

RANDOM FOREST REGRESSION DENGAN LAG FEATURES UNTUK PREDIKSI OUTPUT DAYA SISTEM PJU BERBASIS FRESNEL SOLAR CONCENTRATOR

Muhammad Vivaldi Vikzi Kohar^{1*}, Evelina², Muhammad Nawawi³

^{1,2,3}Politeknik Negeri Sriwijaya; Jalan Sriwijaya Negara, Bukit Besar, Kota Palembang, Sumatera Selatan 30139 ; Telpon : +620711353414 Fax: +62711355918

Keywords:

Random Forest Regression; Lag Features; Fresnel Solar Concentrator; Street Lighting Power Prediction; IoT Multi-Sensor.

Correspondent Email:

vivaldivikzi@gmail.com



Copyright © 2026 The Author(s), Published by Jurnal Informatika dan Teknik Elektro Terapan. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

Abstrak. Variabilitas output daya sistem Penerangan Jalan Umum (PJU) DC berbasis Fresnel Solar Concentrator akibat fluktuasi cuaca menjadi tantangan dalam manajemen energi surya. Penelitian ini membangun model prediksi menggunakan Random Forest Regression (RFR) berbasis lag features time-series sensor IoT dan data BMKG dengan 44 variabel prediktor dari 405 record pengukuran selama 27 hari. Optimasi hyperparameter menggunakan Grid Search Cross-Validation 5-fold menghasilkan konfigurasi optimal $n_estimators=200$ dan $max_depth=15$. Hasil evaluasi menunjukkan $R^2=0,9850$ dan $MAPE=8,29\%$, memenuhi seluruh kriteria keberhasilan. Daya panel (P_Panel) menjadi prediktor dominan dengan importance score 0,1197. Model berhasil memprediksi output daya 7 hari ke depan dengan estimasi energi rata-rata 250 Wh per hari, membuktikan bahwa integrasi lag features pada RFR efektif untuk manajemen energi PJU secara proaktif.

Abstract. The variability of DC Street Lighting (PJU) output power based on Fresnel Solar Concentrator due to weather fluctuations presents a challenge in solar energy management. This study develops a prediction model using Random Forest Regression (RFR) with IoT sensor time-series lag features and BMKG data, utilizing 44 predictor variables from 405 records collected over 27 days. Hyperparameter optimization via 5-fold Grid Search Cross-Validation yielded $n_estimators=200$ and $max_depth=15$. Evaluation results achieved $R^2=0.9850$ and $MAPE=8.29\%$, satisfying all success criteria. Panel power (P_Panel) was the most dominant predictor with importance score 0.1197. The model successfully predicted output power for 7 days ahead with an average energy estimate of 250 Wh per day, proving that lag features integration into RFR is effective for proactive PJU energy management.

1. PENDAHULUAN

Kebutuhan energi listrik untuk infrastruktur publik, khususnya Penerangan Jalan Umum (PJU), terus meningkat seiring pertumbuhan kawasan perkotaan dan pedesaan di Indonesia. PJU konvensional berbasis jaringan listrik PLN menjadi salah satu penyumbang konsumsi energi terbesar pada sektor publik, sehingga konversi menuju sistem PJU berbasis energi terbarukan menjadi prioritas strategis dalam agenda transisi energi nasional [1]. Energi surya

menjadi kandidat utama mengingat Indonesia yang berada di garis khatulistiwa memiliki potensi iradiasi matahari rata-rata mencapai 4,8 kWh/m²/hari dengan total potensi nasional diperkirakan mencapai 112.000 GWp [2].

Sistem PJU berbasis panel surya menawarkan efisiensi transmisi daya lebih tinggi di banding sistem konvensional. Namun, tantangan fundamental yang dihadapi adalah variabilitas output daya akibat fluktuasi iradiasi matahari, perubahan suhu, dan kondisi cuaca yang tidak

menentu. Untuk mengatasi variabilitas tersebut, teknologi *Fresnel Solar Concentrator* (FSC) telah terbukti mampu meningkatkan densitas fluks iradiasi pada permukaan sel surya secara signifikan melalui prinsip pembiasan optik lensa Fresnel yang memfokuskan berkas cahaya matahari ke area yang lebih sempit dan terkonsentrasi [3]. Profil iradiasi yang dihasilkan oleh fitur optis ini sangat berbeda dibandingkan sistem fotovoltaik konvensional. Akibatnya, pola output daya yang dihasilkan memiliki dinamika non-linier yang lebih kompleks.

Berbagai penelitian terdahulu telah mengeksplorasi prediksi daya sistem PV menggunakan pendekatan machine learning. Rangelov et al. (2023) membandingkan performa *Random Forest*, *Deep Neural Network*, dan LSTM untuk peramalan output daya PV jangka pendek menggunakan fitur cuaca dan membuktikan bahwa *Random Forest* memberikan akurasi kompetitif dengan kompleksitas komputasi yang lebih rendah [4]. Keunggulan algoritma *Random Forest* dalam prediksi pembangkitan daya surya untuk stabilitas jaringan listrik dengan akurasi tinggi dibandingkan algoritma lain [5]. Bouakkaz et al. (2025) secara empiris membuktikan bahwa *Random Forest* mengungguli ANN dan SVM dalam memprediksi output daya PV pada berbagai kondisi dataset [6]. Di sisi integrasi data meteorologi, Abdallah et al. (2025) menunjukkan bahwa model *Random Forest* yang menggunakan data cuaca multi-parameter menghasilkan nilai R^2 lebih tinggi dibandingkan model berbasis sensor tunggal [7], sementara Luna-Alvarez et al. (2022) membuktikan bahwa penambahan variabel lama penyinaran matahari dari stasiun meteorologi resmi sebagai fitur input secara signifikan meningkatkan akurasi prediksi iradiasi surya [8]. Dalam konteks Indonesia, Noviyanti et al. mengaplikasikan metode *Random Forest* untuk memprediksi potensi energi surya berbasis data cuaca dan menghasilkan akurasi yang menjanjikan untuk perencanaan energi [9].

