



Implementasi Algoritma Prophet dengan Grid Search Hyperparameter Tuning untuk Prediksi Konsumsi Energi Listrik Berbasis IoT

Suhardi*, Tedy Rismawan, Cucu Suhery, Irma Nirmala

Fakultas MIPA, Jurusan Rekayasa Sistem Komputer, Universitas Tanjungpura, Pontianak, Indonesia

Email: ^{1,*}suhardi@siskom.untan.ac.id, ²tedyrismawan@siskom.untan.ac.id, ³csuhery@siskom.untan.ac.id,

⁴irmanirmala@siskom.untan.ac.id

Email Penulis Korespondensi: suhardi@siskom.untan.ac.id

Abstrak—Pemantauan konsumsi energi listrik rumah tangga secara real-time belum cukup untuk mendukung manajemen energi yang adaptif. Oleh karena itu, diperlukan kemampuan prediksi yang akurat sekaligus mudah diinterpretasi. Penelitian ini mengimplementasikan algoritma Prophet, model *time series additive* berbasis komponen tren dan musiman, sebagai inti prediksi konsumsi energi harian pada sistem berbasis *Internet of Things* (IoT) dengan granularitas per-ruangan. Data diperoleh dari sensor PZEM-004T dan NodeMCU ESP32 pada tiga ruangan selama 30 hari, diproses melalui prosedur *grid search* dua tahap untuk optimasi *hyperparameter* model. Hasil evaluasi menunjukkan MAPE pengujian sebesar 1,05%–2,01% di ketiga ruangan, seluruhnya dalam kategori sangat baik (<10%). Selain itu, perbedaan rata-rata MAPE antara data pelatihan dan pengujian hanya mencapai 0,42 poin persentase, yang mengindikasikan generalisasi model yang baik tanpa *overfitting*. Analisis dekomposisi komponen memperlihatkan bahwa pola konsumsi didominasi oleh tren linier yang stabil dengan pola musiman mingguan beramplitudo rendah ($\pm 0,06$ kWh), sehingga memberikan tingkat interpretabilitas yang lebih tinggi dibandingkan model *black-box*. Proyeksi 30 hari ke depan menghasilkan estimasi total ~384 kWh (~Rp 554.817) untuk ketiga ruangan, sehingga dapat dimanfaatkan sebagai dasar dalam penyusunan anggaran dan pengelolaan beban listrik yang adaptif. Kontribusi utama penelitian ini adalah menghadirkan prosedur tuning Prophet yang transparan dan dapat direproduksi untuk data konsumsi energi berskala per-ruangan dengan volume historis terbatas, disertai validasi metrologis sensor akuisisi data sebagai jaminan kualitas input, konteks yang belum banyak dieksplorasi pada literatur Prophet sebelumnya.

Kata Kunci: Prophet; IoT; Time Series; MAPE; PZEM-004T; Hyperparameter Tuning

Abstract—Real-time monitoring of household electricity consumption is not yet sufficient to support adaptive energy management. Therefore, an accurate yet easily interpretable prediction capability is required. This study implements the Prophet algorithm, an additive time series model based on trend and seasonal components, as the core method for predicting daily energy consumption in an Internet of Things (IoT)-based system with per-room granularity. Data were obtained from PZEM-004T sensors and NodeMCU ESP32 modules in three rooms over 30 days, processed through a two-stage grid search procedure for model hyperparameter optimization. The evaluation results show a testing MAPE of 1.05%–2.01% across the three rooms, all falling into the highly accurate category (<10%). Furthermore, the average MAPE difference between the training and testing data reached only 0.42 percentage points, indicating good model generalization without overfitting. Component decomposition analysis reveals that the consumption pattern is dominated by a stable linear trend with a low-amplitude weekly seasonal pattern (± 0.06 kWh), thereby providing a higher level of interpretability compared to black-box models. The 30-day-ahead projection yields a total estimated consumption of approximately 384 kWh (~IDR 554,817) for the three rooms, which can be utilized as a basis for budget planning and adaptive electrical load management. The main contribution of this study is a transparent and reproducible Prophet tuning procedure for per-room electricity consumption data with limited historical volume, supported by metrological validation of the acquisition sensor as an input quality assurance step, a context that has not been widely explored in prior Prophet literature.

Keywords: Prophet; IoT; Time Series; MAPE; PZEM-004T; Hyperparameter Tuning

1. PENDAHULUAN

Energi listrik merupakan kebutuhan dasar yang semakin krusial bagi rumah tangga modern. Data Kementerian ESDM RI mencatat konsumsi listrik per kapita Indonesia mencapai 1.337 kWh pada tahun 2023, meningkat 13,98% dibandingkan tahun sebelumnya [1]. Sektor rumah tangga secara konsisten menjadi salah satu kontributor terbesar konsumsi energi nasional, namun sebagian besar penghuni belum memiliki sistem yang memadai untuk memantau dan mengelola penggunaan energi secara efisien dan proaktif. Kondisi ini menyebabkan pemborosan energi yang tidak disadari, tagihan listrik yang tidak terduga, serta hambatan dalam pencapaian target efisiensi energi nasional.

Internet of Things (IoT) telah terbukti menjadi solusi yang efektif untuk pemantauan konsumsi energi secara *real-time*. Yasa et al. [2] mengembangkan sistem pemantauan kWh meter berbasis sensor PZEM-004T dan mikrokontroler NodeMCU ESP32 yang dapat dipantau dan dikendalikan dari jarak jauh secara *mobile*, membuktikan kelayakan arsitektur ini untuk kebutuhan domestik. Hidayat dan Al-Faris [3] mengimplementasikan sistem monitoring konsumsi listrik rumah tangga berbasis ESP32 dan PZEM-004T yang mampu mengukur tegangan, arus, daya, dan energi secara real-time dan menampilkannya pada perangkat digital pengguna, mengonfirmasi potensi sistem berbasis IoT dalam meningkatkan kesadaran penggunaan energi. Sanya et al. [4] menunjukkan bahwa analitik data *real-time* berbasis IoT memungkinkan identifikasi pola konsumsi listrik yang dapat dijadikan dasar perencanaan penggunaan energi.

Pendekatan berbasis jaringan sensor nirkabel (*Wireless Sensor Network*, WSN) juga telah dieksplorasi untuk manajemen energi. Chéour et al. [5] mengusulkan arsitektur hibrida WSN dengan strategi optimasi konsumsi daya multi-objektif untuk memperpanjang umur jaringan sensor. Naji et al. [6] mengembangkan WSN berbasis konteks untuk sistem manajemen energi bangunan cerdas, membuktikan kemampuan WSN dalam menangkap kondisi lingkungan yang memengaruhi konsumsi. Kassan et al. [7] mendemonstrasikan sistem manajemen energi otonom yang menggunakan



pemanenan energi piezoelektrik pada node sensor nirkabel, membuka peluang instalasi sensor tanpa bergantung pada catu daya eksternal.

