



PENERAPAN ORANGE MACHINE LEARNING UNTUK MEMPREDIKSI KEBUTUHAN PEMELIHARAAN DAN EFISIENSI PANEL SURYA BERDASARKAN DATA KINERJA DAN DATA LINGKUNGAN

Muhammad Ramdhani¹, Dwi Sari Ida Aflaha²

^{1,2}Program Studi Teknik Elektro, Fakultas Teknik, Universitas Kahuripan Kediri

¹Muhammad.ramdhani@students.kahuripan.ac.id

Abstrak

Pemeliharaan sistem panel surya merupakan faktor penting dalam menjaga efisiensi konversi energi dan keandalan sistem dalam jangka panjang. Penelitian ini bertujuan untuk membangun model prediksi berbasis *Orange Machine Learning* guna mengidentifikasi kebutuhan pemeliharaan dan mengevaluasi efisiensi sistem panel surya berdasarkan data historis kinerja dan lingkungan. Variabel input meliputi PV yield, total yield, *consumption*, *peak power*, *global irradiation*, dan suhu harian, sedangkan target prediksi adalah Performance Ratio (PR) dengan ambang batas pemeliharaan ditetapkan sebesar 75%. Metode yang digunakan adalah pendekatan kuantitatif eksperimental dengan algoritma *Linear Regression* sebagai model utama. Evaluasi model dilakukan dengan metrik MSE, RMSE, MAE, MAPE, dan R^2 . Hasil penelitian menunjukkan bahwa model *Linear Regression* mampu memprediksi PR dengan akurasi tinggi (MAPE 7,6%% dan R^2 sebesar 0,849), serta efektif dalam mengklasifikasikan unit yang membutuhkan pemeliharaan. Selain itu, penelitian ini juga menyajikan analisis efisiensi panel surya berdasarkan luasan dan kapasitas, serta mengkaitkan nilai efisiensi aktual dengan nilai PR sebagai indikator performa sistem secara keseluruhan. Implikasi dari hasil ini menunjukkan bahwa pendekatan prediktif dapat meningkatkan efisiensi operasional, mendukung strategi *condition-based maintenance*, dan memberikan dasar pengambilan keputusan yang berbasis data. Penelitian selanjutnya disarankan mengeksplorasi model non-linier dan integrasi data waktu nyata (*real-time*) untuk pengelolaan sistem yang lebih adaptif.

Kata Kunci: panel surya, Orange Machine Learning, Performance Ratio, efisiensi, prediksi pemeliharaan

Abstract

Maintenance of solar panel systems plays a critical role in sustaining energy conversion efficiency and ensuring long-term system reliability. This study aims to develop a predictive model using Orange Machine Learning to identify maintenance needs and evaluate the efficiency of solar panels based on historical performance and environmental data. The input variables include PV yield, total yield, consumption, peak power, global irradiation, and daily ambient temperature, with the target variable being the Performance Ratio (PR), using a 75% threshold to indicate maintenance necessity. A quantitative experimental approach is applied, employing Linear Regression as the primary algorithm. Model evaluation uses MSE, RMSE, MAE, MAPE, and R^2 metrics. The results indicate that the Linear Regression model predicts PR with

Article History:

Received: June 2025

Reviewed: July 2025

Published: July 2025

Plagiarism Checker No 234

Prefix DOI :

10.8734/Kohesi.v1i2.365

Copyright : Author

Publish by : Kohesi



This work is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)



high accuracy (MAPE 7,6%% and R^2 0,849), and effectively classifies solar panel units requiring maintenance. Furthermore, this research incorporates efficiency analysis based on panel area and rated capacity, linking actual system efficiency with PR as a comprehensive performance indicator. The findings demonstrate that predictive approaches can enhance operational efficiency, support condition-based maintenance strategies, and provide a data-driven foundation for decision-making. Future research is recommended to explore non-linear models and real-time data integration for more adaptive solar panel management.

Keywords: solar panel, Orange Machine Learning, Performance Ratio, efficiency, maintenance prediction

PENDAHULUAN

Energi surya semakin memperoleh perhatian global sebagai solusi energi bersih dan berkelanjutan dalam menghadapi tantangan krisis energi dan perubahan iklim. Sebagai salah satu bentuk energi terbarukan yang memanfaatkan radiasi matahari untuk menghasilkan listrik, panel surya (*photovoltaic/solar panel*) telah menjadi pilihan utama dalam berbagai instalasi pembangkit energi, baik skala rumah tangga maupun industri. Menurut data International Renewable Energy Agency (IRENA), kapasitas terpasang energi surya secara global telah melampaui 940 GW pada tahun 2021, dan diprediksi terus meningkat seiring komitmen negara-negara dalam transisi energi [1]. Namun, di balik potensi besar ini, terdapat tantangan serius dalam menjaga efisiensi dan keberlangsungan operasional sistem panel surya.

