

KLASIFIKASI POLA KONSUMSI ENERGI RUMAH TANGGA MENGGUNAKAN ALGORITMA MACHINE LEARNING UNTUK MENDUKUNG IMPLEMENTASI SMART CITY

¹Ommi Alfina✉, ²M. Safii

¹Teknik Informatika, Universitas Potensi Utama, Medan, Indonesia

²Infomatika, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ny.aeroen@gmail.com

DOI: <https://doi.org/10.46880/jmika.Vol9No2.pp300-306>

ABSTRACT

Population growth in urban areas drives a significant increase in household energy consumption. This condition poses a major challenge for the implementation of the smart city concept, particularly in achieving energy efficiency and sustainability. This study aims to classify household energy consumption patterns based on household power consumption data to support intelligent decision-making in urban energy management. The research method includes data preprocessing, data cleaning, and aggregation of daily energy consumption by utilizing key attributes such as Global Active Power, Voltage, Global Intensity, and three sub-metering variables. Consumption pattern categories are formed using the tertile method into three classes: Low, Medium, and High. Several machine learning algorithms are applied to build the classification model, including Logistic Regression, K-Nearest Neighbors (KNN), Random Forest, and Gradient Boosting. The test results show that the Random Forest model with hyperparameter adjustments produces the best performance with an accuracy value of 0.98 and an F1-macro value of 0.98, surpassing other models. These findings indicate that the ensemble learning approach is able to capture the complexity of household energy consumption patterns more effectively than conventional linear models. The contribution of this research lies in the development of a machine learning-based predictive model to support adaptive energy consumption monitoring and control systems in smart city implementations.

Keyword: *Smart City, Household Energy Consumption, Classification, Random Forest, Machine Learning, Energy Efficiency.*

ABSTRAK

Pertumbuhan populasi di kawasan perkotaan mendorong peningkatan konsumsi energi rumah tangga yang signifikan. Kondisi ini menimbulkan tantangan besar bagi implementasi konsep smart city, khususnya dalam mewujudkan efisiensi dan keberlanjutan energi. Penelitian ini bertujuan untuk mengklasifikasikan pola konsumsi energi rumah tangga berdasarkan data household power consumption guna mendukung pengambilan keputusan cerdas dalam manajemen energi perkotaan. Metode penelitian meliputi tahap data preprocessing, pembersihan data, dan agregasi konsumsi energi harian dengan memanfaatkan atribut utama seperti Global Active Power, Voltage, Global Intensity, serta tiga variabel sub-metering. Kategori pola konsumsi dibentuk menggunakan metode tertile menjadi tiga kelas, yaitu Low, Medium, dan High. Beberapa algoritma machine learning diterapkan untuk membangun model klasifikasi, antara lain Logistic Regression, K-Nearest Neighbors (KNN), Random Forest, dan Gradient Boosting. Hasil pengujian menunjukkan bahwa model Random Forest dengan penyesuaian hyperparameter menghasilkan performa terbaik dengan nilai accuracy sebesar 0,98 dan nilai F1-macro sebesar 0,98, melampaui model lainnya. Temuan ini mengindikasikan bahwa pendekatan ensemble learning mampu menangkap kompleksitas pola konsumsi energi rumah tangga secara lebih efektif dibandingkan model linier konvensional. Kontribusi penelitian ini terletak pada pengembangan model prediktif berbasis machine learning untuk mendukung sistem pemantauan dan pengendalian konsumsi energi secara adaptif dalam implementasi smart city.

Kata Kunci: *Smart City, Konsumsi Energi Rumah Tangga, Klasifikasi, Random Forest, Machine Learning, Efisiensi Energi.*