Berbagai metode pembelajaran mesin telah diterapkan untuk prediksi konsumsi energi pada sistem IoT rumah tangga. Hoendarto et al. [8] menerapkan pendekatan Regression Tree pada data sensor IoT untuk prediksi konsumsi daya, menunjukkan kemampuan model tersebut dalam mengatasi pola nonlinier. Angdresey et al. dan Sari et al. [9][10] menggunakan algoritma *k-Nearest Neighbor* (k-NN) untuk peramalan beban rumah tangga, efektif untuk pola berulang namun tanpa mekanisme dekomposisi komponen yang eksplisit. Kolluru et al. [11] menerapkan *Long Short-Term Memory* (LSTM) berbasis PyTorch-Ray Tune pada sistem IoT cerdas dengan akurasi tinggi, meskipun memerlukan sumber daya komputasi signifikan. Natarajan et al. [12] mengintegrasikan model *deep learning* hibrida berbasis IoT untuk peningkatan efisiensi energi bangunan, menunjukkan bahwa pendekatan ensemble dapat melampaui model tunggal dalam akurasi prediksi.

Beberapa studi telah mengembangkan sistem terpadu antara IoT dan pembelajaran mesin untuk aplikasi rumah tangga. Hafeez et al. [13] mengembangkan sistem manajemen energi rumah tangga berbasis IoT yang berfokus pada minimalisasi biaya konsumsi pada jam puncak, namun tanpa komponen prediksi jangka panjang. Rahman et al. [14] mengembangkan sistem prediksi konsumsi peralatan rumah tangga berbasis IoT menggunakan metode ML dengan tambahan pendekatan *explainable AI* (XAI), namun tidak menggunakan model *time series* aditif seperti Prophet. Sheela et al. [15] menggabungkan pembelajaran mesin dengan IoT dalam sistem manajemen energi bangunan cerdas, sementara Stogia et al. [16] mengintegrasikan IoT dengan *digital twin* untuk sistem manajemen energi rumah tangga yang skalabel dan ramah pengguna. Syamala et al. [17] mengintegrasikan berbagai algoritma pembelajaran mesin dengan IoT untuk manajemen energi rumah cerdas, namun pemilihan dan tuning model tidak dilaporkan secara transparan dan dapat direproduksi.

Di sisi lain, algoritma Prophet, model *time series additive* yang dikembangkan oleh Taylor dan Letham [18] telah diterapkan secara luas untuk prediksi konsumsi dan harga energi. Arslan [19] membuktikan efektivitas dekomposisi Prophet melalui model hibrida LSTM dan Prophet untuk data konsumsi energi tujuh negara, menggunakan *dataset benchmark* publik. Liang et al. [20] menggunakan komponen dekomposisi Prophet sebagai fitur rekayasa untuk model prediksi konsumsi energi berbasis GRU-LightGBM, menunjukkan bahwa komponen tren dan musiman Prophet dapat meningkatkan kinerja model ensemble. Son et al. [21] menggabungkan Prophet dengan GRU untuk prediksi konsumsi listrik jangka pendek dan menengah pada skala fasilitas manufaktur. Stefenon et al. [22] mengagregasikan Prophet dengan dekomposisi STL (*Seasonal and Trend decomposition using Loess*) untuk peramalan harga listrik pasar spot Italia, membuktikan keunggulan Prophet dalam menangani musiman berlapis. Sulandari et al. [23] secara khusus mendemonstrasikan pentingnya *hyperparameter tuning* pada Prophet dengan menunjukkan peningkatan akurasi yang signifikan dibandingkan konfigurasi *default*, meskipun menggunakan data agregat skala nasional. Studi terbaru pada jurnal Energies [24] secara eksplisit membandingkan LSTM dan Prophet untuk prediksi permintaan listrik dinamis dan menunjukkan bahwa Prophet mencapai akurasi kompetitif dengan efisiensi komputasi yang lebih tinggi.

Kajian terhadap studi-studi terdahulu mengidentifikasi dua kesenjangan penelitian yang belum terjawab. Pertama, meskipun Prophet terbukti efektif untuk prediksi energi [9][11][12][23][24], seluruh penerapannya menggunakan *dataset* agregat skala besar dengan karakteristik noise rendah dan volume tinggi, sehingga tantangan unik data per-ruangan (amplitudo sinyal kecil, heterogenitas pola antar-ruangan, dan keterbatasan volume historis) belum pernah dihadapi secara eksplisit. Di sisi lain, sistem IoT terintegrasi ML untuk rumah tangga [4] [5][4][5][6] [18][19] tidak menggunakan Prophet dan tidak melaporkan prosedur tuning yang dapat direproduksi. Penelitian ini menutup kesenjangan tersebut dengan menerapkan Prophet pada data sensor IoT per-ruangan yang memiliki ketiga tantangan di atas, disertai grid search dua tahap yang justifikasinya dapat ditelusuri secara transparan.

Model prediksi deret waktu untuk konsumsi energi dapat dikelompokkan menjadi tiga kelas utama [25]. Pertama, model statistik klasik seperti ARIMA dan SARIMA bekerja baik pada data stasioner dengan pola musiman yang kaku, namun memerlukan transformasi data yang ekstensif, tidak mampu menangani *changepoints* secara otomatis, dan performanya menurun signifikan ketika struktur tren data berubah selama periode pengamatan [25][26]. Kedua, model *deep learning* seperti LSTM [10] dan GRU [20] mencapai akurasi tinggi namun memerlukan volume data besar, sumber daya komputasi signifikan, dan menghasilkan model yang tidak transparan (*black-box*) yang merupakan karakteristik yang problematik untuk *deployment* pada server IoT berbiaya rendah dengan data historis terbatas. Studi perbandingan terbaru menunjukkan bahwa Prophet mencapai akurasi kompetitif dibanding LSTM untuk prediksi permintaan listrik dinamis dengan efisiensi komputasi lebih tinggi [17]. Ketiga, Prophet [18] menawarkan posisi yang berbeda yang secara eksplisit memodelkan tren dengan *changepoints* otomatis dan musiman berbasis deret Fourier, robust terhadap *missing values* dan *outlier*, serta menghasilkan dekomposisi komponen yang dapat diinterpretasi secara langsung [26]. Untuk konteks data sensor IoT harian dengan horizon 30 hari dan volume terbatas, Prophet secara arsitektural lebih sesuai dibanding ARIMA yang membutuhkan stasionaritas dan dibanding LSTM yang membutuhkan data jauh lebih banyak untuk konvergensi yang andal.

Tujuan penelitian ini adalah: (1) mengimplementasikan dan mengevaluasi model Prophet [18] sebagai inti prediksi konsumsi energi harian berbasis data sensor IoT per-ruangan; (2) mengembangkan prosedur *hyperparameter tuning* sistematis dua tahap menggunakan *grid search* dengan fungsi objektif MAPE rata-rata multi-ruangan; (3) memvalidasi akurasi sensor PZEM-004T sebagai penjaminan kualitas data input; dan (4) menghasilkan proyeksi 30 hari ke depan beserta estimasi biaya listrik yang dapat langsung dimanfaatkan oleh penghuni.



