



Analisis Intensitas Radiasi Matahari terhadap Efisiensi Panel Surya menggunakan Algoritma *Support Vector Regression* (SVR) dan *Naïve Bayes*

Ramadoni¹, Sri Purwaningsih¹, dan Jesi Pebralia^{1*}

¹*Prodi Fisika, Fakultas Sains Dan Teknologi, Universitas Jambi*

Email: jesipebralia@unja.ac.id

*Corresponding Author

Abstrak

Radiasi matahari merupakan energi alternatif berbentuk panas dari gelombang elektromagnetik yang terdiri dari medan listrik dan magnet. Pemanfaatan energi matahari untuk dikonversi menjadi energi listrik dapat dilakukan melalui panel surya dengan mekanisme efek fotovoltaiik. Penelitian ini bertujuan menganalisis pengaruh intensitas radiasi matahari terhadap efisiensi panel surya menggunakan algoritma *Support Vector Regression* (SVR) dan *Naïve Bayes*. Metode penelitian yang digunakan yaitu metode komputasi dengan teknik *machine learning*. Adapun algoritma yang digunakan yaitu algoritma *Support Vector Regression* dan *Naïve Bayes*. Data yang digunakan berasal dari Badan Meteorologi, Klimatologi, Geofisika (BMKG) Provinsi Jambi. Kinerja setiap model kemudian dievaluasi menggunakan metrik akurasi untuk menentukan perbandingan akurasinya. Hasil penelitian menunjukkan adanya hubungan yang sangat kuat dan positif antara intensitas radiasi matahari dan efisiensi panel surya sebesar 97%. Berdasarkan hasil penelitian, algoritma *Naïve Bayes* mencapai akurasi 96,71%, yang menunjukkan model mampu dalam menangkap hubungan antara intensitas radiasi dan efisiensi panel. Sementara itu, algoritma *Support Vector Regression* memperoleh akurasi sebesar 80,00%.

Kata kunci: Efisiensi Panel Surya, Intensitas Radiasi Matahari, *Machine Learning*, *Naïve Bayes*, *Support Vector Regression* (SVR)

Abstract

Solar radiation is an alternative energy in the form of heat from electromagnetic waves consisting of electric and magnetic fields. The utilization of solar energy to be converted into electrical energy can be done through solar panels with the photovoltaic effect mechanism. This research aims to analyze the effect of solar radiation intensity on solar panel efficiency using the Support Vector Regression (SVR) and Naïve Bayes algorithms. The research method used is a computational method with Machine Learning techniques. The algorithms used are the Support Vector Regression algorithm and Naïve Bayes. The data used comes from the Jambi Province Meteorology, Climatology, Geophysics (BMKG) Agency. The performance of each model was then evaluated using accuracy metrics to determine the accuracy comparison. The results showed a very strong and positive relationship between solar radiation intensity and solar panel efficiency by 97%. Based on the results, the Naïve Bayes algorithm achieved an accuracy of 96.71%, which shows the model is capable in capturing the relationship between radiation intensity and panel efficiency. Meanwhile, the Support Vector Regression algorithm obtained an accuracy of 80.00 %.

Keywords: *Machine Learning, Naïve Bayes, Solar Panel Efficiency, Solar Radiation Intensity, Support Vector Regression (SVR)*

1. PENDAHULUAN

Energi matahari yang mencapai permukaan bumi akan kembali dipancarkan ke luar angkasa. Sekitar 30% dari energi ini dipantulkan oleh permukaan bumi dan atmosfer, dimana nilai albedo atau pantulan bumi dan atmosfer sekitar 30%. Sebagian lainnya, yaitu 19%, diserap oleh atmosfer dan awan, sementara itu 51% terserap oleh permukaan bumi [1]. Sebagian besar panas yang dihasilkan oleh radiasi matahari terperangkap di atmosfer, dengan hanya sebagian kecil yang berhasil keluar kembali ke angkasa, sehingga teknologi seperti panel surya menjadi solusi penting dalam pemanfaatan energi matahari secara lebih efisien [2]. Indonesia memiliki potensi energi surya yang cukup besar karena berada di garis khatulistiwa. Menurut Peraturan Presiden Nomor 05 Tahun 2006, pemerintah merencanakan strategi energi nasional untuk menentukan bauran energi pada tahun 2025 [3].

Energi matahari adalah sumber energi yang tidak akan habis dan dapat dimanfaatkan sebagai energi alternatif yang diubah menjadi listrik menggunakan sel surya. Sejak tahun 1970, sel surya atau *solar cell* telah mengubah pandangan kita tentang energi, menawarkan cara baru untuk mendapatkan listrik tanpa harus membakar bahan bakar fosil seperti minyak bumi, gas alam, atau batu bara, serta tanpa memerlukan reaksi nuklir [4]. Sel surya juga berfungsi dengan baik di hampir seluruh belahan dunia yang mendapat sinar matahari dan prosesnya tidak menghasilkan polusi yang dapat merusak lingkungan sehingga lebih ramah lingkungan. Cara kerja sel surya melibatkan pemanfaatan teori cahaya sebagai partikel. Seperti yang diketahui cahaya memiliki dua sifat alamiah yaitu dapat bersifat sebagai gelombang dan sebagai partikel yang disebut foton [5]. Ketika panel surya menerima cahaya matahari, terjadi pelepasan elektron dari atom, yang menghasilkan aliran listrik. Sistem panel surya, atau fotovoltaik (PV), berfungsi untuk mengubah paparan cahaya matahari menjadi energi listrik. Semakin besar intensitas cahaya matahari yang diterima, semakin banyak energi listrik yang dapat dihasilkan. Sistem panel surya (PV) menggunakan daya listrik sebagai output dari proses konversi, yaitu proses mengubah energi cahaya matahari menjadi energi listrik melalui sel surya [6].