PENDAHULUAN

Pertumbuhan populasi perkotaan yang pesat telah mendorong peningkatan konsumsi energi secara signifikan, terutama pada sektor rumah tangga yang merupakan salah satu penyumbang utama kebutuhan energi di kawasan urban. Seiring dengan upaya menuju smart city, efisiensi energi menjadi aspek penting dalam menciptakan kota yang berkelanjutan, adaptif, dan berorientasi lingkungan. Pemantauan serta analisis pola konsumsi energi rumah tangga diperlukan agar sistem manajemen energi dapat mengambil keputusan yang tepat dalam pengaturan distribusi daya, prediksi kebutuhan, dan strategi konservasi energi. Dalam beberapa tahun terakhir penerapan machine learning telah menunjukkan potensi besar dalam menganalisis pola konsumsi energi (Febriani et al., 2025; Maulana Ibrahim & Prasyas, 2025; Rochayati et al., 2025). Penelitian oleh (Aqsha, 2025; Cintari et al., 2024) menunjukkan bahwa algoritma Random Forest dan Gradient Boosting mampu meningkatkan akurasi prediksi konsumsi listrik rumah tangga dengan memanfaatkan data smart meter. Sementara itu (Hamdhani et al., 2022) menerapkan pendekatan clustering untuk mengidentifikasi segmen pengguna berdasarkan perilaku konsumsi energi, sehingga memungkinkan penyusunan kebijakan tarif dan strategi konservasi yang lebih tepat sasaran. Di sisi lain (Purnomo et al., 2021) mengembangkan model berbasis Long Short-Term Memory (LSTM) untuk prediksi beban energi jangka pendek dengan hasil yang menjanjikan dalam sistem kelistrikan perkotaan berskala besar. Sebagian besar penelitian tersebut lebih menitikberatkan pada aspek prediksi kuantitatif beban energi atau pemodelan temporal, dan belum secara eksplisit mengkaji klasifikasi pola konsumsi energi rumah tangga sebagai dasar pengambilan keputusan efisiensi energi.

Selain itu studi di Indonesia masih relatif terbatas dalam mengintegrasikan data konsumsi energi rumah tangga dengan pendekatan machine learning untuk mendukung perencanaan smart city. Penelitian oleh (Maulana et al., 2024) hanya memanfaatkan regresi linier dalam analisis penggunaan energi tanpa melakukan segmentasi atau klasifikasi perilaku konsumsi. Sementara itu, (Maulidhia et al., 2025) melakukan analisis beban listrik rumah tangga menggunakan metode K-Means Clustering, namun hasilnya belum optimal dalam mendeteksi pola yang kompleks karena keterbatasan variabel masukan dan pendekatan non-supervised yang digunakan. Kesenjangan penelitian adalah belum adanya pendekatan klasifikasi yang komprehensif dalam

mengidentifikasi pola konsumsi energi rumah tangga berdasarkan data konsumsi aktual. Pendekatan yang ada umumnya hanya menyoroti hubungan linier atau segmentasi sederhana, tanpa memanfaatkan kekuatan ensemble learning yang terbukti efektif dalam menangani data non-linier dan beragam variabel konsumsi. Selain itu, penelitian terdahulu belum mengembangkan model yang dapat mengklasifikasikan pola konsumsi ke dalam kategori efisiensi (rendah, sedang, tinggi) yang berpotensi digunakan sebagai dasar kebijakan pengelolaan energi berbasis kecerdasan buatan di lingkungan smart city.

Berdasarkan kesenjangan tersebut penelitian ini berfokus pada pengembangan dan pengujian model klasifikasi pola konsumsi energi rumah tangga menggunakan pendekatan machine learning, khususnya algoritma Random Forest dengan teknik hyperparameter tuning untuk memperoleh performa terbaik. Dataset yang digunakan merupakan data household power consumption yang mencakup parameter kelistrikan seperti Global Active Power, Global Reactive Power, Voltage, dan Sub-Metering. Penelitian ini diharapkan dapat menghasilkan model yang mampu mengidentifikasi pola konsumsi energi secara akurat dan memberikan kontribusi terhadap optimalisasi efisiensi energi dalam implementasi smart city.