Kontribusi utama penelitian ini terhadap kesenjangan yang telah diidentifikasi meliputi tiga hal. Pertama, penelitian ini menghadirkan salah satu penerapan algoritma Prophet pada data konsumsi energi listrik berskala per-ruangan dengan volume historis terbatas. Kedua, penelitian ini menawarkan prosedur grid search dua tahap yang justifikasi pemilihan rentang parameternya dapat ditelusuri secara transparan dan direproduksi. Ketiga, penelitian ini menyertakan validasi metrologis terhadap sensor akuisisi data sebagai bagian dari penjaminan kualitas data input model.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui lima tahapan berurutan yang terintegrasi dalam satu *pipeline* sistem, sebagaimana diperlihatkan pada Gambar 1. Tahap pertama adalah akuisisi data secara *real-time* dari sensor IoT yang dipasang pada setiap ruangan. Tahap kedua adalah praproses data mencakup pembersihan anomali dan konversi ke format deret waktu. Tahap ketiga adalah pemodelan prediktif menggunakan algoritma Prophet [18] disertai optimasi *hyperparameter* melalui *grid search* dua tahap [23]. Tahap keempat adalah evaluasi akurasi model menggunakan metrik MAPE, MAE, dan RMSE berdasarkan skala interpretasi Lewis [27][28]. Tahap kelima adalah proyeksi konsumsi 30 hari ke depan beserta estimasi biaya listrik sebagai keluaran praktis sistem. Kelima tahapan ini membentuk *pipeline* yang berkesinambungan dari pengumpulan data fisik hingga informasi prediktif yang dapat langsung dimanfaatkan pengguna [12][16]. Gambar 1 menyajikan alur keseluruhan *pipeline* tersebut secara visual.



Gambar 1. Alur Pipeline Sistem – Akuisisi Data IoT hingga Prediksi Prophet

2.2 Kajian Algoritma Prophet

Model prediksi deret waktu dapat dikelompokkan menjadi tiga kelas utama berdasarkan pendekatan matematisnya [29]. Kelas pertama adalah model statistik klasik seperti ARIMA dan SARIMA yang bekerja baik pada data stasioner namun memerlukan transformasi data ekstensif dan tidak mampu menangani perubahan tren (*change-points*) secara otomatis [25]. Kelas kedua adalah model *deep learning* seperti LSTM [11] dan GRU [21] yang mencapai akurasi tinggi namun membutuhkan volume data besar dan sumber daya komputasi signifikan, serta menghasilkan model yang tidak transparan (*black-box*) [26]. Studi perbandingan terbaru menunjukkan bahwa Prophet mencapai akurasi kompetitif dibanding LSTM dengan efisiensi komputasi yang lebih tinggi [24]. Kelas ketiga adalah model *additive time series* seperti Prophet [18] yang secara eksplisit memodelkan tren, musiman, dan *change-points*, serta menghasilkan dekomposisi komponen yang dapat diinterpretasi secara langsung. Untuk konteks data sensor IoT harian dengan horison 30 hari dan volume terbatas, Prophet secara arsitektural lebih sesuai dibanding ARIMA yang membutuhkan stasionaritas, dan dibanding LSTM yang membutuhkan data jauh lebih banyak untuk konvergensi yang andal [25]. Prophet memodelkan deret waktu sebagai penjumlahan komponen aditif [18]. Persamaan umum model dinyatakan pada Persamaan (1):

$$y(t) = g(t) + s(t) + \varepsilon_t \quad (1)$$

di mana $y(t)$ adalah nilai aktual konsumsi kWh pada waktu t ; $g(t)$ adalah komponen tren linier dengan *change-points* yang menangkap perubahan laju pertumbuhan; $s(t)$ adalah komponen musiman; dan ε_t adalah residual acak dengan distribusi normal. Komponen musiman $s(t)$ dimodelkan menggunakan deret Fourier orde- N dengan periode $P = 7$ hari untuk musiman mingguan, seperti pada Persamaan (2):

$$s(t) = \sum_{n=1}^N \left[a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right] \quad (2)$$

dengan a_n dan b_n adalah koefisien Fourier yang diestimasi selama pelatihan. Regularisasi diterapkan melalui *prior* Laplace pada parameter *change-point* dan musiman untuk mengontrol *trade-off* antara fleksibilitas model dan risiko *overfitting* [17]. Mekanisme regularisasi bawaan ini menjadi keunggulan penting ketika data pelatihan terbatas seperti pada penelitian ini. Dekomposisi komponen yang eksplisit menjadikan Prophet berbeda dari model *black-box* karena setiap komponen tren dan musiman dapat diinterpretasi secara langsung [12][20].

2.3 Pengumpulan dan Praproses Data

Penggunaan data 30 hari dengan 24 hari pelatihan diakui sebagai keterbatasan volume historis yang perlu diperhatikan. Namun demikian, terdapat dua mekanisme yang memitigasi risiko *overfitting* dalam konteks ini. Pertama, Prophet menerapkan regularisasi melalui *prior* Laplace pada parameter *change-point* dan musiman [18] yang secara mekanistik membatasi kompleksitas model terlepas dari ukuran dataset. Kedua, musiman mingguan yang dimodelkan ($P = 7$ hari) membutuhkan minimal dua hingga tiga siklus penuh untuk estimasi yang andal; 24 hari pelatihan mencakup 3,4 siklus mingguan, melebihi batas minimum tersebut. Data dibagi menggunakan skema *hold-out* sekuensial dengan rasio 80:20, menghasilkan 24 hari pelatihan dan 6 hari validasi. Skema *time-ordered* dipilih untuk mencegah kebocoran informasi



masa depan (*data leakage*) ke model [25]. Penggunaan 24 hari pelatihan secara teknis memadai untuk estimasi musiman mingguan yang andal karena mencakup 3,4 siklus mingguan penuh — melampaui batas minimum dua hingga tiga siklus yang diperlukan. Selain itu, regularisasi *prior* Laplace bawaan Prophet secara mekanistik membatasi kompleksitas model, sehingga memitigasi risiko *overfitting* meski dengan data terbatas.

2.4 Hyperparameter Tuning

Rentang search space pada tahap pertama ditentukan berdasarkan dua pertimbangan. Pertama, nilai-nilai yang dipilih mengapit nilai default yang direkomendasikan oleh Taylor dan Letham [18] dengan *changepoint_prior_scale default* = 0,05 berada di antara 0,01 dan 0,1; *seasonality_prior_scale default* = 10 merupakan batas atas *grid* yang dipilih, sehingga eksplorasi mencakup wilayah di bawah dan di atas perilaku default. Kedua, keempat nilai pada masing-masing parameter membentuk *grid* logaritmik yang mencakup tiga orde magnitudo, sesuai dengan praktik standar tuning parameter regularisasi yang efeknya bersifat multiplikatif. Nilai optimal yang ditemukan (*changepoint* $\approx$ 0,04; *seasonality* $\approx$ 0,01) berada di dalam rentang yang dieksplorasi, mengonfirmasi bahwa *search space* tahap pertama sudah mencakup daerah solusi. *Grid search* dua tahap diterapkan untuk menemukan kombinasi *hyperparameter* optimal. Tahap pertama mengeksplorasi $4 \times 4 = 16$ kombinasi yang tersusun pada Tabel 1, dengan fungsi objektif berupa rata-rata MAPE dari tiga ruangan pada data validasi. Pendekatan rata-rata multi-ruangan memastikan parameter terpilih bersifat generik dan tidak *overfit* ke satu ruangan tertentu. Tahap kedua membentuk *refined grid* dengan nilai inkremental di sekitar kandidat terbaik tahap pertama menggunakan algoritma *create_incremental_grid* dengan langkah adaptif, sehingga eksplorasi menjadi lebih presisi tanpa meledakkan biaya komputasi.