Pentingnya analisis efisiensi panel surya berdasarkan nilai intensitas radiasi matahari langsung, global, dan pantul ini terlihat dari beberapa aspek kehidupan yang sering ditemui, yaitu kebutuhan akan energi listrik yang semakin meningkat. Dengan meningkatnya efisiensi panel surya, biaya listrik dapat ditekan, dan akses terhadap energi terbarukan menjadi lebih luas dan merata. Hal ini tidak hanya berdampak secara ekonomi, tetapi juga mendukung transisi menuju sistem energi yang berkelanjutan.

Beralih ke energi bersih merupakan langkah strategis untuk mengurangi emisi gas rumah kaca yang menjadi penyebab utama perubahan iklim. Energi bersih seperti tenaga surya dapat membantu menurunkan ketergantungan pada bahan bakar fosil, serta memperbaiki kualitas udara. Kualitas udara yang baik sangat penting bagi kesehatan masyarakat, terutama di wilayah perkotaan yang padat. Dengan demikian, pemanfaatan

energi bersih membawa manfaat tidak hanya bagi lingkungan, tetapi juga bagi kesejahteraan manusia.

Upaya kemajuan teknologi dan metode analisis data modern, seperti *Machine Learning*, memberikan solusi yang lebih efektif dan akurat untuk memprediksi efisiensi panel surya berdasarkan berbagai variabel. Algoritma *Machine Learning* mampu mempelajari pola dari data sebelumnya dan memberikan prediksi yang lebih tepat dibandingkan metode tradisional [7]. *Machine Learning* digunakan untuk mengajarkan mesin agar dapat menangani data dengan lebih efisien, Namun seringkali kita kesulitan untuk menafsirkan informasi yang diambil dari data tersebut. Dalam situasi seperti ini, penerapan pembelajaran mesin menjadi solusi [8]. Kecerdasan buatan (AI), khususnya pembelajaran mesin (*Machine Learning*) telah berkembang pesat dalam beberapa tahun terakhir dalam konteks analisis data dan komputasi yang biasanya memungkinkan aplikasi berfungsi secara cerdas [9].

Secara umum, teknik *Machine Learning* dapat digunakan untuk melakukan klasifikasi dan prediksi. Dalam penelitian Ananda *et al.* (2024), algoritma SVM mampu mengklasifikasikan tumor otak dengan akurasi 90% [10]. Pebralia (2022) menggunakan regresi linier berganda untuk memprediksi curah hujan dan memperoleh nilai MAE 2.27, MSE 14.02, dan RMSE 3.74 [11]. Sementara itu, Amanda & Pebralia (2024) menunjukkan bahwa algoritma *Random Forest* dapat memprediksi kandungan hara tanah dengan sangat baik, mencapai akurasi 99.85% dan MAE 0.15% [12].

Pada penelitian sebelumnya yang dilakukan oleh Nurvita *et al* (2017) menggunakan algoritma *Support Vector Regression* yakni peramalan *irradiance* cahaya matahari pada sel surya dengan metode *Support Vector Regression* (SVR). Hasil yang ditunjukkan nilai hasil evaluasi menunjukkan nilai RMSE sebesar 243,675 dan %RMSE mencapai 182% pada data pelatihan, serta RMSE sebesar 203,791% dan %RMSE sebesar 189% pada data pengujian [13]. Selanjutnya pada penelitian oleh Kwon dan Kwasinski (2019) mengenai prediksi *irradiance* matahari menggunakan *Naïve Bayes* menghasilkan korelasi sebesar 86,33% [14]. Selain itu juga penelitian ninuk *et al* (2019) dengan menggunakan algoritma *Naïve Bayes* menunjukkan nilai akurasi sebesar 83% [15].

Pada dasarnya telah banyak penelitian yang telah membuktikan keberhasilan algoritma *Machine Learning* dalam menganalisis hubungan antara intensitas radiasi matahari dan efisiensi panel surya, akan tetapi masih terdapat beberapa parameter yang belum banyak dianalisis. Pertama, sebagian besar studi sebelumnya hanya mengkaji satu jenis radiasi matahari, seperti radiasi global, tanpa melibatkan jenis radiasi lainnya seperti radiasi difusi dan pantul secara bersamaan. Kedua, perbandingan langsung antara algoritma klasifikasi seperti *Naïve Bayes* dan algoritma regresi seperti *Support Vector Regression* (SVR) dalam konteks prediksi efisiensi panel surya belum pernah dilakukan. Berdasarkan hal tersebut, penelitian ini menjadi penting dilakukan untuk mengevaluasi dan membandingkan performa algoritma *Naïve Bayes* dan *Support Vector Regression*.