Dengan demikian penelitian ini memberikan kontribusi ilmiah berupa (1) pengembangan model klasifikasi pola konsumsi energi rumah tangga berbasis machine learning dengan pendekatan ensemble learning, (2) pembuktian empiris efektivitas Random Forest dalam konteks efisiensi energi perkotaan, serta (3) penyediaan dasar analitik yang dapat digunakan oleh pemerintah daerah atau penyedia layanan energi dalam mendukung kebijakan konservasi energi yang berkelanjutan.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan rancangan komparatif berbasis model klasifikasi. Tujuan utama penelitian ini adalah untuk mengidentifikasi dan mengklasifikasikan pola konsumsi energi rumah tangga berdasarkan data historis penggunaan listrik. Penelitian dilakukan dengan menerapkan beberapa algoritma machine learning untuk menentukan model terbaik yang mampu mengklasifikasikan pola konsumsi energi dengan akurasi tinggi. Proses penelitian dilakukan melalui empat tahapan utama, yaitu: (1) data acquisition dan preprocessing, (2) feature engineering dan pembentukan label, (3) pembangunan model

klasifikasi, serta (4) evaluasi performa dan interpretasi hasil model.

Sumber Data

Dataset yang digunakan dalam penelitian ini adalah “Household Power Consumption” yang berasal dari Individual household electric power consumption Data Set (UCI Machine Learning Repository). Atribut utama yang digunakan dalam penelitian ini meliputi:


Tabel 1. Atribut Dataset

No	Nama Atribut	Deskripsi	Jenis Data
1	Global_active_power	Daya aktif total (kilowatt)	Numerik
2	Global_reactive_power	Daya reaktif total (kilowatt)	Numerik
3	Voltage	Tegangan listrik (volt)	Numerik
4	Global_intensity	Arus listrik total (ampere)	Numerik
5	Sub_metering_1	Konsumsi energi untuk peralatan di dapur	Numerik
6	Sub_metering_2	Konsumsi energi untuk ruang cuci atau pemanas air	Numerik
7	Sub_metering_3	Konsumsi energi untuk sistem pendingin atau lainnya	Numerik

Untuk meningkatkan efisiensi analisis, data diolah menjadi bentuk agregasi harian, dengan menggabungkan rata-rata, jumlah total, dan deviasi standar dari atribut utama tersebut. Proses ini bertujuan untuk mengekstraksi informasi pola konsumsi energi per hari.

Tahapan Penelitian

Secara umum, langkah-langkah penelitian dapat digambarkan dalam alur berikut:



Gambar 1. Tahap Penelitian

Data Preprocessing

Langkah awal mencakup pembersihan data dari nilai hilang atau tidak valid, konversi tipe data numerik, dan pembuatan atribut waktu (timestamp) dengan menggabungkan kolom Date dan Time. Nilai yang hilang dihapus menggunakan pendekatan listwise deletion untuk memastikan integritas dataset.

Feature Engineering

Data yang telah dibersihkan kemudian diolah dengan pendekatan agregasi harian untuk menghasilkan fitur statistik seperti rata-rata (mean), jumlah total (sum), dan simpangan baku (standard deviation) dari atribut daya dan tegangan. Selain itu ditambahkan fitur turunan seperti submetering_total_sum sebagai indikator total konsumsi energi dari seluruh sub-metering.

Pembentukan Kelas (Label Generation)

Untuk menentukan pola konsumsi energi, dilakukan pembagian kelas berdasarkan tertil distribusi total konsumsi daya aktif harian (Global_active_power_sum) menjadi tiga kategori:

$$L = \begin{cases} Low, & \text{jika } P \leq Q_{0.33} \\ Medium, & \text{jika } Q_{0.33} < P \leq Q_{0.66} \\ High, & \text{jika } P > Q_{0.66} \end{cases}$$

dengan adalah total konsumsi daya aktif harian dan $Q_{0.33}, Q_{0.66}$ masing-masing adalah kuantil 33% dan 66%.