Tabel 1. Grid Hyperparameter Pencarian Tahap Pertama

Parameter	Nilai 1	Nilai 2	Nilai 3	Nilai 4
<i>changepoint_prior_scale</i>	0,001	0,01	0,1	0,5
<i>seasonality_prior_scale</i>	0,01	0,1	1,0	10,0

2.5 Evaluasi Model

Kinerja model dievaluasi menggunakan tiga metrik. *Mean Absolute Percentage Error* (MAPE) digunakan sebagai metrik utama karena bersifat *scale-independent* sehingga memungkinkan perbandingan lintas ruangan. *Mean Absolute Error* (MAE) dalam satuan kWh memberikan interpretasi langsung bagi pengguna akhir. *Root Mean Square Error* (RMSE) lebih sensitif terhadap deviasi besar sehingga berguna untuk mengidentifikasi titik prediksi ekstrem. Ketiga metrik dinyatakan pada Persamaan (3), (4), dan (5). Kategori akurasi MAPE mengacu pada skala Lewis [26]: <10% = sangat baik, 10–20% = baik, 20–50% = wajar, >50% = tidak akurat. Meskipun sumber klasifikasi ini berasal dari tahun 1982, skala tersebut tetap menjadi rujukan standar dalam studi peramalan konsumsi energi kontemporer dan konsisten digunakan pada berbagai penelitian berbasis Prophet dan model deret waktu lain yang menjadi pembanding pada penelitian ini [20], [22], sehingga penggunaannya di sini bukan merepresentasikan literatur *state-of-the-art*, melainkan rujukan definisi metrik yang bersifat baku.

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100\% \quad (1)$$

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

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

3. HASIL DAN PEMBAHASAN


3.1 Karakteristik Data Konsumsi Energi

Tabel 2 menyajikan statistik deskriptif data konsumsi harian tiga ruangan selama September 2025. Nilai *Coefficient of Variation* (CV) yang rendah (1,85%–3,25%) mengindikasikan stabilitas pola konsumsi yang tinggi tanpa lonjakan atau penurunan ekstrem sepanjang periode pengamatan. Stabilitas ini merupakan prasyarat yang menguntungkan bagi model deret waktu aditif seperti Prophet, karena komponen tren dan musiman dapat diestimasi dengan lebih andal dari data yang tidak terdistorsi oleh *outlier* sistemik. Pada saat yang sama, nilai CV yang rendah ini juga menjadi konteks penting untuk menginterpretasikan MAPE yang dicapai model sebagaimana dibahas lebih lanjut pada Subbab 3.8. Peringkat konsumsi konsisten sepanjang periode: Ruangan 3 (mean 4,458 kWh/hari) > Ruangan 2 (4,158 kWh/hari) > Ruangan 1 (3,546 kWh/hari), mengindikasikan perbedaan beban elektronik yang relatif tetap antar ruangan. Visualisasi tren konsumsi harian disajikan pada Gambar 2.

Tabel 2. Statistik Deskriptif Konsumsi Energi Harian (n = 30 hari)

Statistik	Ruangan 1	Ruangan 2	Ruangan 3	Satuan
Mean	3,546	4,158	4,458	kWh/hari

Statistik	Ruangan 1	Ruangan 2	Ruangan 3	Satuan
Standar Deviasi	0,115	0,077	0,120	kWh
Minimum	3,39	4,01	4,19	kWh/hari
Maksimum	3,81	4,28	4,69	kWh/hari
Coeff. of Variation (CV)	3,25%	1,85%	2,69%	—




Gambar 2. Pola Konsumsi Energi Harian Tiga Ruangan, September 2025

3.2 Validasi Metrologi Sensor PZEM-004T

Kualitas data input model sangat bergantung pada keandalan sensor. Validasi dilakukan terhadap 30 sampel per parameter dengan membandingkan pembacaan sensor PZEM-004T terhadap alat ukur standar. Tabel 3 merangkum hasil lengkap, dan Gambar 3 menyajikan perbandingan visual. Berdasarkan Tabel dan gambar tersebut, sensor PZEM-004T menunjukkan akurasi yang memadai untuk ketiga parameter. Error relatif tegangan (0,1247%) dan daya (0,37%) berada jauh di bawah toleransi umum 1% untuk sistem monitoring operasional. Error arus (2,72%) lebih tinggi, terutama pada beban kecil seperti charger (<0,35 A), yang merupakan fenomena lazim pada sensor *current transformer* akibat keterbatasan resolusi pada nilai arus rendah. Implikasi metrologi ini penting: untuk akumulasi energi harian (kWh), error arus teredam melalui integrasi terhadap waktu dan dominasi beban menengah-besar (kipas, setrika) yang memiliki error relatif lebih rendah (~0,7–1,4%). Akurasi ini menjamin bahwa penyimpangan dalam prediksi Prophet berasal dari keterbatasan model, bukan derau pada data input, sehingga hubungan sebab-akibat dalam analisis dapat ditarik dengan lebih andal.

Tabel 3. Ringkasan Validasi Metrologi Sensor PZEM-004T (n = 30 sampel per parameter)


Parameter	Satuan	Rata-rata Error Selisih	Error Relatif (%)	Beban Uji	n
Tegangan	V	0,260	0,1247	Umum (206–211 V)	30
Arus	A	0,012	2,7181	Charger, kipas, setrika	30
Daya	W	0,363	0,3742	Charger, kipas, setrika	30



Gambar 3. Validasi Metrologi Sensor PZEM-004T: Nilai Sensor vs Alat Ukur Standar. (a) Tegangan, (b) Arus, (c) Daya. Garis merah menunjukkan garis ideal $y = x$

3.3 Hasil Hyperparameter Tuning

Grid search tahap pertama mengidentifikasi kombinasi $\text{changepoint_prior_scale} = 0,1$ dan $\text{seasonality_prior_scale} = 1,0$ sebagai kandidat optimal dengan rata-rata MAPE $\sim 1,12\%$. Peta panas seluruh kombinasi grid disajikan pada Gambar 4. *Refined grid* tahap kedua menghasilkan nilai optimal akhir: $\text{changepoint_prior_scale} \approx 0,04$ dan $\text{seasonality_prior_scale} \approx 0,01$. Nilai $\text{changepoint_prior_scale}$ yang rendah (0,04) mengekspresikan preferensi tren bertahap tanpa lonjakan mendadak, selaras dengan pola data yang menunjukkan perubahan konsumsi perlahan. Nilai $\text{seasonality_prior_scale}$ yang sangat rendah (0,01) menekan amplitudo musiman menandakan konsistensi dengan CV data yang kecil dan variasi aktivitas mingguan penghuni yang relatif terpol. Kedua nilai ini secara fisik masuk akal sebagai representasi karakteristik konsumsi energi hunian tipe kos.



Gambar 4. Peta Panas Grid Search Hyperparameter Prophet: Rata-rata MAPE (%) pada Ruang Parameter 4×4. Kotak biru menandai kombinasi parameter terbaik


3.4 Akurasi Model Prophet

Tabel 4 menyajikan hasil evaluasi komprehensif model dengan hyperparameter optimal. Semua nilai MAPE berada dalam kategori sangat baik (<10%) berdasarkan skala Lewis [26].


