,128), *bottleneck* (4,8,16), *dropout* (0,0), dan aktivasi (ReLU). Early stopping digunakan berdasarkan MSE validasi.

2.6. Mekanisme Thresholding

Pendekatan deteksi anomali berbasis AE memanfaatkan nilai *error* rekonstruksi. Data yang *error*-nya melampaui ambang batas dianggap anomali atau pemborosan energi. Berikut definisi anomali:

$$Anomali(x) = \begin{cases} 1, & L(x, \hat{x}) > \tau_h \\ 0, & L(x, \hat{x}) \leq \tau_h \end{cases} \quad (3)$$

Ambang (τ_h) adaptif ditentukan berdasarkan distribusi *error* tiap rumah. *HomeA* memiliki ambang 0,063, sedangkan *HomeB* 0,086 seperti yang ditunjukkan pada Tabel 1. Perbedaan ini menegaskan bahwa konsumsi energi tiap rumah memiliki karakteristik unik, sehingga threshold tunggal tidak cukup representatif.

Table 1. Ambang Adaptif Per Rumah (Kuantil 99,5% Skor *Train*-Validasi)

Home	Thresholds
A	0.06343867445955312
B	0.08593877118804358

2.7. Metode Evaluasi

Evaluasi kuantitatif berfokus pada rerata *error* rekonstruksi di *test*, jumlah dan laju anomali yang terdeteksi, distribusi *error*, dan atribusi per-fitur (kontribusi *error* per fitur) untuk interpretabilitas.

1. Akurasi rekonstruksi diukur dengan *Mean Reconstruction Error* (MRE)

$$\left(\text{MRE} = \frac{1}{N_{\text{test}}} \sum_{i=1}^{N_{\text{test}}} s(x_i) \right), \text{ dengan } \left(s(x) = \frac{1}{d} |x - \hat{x}|^2 \right) \quad (4)$$

2. Intensitas deteksi dilaporkan sebagai jumlah anomali dan Anomaly Rate

$$\left(\text{AR} = \frac{1}{N_{\text{test}}} \sum o1[s(x_i) \geq T_g(i)] \right) \quad (5)$$

baik global maupun per-rumah/per-channel, untuk menilai proporsi kejadian terhadap total observasi.

3. Karakteristik distribusi skor dianalisis melalui histogram dan ringkasan kuantil ($p50, p90, p99, p99.5$); konsistensinya terhadap ambang pelatihan (T_g) diperiksa guna memastikan kalibrasi ($\text{proporsiskor} < (T_g)$) sesuai desain.
4. Interpretabilitas fitur dihitung dari kontribusi per-fitur ($e_j = (x_j - \hat{x}_j)^2$) dan dirangkum pada Top-N anomali (N=30) untuk memperoleh peringkat fitur yang dominan. Seluruh metrik dilaporkan beserta agregasi per-kelompok (rumah/kanal) dan profil waktu (deret waktu).

3. HASIL DAN DISKUSI

3.1. Dataset dan Rekayasa Fitur

Dataset terdiri atas 23.028 window dari dua rumah (*homeA*, *homeB*) dan dua kanal (1, 2) dengan resolusi sekitar 30 detik per rumah-kanal. Setiap window memiliki fitur numerik berikut:

1. Tegangan : V_mean, V_std, V_p95, V_slope
2. Arus : I_mean, I_std, I_p95, I_slope
3. Daya : P_mean, P_std, P_p95, P_slope
4. Faktor daya : pf_mean, pf_std, pf_p95, pf_slope
5. Peristiwa transien : P_transients

Serta kolom identitas: *home*, *channel*, dan *time stemp window_start*.

Dalam *pre-processing*, kami menerapkan imputasi median dan normalisasi RobustScaler. *Dataset* diurutkan berdasarkan waktu dan dipecah menjadi *train/val/test* = 70%/ 15%/ 15% secara *time-aware*. Data dapat dilihat pada Tabel 2,3 dan 4.