Penelitian ini secara khusus memilih algoritma *Naïve Bayes* dan *Support Vector Regression* (SVR) karena keduanya merepresentasikan dua pendekatan yang berbeda namun populer dalam *Machine Learning*. *Naïve Bayes* dipilih karena kesederhanaannya, efisiensi komputasi yang tinggi, serta kemampuannya dalam menangani data berdimensi tinggi dan

memberikan hasil klasifikasi yang baik meskipun dengan asumsi yang sederhana. Sementara itu, *Support Vector Regression* dipilih karena dikenal memiliki performa unggul dalam masalah regresi nonlinier, dengan kemampuan mengatasi hubungan kompleks antara input dan output, terutama dalam prediksi numerik seperti efisiensi panel surya. Penggunaan dua pendekatan algoritma dan tiga parameter radiasi matahari diharapkan mampu meningkatkan akurasi prediksi efisiensi panel surya di lingkungan tropis secara akurat.

2. METODE PENELITIAN

2.1 Peralatan Dan Bahan

Bahan penelitian ini mencakup variabel utama yang berkaitan dengan intensitas radiasi matahari, yaitu intensitas radiasi matahari difusi, intensitas radiasi matahari pantul, dan intensitas radiasi matahari global. Alat untuk pengolahan dan analisis data, penelitian ini menggunakan PC sebagai perangkat keras utama, dengan sistem operasi *Windows* dan perangkat lunak MATLAB untuk pemodelan *machine learning*. Instrumen pengukuran meliputi *Automatic Solar Radiation Station* (ASRS) untuk mengukur intensitas radiasi matahari. Analisis *Machine Learning* dilakukan menggunakan *Statistics and Machine Learning Toolbox* untuk mengevaluasi algoritma seperti yaitu *Support Vector Regression* (SVR) dan *Naïve Bayes*.

2.2 Objek Dan Variabel Penelitian

Objek penelitian ini adalah data radiasi matahari yang diperoleh dari *Automatic solar radiation station* (ASRS) yaitu meliputi *diffusion radiation*, *global radiation*, *reflected radiation* yang terletak di BMKG-Stasiun Klimatologi Jambi. Penelitian ini memiliki dua jenis variabel, yaitu variabel independen dan variabel dependen. Variabel independen atau variabel bebas dalam penelitian ini adalah nilai intensitas radiasi matahari yang diukur dalam satuan watt per meter persegi (W/m^2), Variabel-variabel ini berperan sebagai faktor-faktor yang memengaruhi performa panel surya. Sementara itu, variabel dependen atau variabel terikat adalah efisiensi panel surya, yang menggambarkan seberapa efektif panel surya mengubah radiasi matahari menjadi energi listrik.

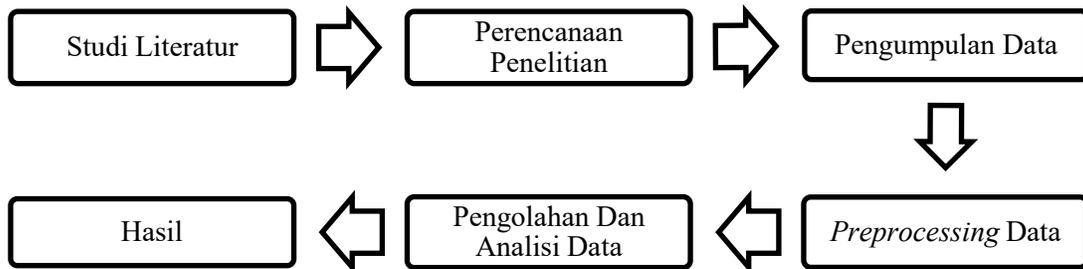
2.3 Metode Numerik

Metode numerik yang digunakan dalam penelitian ini meliputi *Support Vector Regression* (SVR) dan *Naïve Bayes*. SVR diimplementasikan menggunakan fungsi *fitrsvm* dengan kernel *radial basis function* (RBF), yang dikenal efektif dalam menangani masalah regresi nonlinier. SVR bekerja dengan mencari *hyperplane* optimal yang meminimalkan kesalahan prediksi dalam batas toleransi tertentu (*epsilon*), sekaligus menjaga margin maksimum terhadap data pelatihan. Pemilihan kernel RBF dilakukan karena kemampuannya dalam menangani data berdimensi tinggi dan pola yang kompleks, yaitu hubungan antara intensitas radiasi matahari dan efisiensi panel surya. *Support Vector Regression* digunakan untuk memprediksi nilai efisiensi panel surya secara kontinu berdasarkan nilai-nilai radiasi matahari yang diperoleh dari data historis.

2.4 Prosedur Penelitian

Penelitian ini dilakukan melalui beberapa tahap untuk menganalisis performa algoritma *Machine Learning* dalam memprediksi efisiensi panel surya berdasarkan intensitas radiasi matahari. Tahap awal dimulai dengan studi literatur untuk memahami konsep dasar, algoritma yang relevan, serta pemahaman tentang alat *automatic solar radiation station* (ASRS). Selanjutnya, perancangan penelitian dilakukan dengan menentukan algoritma yang akan digunakan, yaitu *Support Vector Regression* (SVR), *Naïve Bayes*, serta pemilihan parameter dan data yang dibutuhkan. Data dikumpulkan dari ASRS, lalu dibagi menjadi data latih (80%) dan data uji (20%) untuk membangun dan menguji model prediksi. Setelah itu, dilakukan *pre-processing* data yaitu normalisasi menggunakan metode Min-Max untuk meningkatkan akurasi model.