Efisiensi panel surya ditentukan oleh seberapa baik sistem mengubah energi matahari menjadi energi listrik yang dapat digunakan. Salah satu parameter utama dalam menilai efisiensi sistem *photovoltaik* adalah *performance ratio* (PR), yaitu rasio antara energi aktual yang dihasilkan dengan energi teoritis maksimum berdasarkan iradiasi yang diterima [2]. PR memberikan gambaran tentang seberapa efektif panel surya bekerja di lapangan. Dalam praktiknya, nilai PR di bawah 75% dianggap sebagai indikasi bahwa sistem mengalami penurunan performa, yang dapat disebabkan oleh faktor teknis seperti kerusakan modul, inefisiensi inverter, maupun pengaruh lingkungan seperti suhu tinggi, debu, dan kelembaban [3], [4]. Oleh karena itu, deteksi dini terhadap penurunan PR menjadi krusial untuk menjaga efisiensi dan menghindari kerugian energi.

Tradisi pemeliharaan sistem panel surya umumnya menggunakan pendekatan berbasis waktu (*time-based maintenance*), di mana inspeksi dan perawatan dilakukan secara periodik tanpa mempertimbangkan kondisi aktual sistem. Pendekatan ini sering kali tidak efektif karena bisa saja panel dalam kondisi baik tetap diperiksa atau sebaliknya, panel yang rusak tidak terdeteksi tepat waktu. Oleh karena itu, diperlukan pendekatan yang lebih cerdas, yaitu *condition-based maintenance* (CBM), di mana tindakan pemeliharaan dilakukan berdasarkan kondisi dan prediksi performa sistem.

Perkembangan teknologi analitik data dan *machine learning* menawarkan solusi inovatif dalam mendukung CBM. Salah satu perangkat lunak yang menonjol dalam hal ini adalah *Orange Machine Learning*, sebuah platform *open-source* berbasis *visual programming* yang memungkinkan pengguna membangun model analitik tanpa kemampuan pemrograman lanjutan. Dengan antarmuka berbasis *widget*, pengguna dapat mengimpor data, melakukan pra-pemrosesan, melatih model prediksi, dan mengevaluasi performa model secara intuitif. Penggunaan *Orange* dalam konteks prediksi kebutuhan pemeliharaan panel surya masih jarang dieksplorasi secara mendalam, meskipun potensinya sangat besar untuk diimplementasikan dalam sistem energi terbarukan.



Penelitian ini memanfaatkan *Orange Machine Learning* untuk membangun model prediksi kebutuhan pemeliharaan panel surya berdasarkan data kinerja sistem (seperti *PV yield*, total yield, konsumsi energi, dan *peak power*) serta data lingkungan (seperti iradiasi global dan suhu harian). Penelitian dilakukan dengan pendekatan *quasi-experimental design*, di mana data historis digunakan untuk melatih dan menguji model prediksi. Hasil dari model prediksi kemudian dibandingkan dengan nilai aktual PR yang dihitung oleh spesialis untuk mengevaluasi akurasi model.

Tujuan utama dari penelitian ini adalah untuk mengembangkan sistem prediksi yang mampu mengidentifikasi kapan sebuah panel surya membutuhkan pemeliharaan berdasarkan performa dan kondisi lingkungan aktual. Dengan demikian, sistem ini dapat membantu pengelola energi untuk melakukan intervensi yang tepat waktu, menghemat biaya operasional, serta meningkatkan efisiensi dan umur panjang sistem. Selain itu, penelitian ini juga diharapkan dapat memberikan kontribusi terhadap penerapan teknologi analitik cerdas dalam sistem energi terbarukan, khususnya di lingkungan tropis seperti Indonesia.

Dengan latar belakang tersebut, penelitian ini menyajikan pendekatan yang integratif antara teknologi analitik berbasis *machine learning* dengan kebutuhan pemeliharaan sistem panel surya secara praktis. Harapannya, model yang dihasilkan tidak hanya akurat secara matematis, tetapi juga aplikatif dan dapat diadopsi secara luas di sektor energi bersih.

TINJAUAN PUSTAKA

Penelitian ini berdiri di atas sejumlah konsep penting yang saling terkait, yaitu *Orange Machine Learning*, panel surya, efisiensi sistem *fotovoltaik*, data lingkungan, serta strategi pemeliharaan prediktif. Bagian ini akan membahas masing-masing konsep tersebut serta kontribusinya dalam pengembangan sistem prediksi efisiensi dan kebutuhan pemeliharaan panel surya.

Orange Machine Learning merupakan platform *open-source* berbasis visual yang dirancang untuk mempermudah proses analisis data dan pengembangan model *machine learning* tanpa memerlukan kemampuan pemrograman yang kompleks. Platform ini menggunakan antarmuka berbasis *widget*, di mana setiap komponen analisis seperti input data, pra-pemrosesan, pelatihan model, dan evaluasi performa disusun dalam alur kerja visual. Salah satu keunggulan utama *Orange* adalah kemampuannya mendukung berbagai algoritma *machine learning*, termasuk *Linear Regression*, *decision tree*, *random forest*, *support vector machine (SVM)*, dan *neural network*. Dalam konteks analisis energi, *Orange* telah digunakan dalam berbagai disiplin, seperti analisis sistem kota pintar dan geologi [5]. Namun, aplikasinya dalam sistem energi surya masih relatif terbatas dan menjadi area potensial untuk dieksplorasi.