Walaupun studi-studi tersebut telah memberikan kontribusi yang berarti, masih ada kekosongan penelitian yang belum terjawab. Seluruh penelitian sebelumnya memanfaatkan sistem PV tradisional tanpa konsentrator optik, sehingga sifat data daya yang dihasilkan secara

mendasar berbeda dengan sistem yang menggabungkan *Fresnel Solar Concentrator* yang menghasilkan densitas fluks cahaya lebih tinggi serta pola non-linier yang lebih rumit. Kedua, belum ada studi yang menggabungkan instrumentasi IoT multi-sensor berbasis ESP32 dengan dua unit INA219, sensor voltase, dan sensor LDR secara bersamaan sebagai variabel prediktor dalam satu kerangka pemodelan prediktif. Lalu ketiga penggabungan data meteorologi resmi BMKG stasiun Palembang sebagai sumber data eksternal yang di kombinasi dengan data sensor IoT lokal dalam satu alur machine learning belum pernah diterapkan pada konteks sistem PJU DC skala prototipe. Kebaruan penelitian ini terletak pada gabungan antara sistem pembangkitan yang menggunakan *Fresnel Solar Concentrator*, pengumpulan data waktu nyata multi-sensor IoT ESP32, serta integrasi data meteorologi dari BMKG dalam satu arsitektur pemodelan *Random Forest Regression* yang lengkap untuk sistem PJU DC otomatis.

Selain itu, untuk meningkatkan kemampuan prediksi pada domain *time-series*, penelitian ini menggunakan fitur *lag features* sebagai representasi memori temporal data sensor, meliputi nilai daya, tegangan, dan arus pada lag $t-1$, $t-2$, $t-3$, $t-4$, $t-7$, dan $t-14$ (setiap lag mewakili 30 menit), serta *rolling statistics* (mean dan standar deviasi dalam jendela 2 jam) dan fitur *yesterday same slot*. Dengan demikian, total terdapat 44 fitur prediktor yang digunakan dalam model RFR, memungkinkan model untuk belajar dari pola temporal jangka pendek maupun siklus harian sistem PJU berbasis *Fresnel Solar Concentrator*.

Berdasarkan celah tersebut, penelitian ini bertujuan untuk: (1) Membangun model *Random Forest Regression* berbasis lag features *time-series* menggunakan 44 variabel prediktor gabungan data sensor IoT multi-sensor (ESP32, INA219, sensor tegangan, LDR) dan data cuaca BMKG untuk memprediksi output daya sistem PJU berbasis *Fresnel Solar Concentrator*; (2) Mengevaluasi performa model *Random Forest Regression* secara kuantitatif menggunakan metrik R^2 , RMSE, MAE, dan MAPE pada data *testing set* yang belum pernah dilihat model selama pelatihan; (3) Mengidentifikasi variabel prediktor yang paling signifikan mempengaruhi output daya sistem PJU berbasis *Fresnel Solar*

Concentrator melalui analisis *Feature Importance* model *Random Forest Regression*.; (4) Menganalisis kontribusi integrasi data cuaca BMKG terhadap akurasi prediksi output daya ; (5) Menghasilkan prediksi output daya sistem PJU untuk 7 hari ke depan menggunakan strategi *recursive multi-step forecasting* sebagai dasar optimasi manajemen energi. Studi ini diharapkan dapat memberikan kontribusi ilmiah dalam bentuk kerangka pemodelan prediktif yang dapat disatukan ke dalam sistem manajemen energi PJU surya guna mendukung pengelolaan energi yang lebih responsif dan fleksibel.

2. PUSTAKA

2.1 *Fresnel Solar Concentrator*

Fresnel Solar Concentrator merupakan teknologi konsentrasi cahaya matahari yang memanfaatkan lensa Fresnel berbahan PMMA (*Polymethyl Methacrylate*) untuk memfokuskan berkas cahaya matahari dari area permukaan luas ke area yang lebih kecil pada permukaan sel surya. Prinsip kerjanya didasarkan pada pembiasan optik melalui serangkaian cincin konsentris (*annular zones*) yang mengarahkan cahaya menuju titik fokus yang sama, sehingga intensitas iradiasi yang diterima panel surya meningkat signifikan tanpa memperbesar ukuran panel [3]. Cahaya yang melewati lensa mengalami tiga fenomena optik yaitu transmisi, pembiasan, dan pemantulan, di mana sebagian besar cahaya ditransmisikan dan diserap sel surya sehingga meningkatkan efektivitas penangkapan energi [10]. Penggunaan FSC pada sistem PJU menghasilkan karakteristik data output daya yang lebih dinamis dan non-linier dibandingkan sistem PV konvensional, menjadikannya domain yang menantang sekaligus menarik untuk dimodelkan menggunakan pendekatan machine learning.

2.2 Instrumentasi Berbasis ESP 32

ESP32 adalah mikrokontroler SoC dual-core Xtensa LX6 dengan kecepatan clock 240 MHz yang mengintegrasikan WiFi 802.11 b/g/n dan Bluetooth 4.2 dalam satu chip [11]. Kemampuan komunikasi I2C multi-slave memungkinkan ESP32 membaca dua unit sensor INA219 secara simultan melalui pengalamatan berbeda (0x40 dan 0x41), sementara ADC 12-bit beresolusi tinggi

digunakan untuk membaca sinyal analog dari sensor LDR dan voltage divider [11]. Dalam penelitian ini, ESP32 berfungsi sebagai unit akuisisi data utama yang mencatat parameter operasional sistem secara real-time setiap 30 menit dan mentransmisikannya ke platform cloud Blynk.

Sensor INA219 digunakan untuk mengukur arus DC secara simultan dengan antarmuka I2C, di mana daya dihitung langsung oleh chip internal melalui persamaan $P = V \times I$. Penelitian sebelumnya menunjukkan bahwa error pengukuran INA219 untuk tegangan hanya 0,3%, arus 1,8%, dan daya 1,26% dibandingkan multimeter standar, menjadikannya instrumen yang sangat layak untuk akuisisi data sistem panel surya [12].

Sensor tegangan berbasis voltage divider merupakan rangkaian elektronika yang berfungsi menurunkan level tegangan keluaran panel surya (12V–20V) menjadi tegangan yang aman untuk dibaca ADC mikrokontroler ESP32 (maksimal 3,3V) [11]. Prinsip kerjanya memanfaatkan dua resistor yang disusun seri, di mana tegangan output diambil dari titik tengah rangkaian sesuai hukum Ohm. Tantangan utama penggunaan voltage divider sederhana adalah tingkat galat yang cukup tinggi akibat toleransi nilai resistor dan fluktuasi suhu lingkungan, di mana rangkaian pembagi tegangan murni dapat memiliki tingkat kesalahan hingga 34,88%. Oleh karena itu, tahap kalibrasi menggunakan metode Regresi Linear Sederhana dilakukan dengan membandingkan nilai bacaan sensor terhadap multimeter standar sehingga error dapat ditekan hingga 0,45% [12]. Dalam penelitian ini, dua unit sensor tegangan DC dipasang masing-masing pada sisi panel surya dan sisi baterai untuk memantau level tegangan secara real-time sebagai variabel prediktor model *Random Forest Regression*.