Data yang telah diproses kemudian diolah menggunakan algoritma yang telah ditentukan, dan hasil prediksi dari model diuji menggunakan metrik evaluasi seperti *mean absolute error* (MAE), *mean Squared error* (MSE), *Root mean squared error* (RMSE), dan *R-squared* (R^2). Evaluasi ini penting untuk melihat keakuratan dan efektivitas masing-masing algoritma dalam menangani data baru. Tahap akhir dari penelitian ini adalah menarik kesimpulan dari hasil evaluasi dan memberikan rekomendasi terkait algoritma yang paling efektif untuk prediksi efisiensi panel surya berdasarkan data intensitas radiasi matahari.



Gambar 1. Diagram alir penelitian

2.5 Teknik Pengolahan Dan Analisis Data

Teknik pengumpulan data dalam penelitian ini dilakukan dengan memanfaatkan data yang diperoleh langsung dari *Automatic Solar Radiation Station* (ASRS). Proses analisis data dalam penelitian ini diawali dengan perhitungan efisiensi panel surya setiap 10 menit menggunakan rasio antara daya listrik yang dihasilkan dengan daya radiasi matahari yang diterima oleh panel. Perhitungan ini dilakukan untuk memperoleh gambaran perubahan efisiensi panel surya dalam berbagai kondisi radiasi matahari sepanjang hari. Menurut Rahmat (2021) [16]. Berikut persamaan yang digunakan untuk menghitung efisiensi panel surya.

$$P_{in} = J \times A \quad (1)$$

$$P_{out} = V_{oc} \times I_{sc} \times FF \quad (2)$$

$$\eta = \frac{P_{in}}{P_{out}} \times 100 \% \quad (3)$$

Dimana J adalah intensitas radiasi matahari (W/m^2), A adalah luas panel (m^2) dan η adalah efisiensi panel surya V_{oc} , I_{sc} , FF adalah didapatkan dari spesifikasi modul panel surya yang digunakan. Data diproses menggunakan MATLAB, diawali dengan *preprocessing* data untuk membersihkan dan menyiapkan dataset sebelum dianalisis lebih lanjut. Setelah tahap *preprocessing*, dilakukan analisis regresi guna mengidentifikasi hubungan antara variabel bebas intensitas radiasi matahari dengan variabel terikat efisiensi panel surya. Hasil regresi ini memberikan gambaran awal mengenai pola hubungan antara variabel-variabel dalam model. Menurut Gusmaliza (2025) adalah pembagian data menjadi 80% untuk *training* dan 20% untuk *testing*, yang bertujuan untuk melatih model secara optimal sebelum diuji pada data baru [17]. Setelah model dilatih dan diuji, dilakukan evaluasi kinerja menggunakan metrik RMSE (*Root Mean Square Error*), MAE (*Mean Absolute Error*), MSE (*Mean Squared Error*), serta akurasi dari masing-masing algoritma yang digunakan. Evaluasi ini bertujuan untuk menentukan model *Machine Learning* yang paling efektif dalam memprediksi efisiensi panel surya berdasarkan intensitas radiasi matahari. Perbandingan model dievaluasi berdasarkan nilai MSE, RMSE, MAE dan R^2 Score. Di mana nilai RMSE terendah dan R^2 Score yang tinggi dapat dipilih sebagai model prediksi dalam penelitian ini. Berikut adalah rumus MSE, RMSE, MAE dan R^2 (Hamdanah dan Fitriah, 2023) [18].

$$MSE = \frac{1}{n} \sum_{i=1}^m (X_i - Y_i)^2 \quad (4)$$

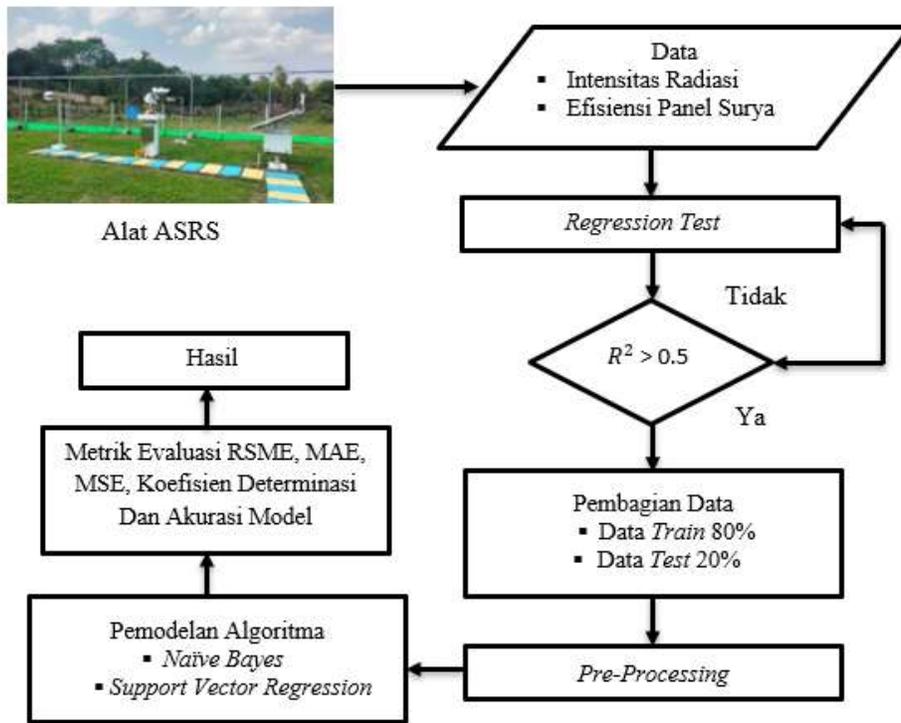
$$RMSE = \sqrt{\frac{1}{2} \sum_{i=1}^m (X_i - Y_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=m}^m |X_i - Y_i| \quad (6)$$