Tabel 4. Hasil Evaluasi Model Prophet: MAPE, MAE, dan RMSE per Ruangan dan Fase

Ruangan	Fase	MAPE (%)	MAE (kWh)	RMSE (kWh)	n	Kategori
Ruangan 1	Training	0,86	0,031	0,038	24	Sangat Baik
Ruangan 1	Testing	2,01	0,071	0,082	6	Sangat Baik
Ruangan 2	Training	0,94	0,039	0,050	24	Sangat Baik
Ruangan 2	Testing	1,05	0,045	0,053	6	Sangat Baik
Ruangan 3	Training	1,14	0,050	0,057	24	Sangat Baik
Ruangan 3	Testing	1,15	0,054	0,066	6	Sangat Baik
Rata-Rata	Training	0,98	0,040	0,048	24	—
Rata-Rata	Testing	1,40	0,057	0,067	6	—

Berdasarkan Tabel 4, pada Ruangan 1 menunjukkan performa terbaik pada *fase training* (MAPE 0,86%) namun memiliki selisih terbesar antara *training* dan *testing* (2,01%). Selisih sekitar 1,15 poin, persentase ini mengindikasikan ruangan 1 memiliki variabilitas konsumsi yang sedikit lebih tinggi pada data uji. Pada ruangan 2, nilai MAPE *training* 0,94% dan *testing* hanya 1,05%, selisihnya sangat kecil (0,11 poin). Ini menunjukkan pola konsumsi ruangan 2 paling stabil dan mudah diprediksi model. Sementara pada ruangan 3 memiliki nilai MAPE *training* tertinggi yaitu 1,14% namun *testing*-nya hampir sama (1,15%), artinya model sangat konsisten meski akurasi absolutnya sedikit lebih rendah dibanding ruangan lain. Gambar 5 menyajikan perbandingan visual antara data konsumsi aktual dan hasil prediksi model Prophet untuk ketiga ruangan sepanjang September 2025, dengan pemisahan yang jelas antara fase *training* dan fase *testing*. Sementara untuk memudahkan perbandingan kuantitatif kinerja model antar ruangan dan antar fase, Gambar 6 menyajikan nilai MAPE dalam bentuk diagram batang.



Gambar 5. Perbandingan Data Aktual vs Prediksi Prophet per Ruangan, September 2025. Garis vertikal menandai batas data training (kiri) dan testing (kanan)



Gambar 6. Perbandingan Nilai MAPE Fase Training vs Testing per Ruangan

Berdasarkan nilai-nilai tersebut, semua nilai MAPE berada jauh di bawah 10%, masuk kategori “Sangat Baik” berdasarkan skala Lewis. Hal ini menunjukkan bahwa model Prophet terbukti mampu memprediksi konsumsi listrik per ruangan dengan akurasi tinggi dan generalisasi yang baik.

3.5 Analisis Error per Hari pada Fase Testing

Tabel 5 menyajikan detail error per hari selama enam hari validasi (25–30 September 2025), memungkinkan analisis granular yang tidak tersedia dari evaluasi agregat saja.


Tabel 5. Detail Error per Hari pada Fase Testing (25–30 September 2025)

Tanggal	Ytrue R1	Yhat R1	Error% R1	Error% R2	Ytrue R3	Error% R3
25 Sep	3,520	3,442	2,22%	0,41%	4,550	0,18%
26 Sep	3,590	3,478	3,12%	1,70%	4,620	2,10%
27 Sep	3,490	3,501	0,32%	2,20%	4,560	0,15%
28 Sep	3,420	3,487	1,96%	1,05%	4,640	1,42%
29 Sep	3,470	3,438	0,92%	0,35%	4,690	2,26%
30 Sep	3,570	3,445	3,50%	0,59%	4,600	0,80%

Error tertinggi pada Ruangan 1 teridentifikasi pada 26 September (3,12%) dan 30 September (3,50%), yang keduanya merupakan hari Jumat. Pola ini dapat dikaitkan dengan variasi aktivitas akhir pekan yang berbeda dari pola harian reguler minggu kerja. Namun demikian, Ruangan 2 dan 3 tidak menunjukkan eskalasi error pada tanggal yang sama, mengindikasikan bahwa deviasi ini bersifat spesifik-ruangan, bukan disebabkan oleh faktor sistemik seperti gangguan sensor atau anomali jaringan listrik. Residual rata-rata pada fase testing bernilai positif (+0,036 hingga +0,054 kWh), mengindikasikan kecenderungan model untuk sedikit meremehkan konsumsi aktual. Kecenderungan ini konsisten dengan adanya tren naik halus pada data, di mana model yang dilatih pada 24 hari pertama belum sepenuhnya mengantisipasi peningkatan marginal di enam hari terakhir.


3.6 Dekomposisi Komponen dan Prediksi 30 Hari ke Depan

Model Prophet mengidentifikasi dua *change points* pada hari ke-10 (10 September 2025) dan hari ke-18 (18 September 2025), di mana algoritma mendeteksi perubahan laju tren konsumsi yang melebihi ambang yang ditetapkan oleh *prior* regularisasi (*change point prior scale* = 0,04). Secara matematis, ini berarti gradien fungsi tren $g(t)$ mengalami perubahan yang signifikan pada kedua titik tersebut. Penelitian ini tidak mengumpulkan data aktivitas penghuni secara paralel, sehingga penyebab spesifik perubahan tren di kedua titik ini tidak dapat ditentukan secara kausal. Identifikasi *change point* dalam konteks ini berfungsi sebagai informasi diagnostik model yang menunjukkan bahwa terdapat perubahan pola konsumsi yang cukup substansial untuk ditangkap oleh model, terlepas dari penyebab eksternalnya. Untuk penelitian lanjutan, pengumpulan data kontekstual seperti log penggunaan perangkat atau catatan aktivitas penghuni akan memungkinkan validasi kausal atas titik-titik perubahan yang teridentifikasi. Gambar 7 menyajikan dekomposisi model Prophet untuk Ruangan 1 selama periode prediksi Oktober 2025 dan Gambar 8 menyajikan prediksi 30 hari ke depan untuk ketiga ruangan beserta data historis September sebagai konteks



Gambar 7. Dekomposisi Komponen Model Prophet untuk Ruang 1, Oktober 2025. Atas: prediksi akhir $\hat{y}$; Tengah: tren $g(t)$; Bawah: musiman mingguan $s(t)$

Gambar 7 terdiri dari tiga panel vertikal. Panel atas menampilkan prediksi akhir $\hat{y}$ sebagai hasil penjumlahan komponen. Panel tengah menampilkan komponen tren $g(t)$ yang menunjukkan kenaikan sangat gradual ($\sim 0,131$ kWh selama sebulan) yang mencerminkan penambahan beban elektronik yang perlahan tanpa lonjakan mendadak, konsisten dengan nilai *changepoint prior scale* = 0,04 yang dipilih melalui *grid search*. Panel bawah menampilkan komponen musiman mingguan $s(t)$ dalam bentuk diagram batang berwarna: batang positif (biru) menunjukkan hari dengan konsumsi di atas rata-rata mingguan, sedangkan batang negatif (merah) menunjukkan hari di bawah rata-rata. Amplitudo musiman yang kecil ($\pm 0,06$ kWh) mengonfirmasi bahwa variasi mingguan bersifat periodik namun lemah, selaras dengan nilai *seasonality prior scale* = 0,01 yang menekan kontribusi komponen ini.