Table 2. Ringkasan *Dataset RAW*

No.	Home	channel	V	I	P	pf	Wh
1	A	1	219,99	0,40	91,03	0,96	0,05
2	A	1	220,12	0,48	105,52	0,97	0,11
3	A	1	220,41	0,49	104,85	0,95	0,17
...	...	...	...	...	...	...	...
34599	B	2	219,74	0,06	15,98	0,96	1107,93
34600	B	2	221	0,88	16,88	0,94	1107,94

Table 3. *Dataset* Berbasis Window dan Stride



No.	Home	Channel	Window Start	V_mean	V_std	V_p95	V_slope	I_mean	...	P_transient
1	A	1	00:00:00	221,64	0,85	222,99	0,05	0,46	..	1
2	A	1	00:00:30	222,26	0,69	223,15	0,04	0,47	..	4
3	A	1	00:01:00	222,65	0,45	223,27	0,02	0,46	..	3
...	...	...	...	...	...	...	...	...	...	...
23027	B	2	23:57:30	217,74	0,65	218,93	0,03	0,07	..	6
23028	B	2	23:58:00	218,36	0,86	219,80	0,05	0,07	..	6

Table 4. Jumlah *Dataset Split* (Window)

Train	Validasi	Test	Fitur (Numerik)
16119	3454	3455	17

3.2. Analisa Rekonstruksi *error*

Rerata *error* rekonstruksi pada data uji sebesar 0,0031 menunjukkan performa tinggi model dalam memahami pola konsumsi energi normal. Histogram *error* memperlihatkan distribusi dengan puncak tajam pada *error* rendah, yang menandakan sebagian besar konsumsi listrik berada dalam kategori efisien. Ekor distribusi panjang mengindikasikan keberadaan anomali atau periode pemborosan energi. Temuan ini memperlihatkan bahwa AE berhasil membedakan pola konsumsi normal dan abnormal/ anomali secara signifikan yang dapat dilihat pada Gambar 3 dan 4.


**Gambar 3.** Distribusi Rekonstruksi *Error***Gambar 4.** Rekonstruksi *Error* Vs Time

3.3. Adaptive Thresholding

Ambang adaptif memperlihatkan perbedaan pola konsumsi energi antar rumah. *HomeA* lebih sensitif dengan ambang 0,063, sementara *HomeB* lebih toleran dengan ambang 0,086. Hal ini menggambarkan variasi gaya hidup atau jumlah perangkat yang digunakan di masing-masing rumah. Dengan pendekatan ini, deteksi anomali menjadi lebih akurat karena memperhitungkan karakteristik unik tiap rumah tangga, mengurangi risiko *false positive* pada rumah dengan konsumsi tinggi.

3.4. Performa Deteksi Anomali

Sepuluh anomali terbesar berhasil diidentifikasi berdasarkan *error* rekonstruksi. Pola ini merepresentasikan penggunaan energi yang tidak efisien, seperti lonjakan konsumsi pada jam tidak lazim atau beban daya yang tidak sesuai dengan profil normal rumah tangga. Temuan ini menunjukkan bahwa model dapat berfungsi sebagai sistem peringatan dini terhadap konsumsi listrik boros yang dapat dilihat pada Gambar 5.



Gambar 5. Sepuluh Anomali Terbesar Berdasarkan *Error* Rekonstruksi

3.5. Kontribusi Fitur

Analisis kontribusi fitur menunjukkan bahwa arus dan daya merupakan variabel dengan kontribusi terbesar terhadap *error* rekonstruksi, sehingga menjadi indikator utama dalam pendeteksian anomali konsumsi energi. Sebaliknya, tegangan menunjukkan kontribusi yang relatif rendah karena cenderung stabil pada sistem kelistrikan rumah tangga. Temuan ini mengindikasikan bahwa lonjakan arus atau peningkatan daya yang tidak proporsional merupakan ciri utama pemborosan energi pada level jendela waktu konsumsi. Hasil ini menghasilkan *output* penelitian berupa indikator fitur dominan pemborosan energi, yang dapat dimanfaatkan sebagai dasar interpretasi teknis dan pengambilan keputusan penghematan energi pada sistem berbasis IoT.

3.6. Diskusi

Hasil penelitian menunjukkan bahwa AE mampu memodelkan pola konsumsi energi normal secara efektif, yang ditunjukkan oleh rendahnya *error* rekonstruksi pada data uji. Kemampuan ini muncul karena AE dilatih untuk merekonstruksi pola konsumsi yang dominan, sehingga perilaku konsumsi yang menyimpang menghasilkan *error* yang lebih tinggi dan terdeteksi sebagai anomali. Dibandingkan dengan pendekatan berbasis outlier detection seperti LOF, metode AE memiliki keunggulan dalam menangani data berdimensi tinggi dan deret waktu yang kompleks tanpa memerlukan asumsi distribusi data. Berbeda dengan pendekatan VAE yang lebih kompleks secara komputasi, penggunaan AE standar dalam penelitian ini lebih sesuai untuk implementasi pada lingkungan IoT rumah tangga dengan keterbatasan sumber daya.