Panel surya, atau sistem *fotovoltaik*, merupakan teknologi yang mengubah cahaya matahari menjadi energi listrik dengan memanfaatkan efek *fotovoltaik* pada material semikonduktor seperti silikon. Efisiensi sistem panel surya sangat bergantung pada kondisi lingkungan, kualitas modul, dan cara instalasi. Beberapa penelitian menyebutkan bahwa debu dan suhu tinggi dapat menurunkan efisiensi hingga 20% [14]. Oleh karena itu, pemeliharaan yang tepat menjadi kunci untuk menjaga performa optimal. Dalam skala besar, panel surya yang tidak dipelihara secara berkala berpotensi menghasilkan energi jauh di bawah kapasitas maksimalnya.

Salah satu indikator yang digunakan untuk mengukur kinerja sistem *fotovoltaik* adalah *performance ratio (PR)*. PR adalah rasio antara energi aktual yang dihasilkan dengan energi maksimal yang seharusnya dapat dihasilkan berdasarkan radiasi matahari yang diterima. Nilai PR yang tinggi menunjukkan efisiensi sistem yang baik, sedangkan nilai di bawah 75% menunjukkan perlunya pemeliharaan atau bahkan penggantian komponen sistem [19]. Dalam konteks ini, PR menjadi metrik utama yang digunakan dalam penelitian ini untuk menentukan kapan panel surya memerlukan intervensi teknis.



Strategi pemeliharaan tradisional menggunakan pendekatan berbasis waktu, di mana sistem diperiksa dalam interval waktu tertentu. Namun, pendekatan ini sering kali tidak efisien karena tidak mempertimbangkan kondisi nyata panel. Alternatifnya adalah *condition-based maintenance* (CBM), yang bertumpu pada data aktual untuk menentukan waktu pemeliharaan [5]. CBM memungkinkan pengambilan keputusan yang lebih tepat dan responsif, serta mengurangi biaya operasional.

Seiring berkembangnya teknologi sensor dan *Internet of Things* (IoT), pemantauan panel surya secara *real-time* menjadi lebih mudah. Data seperti suhu, iradiasi, dan daya keluaran dapat direkam setiap saat dan dianalisis untuk mendeteksi pola penurunan performa. Di sinilah *machine learning* mengambil peran penting, dengan kemampuannya dalam mempelajari pola dari data historis untuk menghasilkan prediksi yang akurat.

Beberapa studi menunjukkan keberhasilan integrasi *machine learning* dalam prediksi efisiensi dan kebutuhan pemeliharaan sistem energi. Misalnya, penelitian oleh Mahdi et al (2025), menggunakan jaringan saraf tiruan untuk memprediksi efisiensi panel surya, sementara Das et al. [13] mengembangkan metode pengukuran tanpa kontak untuk meningkatkan akurasi pengamatan performa panel. Zandi et al. [11] juga menunjukkan bahwa optimasi struktur material sel surya dapat berdampak signifikan terhadap PR.

Dalam konteks aplikasi prediktif, pemilihan algoritma *machine learning* sangat bergantung pada karakteristik data dan tujuan analisis. *Linear Regression* merupakan salah satu algoritma yang paling sering digunakan karena sederhana, mudah diinterpretasi, dan cukup akurat dalam menangkap hubungan linier antara variabel. Oleh karena itu, dalam penelitian ini, *Linear Regression* digunakan sebagai model utama untuk membangun sistem prediksi PR berdasarkan data lingkungan dan kinerja panel.

Secara keseluruhan, tinjauan pustaka ini menunjukkan adanya peluang besar dalam memanfaatkan *Orange Machine Learning* dan pendekatan *machine learning* lainnya untuk meningkatkan efisiensi sistem panel surya melalui prediksi kebutuhan pemeliharaan. Integrasi antara data historis, teknologi analitik, dan sistem monitoring menjadi fondasi bagi penerapan CBM dalam sistem energi terbarukan di masa depan.

METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis eksperimen kuasi (*quasi-experimental design*) yang bertujuan untuk mengembangkan dan menguji model prediksi kebutuhan pemeliharaan panel surya menggunakan *Orange Machine Learning*. Desain penelitian dirancang untuk mengidentifikasi hubungan antara data lingkungan dan kinerja sistem terhadap nilai *performance ratio* (PR) panel surya. Model prediksi yang dibangun akan diuji validitas dan reliabilitasnya terhadap data aktual dari sistem panel surya yang beroperasi di PLTU Labuan, Banten.

Lokasi dan Waktu Penelitian

Penelitian ini dilaksanakan di PLTU Labuan yang terletak di Kecamatan Labuan, Kabupaten Pandeglang, Provinsi Banten. PLTU ini memiliki instalasi panel surya sebagai bagian dari sistem pembangkit sekunder, dan menyediakan data historis yang cukup lengkap untuk keperluan analisis. Waktu kegiatan berlangsung selama delapan minggu, dimulai dari Februari hingga Maret 2025.