Gambar 8. Prediksi Konsumsi Energi 30 Hari ke Depan (Oktober 2025) untuk Tiga Ruang. Area bayangan: interval kepercayaan

Tabel 6. Estimasi Konsumsi dan Biaya Listrik Oktober 2025 (Tarif Rp 1.444,70/kWh)

Ruang	Total Prediksi (kWh)	Total Biaya (Rp)	Rata-rata Harian (kWh)
Ruang 1	107,37	155.120	3,579
Ruang 2	132,10	190.852	4,403
Ruang 3	144,56	208.844	4,819
Total	384,04	554.817	12,801

Proyeksi Oktober 2025 (Gambar 8) menunjukkan tren naik halus di ketiga ruangan, konsisten dengan komponen $g(t)$. Total estimasi ~ 384 kWh setara $\sim$ Rp 554.817 untuk tiga ruangan. Sebagai konteks kewajaran, rata-rata tagihan listrik rumah tangga Indonesia untuk daya terpasang 900 VA berkisar Rp 100.000–150.000 per bulan. Estimasi $\sim$ Rp 185.000 per ruangan per bulan tergolong wajar untuk hunian aktif dengan penggunaan kipas angin, laptop, dan lampu sepanjang hari.



3.7 Pembahasan

3.7.1 Kinerja Model: Akurasi dan Pengaruh Karakteristik Data

Nilai MAPE testing 1,05–2,01% merupakan hasil yang sangat kompetitif, namun harus diinterpretasikan dengan mempertimbangkan karakteristik data. Nilai CV sebesar 1,85–3,25% mengindikasikan bahwa data konsumsi harian sangat stabil dengan variasi relatif terhadap mean sangat kecil. Dalam kondisi ini, model naif berbasis rata-rata pun akan menghasilkan MAPE yang rendah. Namun yang signifikan adalah bahwa model Prophet, melalui komponen tren dan musiman, secara konsisten mengungguli prediksi naif dengan menangkap pola temporal yang bermakna. Hal ini dikonfirmasi oleh kenyataan bahwa selisih MAPE *training-testing* sangat kecil (rata-rata 0,42 poin), selisih rata-rata MAPE *training-testing* sebesar 0,42 poin persentase mengindikasikan tidak terjadi *overfitting* yang signifikan pada periode evaluasi ini. Perlu dicatat bahwa indikator ini bersifat deskriptif; uji formal seperti analisis autokorelasi residual dapat memberikan konfirmasi yang lebih kuat dan direkomendasikan untuk penelitian lanjutan dengan dataset yang lebih panjang. Untuk memperkuat klaim tidak terjadi *overfitting*, dilakukan uji Ljung-Box pada residual model ($y_{\text{true}} - \hat{y}$) di ketiga ruangan dengan lag 1, 2, 3, 5, dan 7. Hipotesis nol (H_0) menyatakan bahwa residual bersifat acak (*white noise*) tanpa autokorelasi. Hasil menunjukkan bahwa seluruh 15 kombinasi ruangan-lag gagal menolak H_0 pada $\alpha = 0,05$ (nilai-p berkisar antara 0,082 hingga 0,937), mengonfirmasi bahwa tidak terdapat pola sistematis yang tersisa dalam residual model. Residual juga menunjukkan mean mendekati nol (0,007–0,011 kWh) dengan standar deviasi kecil (0,050–0,059 kWh), mengindikasikan bias prediksi yang minimal. Secara bersama-sama, hasil uji formal ini memberikan konfirmasi statistik bahwa model Prophet dengan *hyperparameter* yang dipilih tidak mengalami *overfitting* pada data yang tersedia.

3.7.2 Perbandingan Kinerja dengan Pendekatan Lain

Tabel 7 merangkum posisi penelitian ini terhadap studi-studi terdahulu berdasarkan empat dimensi kontribusi. Dari sisi akurasi, MAPE pengujian 1,05%–2,01% yang dicapai penelitian ini bersifat kompetitif dibandingkan LSTM dengan tuning Ray Tune [11], namun dengan keunggulan interpretabilitas yang tidak dimiliki model *black-box* tersebut. Perbandingan langsung antara Prophet dan LSTM [24] mengonfirmasi bahwa Prophet mencapai akurasi setara LSTM pada data konsumsi listrik dinamis, sekaligus lebih efisien secara komputasi. Studi Kwarteng dan Andreevich [26] secara eksplisit membuktikan superioritas Prophet atas ARIMA/SARIMA pada data dengan pola tren yang berubah, selaras dengan temuan penelitian ini di mana dua *change points* berhasil teridentifikasi.

Tabel 7. Perbandingan Hasil Penelitian dengan Studi Terdahulu

Peneliti & Tahun	Metode	Data Sensor IoT Fisik	Granularitas Per-Ruangan	Hyperparameter Tuning Transparan	Validasi Residual Formal
Sari et al. [10] 2023	k-NN	X	X	X	X
Kolluru et al. [11] 2024	LSTM	✓	X	✓ (Ray Tune)	X
Sulandari et al. [23] 2024	Prophet	X	X	✓ (sebagian)	X
Son et al. [21] 2023	Prophet+GRU	X	X	X	X
Albahli, S. [24] 2025	LSTM vs Prophet	X	X	X	X
Kwarteng & Andreevich [26] 2024	ARIMA vs Prophet	X	X	X	X
Penelitian ini	Prophet	✓	✓	✓ (2 tahap)	✓ (Ljung-Box)

Dimensi yang paling membedakan penelitian ini dari seluruh studi terdahulu adalah validasi residual formal menggunakan uji Ljung-Box. Hasil uji Ljung-Box dalam penelitian ini ($p > 0,05$ pada semua lag untuk ketiga ruangan) memberikan konfirmasi statistik yang lebih kuat dibandingkan perbandingan angka MAPE semata, menjawab pertanyaan mendasar apakah model benar-benar menangkap struktur data atau sekadar menghafal pola pelatihan.

3.7.3 Implikasi Praktis

Informasi prediksi yang dihasilkan sistem ini memiliki nilai praktis langsung. Pertama, pengelola kos atau rumah tangga dapat memperkirakan tagihan listrik sebulan ke depan dengan akurasi tinggi, memungkinkan perencanaan anggaran yang lebih baik. Kedua, profil tren halus dan musiman lemah yang teridentifikasi memungkinkan penentuan ambang peringatan konsumsi yang tepat tanpa *buffer* energi berlebih, sehingga relay pengaman 350 W dapat diatur ulang berdasarkan prediksi beban, bukan nilai tetap semata. Ketiga, komponen musiman $s(t)$ yang mengidentifikasi hari Rabu sebagai puncak mingguan memberikan panduan untuk *load shifting*. Dengan demikian, pengguna dapat menjadwalkan penggunaan peralatan berdaya tinggi ke hari Senin ketika konsumsi cenderung rendah. Lebih jauh, kerangka IoT yang terintegrasi dengan kemampuan prediktif ini berpotensi dikembangkan menuju sistem manajemen energi rumah tangga yang



komprehensif, sebagaimana diusulkan oleh Stogia et al. [15] melalui integrasi digital twin, yang memungkinkan simulasi skenario beban sebelum penerapan aktual dilakukan.