Sensor LDR GL5528 digunakan sebagai indikator intensitas cahaya ambien sekaligus trigger otomatisasi ON/OFF lampu jalan berdasarkan threshold gelap/terang yang dikonfigurasi melalui pemrograman ESP32 [13]. Prinsip kerja LDR didasarkan pada efek fotokonduktif, di mana resistansinya dapat mencapai 1 M Ω pada kondisi gelap dan turun drastis menjadi 8–20 k Ω pada kondisi cahaya terang [13]. Perubahan resistansi ini dibaca oleh ADC ESP32 sebagai sinyal tegangan melalui

pembagi tegangan untuk menentukan kondisi siang atau malam hari, sekaligus menjadi variabel prediktor yang merepresentasikan kondisi iradiasi ambien dalam model machine learning.

2.3 Data Meteorologi BMKG

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) menyediakan data cuaca historis harian secara terbuka melalui portal resmi dataonline.bmkg.go.id, mencakup parameter lama penyinaran matahari (SS, jam/hari) dan curah hujan (RR, mm) serta suhu minimal dan maksimal harian dari stasiun-stasiun meteorologi yang tersebar di seluruh Indonesia[14]. Parameter lama penyinaran matahari merepresentasikan durasi aktual paparan sinar matahari langsung per hari yang berkorelasi kuat dengan total iradiasi harian, sementara curah hujan menjadi indikator tutupan awan yang secara langsung mereduksi transmisivitas atmosfer dan iradiasi yang diterima panel surya. Integrasi data BMKG sebagai fitur eksternal dalam model machine learning telah terbukti secara konsisten meningkatkan akurasi prediksi output daya PV dibandingkan model yang hanya mengandalkan data sensor lokal [7].

2.4 Random Forest Regression

Random Forest adalah algoritma ensemble learning yang menggabungkan beberapa pohon keputusan untuk meningkatkan akurasi prediksi dan mengurangi overfitting. Keunggulan Random Forest terletak pada kemampuannya menangani data dengan dimensi tinggi dan interaksi antar variabel yang kompleks[15].

Random Forest Regression (RFR) merupakan algoritma *ensemble learning* yang dikembangkan oleh Breiman (2001) berdasarkan konsep bagging dan seleksi fitur acak [16]. RFR mengkonstruksi sejumlah pohon keputusan independen yang masing-masing dilatih pada subset data bootstrap berbeda, kemudian mengagregasi prediksi seluruh pohon melalui mekanisme rata-rata:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B hb(x) \quad (1)$$

Di mana $\hat{y}$ adalah prediksi output daya akhir, B adalah jumlah total pohon dalam ensemble,

dan $hb(x)$ adalah prediksi pohon ke- b untuk input fitur x . Mekanisme agregasi ini secara efektif mereduksi varians prediksi dan mengurangi risiko overfitting yang menjadi kelemahan utama decision tree tunggal [16].

Keunggulan RFR yang relevan untuk penelitian ini meliputi kemampuan menangkap hubungan non-linier kompleks antar variabel sensor tanpa memerlukan asumsi distribusi data, ketangguhan terhadap outlier yang umum muncul pada data sensor IoT, serta fitur Feature Importance yang mengkuantifikasi kontribusi relatif setiap variabel prediktor terhadap akurasi prediksi [5]. Optimasi *hyperparameter* dilakukan menggunakan *Grid Search Cross-Validation 5-Fold* dengan parameter utama $n_estimators$, max_depth , dan $max_features$ untuk menemukan kombinasi yang menghasilkan generalization error terendah.

2.5 Lag Features Pada Data Time Series

Lag features merupakan teknik rekayasa fitur (*feature engineering*) yang banyak digunakan dalam analisis data *time-series* untuk memasukkan nilai historis suatu variabel sebagai prediktor tambahan dalam model. Pada konteks prediksi output daya sistem PJU DC, data sensor yang dikumpulkan setiap 30 menit membentuk urutan temporal yang memiliki autokorelasi, di mana nilai daya pada suatu waktu t dipengaruhi oleh nilai daya pada waktu-waktu sebelumnya ($t-1$, $t-2$, ..., $t-n$).

Secara matematis, lag feature ke- k dari variabel Y didefinisikan sebagai: $Y_lag(k) = Y(t-k)$ di mana k adalah jumlah langkah waktu ke belakang dan setiap langkah mewakili 30 menit dalam penelitian ini. Selain lag features, *rolling statistics* seperti rata-rata bergerak (*rolling mean*) dan standar deviasi bergerak (*rolling std*) dalam jendela waktu tertentu juga digunakan untuk menangkap tren jangka pendek dari data sensor.

Keunggulan penggunaan *lag features* dalam kombinasi dengan *Random Forest Regression* terletak pada kemampuan model untuk menginternalisasi dinamika temporal sistem tanpa perlu menerapkan model *autoregressive* yang lebih kompleks seperti ARIMA atau LSTM. Random Forest dapat memproses lag features sebagai fitur independen biasa, sehingga memanfaatkan hubungan non-linear antara nilai historis dan nilai saat ini dengan

cara yang lebih fleksibel dan robust terhadap *noise*.

2.5 Metrik Evaluasi Model

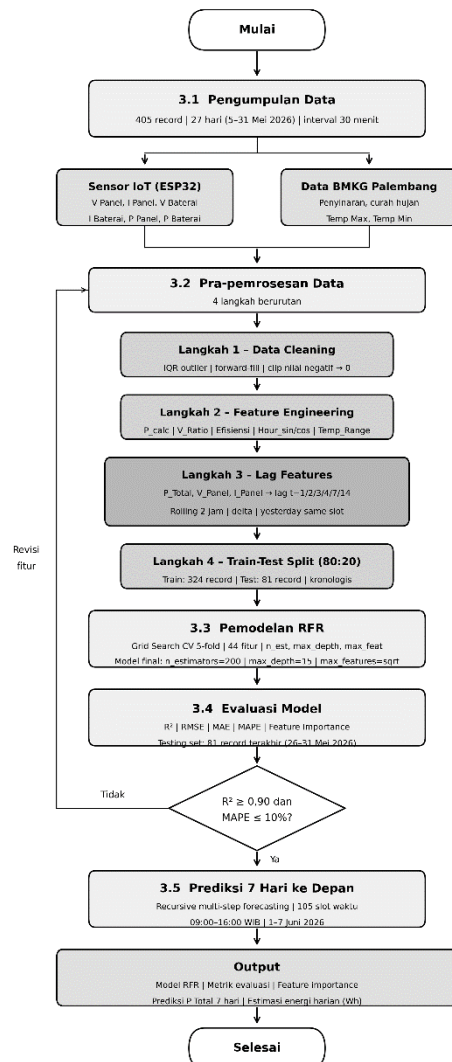
Performa model RFR menggunakan empat metrik kuantitatif standar. Koefisien Determinasi (R^2) mengukur proporsi variansi data yang mampu dijelaskan oleh model, dengan nilai mendekati 1,0 menunjukkan kemampuan prediksi yang sangat baik [18]. Root Mean Square Error (RMSE) mengukur rata-rata besarnya kesalahan prediksi dalam satuan yang sama dengan variabel target (Watt), sensitif terhadap kesalahan besar [19]. Mean Absolute Error (MAE) mengukur rata-rata kesalahan absolut prediksi yang lebih robust terhadap outlier dibandingkan RMSE. Mean Absolute Percentage Error (MAPE) menyatakan besarnya kesalahan dalam bentuk persentase sehingga memberikan interpretasi intuitif bagi operator sistem energi [20]. Kriteria keberhasilan model ditetapkan pada $R^2 \geq 0,90$ dan $MAPE \leq 10\%$.