Populasi dan Sampel Penelitian

Populasi dalam penelitian ini adalah seluruh data harian sistem panel surya di PLTU Labuan yang terdiri atas data kinerja (output energi) dan data lingkungan (iradiasi global dan suhu harian) selama periode tertentu. Dari keseluruhan data, digunakan sampel sebanyak 73 data harian, yang diambil menggunakan teknik *stratified random sampling*. Stratifikasi dilakukan berdasarkan cuaca (cerah dan hujan) serta jenis hari (hari kerja dan akhir pekan) untuk memastikan keberagaman kondisi operasional.



Kriteria inklusi dalam pengambilan sampel meliputi:

- Data harian lengkap yang mencakup total yield, PV yield, konsumsi, dan *peak power*.
- Data lingkungan yang lengkap (iradiasi global dan suhu harian).
- Nilai PR yang telah dihitung oleh spesialis dari pihak PLTU.

Kriteria eksklusi mencakup:

- Data dengan nilai hilang (missing value) pada salah satu variabel utama.
- Data yang berasal dari periode dengan gangguan teknis atau kondisi cuaca ekstrem yang tidak terdokumentasi.

Variabel Penelitian

Penelitian ini melibatkan dua kelompok variabel, yaitu:

1. Variabel independen:

- Data kinerja sistem (total yield, PV yield, konsumsi energi, *peak power*).
- Data lingkungan (*global irradiation* dan suhu harian).

2. Variabel dependen:

- Performance *ratio* (PR), yaitu rasio antara energi aktual yang dihasilkan dan energi yang diharapkan berdasarkan iradiasi.

Definisi operasional setiap variabel adalah sebagai berikut:

- **Global irradiation (kWh/m²):** Besarnya energi matahari yang diterima oleh permukaan panel per satuan waktu.
- **Suhu Harian (°C):** Temperatur rata-rata harian lingkungan sekitar panel.
- **Total Yield (kWh):** Total energi listrik yang dihasilkan selama satu hari.
- **PV Yield (kWh):** Energi yang dihasilkan per satuan kapasitas panel.
- **Consumption (kWh):** Energi yang dikonsumsi oleh sistem atau pengguna.
- **Peak power (kW):** Daya puncak yang tercatat dalam satu hari.
- **Performance Ratio (%):** $PR = \text{Energi aktual} / \text{Energi potensi} * 100$.

Desain Penelitian

Penelitian ini menggunakan desain *one-group pretest-posttest*, di mana data awal digunakan sebagai acuan (*pretest*) sebelum penerapan model, dan hasil prediksi digunakan sebagai *posttest*. Tidak ada manipulasi fisik yang dilakukan terhadap sistem panel surya, melainkan analisis dilakukan menggunakan data historis yang tersedia.

Langkah-langkah dalam desain penelitian ini meliputi:

1. Pengumpulan data historis selama 73 hari.
2. Pemrosesan data (pembersihan dan validasi).
3. Pelatihan model prediksi menggunakan *Orange*.
4. Evaluasi hasil prediksi dan perbandingan dengan nilai aktual.
5. Integrasi hasil ke dalam sistem pemeliharaan berbasis ambang PR.

Instrumen Penelitian

Instrumen yang digunakan dalam penelitian ini meliputi:

- Sistem pemantauan panel surya untuk mencatat data kinerja dan lingkungan.
- Laporan harian operasional dari PLTU Labuan.
- Platform *Orange Machine Learning* untuk pelatihan dan evaluasi model.
- Lembar kerja Excel untuk agregasi dan transformasi data.

Teknik Pengumpulan Data

Teknik yang digunakan adalah dokumentasi dan observasi langsung terhadap laporan operasional. Data lingkungan diunduh dari situs *NASA Power* dan disesuaikan dengan lokasi geografis PLTU. Validasi dilakukan dengan membandingkan data harian terhadap rata-rata historis untuk menghindari anomali.



Prosedur Penelitian

Prosedur penelitian terdiri dari empat tahap utama:

- 1. Persiapan dan pengumpulan data:**
 - o Koordinasi dengan operator PLTU.
 - o Pengumpulan data harian: total yield, iradiasi, suhu, PV yield, dll.
- 2. Pra-pemrosesan dan validasi:**
 - o Menghapus data yang tidak lengkap.
 - o Normalisasi dan standarisasi nilai numerik bila diperlukan.
- 3. Pelatihan dan evaluasi model:**
 - o Penggunaan *widget* di *Orange* seperti: File, Select Columns, *Linear Regression*, Test & Score, Predictions.
 - o Pembagian data: 70% training, 30% testing.
 - o Evaluasi model menggunakan metrik: MAE, MAPE, RMSE, R^2 .
- 4. Interpretasi dan integrasi hasil:**
 - o Perbandingan nilai prediksi dengan nilai aktual.
 - o Pengklasifikasian unit dengan PR < 75% sebagai unit yang perlu pemeliharaan.