3.7.4 Keterbatasan dan Arah Pengembangan

Beberapa keterbatasan perlu diakui secara eksplisit. Pertama, dataset mencakup satu bulan dari satu lingkungan kos, sehingga generalisasi ke konteks hunian berbeda (variasi beban, jumlah penghuni, tipe bangunan) belum dapat diklaim. Kedua, pengujian aktuator relay hanya dilakukan pada empat skenario ambang batas; uji *edge case* (nilai tepat di ambang, osilasi sekitar ambang) dan pengukuran latensi respons masih diperlukan. Ketiga, skema validasi *hold-out* 24/6 hari dapat dilengkapi dengan *time-series cross-validation* bergulir untuk estimasi generalisasi yang lebih robust. Keempat, interval prediksi (*confidence interval* 80–95%) belum dilaporkan secara eksplisit, yang membatasi penggunaan hasil untuk *risk-aware scheduling*. Perbaikan atas keempat keterbatasan ini direkomendasikan untuk penelitian lanjutan, seiring perluasan dataset ke horison lebih panjang yang memungkinkan komponen musiman tahunan diaktifkan. Selain itu, perluasan validasi ke berbagai tipe hunian (apartemen, rumah tapak, asrama) dengan variasi pola aktivitas penghuni yang beragam akan meningkatkan generalisasi model dan memperkuat klaim keandalan algoritma Prophet sebagai solusi prediksi energi IoT yang robust untuk konteks domestik Indonesia.

4. KESIMPULAN

Kontribusi utama penelitian ini adalah: (1) penerapan algoritma Prophet pada data konsumsi energi per-ruangan dengan volume historis terbatas, konteks yang belum banyak dieksplorasi pada literatur Prophet sebelumnya; (2) prosedur grid search dua tahap yang justifikasi rentang parameternya transparan dan dapat direproduksi; serta (3) validasi metrologis sensor akuisisi data sebagai bagian integral penjaminan kualitas data input model prediksi. Penelitian ini berhasil mengimplementasikan dan mengevaluasi model Prophet sebagai inti prediksi konsumsi energi listrik harian pada sistem IoT berbasis sensor PZEM-004T dan mikrokontroler NodeMCU ESP32. Validasi metrologi sensor menghasilkan *error* relatif tegangan 0,1247%, daya 0,37%, dan arus 2,72%, menjamin kualitas data input model. Prosedur *grid search* dua tahap menghasilkan *hyperparameter* optimal *changepoint_prior_scale* $\approx 0,04$ dan *seasonality_prior_scale* $\approx 0,01$, yang secara fisik merepresentasikan tren bertahap dan musiman mingguan beramplitudo kecil sesuai karakteristik data. Model Prophet mencapai rata-rata MAPE training 0,98% dan testing 1,40% di tiga ruangan, keduanya dalam kategori sangat baik (<10%) berdasarkan skala Lewis. Selisih kecil antara MAPE training dan testing mengindikasikan generalisasi yang baik tanpa *overfitting*. Nilai CV data yang rendah (1,85–3,25%) memberikan konteks yang jujur bagi capaian MAPE tersebut. Dekomposisi komponen mengidentifikasi dua *changepoints* pada hari ke-10 dan ke-18, musiman mingguan dengan puncak di hari Rabu, dan tren kenaikan halus $\sim 0,131$ kWh per bulan. Transparansi dekomposisi ini menjadi keunggulan Prophet dibandingkan model *black-box* seperti LSTM. Proyeksi 30 hari ke depan menghasilkan estimasi total ~ 384 kWh ($\sim$ Rp 554.817) untuk tiga ruangan selama Oktober 2025, memberikan nilai praktis langsung bagi pengelola hunian dalam perencanaan anggaran dan manajemen beban proaktif. Untuk pengembangan lanjutan, disarankan: (1) penerapan *time-series cross-validation* bergulir; (2) pelaporan *confidence interval* (80–95%) untuk kuantifikasi ketidakpastian; (3) perluasan dataset ke horison >3 bulan; dan (4) perbandingan sistematis Prophet dengan model LSTM dan Transformer pada data yang sama untuk mendapatkan *trade-off* akurasi-interpretabilitas yang komprehensif. Dengan 30 hari data, model Prophet hanya mampu mengidentifikasi dan memproyeksikan musiman mingguan ($P = 7$ hari) yang mencakup 4,3 siklus penuh dalam periode pengamatan yaitu jumlah yang memadai untuk estimasi komponen Fourier yang stabil. Sebaliknya, pola musiman bulanan (misalnya fluktuasi konsumsi awal vs. akhir bulan terkait siklus gaji) dan musiman tahunan (perbedaan musim kemarau vs. hujan yang memengaruhi penggunaan kipas dan AC) sama sekali tidak dapat ditangkap dengan dataset ini, karena keduanya membutuhkan minimal dua hingga tiga siklus penuh sebagai syarat estimasi yang andal. Konsekuensinya, proyeksi yang dihasilkan mengandung asumsi implisit bahwa pola mingguan yang teramati pada September 2025 akan berlanjut ke Oktober 2025 sebuah asumsi yang wajar dalam jangka pendek namun semakin lemah seiring bertambahnya horison prediksi. Penelitian lanjutan dengan data minimum enam bulan akan memungkinkan pengaktifan komponen musiman bulanan, sementara data satu tahun penuh diperlukan untuk musiman tahunan yang representatif.

REFERENCES

- [1] Kementerian ESDM, “Handbook Of Energy & Economic Statistics Of Indonesia 2024”, [Online]. Available: <https://www.esdm.go.id/assets/media/content/content-handbook-of-energy-and-economic-statistics-of-indonesia-2024.pdf>
- [2] K. A. Yasa, I. M. Purbhawa, I. M. S. Yasa, I. W. Teresna, A. Nugroho, and S. Winardi, “IoT-based Electrical Power Recording using ESP32 and PZEM-004T Microcontrollers,” *J. Comput. Sci. Technol. Stud.*, vol. 5, no. 4, pp. 62–68, 2023, doi: 10.32996/jcsts.2023.5.4.7.
- [3] K. M. W. Hidayat and M. G. Al-Faris, “IoT-Based Electrical Power Consumption Monitoring System in Households Using ESP32 and PZEM-004T,” *Brill. Res. Artif. Intell.*, vol. 5, no. 2, pp. 1077–1081, 2025, doi: 10.47709/brilliance.v5i2.6368.
- [4] W. M. Sanya, G. Bajpai, O. H. Kombo, and E. Twahirwa, “Real-Time Data Analytics for Monitoring Electricity Consumption Using IoT Technology,” *Tanzania J. Eng. Technol.*, vol. 41, no. 1, pp. 28–37, 2022, doi: 10.52339/tjet.vi.770.
- [5] R. Chéour et al., “Towards hybrid energy-efficient power management in wireless sensor networks,” *Sensors*, vol. 22, no. 1, pp. 1–17, 2022, doi: 10.3390/s22010301.
- [6] M. Bourdeau, J. Waeytens, N. Aouani, P. Basset, and E. Nefzaoui, “A Wireless Sensor Network for Residential Building Energy