3. METODE PENELITIAN

Penelitian ini merupakan penelitian eksperimental berbasis rancang bangun (*experimental engineering research*) yang mengintegrasikan dua domain utama, yaitu rekayasa perangkat keras sistem berbasis *Fresnel Solar Concentrator* dan pemodelan prediktif menggunakan algoritma *Random Forest Regression* (RFR). Penelitian dilaksanakan dalam dua tahap utama: (1) tahap akuisisi data primer multi-sensor, dan (2) tahap pemodelan komputasi menggunakan Python 3.x di lingkungan Google Colab dengan library *scikit-learn*, *pandas*, *numpy*, dan *matplotlib*.

Sistem dibangun pada skala laboratorium dengan panel surya 50 Wp/12V monokristalin yang dilengkapi *Fresnel Solar Concentrator* berbahan PMMA berukuran 30×30 cm. Sistem dikonfigurasi sebagai PJU *off-grid* yang terintegrasi dengan MPPT *Charge Controller* 10A dan baterai VRLA 12V 7Ah sebagai penyimpanan energi, serta lampu LED DC 12V 10W sebagai beban.

Gambar 1. Flowchart Metode penelitian



Sumber : Hasil Penelitian (2026)

3.1 Teknik Pengumpulan Data

1. Data Primer (Sensor)

Data prime diperoleh melalui proses pengukuran langsung pada sistem PJU berbasis *Fresnel Solar Concentrator* yang dilakukan secara manual selama 27 hari (5–31 Mei 2026) dari pukul 09.00 hingga 16.00 WIB dengan interval pencatatan setiap 30 menit. Pengukuran dilakukan menggunakan multimeter digital sebagai alat ukur referensi untuk memvalidasi pembacaan sensor, sehingga menghasilkan 405 record data yang terstruktur.

Parameter yang diukur pada setiap interval waktu meliputi tegangan keluaran panel surya (V Panel, Volt), arus keluaran panel surya (I Panel, Ampere), tegangan sisi baterai (V Baterai, Volt), dan arus sisi baterai (I Baterai,

Ampere). Kondisi cuaca pada setiap sesi pengukuran dicatat secara visual lapangan dalam empat kategori: Cerah (210 record), Hujan (120 record), Berawan (60 record), dan Mendung (15 record). Daya panel (P Panel) dan daya baterai (P Baterai) dihitung menggunakan persamaan $P = V \times I$, menghasilkan variabel target P Total.

2. Data Eksternal (BMKG)

Data meteorologi harian diperoleh dari portal resmi situs BMKG untuk Stasiun Palembang, mencakup periode 5–31 Mei 2026. Parameter yang digunakan meliputi lama penyinaran matahari (SS, jam/hari), curah hujan (RR, mm), temperatur maksimum (Temp Max, °C), dan temperatur minimum (Temp Min, °C). Sinkronisasi dengan dataset sensor dilakukan menggunakan fungsi *pd.merge()* berdasarkan kolom tanggal sebagai kunci join, sehingga setiap record IoT (resolusi 30 menit) diperkaya dengan informasi cuaca harian BMKG.

3.2 Sumber dan Karakteristik Data

Dataset akhir terdiri dari 405 record (27 hari $\times$ 15 record/hari) dengan variasi kondisi cuaca yang representatif. Rincian variabel prediktor (fitur input) dan variabel target disajikan pada Tabel .

Tabel 1. Variable dataset awal

Variabel	Sat	Sumber	Ket
I Panel	A	INA219	Arus Keluaran Panel Surya
V Panel	V	Voltage Sensor	Tegangan Keluaran Panel Surya
I Baterai	A	INA219	Arus Sisi Baterai
V Baterai	V	Voltage Sensor	Tegangan Sisi Sensor
P Panel	W	VxI Panel	Daya Panel
P Baterai	W	VxI Baterai	Daya Baterai
Hour	Jam	RTC ESP32	Jam pengambilan Data

Temp max	C	BMKG	Suhu udara Maksimum harian
Temp Min	C	BMKG	Suhu Udara Minimum
Penyinaran Matahari	SS	BMKG	Lama Penyinaran Matahari
Curah Hujan	RR	BMKG	Curah Hujan harian
Kondisi Cuaca	-	Obsevasi	Encoded
Lag Features	-	Turunan sensor	18 lag features, Rolling, yesterday
P total	W	P panel + P baterai (daya setiap jam)	Target prediksi

Sumber : Hasil Penelitian(2026)

3.3 Pra-pemrosesan data

Data mentah hasil pengukuran tidak dapat langsung digunakan untuk melatih model karena potensi adanya anomali, *missing values*, dan inkonsistensi format. Tahap pra-pemrosesan dilakukan melalui empat langkah berurutan sebagai berikut.

1. **Data Cleaning.** Nilai anomali dideteksi dengan metode Interquartile Range (IQR): nilai di luar batas $[Q1 - 1,5 \times IQR, Q3 + 1,5 \times IQR]$ diimputasi menggunakan metode forward-fill. Nilai daya negatif di-clip ke 0 (daya tidak mungkin negatif secara fisika). Missing values pada data BMKG dengan kode '8888' atau '9999' diimputasi dengan interpolasi linear.
2. **Feature Engineering.** Fitur turunan ditambahkan meliputi: (a) daya kalkulasi $P_Panel_calc = V_Panel \times I_Panel$ dan $P_Baterai_calc = V_Baterai \times I_Baterai$ (b) fitur Efisiensi $P_Baterai/P_Panel$; (c) fitur waktu siklik $Hour_sin$ dan $Hour_cos$ serta $TimeSlot_sin$ dan $TimeSlot_cos$; serta (d) $Temp_Range = Temp_Max - Temp_Min$ dan yang terakhir encoding kondisi cuaca (LabelEncoder).