Penerapan ambang adaptif per rumah terbukti meningkatkan relevansi deteksi anomali dengan menyesuaikan karakteristik konsumsi energi masing-masing rumah tangga. Pendekatan ini mengurangi potensi *false positive* yang umum terjadi pada penggunaan ambang global, khususnya pada rumah dengan tingkat konsumsi energi yang berbeda secara signifikan. Meskipun menunjukkan hasil yang menjanjikan, penelitian ini memiliki keterbatasan pada jumlah rumah tangga yang dianalisis serta belum mempertimbangkan dinamika musiman konsumsi energi dalam jangka panjang. Pengembangan selanjutnya dapat diarahkan pada evaluasi multi-rumah berskala besar, integrasi model sekuensial, serta implementasi langsung pada perangkat edge IoT untuk deteksi pemborosan energi secara *real-time*.

4. KESIMPULAN

Penelitian ini membuktikan bahwa AE merupakan pendekatan efektif dalam mendeteksi pemborosan energi rumah tangga. Hasil utama meliputi *error* rekonstruksi rendah (0,0031) pada data uji, *threshold* adaptif meningkatkan sensitivitas deteksi (*homeA*: 0,063; *homeB*: 0,086), anomali signifikan berhasil teridentifikasi dan relevan dengan pola konsumsi perangkat berdaya tinggi, arus dan daya terbukti sebagai indikator dominan pemborosan energi. Pipeline akhir imputasi median, RobustScaler, pemisahan berbasis waktu, pelatihan AE (AdamW, *early stopping*), pemilihan hiperparameter melalui grid, serta penetapan ambang p99.5 per-rumah—menghasilkan MRE test 3.17×10^{-3} dan AR global 0.52% pada korpus uji (3.455 window). Nilai ambang 0.0634 (*homeA*) dan 0.0859 (*homeB*) menjaga kalibrasi keputusan antar-rumah, sementara analisis per-fitur memberi petunjuk teknis (pf dan slope/variabilitas) yang relevan untuk tindakan penghematan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada DRTPM Kemendikisaintek atas pendanaan melalui hibah penelitian BIMA tahun 2025, serta kepada tim peneliti dan mahasiswa yang telah membantu pengumpulan dan pengolahan data.

REFERENSI

- [1] Z. Chuncheng, Z. Lili, and L. Qing, "Research on Electricity Demand Forecasting Model and Application of China Adapting to Supply-Side Structural Reform," in *2019 2nd Asia Conference on Energy and Environment Engineering (ACEEE)*, 2019, pp. 69–73. doi: 10.1109/ACEEE.2019.8816907.
- [2] M. A. McNeil, N. Karali, and V. Letschert, "Forecasting Indonesia's electricity load through 2030 and peak demand reductions from appliance and lighting efficiency," *Energy for Sustainable Development*, vol. 49, pp. 65–77, Apr. 2019, doi: 10.1016/j.esd.2019.01.001.
- [3] A. Copiaco, Y. Himeur, A. Amira, W. Mansoor, F. Fadli, and S. Atalla, "Exploring Deep Time-Series Imaging for Anomaly Detection of Building Energy Consumption," in *2022 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*, 2022, pp. 1–5. doi: 10.1109/CSDE56538.2022.10089265.
- [4] Z. K. Shahid, S. Saguna, and C. Åhlund, "Variational Autoencoders for Anomaly Detection and Transfer Knowledge in Electricity and District Heating Consumption," *IEEE Trans Ind Appl*, vol. 60, no. 5, pp. 7437–7450, 2024, doi: 10.1109/TIA.2024.3425805.
- [5] H.-A. Dang, V.-D. Dao, C.-D. Dang, N. H. Nguyen, and A. Hoang, "Identifying Abnormal Energy Consumption Patterns in Industrial Settings: Application of Local Outlier Factor Algorithm for a Processing Factory in Vietnam," in *2023 Asia Meeting on Environment and Electrical Engineering (EEE-AM)*, 2023, pp. 1–5. doi: 10.1109/EEE-AM58328.2023.10395078.
- [6] S. Gupta and B. Gupta, "Energy Anomaly Detection and Modelling on Smart Premises using SDAR," in *2021 International Conference on Industrial Electronics Research and Applications (ICIARA)*, 2021, pp. 1–5. doi: 10.1109/ICIARA53202.2021.9726730.
- [7] L. G and R. Gopal, "Design and Development of IoT Prototype for Real-Time Theft Detection and Optimization of Electricity Using Machine Learning Techniques," in *2024 2nd International Conference on Computing and Data Analytics (ICCDAA)*, 2024, pp. 1–4. doi: 10.1109/ICCDAA64887.2024.10867342.
- [8] S. Madakam, R. Ramaswamy, and S. Tripathi, "Internet of Things (IoT): A Literature Review," *Journal of Computer and Communications*, vol. 03, no. 05, pp. 164–173, 2015, doi: 10.4236/jcc.2015.35021.
- [9] J. Corona, M. Antunes, and R. L. Aguiar, "Eco-Friendly Intrusion Detection: Evaluating Energy Costs of Learning," in *2023 IEEE 9th World Forum on Internet of Things (WF-IoT)*, 2023, pp. 1–6. doi: 10.1109/WF-IoT58464.2023.10539426.
- [10] S. Piu, A. Arifin, and M. Rizal, "Optimasi Penggunaan Energi Listrik Bagi Pelanggan Rumah Tangga Berbasis Machine Learning dan Internet of Things," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 1, pp. 84–92, Nov. 2024, doi: 10.57152/malcom.v5i1.1694.
- [11] N. S. Krishna, Y. V. P. Kumar, K. P. Prakash, and G. P. Reddy, "Machine Learning and Statistical Techniques for Outlier Detection in Smart Home Energy Consumption," in *2024 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream)*, 2024, pp. 1–4. doi: 10.1109/eStream61684.2024.10542609.
- [12] A. Takiddin, M. Ismail, U. Zafar, and E. Serpedin, "Deep Autoencoder-Based Anomaly Detection of Electricity Theft Cyberattacks in Smart Grids," *IEEE Syst J*, vol. 16, no. 3, pp. 4106–4117, 2022, doi: 10.1109/JSYST.2021.3136683.