$$R^2 = \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (7)$$

$$\text{Akurasi} = (1 - MAE) \times 100\% \quad (8)$$

dimana y_i adalah nilai aktual, \hat{y}_i adalah nilai prediksi, dan \bar{y}_i adalah rata-rata dari nilai aktual. Nilai R^2 ini digunakan untuk mengukur seberapa baik model menjelaskan variasi dalam data. Untuk mengevaluasi kinerja model, beberapa metrik digunakan, termasuk *mean absolute error* (MAE), *mean squared error* (MSE), *root mean squared error* (RMSE), *coefficient of determination* (R^2). MAE mengukur rata-rata selisih absolut antara nilai aktual dan prediksi. MSE menghitung rata-rata kuadrat dari selisih tersebut. RMSE adalah akar dari MSE, sehingga lebih mudah diinterpretasikan. Nilai MAE, MSE, dan RMSE yang kecil menunjukkan model yang baik. R^2 mengukur seberapa besar variasi data yang dapat dijelaskan oleh model. Nilai R^2 mendekati 1 menandakan model yang sangat baik. Jika R^2 mendekati 0, model kurang mampu menjelaskan data. Metrik ini saling melengkapi dalam menilai performa model. Penggunaan berbagai metrik ini penting karena masing-masing memberikan sudut pandang yang berbeda terhadap kinerja model. Dalam praktiknya, pemilihan metrik evaluasi bergantung pada konteks dan tujuan dari analisis data yang dilakukan.



Gambar 2. Diagram alir teknik analisis dan pengolahan data

2.6 Analisis Dan Evaluasi Peforma

Analisis dilakukan dengan menggunakan metrik performa yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Coefficient of Determination* (R^2), dihitung berdasarkan pada persamaan (4), (5), (6), (7) dan (8). Pemilihan metrik ini bertujuan untuk melihat seberapa besar kesalahan prediksi dan seberapa baik kualitas model. MAE mengukur rata-rata selisih antara nilai prediksi dan aktual, sedangkan MSE dan RMSE lebih menekankan kesalahan besar. R^2 menunjukkan seberapa baik input dapat menjelaskan hasil prediksi secara keseluruhan. Selanjutnya, model di klasifikasi berdasarkan nilai-nilai metrik tersebut memberikan tolok ukur objektif dalam mengevaluasi dan membandingkan algoritma yang digunakan. Sebagaimana menurut Sang et al (2021), untuk klasifikasi performa berdasarkan nilai akurasi ditampilkan pada tabel 1.

Tabel 1. Klasifikasi peforma berdasarkan nilai akurasi [19]

Rentang Nilai	Akurasi
90% -100%	Sangat Baik
80% -90 %	Baik
70 % - 80%	Cukup
60% -70%	Buruk
< = 60%	Sangat Buruk

3. HASIL DAN PEMBAHASAN

3.1 *Preprocessing Dan Pembagian Data*

Tahap persiapan dalam penelitian ini adalah persiapan data (*preprocessing data*), yang bertujuan untuk memastikan data dalam kondisi bersih dan siap digunakan dalam analisis *Machine Learning*. Proses ini mencakup penghapusan nilai yang hilang, normalisasi untuk menyelaraskan skala variabel. Metode normalisasi dilakukan menggunakan metode *Min-Max Normalization*, yang bertujuan untuk menghindari bias akibat perbedaan skala pada setiap fitur dalam dataset. Selanjutnya adalah pembagian data, tujuan utama dari pembagian ini adalah untuk memastikan bahwa model tidak hanya bekerja dengan baik pada data latihannya, tetapi juga mampu memberikan hasil prediksi yang akurat saat dihadapkan pada data baru (uji).

Tabel 2. Sampel data untuk 5 baris data pertama normalisasi

Tanggal/Waktu	Intensitas Rad_Difusi	Intensitas Rad_Global	Intensitas Rad_Pantul	Efisiensi Panel Surya
	W/m ²	W/m ²	W/m ²	%
2021-Jan-01 06:00	0.0047998	0.0031304	0.0020031	0.068424
2021-Jan-01 06:10	0.011071	0.0066405	0.0003947	0.10478
2021-Jan-01 06:20	0.020415	0.011583	0.0068211	0.13078
2021-Jan-01 06:30	0.030398	0.017672	0.0096952	0.21073
2021-Jan-01 06:40	0.049853	0.028632	0.015252	0.03854

Mengacu pada penelitian yang dilakukan oleh Gusmaliza (2025) menunjukkan bahwa pembagian data sebesar 80% untuk data latih dan 20% untuk data uji mampu menghasilkan performa evaluasi yang sangat baik. Model yang dibangun mampu mencapai akurasi sangat baik. Sehingga pada penelitian ini penulis membagi data sebesar 80% untuk data latih dan 20% untuk data uji. Proses pelatihan dan pengujian dilakukan secara terpisah untuk menjaga keakuratan evaluasi. Hasil dari pembagian data ini kemudian dianalisis menggunakan metrik performa yang telah dijelaskan sebelumnya. Oleh karena itu, pembagian ini diharapkan dapat menghasilkan evaluasi yang akurat dan relevan terhadap performa model yang digunakan. Hasil evaluasi menunjukkan bahwa pembagian data ini efektif dalam menguji kemampuan generalisasi model terhadap data baru.