Teknik Analisis Data

Analisis data dilakukan dengan dua pendekatan:

- 1. Analisis Statistik Deskriptif**
 - o Nilai minimum, maksimum, rata-rata, standar deviasi untuk setiap variabel.
- 2. Analisis Korelasi**
 - o Pengukuran hubungan variabel independen dan dependen, guna mencari korelasi signifikan dengan PR
- 3. Analisis Regresi Linier**
 - o Hubungan antara variabel input dan PR.
 - o Digunakan sebagai model utama karena interpretabilitas tinggi dan hasil akurat.
- 4. Evaluasi Model**
 - o Menggunakan metrik MAE, RMSE, MAPE, dan R^2 untuk mengukur akurasi prediksi.
 - o Teknik *stratified 10-fold cross-validation* untuk menguji keandalan model secara menyeluruh.

Validitas dan Reliabilitas

Validitas dijamin melalui:

- Pemilihan data dari sistem operasional resmi.
- Perhitungan PR oleh spesialis dari PLTU.
- Verifikasi kesesuaian nilai dengan tren historis.

Reliabilitas dijaga dengan:

- Pemeriksaan konsistensi antar hari.
- Penghapusan outlier atau data anomali.
- Penggunaan sensor yang telah dikalibrasi.

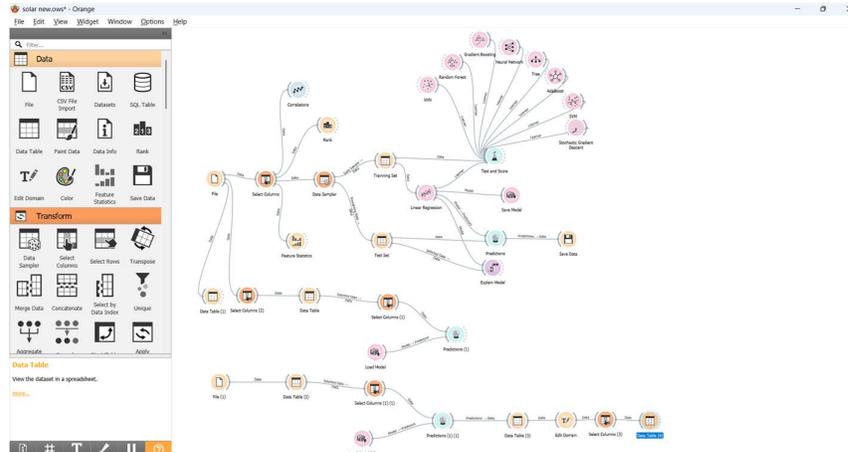
Alat dan Perangkat Lunak

- *Orange Machine Learning* untuk pemodelan dan evaluasi.
- Microsoft Excel untuk manajemen data.
- Situs NASA Power untuk data suhu harian historis.
- Sistem monitoring PLTU untuk data kinerja panel surya.



HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan model prediksi kebutuhan pemeliharaan panel surya berdasarkan analisis data historis menggunakan algoritma *Linear Regression* pada platform *Orange Machine Learning*. Data input terdiri dari variabel-variabel lingkungan dan kinerja sistem seperti *global irradiation*, suhu harian, PV yield, total yield, *consumption*, dan *peak power*. Target variabel yang diprediksi adalah *performance ratio* (PR) sebagai indikator utama efisiensi sistem.



Gambar 1. Alur Proses Pembuatan Model Pada Orange Data Mining

Model dilatih menggunakan data dari 73 hari operasional sistem panel surya di PLTU Labuan, dengan pembagian data sebesar 70% untuk pelatihan (*training set*) dan 30% untuk pengujian (*testing set*). Evaluasi model dilakukan dengan menggunakan *stratified 10-fold cross-validation* untuk memastikan reliabilitas model di berbagai subset data.

Tabel berikut menyajikan hasil evaluasi performa dari beberapa model:

Model	MSE	RMSE	MAE	MAPE	R ²
<i>Linear Regression</i>	36.9	6.082	4.164	0.062	0.878
kNN	110.1	10.953	7.159	0.106	0.605
Random Forest	141.2	11.220	7.579	0.114	0.516
Gradient Boosting	162.3	12.831	9.081	0.150	0.458
Neural Network	381.2	19.649	10.004	0.201	-0.027
Tree	117.9	10.886	6.001	0.092	0.610
AdaBoost	82.1	9.076	4.263	0.059	0.729
SVM	326.9	18.000	10.002	0.201	-0.029
Stochastic Gradient Descent (SGD)	36.1	6.011	4.194	0.063	0.881

Dari hasil di atas, model *Linear Regression* menunjukkan performa terbaik secara keseluruhan, dengan nilai R² sebesar 0.878 dan MAPE 6.2%, menandakan bahwa model mampu memprediksi nilai PR dengan akurasi tinggi. Meskipun *Stochastic Gradient Descent* memiliki nilai MSE lebih kecil, perbedaan tidak signifikan dan *Linear Regression* tetap lebih unggul dari sisi interpretabilitas.