3. Tahap 3 *Lag Features*. Lag features merupakan representasi nilai historis variabel sensor pada waktu sebelumnya yang digunakan sebagai prediktor tambahan untuk menangkap pola temporal data *time-series*. Mengingat data sensor dikumpulkan setiap 30 menit, setiap satu langkah lag (lag-1) merepresentasikan kondisi 30 menit sebelumnya. Lag features dibuat dari variabel P_Total, V_Panel, dan I_Panel pada lag t-1, t-2, t-3, t-4, t-7, dan t-14 (masing-masing satu lag = 30 menit). Selain itu ditambahkan rolling mean dan rolling std dalam jendela 4 slot (2 jam), delta (laju perubahan satu slot), serta yesterday same slot (nilai pada slot yang sama hari sebelumnya). Setelah pembuatan lag features, baris dengan nilai NaN dibuang sehingga tersisa 391 record yang valid.
4. Train-Test Split. Dataset dibagi secara kronologis (bukan acak) dengan rasio 80:20, di mana 324 record pertama digunakan sebagai training set dan 81 record terakhir sebagai testing set. Pembagian kronologis ini penting untuk menghindari data leakage temporal dan mensimulasikan kondisi deployment yang sesungguhnya. Total fitur yang digunakan: 44 fitur

3.4 Permodelan *Random Forest Regression* dan Optimasi Hyperparameter

Model RFR dibangun menggunakan library scikit-learn pada Python 3.x. Optimasi hyperparameter dilakukan menggunakan *GridSearchCV* dengan 5-fold cross-validation pada training set dengan ruang pencarian sebagai berikut:

Tabel 2. Hyperparameter

Hyperparameter	Nilai	Fungsi
n_estimators	[50, 100, 200, 300]	Jumlah Pohon dalam ensemble
max_depth	[None, 10, 20, 30]	Kedalaman Maksimum Pohon
min_samples_split	[2, 5, 10]	Minimum sampel untuk split mode
max_features	['sqrt', 'log2']	Jumlah fitur acak tiap

Model dengan menggunakan kombinasi hyperparameter yang menghasilkan R^2 cross-validation tertinggi pada training set dipilih sebagai model final dan dilatih ulang menggunakan seluruh training set. Model final kemudian disimpan dalam format .pkl menggunakan library joblib untuk keperluan deployment dan prediksi.

3.6 Lag Features

Lag features merupakan representasi nilai historis variabel sensor pada waktu-waktu sebelumnya yang digunakan sebagai prediktor tambahan untuk menangkap pola temporal data *time-series*. Mengingat data sensor dikumpulkan setiap 30 menit, setiap satu langkah lag (lag-1) merepresentasikan kondisi 30 menit sebelumnya. Lag features dibangun dari tiga variabel utama yaitu P_Total, V_Panel, dan I_Panel pada enam tingkat lag sebagaimana ditampilkan pada Tabel dibawah.

Tabel 3. Variable Lag features

Lag	Time	Variable Lag	Ket
t-1	30 menit	P_Total_lag1, V_Panel_lag1, I_Panel_lag	Kondisi 1 Slot sebelumnya
t-2	60 menit	P_Total_lag2, V_Panel_lag2, I_Panel_lag2	Kondisi 2 Slot sebelumnya
t-3	90 menit	P_Total_lag3, V_Panel_lag3, I_Panel_lag3	Kondisi 3 slot sebelumnya
t-4	120 menit	P_Total_lag4	Kondisi 4 slot sebelumnya
t-5	210 menit	P_Total_lag7	Kondisi 7 slot sebelumnya
t-6	420 Menit	P_Total_lag14	Kondisi 14 slot (7 jam) sebelumnya

Sumber : Hasil penelitian (2026)

Selain lag features, tiga jenis fitur temporal tambahan juga dibangun yaitu: (1) *Rolling mean* dan *rolling std* P_Total, V_Panel, dan I_Panel dalam jendela waktu 4 slot (2 jam) untuk menangkap tren jangka pendek; (2) *Delta* atau laju perubahan satu slot (P_Total_delta1 dan V_Panel_delta1) untuk menangkap

dinamika perubahan daya sesaat; serta (3) *Yesterday same slot* yaitu nilai P_{Total} pada slot waktu yang sama di hari sebelumnya untuk menangkap pola siklus harian. Setelah seluruh lag features dibuat, baris dengan nilai NaN yang terbentuk pada baris-baris awal dataset dibuang, sehingga total record efektif yang masuk ke model adalah 391 record.

3.5 Prediksi 7 Hari ke Depan

Prediksi output daya untuk 7 hari ke depan dilakukan menggunakan strategi *recursive multi-step forecasting*, di mana prediksi pada setiap slot waktu dimasukkan kembali sebagai lag feature untuk prediksi slot berikutnya. Jadwal operasional yang diprediksi adalah pukul 09:00–16:00 WIB setiap 30 menit (15 slot per hari). Estimasi kondisi cuaca 7 hari ke depan menggunakan rata-rata historis per hari dalam seminggu dari dataset yang ada, sebagai pendekatan apabila prakiraan BMKG resmi tidak tersedia.

3.6 Evaluasi Model

Evaluasi performa model dilakukan secara eksklusif pada testing set menggunakan empat metrik kuantitatif sebagai berikut:

Tabel 4. Metrik dan Kriteria

Metrik	Kriteria Keberhasilan
R^2	$\geq 0,90$
RMSE	Seminimal Mungkin
MAE	Seminimal Mungkin
MAPE	$\leq 10\%$

Analisis Feature Importance dilakukan dengan mengekstraksi nilai feature importance dari model RFR final untuk mengidentifikasi variabel prediktor yang paling signifikan berkontribusi terhadap akurasi prediksi output daya sistem PJU DC berbasis *Fresnel Solar Concentrator*. Hasil divisualisasikan dalam bentuk bar chart horizontal yang diurutkan berdasarkan tingkat kepentingan masing-masing fitur.

4. HASIL DAN PEMBAHASAN

4.1 Karakteristik dan Analisis Eksplorasi Data

Dataset yang digunakan dalam penelitian ini terdiri dari 405 record pengukuran yang dikumpulkan selama 27 hari (5–31 Mei 2026) dengan interval 30 menit dari pukul 09.00 hingga 16.00 WIB. Berdasarkan hasil eksplorasi data awal, distribusi P_{Total} menunjukkan nilai rata-rata sebesar 33,79 Watt dan median 30,87 Watt, dengan rentang nilai antara 0 hingga 76,97 Watt. Variasi yang besar ini mencerminkan karakteristik dinamis sistem PJU berbasis *Fresnel Solar Concentrator* yang sangat sensitif terhadap perubahan kondisi cuaca dan intensitas iradiasi matahari.

Analisis distribusi P_{Total} berdasarkan kondisi cuaca menunjukkan perbedaan yang sangat signifikan antar kategori, sebagaimana disajikan pada Tabel.