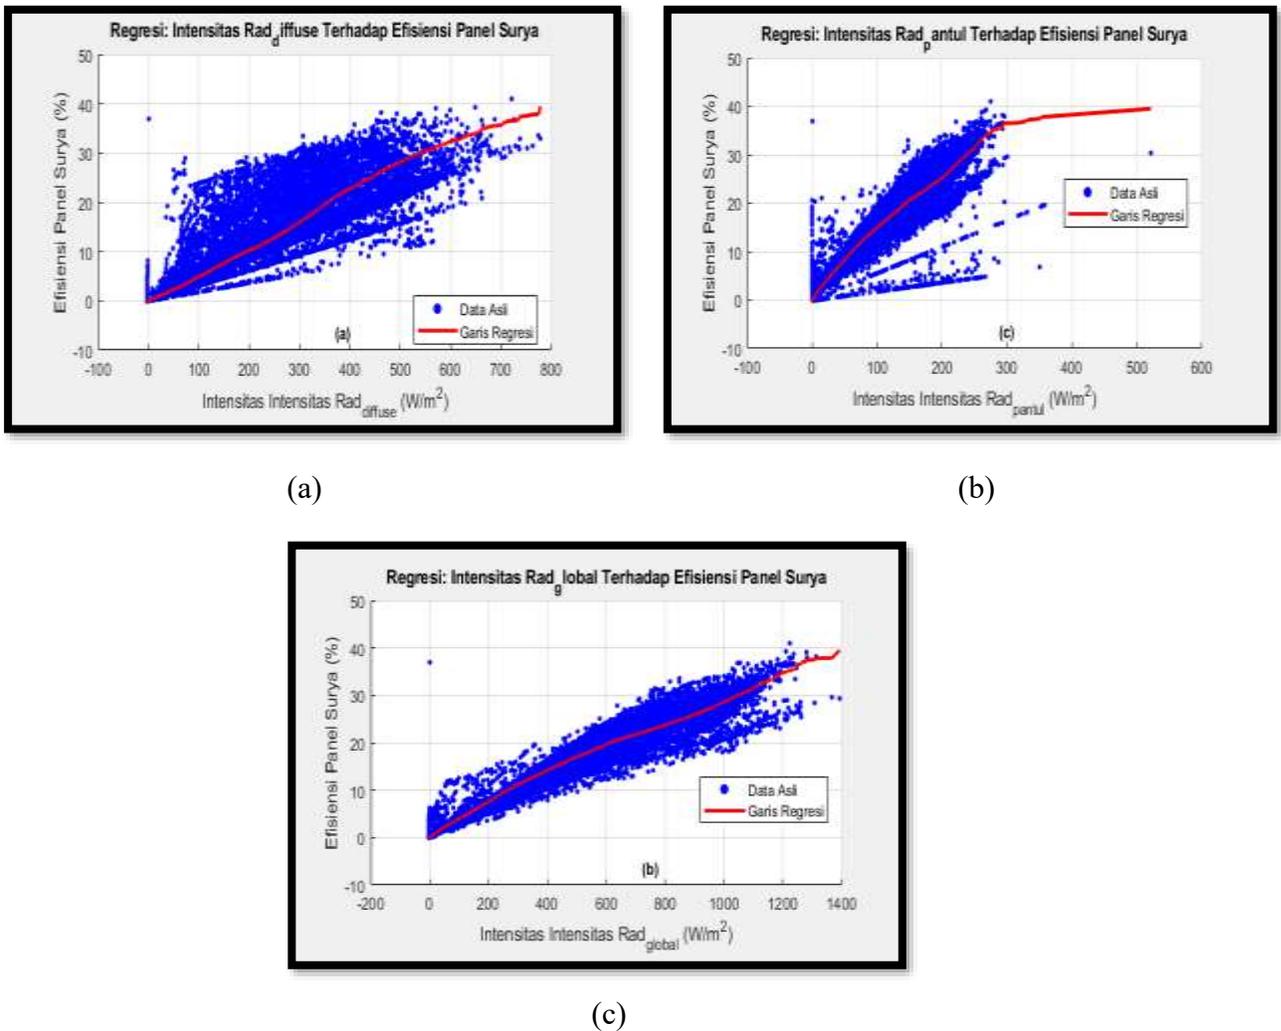
3.2 *Regression Test*

Uji regresi dilakukan dengan menggunakan variabel independen yaitu Intensitas radiasi *diffuse* (X_1), Intensitas radiasi global (X_2), dan Intensitas radiasi pantul (X_3), sedangkan variabel dependennya adalah efisiensi panel surya (Y). Metode regresi linear

dipilih karena mampu menggambarkan hubungan linier antar variabel dan menghitung pada masing-masing variabel terhadap perubahan nilai efisiensi panel surya. Berdasarkan hasil pengolahan data, diperoleh model regresi linear sebagai berikut:

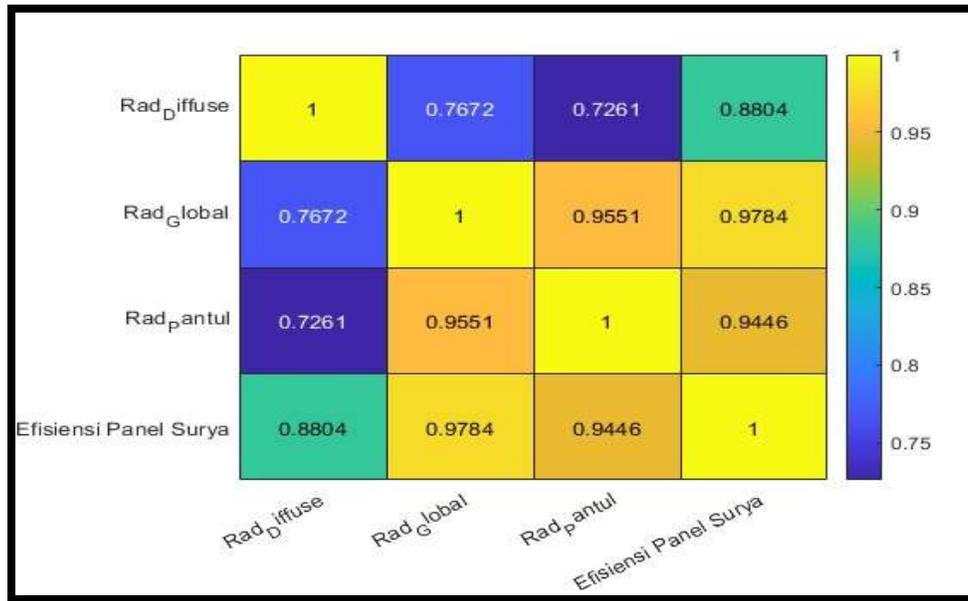
$$Y = 0.0022 + 0.0185X_1 + 0.0185X_2 + 0.0185X_3 \quad (9)$$

Pada persamaan (8) regresi linear yang diperoleh, nilai *intercept* sebesar 0.0022 menggambarkan efisiensi awal panel surya saat seluruh variabel independen bernilai nol. Koefisien X_1 , X_2 , dan X_3 masing-masing sebesar 0.0185 menunjukkan bahwa setiap peningkatan satu satuan pada intensitas radiasi *diffuse*, intensitas radiasi global, dan intensitas radiasi pantul akan meningkatkan efisiensi panel surya sebesar 0.0185, dengan asumsi variabel lainnya tetap. Berikut ini ditampilkan hasil grafik dari persamaan regresi linier:



Gambar 3. Grafik persamaan regresi linier: (a). Regresi intensitas radiasi *diffuse*, (b). Regresi intensitas radiasi pantul, (c). Regresi intensitas radiasi global

Pada gambar 3, dimana grafik tersebut menunjukkan hubungan matematis antara intensitas radiasi matahari (*diffuse*, global, dan pantul) dengan efisiensi panel surya berdasarkan analisis regresi linear. Sumbu x menunjukkan intensitas radiasi, dan sumbu y menunjukkan efisiensi panel surya. Garis pada grafik menggambarkan hubungan linear yang jelas antara perubahan intensitas radiasi dan efisiensi panel surya sesuai persamaan liner yang ditunjukkan pada persamaan (8). Selanjutnya juga didapatkan hasil *heatmap* korelasi antara Intesitas radiasi matahari terhadap efisieinsi panel surya.



Gambar 4. *Heatmap* korelasi antara intensitas radiasi matahari terhadap efesiensi panel surya

Heatmap korelasi diatas menunjukkan korelasi antara intensitas radiasi matahari dan efisiensi panel surya, dengan nilai berkisar antara 0 hingga 1. Intensitas radiasi global memiliki korelasi tertinggi terhadap efisiensi panel surya yaitu 0.9784, diikuti intensitas radiasi pantul (0.9446), dan intensitas radiasi *diffuse* (0.8804). Korelasi antar variabel juga kuat, terutama antara radiasi global dan pantul (0.9551), menunjukkan bahwa ketiga jenis radiasi memiliki pengaruh signifikan terhadap efisiensi panel surya. Hasil korelasi juga menunjukan nilai yang kuat dan tinggi antara intensitas radiasi matahari terhadap efisiensi panel surya dengan nilai korelasi 0.9784 atau 97%.

3.2 Pemodelan Algoritma

Naïve Bayes

Model *Naïve Bayes* yang digunakan untuk mengklasifikasikan efisiensi panel surya berdasarkan intensitas radiasi matahari. Tujuannya adalah agar model dapat membedakan performa panel surya dalam kondisi yang berbeda. Model *Naïve Bayes* bekerja dengan menghitung probabilitas dari setiap kelas berdasarkan fitur yang diberikan. Model ini memiliki asumsi bahwa setiap variabel independen tidak saling bergantung satu sama lain, meskipun pada kenyataannya mungkin ada hubungan di antara variabel-variabel tersebut.