- [13] D. Wang, T. Enlund, J. Trygg, M. Tysklind, and L. Jiang, "Toward Delicate Anomaly Detection of Energy Consumption for Buildings: Enhance the Performance From Two Levels," *IEEE Access*, vol. 10, pp. 31649–31659, 2022, doi: 10.1109/ACCESS.2022.3160170.
- [14] Y. Choi, T. Y. Ku, and W.-K. Park, "Handling anomaly in residential energy consumption data," in *2023 14th International Conference on Information and Communication Technology Convergence (ICTC)*, 2023, pp. 1309–1312. doi: 10.1109/ICTC58733.2023.10392520.
- [15] W. Zhuang, W. Zhang, and H. Yuan, "Abnormal Analysis System and Analysis of Residential Electricity Consumption Based on Electricity Data," in *2024 International Conference on Optimization Computing and Wireless Communication (ICOCWC)*, 2024, pp. 1–4. doi: 10.1109/ICOCWC60930.2024.10470748.
- [16] Arwansyah *et al.*, "Deep Sequence Models for Time Series Data: A Comparative Study and Parameter Fine-Tuning Approach," in *2024 11th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, 2024, pp. 703–709. doi: 10.1109/EECSI63442.2024.10776052.
- [17] T. Śmiałkowski and A. Czyżewski, "Autoencoder Application for Anomaly Detection in Power Consumption of Lighting Systems," *IEEE Access*, vol. 11, pp. 124150–124162, 2023, doi: 10.1109/ACCESS.2023.3330135.
- [18] H. Çimen, Y. Wu, Y. Wu, Y. Terriche, J. C. Vasquez, and J. M. Guerrero, "Deep Learning-Based Probabilistic Autoencoder for Residential Energy Disaggregation: An Adversarial Approach," *IEEE Trans Industr Inform*, vol. 18, no. 12, pp. 8399–8408, 2022, doi: 10.1109/TII.2022.3150334.
- [19] G. Li, S. Peng, C. Wang, J. Niu, and Y. Yuan, "An energy-efficient data collection scheme using denoising autoencoder in wireless sensor networks," *Tsinghua Sci Technol*, vol. 24, no. 1, pp. 86–96, 2019, doi: 10.26599/TST.2018.9010002.
- [20] C. Wang, S. H. Tindemans, and P. Palensky, "Improved Anomaly Detection and Localization Using Whitening-Enhanced Autoencoders," *IEEE Trans Industr Inform*, vol. 20, no. 1, pp. 659–668, 2024, doi: 10.1109/TII.2023.3268685.