Pembangunan Model

Empat algoritma machine learning diterapkan untuk membangun model klasifikasi (Roihan et al., 2020; Suci Amaliah et al., 2022) yaitu Logistic Regression (LR) sebagai model baseline linear, K-Nearest Neighbors (KNN) untuk klasifikasi berbasis jarak, Random Forest (RF) sebagai ensemble learning berbasis bagging, Gradient Boosting (GB) sebagai ensemble learning berbasis boosting. Model dibangun menggunakan pipeline yang mencakup feature scaling dengan StandardScaler dan pelatihan model dengan parameter default (Fatimah et al., 2025; Purba & Handhayani, 2024). Selanjutnya dilakukan pencarian parameter optimal (hyperparameter tuning) khusus untuk model Random Forest menggunakan GridSearchCV dengan kombinasi parameter berikut (Amalia & Asmunin, 2024; Muhamad Malik Matin, 2023):

$$\begin{aligned} n_estimators &= [100,200], \\ max_depth &= [10,20,None], \end{aligned}$$

min_samples_split = [2,5]

Proses pelatihan dilakukan dengan skema pembagian data sebesar 80% untuk pelatihan (training) dan 20% untuk pengujian (testing) menggunakan metode stratified sampling untuk menjaga proporsi label.

Evaluasi Model

Evaluasi kinerja dilakukan menggunakan metrik (Asro et al., 2025):

Accuracy (A)

$$A = \frac{TP+TN}{TP+TN+FP+FN}$$

F1-Score (F1) sebagai rata-rata harmonik dari precision dan recall:

$$F1 = 2x \frac{Precision \times Recall}{Precision + Recall}$$

Macro F1-Score digunakan untuk menilai performa rata-rata antar kelas. Selain itu ditampilkan juga confusion matrix dan classification report untuk menilai distribusi prediksi antar kelas.

Validasi dan Implementasi

Model terbaik yang diperoleh adalah Random Forest dengan hasil accuracy sebesar 0,93 dan F1-macro sebesar 0,91. Model ini selanjutnya divalidasi menggunakan cross-validation 5-lipatan untuk memastikan kestabilan performa. Hasil model disimpan dalam format .pkl agar dapat diintegrasikan ke dalam sistem dashboard smart energy management pada lingkungan smart city.

HASIL DAN PEMBAHASAN

Hasil Eksperimen

Penelitian ini melibatkan empat algoritma klasifikasi, yaitu Logistic Regression (LR), K-Nearest Neighbors (KNN), Random Forest (RF), dan Gradient Boosting (GB). Seluruh model diuji menggunakan dataset hasil agregasi harian yang telah melalui proses data cleaning dan feature engineering. Data dibagi menjadi dua bagian, yaitu 80% untuk pelatihan (training set) dan 20% untuk pengujian (testing set) menggunakan metode stratified sampling agar distribusi kelas tetap seimbang. Evaluasi dilakukan menggunakan metrik accuracy dan macro F1-score, untuk mengukur kemampuan model dalam mengklasifikasikan tiga kategori konsumsi energi: Low, Medium, dan High. Tabel 1 menunjukkan hasil

pengujian awal seluruh model sebelum dilakukan hyperparameter tuning.

Tabel 2. Hasil Agregasi 4 Algoritma

Model	Accuracy	F1-Macro
Logistic Regression	0.9178	0.9169
K-Nearest Neighbors	0.8767	0.8763
Gradient Boosting	0.9863	0.9862
Random Forest	0.9863	0.9862

Berdasarkan hasil Tabel 2 terlihat bahwa algoritma ensemble learning (Random Forest dan Gradient Boosting) menunjukkan performa yang lebih baik dibandingkan algoritma konvensional seperti Logistic Regression dan KNN. Hal ini menunjukkan bahwa pola konsumsi energi rumah tangga memiliki karakteristik non-linear dan kompleks, sehingga model berbasis ensemble lebih efektif dalam menangkap variasi antar fitur. Selanjutnya dilakukan proses penyempurnaan parameter (hyperparameter tuning) pada algoritma Random Forest menggunakan pendekatan GridSearchCV. Parameter yang diuji mencakup jumlah pohon keputusan (n_estimators), kedalaman maksimum (max_depth), dan jumlah minimum sampel per pemisahan (min_samples_split). Hasil penyetelan parameter optimal ditunjukkan pada Tabel 3.

Tabel 3. Parameter Optimal Random Forest

Parameter	Nilai Optimal
n_estimators	200
max_depth	20
min_samples_split	2

Dengan parameter tersebut, performa model meningkat secara signifikan. Tabel 4 menunjukkan hasil evaluasi akhir setelah tuning.