- and Indoor Environmental Quality Monitoring: Design, Instrumentation, Data Analysis and Feedback,” *Sensors*, vol. 23, no. 12, 2023, doi: 10.3390/s23125580.
- [7] S. Naifar, O. Kanoun, and C. Trigona, “Energy Harvesting Technologies and Applications for the Internet of Things and Wireless Sensor Networks,” *Sensors*, vol. 24, no. 14, pp. 1–5, 2024, doi: 10.3390/s24144688.
 - [8] G. Hoendarto, A. Saikhu, and R. V. Hari Ginardi, “Bridging IoT devices and machine learning for predicting power consumption: case study universitas Widya Dharma Pontianak,” *Energy Informatics*, vol. 8, no. 1, 2025, doi: 10.1186/s42162-025-00540-6.
 - [9] A. Angdresey, L. Sitanayah, and Z. M. P. Rumpesak, “An Electricity Consumption Monitoring and Prediction System Based on The Internet of Things,” in *Proceedings of the 2022 International Conference on Informatics, Multimedia, Cyber and Information System (ICIC)*, IEEE, 2022. doi: 10.1109/ICIC56845.2022.10007020.
 - [10] M. Sari *et al.*, “Machine Learning-Based Energy Use Prediction for the Smart Building Energy Management System,” *J. Inf. Technol. Constr.*, vol. 28, no. April, pp. 622–645, 2023, doi: 10.36680/j.itcon.2023.033.
 - [11] V. K. Kolluru, Y. Challagundla, A. N. Chintakunta, B. Roy, A. Bermak, and D. S. M. Ranjitkar, “AI-Driven Energy Optimization: Household Power Consumption Prediction With LSTM Networks and PyTorch-Ray Tune in Smart IoT Systems,” in *Proceedings of the 2024 International Conference on Microelectronics (ICM)*, IEEE, 2024. doi: 10.1109/icm63406.2024.10815802.
 - [12] Y. Natarajan, S. K. Md Alwi, A. Mukherjee, G. P. Ganapathy, V. Mohanavel, and S. Rajkumar, “Enhancing Building Energy Efficiency with IoT-Driven Hybrid Deep Learning Models for Accurate Energy Consumption Prediction,” *Sustainability*, vol. 16, no. 5, p. 1925, 2024, doi: 10.3390/su16051925.
 - [13] G. Hafeez *et al.*, “Efficient energy management of IoT-enabled smart homes under price-based demand response program in smart grid,” *Sensors (Switzerland)*, vol. 20, no. 11, 2020, doi: 10.3390/s20113155.
 - [14] A. Rahman, S. Hossain, S. Ahmed, and M. T. Ahmed, “IoT Based Smart Energy Consumption Prediction for Home Appliances,” *Int. J. Inf. Eng. Electron. Bus.*, vol. 17, no. 2, pp. 111–128, 2025, doi: 10.5815/ijeeb.2025.02.06.
 - [15] *et al.* M.S. Sheela, S. Gopalakrishnan, I.P. Begum, J.J. Hephziah, M. Gopianand, D. Harika, “14. 21. View of Enhancing Energy Efficiency With Smart Building Energy Management System Using Machine Learning and IOT.pdf.”
 - [16] M. Stogia, G. Salerno, S. Ferretti, and D. Montesi, “A Scalable and User-Friendly Framework Integrating IoT and Digital Twins for Home Energy Management Systems,” *Appl. Sci.*, vol. 14, no. 24, p. 11834, 2024, doi: 10.3390/app142411834.
 - [17] M. Syamala, C. R. Komala, P. V. Pramila, S. Dash, S. Meenakshi, and S. Boopathi, “Machine Learning-Integrated IoT-Based Smart Home Energy Management System,” in *Handbook of Research on Deep Learning Techniques for Cloud-Based Industrial IoT*, Hershey, PA: IGI Global, 2023, pp. 219–235. doi: 10.4018/978-1-6684-8098-4.ch013.
 - [18] S. J. Taylor and B. Letham, “Forecasting at Scale,” *Am. Stat.*, vol. 72, no. 1, pp. 37–45, 2018, doi: 10.1080/00031305.2017.1380080.
 - [19] S. Arslan, “A Hybrid Forecasting Model Using LSTM and Prophet for Energy Consumption with Decomposition of Time Series Data,” *PeerJ Comput. Sci.*, vol. 8, p. e1001, 2022, doi: 10.7717/peerj-cs.1001.
 - [20] S. Liang *et al.*, “Energy Consumption Prediction Using the GRU-MMattention-LightGBM Model with Features of Prophet Decomposition,” *PLoS One*, vol. 18, no. 1, p. e0277085, 2023, doi: 10.1371/journal.pone.0277085.
 - [21] J. Kim, Y. Kim, G. Kim, C.-K. Kim, and S. Kim, “Short- and Medium-Term Electricity Consumption Forecasting Using Prophet and GRU,” *Sustainability*, vol. 15, no. 22, p. 15860, 2023, doi: 10.3390/su152215860.
 - [22] S. F. Stefenon, L. O. Seman, V. C. Mariani, and L. dos S. Coelho, “Aggregating Prophet and Seasonal Trend Decomposition for Time Series Forecasting of Italian Electricity Spot Prices,” *Energies*, vol. 16, no. 3, p. 1371, 2023, doi: 10.3390/en16031371.
 - [23] W. Sulandari, Y. Yudhanto, R. Hapsari, M. D. Wijayanti, and H. F. Pardede, “Implementation of Prophet in American Electricity Forecasting With and Without Parameter Tuning,” *Media Stat.*, vol. 17, no. 1, pp. 93–104, 2024, doi: 10.14710/medstat.17.1.93-104.
 - [24] “LSTM vs. Prophet: Achieving Superior Accuracy in Dynamic Electricity Demand Forecasting,” *Energies*, vol. 18, no. 2, p. 278, 2025, doi: 10.3390/en18020278.
 - [25] R. V. Klyuev *et al.*, “Methods of Forecasting Electric Energy Consumption: A Literature Review,” *Energies*, vol. 15, no. 23, 2022, doi: 10.3390/en15238919.
 - [26] S. Kwarteng and P. Andreevich, “Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting,” *Res. Dev.*, vol. 5, no. 4, pp. 110–120, 2024, doi: 10.11648/j.rd.20240504.13.
 - [27] C. D. Lewis, *Industrial and Business Forecasting Methods*. London: Butterworths, 1982.
 - [28] A. Jain and S. C. Gupta, “Evaluation of electrical load demand forecasting using various machine learning algorithms,” *Front. Energy Res.*, vol. 12, no. June, pp. 1–18, 2024, doi: 10.3389/fenrg.2024.1408119.
 - [29] A. A. Pierre, S. A. Akim, A. K. Semenyio, and B. Babiga, “Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU Approaches,” *Energies*, vol. 16, no. 12, 2023, doi: 10.3390/en16124739.