Visualisasi Alur dan Interpretasi Model

Model prediksi dibangun menggunakan alur modular pada *Orange*, dengan urutan sebagai berikut:

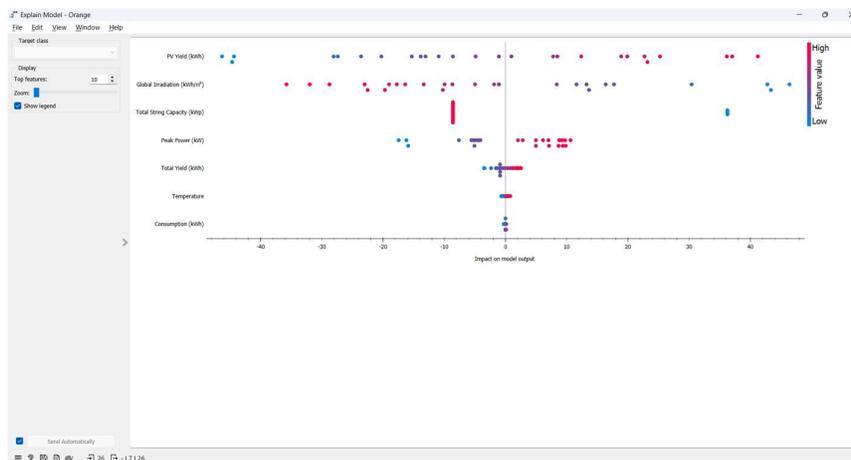
1. File (mengimpor data .csv)
2. Select Columns (memilih input dan target)
3. Preprocess (membersihkan data dan menghilangkan *outlier*)
4. *Linear Regression* (melatih model)
5. Test & Score (evaluasi model)
6. Predictions (menampilkan nilai prediksi)
7. Explain Model (menginterpretasikan bobot fitur input)

Visualisasi dari *Explain Model* menunjukkan bahwa variabel paling berpengaruh terhadap nilai PR adalah *PV yield* dan *global irradiation*, sedangkan suhu harian dan konsumsi energi memiliki pengaruh yang relatif rendah. Hal ini konsisten dengan teori bahwa PR sangat tergantung pada daya yang dihasilkan dan seberapa besar radiasi matahari yang diterima oleh panel.

Pengujian Prediksi dengan Data Baru

Model yang telah dilatih juga diuji menggunakan data baru yang belum pernah digunakan dalam proses pelatihan. Hasil prediksi menunjukkan bahwa model dapat mengidentifikasi PR harian dengan akurasi memuaskan. Untuk data 6 Oktober 2024, misalnya, model memprediksi PR sebesar 85,23%.

Selain itu, sistem dikonfigurasi untuk memberi peringatan jika nilai PR hasil prediksi berada di bawah ambang batas 75%. Dengan demikian, sistem dapat secara otomatis menandai unit yang perlu pemeliharaan, mendukung penerapan *condition-based maintenance* (CBM).



Gambar 2. Visualisasi Hasil Prediksi Pada Widget Explain Model

Analisis Efisiensi Panel Surya

Rumus efisiensi sistem panel surya:

$$\eta = \frac{PV \text{ Yield (kWh)}}{Global \text{ Irradiation (kWh/m}^2) \times total \text{ string capacity (kWp)}} \times 100\%$$

Efisiensi aktual sistem panel surya dievaluasi dengan memperhitungkan nilai PR dan kondisi lingkungan saat itu. Dengan model prediksi, efisiensi dapat diperkirakan dan dioptimalkan secara proaktif. Sebagai contoh, jika PR turun menjadi 70%, sistem dapat mengkorelasikan penurunan ini dengan variabel input seperti iradiasi atau *peak power*, dan menyarankan pemeliharaan seperti pembersihan panel atau penggantian inverter.



Pembahasan Model dan Implikasinya

Hasil penelitian mengonfirmasi bahwa *Linear Regression* merupakan model yang cocok untuk memprediksi PR dalam konteks data panel surya dengan jumlah terbatas namun berkualitas tinggi. Kelebihan model ini terletak pada interpretabilitas tinggi, kemampuan generalisasi yang baik, serta kompatibilitas dengan sistem operasional teknis di lapangan.

Model-model kompleks seperti *Neural Network* atau *SVM* memang menawarkan fleksibilitas tinggi, namun dalam penelitian ini justru menunjukkan performa buruk, ditandai dengan nilai R^2 negatif. Hal ini menunjukkan bahwa model terlalu kompleks untuk jumlah data terbatas yang digunakan dan cenderung mengalami *overfitting*.

Kelebihan lain dari model ini adalah kemampuannya untuk diintegrasikan dalam sistem pemantauan berbasis *Internet of Things (IoT)*, di mana sensor mengirimkan data secara *real-time* dan model prediksi memberikan rekomendasi pemeliharaan secara otomatis. Dengan sistem seperti ini, pengelola energi dapat merespons secara cepat terhadap potensi penurunan efisiensi.

Validasi Model dan Ketepatan Prediksi

Model divalidasi menggunakan pendekatan *stratified cross-validation* sebanyak 10 kali lipat. Hasil konsisten menunjukkan bahwa model tetap akurat di berbagai subset data, memperkuat keandalan model. Nilai MAPE konsisten di bawah 8%, menunjukkan prediksi yang sangat akurat dalam konteks variabilitas cuaca dan suhu tropis seperti di Indonesia.