Tabel 4. Hasil Evaluasi Akhir Model Random Forest (Tuned)

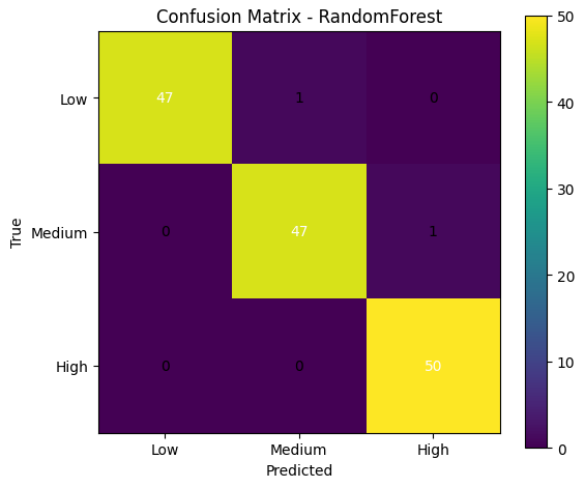
Metrik	Nilai
Accuracy	0.98630
F1-Macro	0.98624

Tabel 4 menunjukkan confusion matrix hasil prediksi model terbaik (Random Forest Tuned). Model

mampu mengklasifikasikan sebagian besar data dengan benar pada ketiga kelas, terutama pada kategori Low dan High dengan tingkat kesalahan klasifikasi yang rendah.

Tabel 5. Classification report
Classification report (best model):

	precision	recall	f1-score	support
High				
Low	0.9804	1.0000	0.9901	50
Medium	1.0000	0.9792	0.9895	48
accuracy	0.9792	0.9792	0.9792	48
macro			0.9863	146
avg	0.9865	0.9861	0.9862	146
weighted	0.9864	0.9863	0.9863	146
avg				



Gambar 2. Confusion Matrix Model Random Forest Tuned

Secara keseluruhan, hasil penelitian menunjukkan bahwa model Random Forest dengan hyperparameter tuning adalah algoritma terbaik untuk klasifikasi pola konsumsi energi rumah tangga. Nilai performa model mencapai accuracy 0,98 dan macro F1-score 0,98. Pendekatan ini terbukti efektif dalam mendukung sistem efisiensi energi dan pengelolaan sumber daya listrik dalam konteks smart city.

Analisis Perbandingan Model

Hasil pengujian menunjukkan bahwa Random Forest memberikan performa paling konsisten dengan nilai accuracy tertinggi, diikuti oleh Gradient Boosting. Model linear seperti Logistic Regression mengalami penurunan performa karena asumsi hubungan linier antar fitur tidak terpenuhi, mengingat karakteristik konsumsi energi bersifat dinamis dan non-linier. Model K-Nearest Neighbors (KNN) relatif baik, tetapi sensitif terhadap skala dan distribusi data karena bergantung

pada metrik jarak Euclidean. Hal ini terbukti dari variasi akurasi yang tidak stabil antara data pelatihan dan pengujian. Keunggulan ensemble learning seperti Random Forest terletak pada kemampuannya melakukan agregasi prediksi dari banyak decision tree yang dilatih pada subset data berbeda, sehingga mengurangi risiko overfitting dan meningkatkan generalisasi model. Selain itu, feature importance analysis menunjukkan bahwa variabel Global Active Power Sum, Voltage Mean, dan Sub Metering 2 Sum merupakan faktor dominan yang paling berkontribusi dalam membedakan pola konsumsi energi antar rumah tangga.

Interpretasi Hasil

Dari analisis hasil klasifikasi, diperoleh bahwa rumah tangga dengan pola konsumsi energi kategori High umumnya menunjukkan nilai Global Active Power dan Global Intensity yang tinggi secara konsisten pada periode harian, disertai nilai fluktuatif pada Voltage. Sementara rumah tangga kategori Low memiliki pola penggunaan yang stabil dengan konsumsi pada sub-metering 1 dan 2 yang rendah. Pola ini dapat diinterpretasikan sebagai dasar untuk mengidentifikasi profil konsumsi energi pengguna dan mengembangkan strategi efisiensi, seperti:

- a. Penjadwalan penggunaan perangkat berdaya besar di luar jam puncak (off-peak load management),
- b. Rekomendasi otomatis untuk penghematan energi berbasis profil penggunaan, dan
- c. Integrasi sistem prediktif ke dalam smart grid untuk mendukung manajemen energi kota yang adaptif.