Tabel 5. Distribusi daya total terhadap cuaca

Kondisi Cuaca	Record	P Min (W)	P Max (W)	P Mean (W)
Cerah	210	7,18	76,97	50,30
Berawan	60	0,00	52,66	23,89
Hujan	120	0,00	31,46	12,34
Mendung	15	0,40	29,98	13,74
Total	405	0,00	76,97	33,79

Sumber : Hasil Penelitian (2026)

Kondisi cerah mendominasi dataset (51,9%) dengan rata-rata P_{Total} tertinggi sebesar 50,30 Watt, hampir empat kali lipat dibandingkan kondisi hujan (12,34 Watt). Perbedaan ekstrem ini membuktikan bahwa kondisi meteorologi merupakan faktor determinan utama variabilitas output daya pada sistem PJU berbasis *Fresnel Solar Concentrator*, sekaligus menjustifikasi pentingnya integrasi data BMKG sebagai variabel prediktor dalam model RFR.

4.2 Hasil Optimasi Hyperparameter

Proses Optimasi Hyperparameter dilakukan menggunakan metode Grid Search Cross-Validation 5-Fold menghasilkan kombinasi hyperparameter terbaik sebagaimana disajikan pada Tabel.

Table 6. Hasil Optimasi Hyperparameter

Hyperparameter	Nilai	Keterangan
n_estimators	200	Jumlah Pohon Dalam Ensemble


max_depth	15	Kedalaman dibatasi 15 level, menjaga keseimbangan akurasi dan generalisasi
min_samples_split	2	Minimum 2 sampel untuk melakukan Split Node
Best CV RSquare	0,9953	Kemampuan generalisasi sangat tinggi pada data training
max_features	sqrt	Akar kuadrat jumlah fitur di pilih tiap split

Sumber : Hasil Penelitian (2026)

Nilai *max_depth* yaitu 15 yang terpilih mengindikasikan bahwa dengan pembatasan kedalaman pohon lebih optimal dibandingkan pohon yang tumbuh penuh tanpa batas, karena dapat mencegah *overfitting* pada dataset dengan 44 fitur dan 324 record training. Nilai *n_estimators* = 200 dipilih karena memberikan stabilitas prediksi lebih baik dibandingkan 100 pohon tanpa penambahan waktu komputasi yang signifikan


4.3 Evaluasi Performa Model

Model RFR dievaluasi pada 81 record testing set (periode 26–31 Mei 2026) yang tidak pernah dilihat model selama proses pelatihan. Hasil plot aktual vs prediksi pada testing set serta scatter plot disajikan pada Gambar 2. Aktuan vs Prediksi test set



Sumber : Hasil Penelitian (2026)

Gambar 3. Scatter plot actual vs prediksi



Sumber : hasil Penelitian (2026)

Nilai $R^2 = 0,9850$ mengindikasikan bahwa model mampu menjelaskan 98,50% variansi total data output daya sistem PJU, membuktikan keandalan pendekatan RFR berbasis lag features untuk permasalahan prediksi time-series daya PJU DC berbasis *Fresnel Solar Concentrator*. Nilai RMSE sebesar 2,37 Watt berarti rata-rata penyimpangan prediksi hanya $\pm 2,37$ Watt dari nilai aktual, yang sangat kecil relatif terhadap rentang daya 0–76,97 Watt (error relatif $\sim 3,1\%$). Nilai MAPE sebesar 8,29% termasuk dalam kategori prediksi sangat baik karena berada di bawah ambang batas 10% yang ditetapkan sebagai kriteria keberhasilan penelitian.

Visualisasi scatter plot pada Gambar menunjukkan sebaran titik data yang sangat dekat dengan garis ideal $y=x$ di sepanjang rentang daya 0 hingga 76,97 Watt, mengkonfirmasi bahwa model tidak hanya akurat pada rentang daya tertentu tetapi konsisten di seluruh rentang operasional sistem PJU.

Hasil evaluasi kuantitatif model pada testing set disajikan secara lengkap pada Tabel dibawah.

Tabel 7. Hasil metrik evaluasi


Metrik	Nilai	Status
R^2	0,9850	Terpenuhi
RMSE	2,3729 watt	Sangat Baik
MAE	1,4245 watt	Sangat Baik
MAPE	8,29	Terpenuhi

Sumber : Hasil Penelitian (2026)

4.4 Analisis Feature Importance

Analisis *Feature Importance* dilakukan untuk mengidentifikasi variabel prediktor yang paling berkontribusi terhadap akurasi prediksi model RFR. Hasil top 20 fitur terpenting divisualisasikan pada Gambar

Gambar 4. Hasil Analisis feature Importance



Sumber : Hasil Penelitian (2026)


Terdapat tiga temuan penting. Pertama, variabel sensor IoT beserta turunannya mendominasi prediksi dengan kontribusi kumulatif sebesar 82,6% dari total feature importance. P_Panel menjadi fitur paling dominan (0,1197), diikuti P_Panel_calc (0,1099) yang merupakan kalkulasi redundan dari $V_Panel \times I_Panel$, keduanya secara fisika mengukur hal yang sama sehingga memperkuat sinyal prediksi. Kedua, lag features dan rolling features secara kolektif berkontribusi sebesar 15,9%, dengan V_Panel_lag1 sebagai lag feature paling informatif (peringkat 10, importance 0,0346). Hal ini membuktikan bahwa informasi temporal 30 menit sebelumnya memiliki nilai prediksi yang nyata pada sistem PJU time-series ini. Ketiga, Cuaca Encoded dari data BMKG menempati peringkat ke-20 dengan importance hanya 0,0030 (0,3%). Rendahnya kontribusi ini disebabkan oleh resolusi data BMKG yang harian, sementara sensor memiliki resolusi 30 menit, sehingga nilai daya dari sensor sudah secara implisit mengandung informasi kondisi cuaca saat itu.

4.5 Prediksi Output Daya 7 Hari ke Depan

Prediksi output daya untuk 7 hari ke depan (1–7 Juni 2026) dilakukan menggunakan strategi *recursive multi-step forecasting*, di mana hasil prediksi setiap slot waktu digunakan sebagai lag feature untuk prediksi slot berikutnya. Jadwal prediksi mencakup pukul 09:00–16:00 WIB setiap 30 menit (15 slot per


hari). Visualisasi prediksi per slot dan ringkasan harian disajikan pada Gambar

Gambar 5. Prediksi P total 7 hari kedepan




Sumber : Hasil penelitian (2026)

Gambar 6. Ringkasan daya Prediksi per hari



Sumber : Hasil penelitian (2026)

Gambar 7. Estimasi energi harian prediksi (wh)



Sumber : Hasil Penelitian (2026)

Model memprediksi bahwa sistem PJU DC berbasis *Fresnel Solar Concentrator* akan menghasilkan rata-rata $\pm 33,4$ Watt per slot waktu dengan estimasi energi harian sebesar ± 250 Wh per hari selama periode 1–7 Juni 2026. Total estimasi energi selama 7 hari adalah 1.749,9 Wh. Pola prediksi menunjukkan profil daya yang konsisten antar hari, dengan daya cenderung lebih rendah pada sesi pagi (09:00–10:00) dan mencapai puncak pada siang hari (11:00–14:00) sesuai pola iradiasi matahari harian di Kota Palembang.