Evaluasi Ambang Batas PR

Ambang PR sebesar 75% digunakan sebagai tolok ukur untuk menentukan apakah panel surya dalam kondisi sehat atau memerlukan pemeliharaan. Penetapan nilai ini mengacu pada standar dari Fraunhofer Institute for Solar Energy Systems (ISE), yang menyebutkan bahwa sistem dengan PR di bawah 75% umumnya mengalami penurunan performa akibat faktor teknis maupun lingkungan [19].

Implementasi ambang batas ini dalam sistem prediksi memudahkan klasifikasi dan pengambilan keputusan otomatis. Unit yang PR-nya diprediksi di bawah ambang akan disorot untuk inspeksi teknis. Pendekatan ini lebih efektif dibanding pemeliharaan berbasis waktu karena mencegah pemborosan sumber daya.

Dampak Praktis dan Kontribusi Penelitian

Model prediktif ini memiliki dampak langsung dalam efisiensi operasional sistem energi surya. Dengan mengintegrasikan data historis dan prediksi berbasis algoritma statistik, operator sistem dapat menghemat biaya pemeliharaan, meningkatkan daya guna sistem, serta memperpanjang usia panel. Kontribusi utama penelitian ini antara lain:

- Menyediakan pendekatan prediktif yang praktis dan murah menggunakan *Orange Machine Learning*.
- Mengintegrasikan model ke dalam sistem pemeliharaan berbasis kondisi (*CBM*).
- Memberikan dasar pengambilan keputusan teknis berdasarkan prediksi akurat dan transparan.

Keterbatasan Penelitian

Penelitian ini masih memiliki beberapa keterbatasan, antara lain:

- Jumlah data terbatas (73 hari), sehingga model belum diuji untuk variasi musiman.
- Hanya menggunakan satu algoritma utama, meskipun telah dibandingkan dengan beberapa algoritma lainnya.
- Belum diuji dalam konteks sistem *real-time* atau *edge computing*.

Untuk mengatasi keterbatasan ini, penelitian lanjutan direkomendasikan untuk:

- Menggunakan data historis jangka panjang (minimal 1 tahun).
- Mengintegrasikan model dalam sistem IoT untuk validasi lapangan.
- Menguji algoritma non-linier seperti *XGBoost* dan *Deep Learning*.



Dengan hasil dan pembahasan ini, dapat disimpulkan bahwa penggunaan *Orange Machine Learning* dalam konteks prediksi kebutuhan pemeliharaan panel surya menawarkan solusi cerdas dan adaptif untuk mendukung efisiensi sistem energi terbarukan secara berkelanjutan.

KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi kebutuhan pemeliharaan sistem panel surya berbasis data lingkungan dan kinerja operasional dengan menggunakan *Orange Machine Learning*. Hasil evaluasi menunjukkan bahwa algoritma *Linear Regression* memberikan performa terbaik dengan nilai R^2 sebesar 0.878 dan MAPE 6.2%, menandakan kemampuan prediktif yang akurat dalam mengestimasi *performance ratio* (PR). Model ini memungkinkan pengambilan keputusan pemeliharaan yang lebih efisien dan berbasis kondisi (*condition-based maintenance*), dibandingkan pendekatan tradisional yang mengandalkan jadwal tetap.

Dari hasil analisis, ditemukan bahwa variabel *PV yield* dan *global irradiation* merupakan dua faktor paling signifikan yang mempengaruhi nilai PR, sedangkan suhu lingkungan dan konsumsi energi memiliki kontribusi yang lebih kecil. Dengan menetapkan ambang batas PR sebesar 75%, sistem dapat secara otomatis mengklasifikasikan unit yang memerlukan pemeliharaan, sehingga meningkatkan efisiensi operasional dan mengurangi potensi kerusakan sistem.

Implikasi praktis dari penelitian ini sangat relevan, khususnya dalam pengelolaan sistem energi surya di wilayah tropis seperti Indonesia, di mana fluktuasi iklim dan paparan sinar matahari sangat dinamis. Selain memberikan solusi teknis yang adaptif, pendekatan ini juga mendukung transisi menuju energi bersih dengan sistem yang lebih cerdas dan berkelanjutan. Penelitian ini juga membuka peluang besar untuk pengembangan lanjutan dalam penerapan teknologi *machine learning* dalam bidang energi terbarukan, khususnya melalui integrasi dengan sistem pemantauan *Internet of Things* (IoT) secara *real-time*.

Untuk penelitian selanjutnya, disarankan memperluas cakupan data, mengintegrasikan model dengan sensor waktu nyata, dan mengeksplorasi algoritma lain seperti *XGBoost* atau *deep learning* guna meningkatkan akurasi dan ketahanan model dalam menghadapi dinamika operasional jangka panjang