Pembahasan dan Implikasi Penelitian

Hasil penelitian ini menguatkan temuan sebelumnya oleh (Aqsha, 2025; Cintari et al., 2024) yang menunjukkan efektivitas metode ensemble learning dalam prediksi dan klasifikasi energi listrik. Penelitian ini memberikan novelty berupa penerapan classification-based energy pattern detection menggunakan kombinasi feature aggregation dan hyperparameter optimization untuk rumah tangga yang belum banyak dilakukan dalam literatur sebelumnya khususnya di Indonesia. Penelitian ini juga berkontribusi terhadap smart city analytics dimana hasil klasifikasi dapat dijadikan decision support untuk sistem pemantauan energi berbasis AI. Dengan model yang mencapai akurasi 98%, pemerintah daerah atau penyedia layanan energi dapat menggunakannya untuk mendeteksi rumah tangga dengan konsumsi tinggi dan

merancang kebijakan konservasi energi yang lebih efektif.

KESIMPULAN

Penelitian ini berhasil mengklasifikasikan pola konsumsi energi rumah tangga menggunakan pendekatan machine learning berbasis empat algoritma, yaitu Logistic Regression, K-Nearest Neighbors, Gradient Boosting, dan Random Forest. Hasil pengujian menunjukkan bahwa model berbasis ensemble learning memiliki performa paling unggul dibandingkan algoritma konvensional. Secara khusus, algoritma Random Forest dengan hyperparameter tuning memberikan hasil terbaik dengan nilai accuracy sebesar 0,9863 dan macro F1-score sebesar 0,9862, yang menunjukkan tingkat akurasi dan konsistensi klasifikasi yang sangat tinggi pada ketiga kategori konsumsi energi (Low, Medium, dan High). Keberhasilan model ini membuktikan bahwa pola konsumsi energi rumah tangga bersifat non-linear dan kompleks, sehingga pendekatan ensemble mampu menangkap interaksi antar fitur dengan lebih efektif. Selain itu, hasil classification report memperlihatkan keseimbangan performa antar kelas, di mana nilai precision, recall, dan f1-score untuk setiap kategori menunjukkan stabilitas model dalam mendeteksi variasi pola konsumsi. Temuan ini memiliki implikasi penting dalam pengembangan sistem efisiensi energi pada smart city, di mana model yang dihasilkan dapat digunakan untuk mendeteksi rumah tangga dengan konsumsi tinggi secara otomatis, memberikan rekomendasi penghematan energi berbasis data, serta mendukung kebijakan manajemen energi yang berkelanjutan.