Konsistensi nilai prediksi antar 7 hari (standar deviasi energi harian hanya $\pm 0,9$ Wh) disebabkan oleh fakta bahwa estimasi kondisi cuaca 7 hari ke depan menggunakan rata-rata historis pola per hari dalam seminggu dari dataset Mei 2026. Untuk implementasi nyata pada sistem manajemen energi PJU, akurasi prediksi jangka panjang dapat ditingkatkan secara signifikan dengan mengganti estimasi historis tersebut menggunakan data prakiraan cuaca resmi BMKG 7 hari ke depan yang tersedia secara terbuka.

Ringkasan hasil prediksi 7 hari ke depan disajikan secara lengkap pada Tabel dibawah.

Tabel 8. Ringkasan Hasil prediksi

Tanggal	P Mean (W)	P Min (W)	P Max (W)	Estimasi Energi harian
1 Juni 2026	33,6	15,3	42,9	252,3
2 Juni 2026	33,1	15,2	42,6	248,5
3 Juni 2026	33,3	15,3	42,7	250,0
4 Juni 2026	33,3	15,3	42,7	249,9
5 Juni 2026	33,3	15,2	42,7	249,6
6 Juni 2026	33,3	15,3	42,7	249,8
7 Juni 2026	33,3	15,3	42,7	249,8
Total				1.749,9 Wh

Sumber : Hasil Penelitian (2026)

Hasil penelitian ini menunjukkan bahwa model *Random Forest Regression* dengan 44 fitur prediktor yang mencakup variabel sensor IoT, lag features time-series, fitur interaksi, dan data BMKG berhasil memprediksi output daya

sistem PJU DC berbasis *Fresnel Solar Concentrator* dengan tingkat akurasi yang sangat tinggi ($R^2 = 0,9850$, MAPE = 8,29%).

Kontribusi utama penelitian ini terhadap literatur yang ada terletak pada tiga aspek. Pertama, integrasi lag features berbasis time-series terbukti menambah nilai prediksi temporal yang tidak dapat ditangkap oleh fitur statis semata, dibuktikan dengan kontribusi kolektif lag dan rolling features sebesar 15,9% dari total feature importance. Kedua, penggunaan *Fresnel Solar Concentrator* menciptakan karakteristik data daya yang unik dengan rentang 0–76,97 Watt dan variabilitas tinggi (std = 21,72 Watt), berbeda dengan sistem PV konvensional, namun terbukti dapat dimodelkan dengan sangat baik menggunakan RFR. Ketiga, kemampuan prediksi 7 hari ke depan menggunakan strategi *recursive multi-step forecasting* membuka peluang implementasi sistem manajemen energi PJU yang proaktif, di mana operator dapat merencanakan strategi pengisian baterai dan penjadwalan beban berdasarkan prediksi ketersediaan energi.

Limitasi penelitian ini meliputi: (1) dataset terbatas pada 27 hari pengukuran di bulan Mei 2026, sehingga model belum terpapar variasi musiman jangka panjang; (2) kondisi cuaca 7 hari ke depan diestimasi dari pola historis, bukan prakiraan BMKG asli.

5. KESIMPULAN

1. Model *Random Forest Regression* berbasis 44 fitur prediktor yang mencakup variabel sensor IoT (V_Panel, I_Panel, V_Baterai, I_Baterai, P_Panel, P_Baterai), lag features time-series (lag t–1 hingga t–14), rolling statistics (window 2 jam), fitur interaksi (V_Ratio, Efisiensi), fitur waktu siklik, dan data cuaca BMKG berhasil dibangun dengan hyperparameter optimal $n_estimators=200$, $max_depth=15$, $min_samples_split=2$, dan $max_features=sqrt$ melalui proses *Grid Search Cross-Validation 5-fold*.
2. Model mencapai performa yang sangat baik pada testing set (81 record, periode 26–31 Mei 2026) dengan nilai $R^2 = 0,9850$, RMSE = 2,3729 Watt, MAE = 1,4245 Watt, dan MAPE = 8,29%, memenuhi seluruh kriteria keberhasilan yang ditetapkan ($R^2 \geq 0,90$ dan $MAPE \leq 10\%$), membuktikan keandalan pendekatan *Random Forest Regression*

berbasis *lag features* untuk prediksi output daya sistem PJU berbasis *Fresnel Solar Concentrator*.

3. Berdasarkan analisis *Feature Importance*, variabel *P_Panel* (0,1197) menjadi prediktor paling dominan, diikuti *P_Panel_calc* (0,1099), *P_Baterai* (0,1090), dan *I_Panel* (0,1043). Secara kumulatif, fitur sensor IoT dan turunannya berkontribusi 82,6% dari total *feature importance*, sementara *lag features* dan *rolling features* berkontribusi 15,9%, membuktikan bahwa instrumentasi IoT multi-sensor berbasis ESP32 merupakan komponen paling kritis dalam sistem prediksi ini.
4. Integrasi data cuaca BMKG (penyinaran matahari, curah hujan, temperatur) memberikan kontribusi yang terbatas pada akurasi model karena perbedaan resolusi temporal — data BMKG bersifat harian sementara data sensor IoT beresolusi 30 menit — sehingga variabel *Cuaca_Encoded* hanya menempati peringkat ke-20 *feature importance* dengan skor 0,0030. Namun data BMKG tetap relevan sebagai konteks meteorologi jangka panjang.
5. Model berhasil memprediksi output daya sistem PJU DC untuk 7 hari ke depan (1–7 Juni 2026) menggunakan strategi *recursive multi-step forecasting* dengan estimasi energi rata-rata ± 250 Wh per hari dan total energi 1.749,9 Wh selama 7 hari, memberikan informasi yang dapat digunakan untuk optimasi jadwal pengisian baterai dan manajemen beban lampu jalan secara proaktif.
6. Kelebihan penelitian ini meliputi: (a) integrasi *lag features* yang terbukti meningkatkan kemampuan prediksi temporal; (b) penggunaan *Fresnel Solar Concentrator* yang meningkatkan densitas iradiasi panel surya secara signifikan; (c) kemampuan prediksi 7 hari ke depan yang langsung dapat diimplementasikan pada sistem manajemen energi PJU; dan (d) model bersifat *scale-invariant* sehingga tidak memerlukan normalisasi data.
7. Kekurangan penelitian ini meliputi: (a) dataset terbatas pada 27 hari pengukuran (405 record) di bulan Mei 2026 sehingga model belum terpapar variasi musiman jangka panjang; (b) estimasi kondisi cuaca 7 hari ke depan masih menggunakan rata-rata

historis, bukan prakiraan BMKG resmi; dan (c) resolusi data BMKG yang harian belum optimal untuk dikombinasikan dengan data sensor beresolusi 30 menit.