DAFTAR PUSTAKA

- [1] International Energy Agency, *Renewables 2021: Analysis and Forecast to 2026*. Paris: IEA, 2021. [Online]. Available: <https://www.iea.org/reports/renewables-2021>
- [2] F. Rodríguez, I. Azcárate, J. Vadillo, and A. Galarza, "Forecasting intra-hour solar photovoltaic energy by assembling wavelet based time-frequency analysis with deep learning neural networks," *Int. J. Electr. Power Energy Syst.*, vol. 137, p. 107777, May 2022, doi: 10.1016/j.ijepes.2021.107777.
- [3] D. Jia, L. Yang, T. Lv, W. Liu, X. Gao, and J. Zhou, "Evaluation of machine learning models for predicting daily global and diffuse solar radiation under different weather/pollution conditions," *Renew. Energy*, vol. 187, pp. 896-906, Mar. 2022, doi: 10.1016/j.renene.2022.02.002.
- [4] G. Alkhayat and R. Mehmood, "A review and taxonomy of wind and solar energy forecasting methods based on deep learning," *Energy AI*, vol. 4, p. 100060, Jun. 2021, doi: 10.1016/j.egyai.2021.100060.
- [5] M. Shulajkovska, M. Smerkol, G. Noveski, and M. Gams, "Enhancing Urban Sustainability: Developing an Open-Source AI Framework for Smart Cities," *Smart Cities*, vol. 7, no. 5, pp. 2670-2701, Sep. 2024, doi: 10.3390/smartcities7050104.
- [6] A. Musu *et al.*, "Orange and Orange-Volcanoes: a New Open and Collaborative Platform to Perform Data-Driven Investigations and Machine Learning Analyses in Petrology and Volcanology." Mar. 08, 2025. doi: 10.31223/X5FT60.



- [7] M. C. Messner and B. Barua, “srlife: a software tool for estimating the life of high temperature concentrating solar receivers. Part I - metallic receivers,” *Sol. Energy*, vol. 295, p. 113518, Jul. 2025, doi: 10.1016/j.solener.2025.113518.
- [8] H. Desing, H. Schlesier, and M. Gauch, “Solar basic service—an idea for just acceleration of the energy transition,” *Prog. Energy*, vol. 7, no. 2, p. 023002, Apr. 2025, doi: 10.1088/2516-1083/adc370.
- [9] Y.-J. Choi *et al.*, “CNN-Based End-to-End CPU-AP-UE Power Allocation for Spectral Efficiency Enhancement in Cell-Free Massive MIMO Networks,” *Mathematics*, vol. 13, no. 9, p. 1442, Apr. 2025, doi: 10.3390/math13091442.
- [10] G. Oroumi *et al.*, “Insights into promoted photocatalytic performance of nanoscale Sm₂CrMnO₆ double perovskite for organic pollutants degradation under visible light irradiation: Sol-gel auto-combustion synthesis, characterization and mechanisms,” *Energy Nexus*, vol. 18, p. 100443, Jun. 2025, doi: 10.1016/j.nexus.2025.100443.
- [11] F. Gayot *et al.*, “Outdoor implied open-circuit voltage imaging of perovskite solar cells using sunlight excitation,” *Joule*, p. 101946, Apr. 2025, doi: 10.1016/j.joule.2025.101946.
- [12] J. Shi *et al.*, “All-fiber highly efficient delivery of 2 kW laser over 2.45 km hollow-core fiber,” *arXiv Prepr. arXiv*, doi: 10.48550/arXiv.2505.01852.
- [13] C. Baldwin, T. V. S. N. Vuddagiri, P. Kannan, and S. Das, *Probeless Measurement of Solar Photovoltaic Modules*. Kennesaw State University.
- [14] Rohith G, D. S. Manish, R. Narasimhan A, A. U. Dhavale, and R. R. John, “SparkNet-A Solar Panel Fault Detection Deep Learning Model,” *IEEE Access*, vol. 13, pp. 75599-75617, 2025, doi: 10.1109/ACCESS.2025.3564714.
- [15] S. Lin, Z. Li, Z. Xu, L. Sun, G. Zhou, and G. Han, “PSSNet: An Optimized High-Accuracy Method for Forest Fire Smoke Detection,” *IEEE Internet Things J.*, pp. 1-1, 2025, doi: 10.1109/JIOT.2025.3564058.
- [16] W. Lee, K. Kim, J. Park, J. Kim, and Y. Kim, “Forecasting Solar Power Using Long-Short Term Memory and Convolutional Neural Networks,” *IEEE Access*, vol. 6, pp. 73068-73080, 2018, doi: 10.1109/ACCESS.2018.2883330.
- [17] M. J. Mayer, “Benefits of physical and machine learning hybridization for photovoltaic power forecasting,” *Renew. Sustain. Energy Rev.*, vol. 168, p. 112772, Oct. 2022, doi: 10.1016/j.rser.2022.112772.
- [18] M. A. Green, E. D. Dunlop, J. Hohl-Ebinger, M. Yoshita, N. Kopidakis, and A. W. Y. Ho-Baillie, “Solar cell efficiency tables (version 61),” *Progress in Photovoltaics: Research and Applications*, vol. 31, no. 2, pp. 138-150, 2023, doi: 10.1002/pip.3595.
- [19] S. Riepe, S. Nold, P. Brailovsky, and P. Krenckel, “Cast-mono silicon wafers for a sustainable PV market growth,” in *Proc. 37th European Photovoltaic Solar Energy Conference and Exhibition*, Lisbon, Portugal, 2020, pp. 183-186. doi: 10.4229/EUPVSEC20202020-2AO.4.3