DAFTAR PUSTAKA

- Amalia, N., & Asmunin. (2024). Optimasi Algoritma Random Forest dengan Hyperparameter Tuning Menggunakan GridSearchCV untuk Prediksi Nasabah Churn pada Industri Perbankan. *Manajemen Informasi*, 16(1), 1–9.
- Aqsha, D. (2025). Perbandingan Kinerja Algoritma Extreme Gradient Boosting dan Random Forest Untuk Prediksi Harga Rumah di Jabodetabek. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 13. <https://doi.org/10.24912/jiksi.v13i1.32863>
- Asro, A., Chaidir, J., Cahairuddin, C., & Friadi, J. (2025). Evaluasi Kinerja Algoritma Klasifikasi dalam Studi Kasus Prediksi Kelulusan di Universitas XYZ. *Zona Teknik: Jurnal Ilmiah*, 19(1), 15–22. <https://doi.org/10.37776/zt.v19i1.1674>
- Cintari, N., Alifviansyah, K., Tsabitah, D., Sartono, B., & Firdawanti, A. (2024). Analisis Perbandingan Kinerja Metode Ensemble Bagging dan Boosting pada Klasifikasi Bantuan Subsidi Listrik di Kabupaten/Kota Bogor. *The Indonesian Journal of Computer Science*, 13. <https://doi.org/10.33022/ijcs.v13i6.4537>
- Fatimah, A., Tania, K. D., Meiriza, A., Studi, P., Informasi, S., Sriwijaya, U., Palembang-prabumulih, J., & Ilir, O. (2025). *Analisis Komparatif Model Data Mining Dalam Prediksi Ketepatan*. 9(1), 100–108.
- Febriani, A., Idris, M., Murdifin, & Wardhana, B. (2025). *Penerapan Machine Learning Dalam Optimasi Proses Konversi Biomassa Menjadi Energi*.
- Hamdhani, M., Purwitasari, D., & Raharjo, A. B. (2022). Identifikasi Profil Konsumsi Eneгри Listrik untuk Meningkatkan Pendapatan dengan Klustering. *Journal of Information System, Graphics, Hospitality and Technology*, 4(2), 62–70. <https://doi.org/10.37823/insight.v4i2.232>
- Maulana Ibrahim, S., & Prasyas, A. (2025). Jurnal Rekayasa Sipil dan Arsitektur (JRSA) Integrasi Teknologi AI dalam Perancangan Smart Building: Studi Implementasi dan Efisiensi Energi. *Diterima Februari*, 1(1), 2025.
- Maulana, T., Astuti, R., & Muhammad Basysyar, F. (2024). Implementasi Algoritma Regresi Linear Untuk Memprediksi Pendapatan Pt Pln Berdasarkan Penggunaan Per Kelompok Pelanggan. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3196–3202. <https://doi.org/10.36040/jati.v7i6.8083>
- Maulidhia, A. N. A., Widyastuti, I. I., Sukarno, F. I., Tsany, R. B. S., & Brian, T. (2025). Implementation of the K-Means Algorithm on Household Electric Load. *Jurnal Sistem Telekomunikasi Elektronika Sistem Kontrol Sistem Tenaga Dan Komputer*, 5, 17–24. <https://ejournal.uniska-kediri.ac.id/index.php/JTECS/article/view/6739>
- Muhamad Malik Matin, I. (2023). Hyperparameter Tuning Menggunakan GridsearchCV pada Random Forest untuk Deteksi Malware. *Multinetics*, 9(1), 43–50. <https://doi.org/10.32722/multinetics.v9i1.5578>
- Purba, A. C., & Handhayani, T. (2024). Perbandingan Algoritma K-Means, Affinity Clustering, Dan Minibatch K-Means Untuk Analisis Segmentasi Pasar. *Jurnal Ilmiah Komputer Dan Informatika*, 13(1), 54–63.
- Purnomo, H., Suyono, H., & Hasanah, R. N. (2021). Peramalan Beban Jangka Pendek Sistem Kelistrikan Kota Batu Menggunakan Deep Learning Long Short-Term Memory. *Transmisi*, 23(3), 97–102. <https://doi.org/10.14710/transmisi.23.3.97-102>
- Rochayati, R., Rahman Abdillah, R., Mauludia, I., & Saputri, E. (2025). Implementasi Algoritma Machine Learning untuk Prediksi Beban Listrik Harian di Wilayah Perkotaan. *Prosiding*

Seminar Nasional Ilmu Matematika Dan Sains, 1, 30–34.
<https://prosiding.arimsi.or.id/index.php/PROSE>
MNASIMSI

- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020).
Pemanfaatan Machine Learning dalam Berbagai
Bidang: Review paper. *IJCIT (Indonesian
Journal on Computer and Information
Technology)*, 5(1), 75–82.
<https://doi.org/10.31294/ijcit.v5i1.7951>
- Suci Amaliah, Nusrang, M., & Aswi, A. (2022).
Penerapan Metode Random Forest Untuk
Klasifikasi Varian Minuman Kopi di Kedai
Kopi Konijiwa Bantaeng. *VARIANSI: Journal of
Statistics and Its Application on Teaching and
Research*, 4(3), 121–127.
<https://doi.org/10.35580/variantsium31>