8. Pengembangan selanjutnya yang direkomendasikan meliputi: (a) memperluas durasi pengambilan data minimal 3–6 bulan untuk mencakup variasi musiman dan meningkatkan robustness model; (b) mengintegrasikan prakiraan cuaca BMKG 7 hari resmi secara *real-time* melalui API untuk meningkatkan akurasi prediksi jangka panjang; (c) membandingkan performa RFR dengan algoritma *deep learning* berbasis *sequence* seperti LSTM atau Transformer yang secara native menangani data *time-series*; dan (d) mengimplementasikan model pada sistem PJU skala penuh di lapangan untuk validasi performa pada kondisi nyata.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Ibu Ir. Evelina, ST., M.Kom. selaku Dosen Pembimbing I dan Bapak Ir. M. Nawawi, M.T. selaku Dosen Pembimbing II atas bimbingan, arahan, dan dukungan yang diberikan selama pelaksanaan penelitian ini. Terima kasih juga disampaikan kepada Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Stasiun Palembang atas ketersediaan data meteorologi yang digunakan dalam penelitian ini, serta kepada Dewan Redaksi Jurnal Informatika dan Teknik Elektro Terapan (JITET) yang telah memberikan kesempatan kepada penulis untuk mempublikasikan hasil penelitian ini..

DAFTAR PUSTAKA

- [1] M. A. Kurniawan *et al.*, “Analisis Perancangan Penerangan Jalan Umum Tenaga Surya (PJU-TS) Akses Desa Wisata Mantar Kabupaten Sumbawa Barat,” vol. 6, pp. 2951–2956, 2023.
- [2] M. S. Alim, S. Thamrin, and R. L. W, “Pemanfaatan Pembangkit Listrik Tenaga Surya sebagai Alternatif Ketahanan Energi Nasional Masa Depan,” vol. 4, no. 3, pp. 2427–2435, 2023.
- [3] M. A. Saputra, M. F. Azis, and E. Aditia, “No Title”.
- [4] J. Gaboitaolelwe, “Machine Learning Based Solar Photovoltaic Power Forecasting: A Review and Comparison,” *IEEE Access*, vol. 11, no. March, pp. 40820–40845, 2023, doi: 10.1109/ACCESS.2023.3270041.
- [5] P. Setiawati *et al.*, “PREDICTING SOLAR

- POWER GENERATION : A MACHINE LEARNING,” vol. 21, no. 1, pp. 34–43, 2025, doi: 10.33480/pilar.v21i1.6126.
- [6] A. Bouakkaz, A. Lahsasna, A. J. Gil, M. Luigi, and R. Jiménez-castaneda, “Evaluating and analyzing the performance of PV power output forecasting using different models of machine-learning techniques considering prediction accuracy,” vol. 14, no. 1, pp. 158–167, 2025.
- [7] A. J. Lari, A. P. Sanfilippo, D. Bachour, and D. Perez-astudillo, “Using Machine Learning Algorithms to Forecast Solar Energy Power Output,” pp. 1–22, 2025.
- [8] C. G. Villegas-mier, J. Rodriguez-resendiz, and J. M. Álvarez-alvarado, “Optimized Random Forest for Solar Radiation Prediction Using Sunshine Hours,” 2022.
- [9] M. Sari, “G-Tech : Jurnal Teknologi Terapan Indonesia Using the Random Forest Method,” vol. 9, no. 4, pp. 1771–1781, 2025.
- [10] E. A. Handoyo *et al.*, “Perancangan dan Pengujian Lensa Fresnel pada Kolektor Surya Plat Datar,” vol. 17, no. 2, 2020, doi: 10.9744/jtm.17.2.48.
- [11] A. I. Press, A. Wagyaana, I. Artikel, J. T. Elektro, and P. N. Jakarta, “Jurnal Ilmiah Setrum,” vol. 8, no. 1, pp. 238–247, 2019.
- [12] W. Satria, W. Indrasari, and R. Fahdiran, “KARAKTERISASI SENSOR ARUS DAN TEGANGAN UNTUK APLIKASI MAXIMUM POWER POINT TRACKER PADA SISTEM PENYIMPANAN ENERGI,” vol. IX, pp. 77–82, 2020.
- [13] D. Aribowo, G. Priyogi, S. Islam, P. T. Elektro, U. Sultan, and A. Tirtayasa, “APLIKASI SENSOR LDR (LIGHT DEPENDENT RESISTOR) UNTUK EFISIENSI ENERGI PADA LAMPU PENERANGAN,” vol. 9, no. 1, 2022.
- [14] BMKG, “DataOnlineBMKG.” [Online]. Available: <https://dataonline.bmkg.go.id/dataonline-home>
- [15] M. Ichsan, “MACHINE LEARNING DETEKSI PENYAKIT PADA KUCING MENGGUNAKAN,” vol. 13, no. 3, 2000.
- [16] L. E. O. Breiman, “Random Forests,” pp. 5–32, 2001.
- [17] F. L. Rashid, M. A. Al-obaidi, and A. J. Mahdi, “Advancements in Fresnel Lens Technology across Diverse Solar Energy Applications : A Comprehensive Review,” 2024.
- [18] G. A. Sehangunaung *et al.*, “KEPUASAN KONSUMEN PENGGUNA APLIKASI LAZADA DI KOTA MANADO THE INFLUENCE OF SERVICE QUALITY ON CUSTOMER SATISFACTION USING DELIVERY Jurnal EMBA Vol . 11 , No . 3 . Juli 2023 , Hal . 1-11,” vol. 11, no. 3, pp. 1–11, 2023.
- [19] J. Adi and S. No, “PENGUKURAN PERFORMA SUPPORT VECTOR MACHINE DAN NEURAL NETWOK DALAM Diyah Ruswanti,” vol. 13, no. mm, pp. 66–75, 2020.
- [20] H. H. Nuha, U. Telkom, and J. Barat, “Mean Absolute Percentage Error (MAPE) dan Penggunaannya,” vol. 3, no. December 2024, pp. 3–5, 2025.