Setelah model dilatih, performanya dievaluasi menggunakan *confusion matrix*, yang menunjukkan seberapa sering model memprediksi kelas dengan benar dan seberapa sering melakukan kesalahan. Nilai akurasi dihitung untuk melihat sejauh mana model dapat mengklasifikasikan data dengan tepat. Selain itu, metrik tambahan seperti RMSE, MAE, dan R^2 juga dihitung untuk memahami sejauh mana prediksi model berbeda dari kenyataan. Berikut adalah hasil numerik matrik konfusi yang ditampilkan pada gambar 5.

Aktual	Rendah	1194	31	
	Sedang		1239	38
	Tinggi		56	1241
		Rendah	Sedang	Tinggi
		Prediksi		

Gambar 5. Model matrik konfusi algoritma *Naïve Bayes*

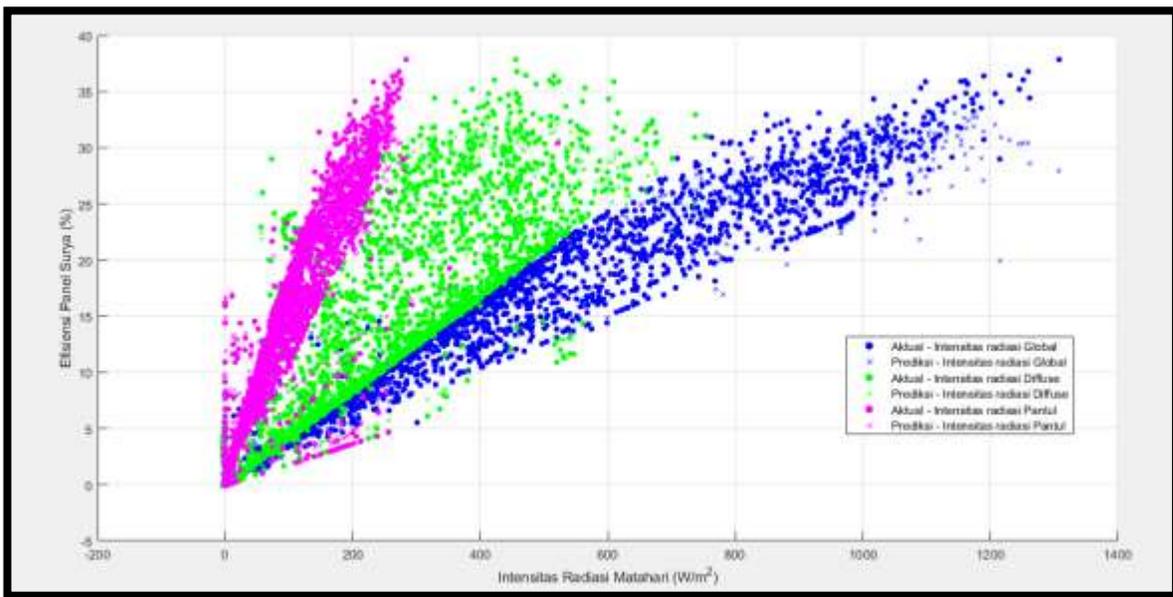
Berdasarkan matrik konfusi diatas, model *Naïve Bayes* menunjukkan kemampuan yang cukup baik dalam mengklasifikasikan efisiensi panel surya. Model berhasil mengklasifikasikan 1194 sampel ke kelas Rendah, 1239 ke kelas Sedang, dan 1241 ke kelas Tinggi. Kesalahan klasifikasi banyak terjadi antara kelas Sedang dan Tinggi, yakni 38 sampel Sedang diklasifikasikan sebagai Tinggi, 56 sampel Tinggi sebagai Sedang, serta 31 data kelas Rendah. Hal ini menunjukkan adanya tumpang tindih antara kelas Sedang dan Tinggi akibat kemiripan pola intensitas radiasi global dan difusi. Grafik yang ditampilkan merupakan hasil model *Naïve Bayes* yang menghitung probabilitas bersyarat berdasarkan teorema *bayes*.

Support Vector Regression

Model *Support Vector Regression* (SVR) pada penelitian ini digunakan untuk menganalisis hubungan antara intensitas radiasi matahari dan efisiensi panel surya. Tujuan penggunaan model ini adalah untuk membangun model prediksi yang mampu memperkirakan efisiensi panel surya berdasarkan intensitas radiasi matahari dengan akurasi tinggi, meskipun data yang digunakan memiliki karakteristik non-linear. Pemilihan kernel Gaussian dilakukan karena kernel ini mampu menangani hubungan yang kompleks dan tidak linier antara variabel input dan output. Pada penelitian ini efisiensi panel surya dipengaruhi oleh berbagai bentuk intensitas radiasi matahari yang tidak selalu memiliki hubungan linier,

sehingga pendekatan non-linear yaitu *Support Vector Regression* dengan kernel *gaussian* dianggap lebih sesuai.

Berdasarkan hasil grafik yang ditunjukkan pada gambar 6, dibawah ini, menunjukkan hubungan antara intensitas radiasi matahari (global, difusi, dan pantul) terhadap efisiensi panel surya, dengan membandingkan data aktual dan hasil prediksi model SVR. Titik-titik berwarna biru, hijau, dan magenta merepresentasikan data aktual untuk masing-masing jenis intensitas radiasi, sedangkan tanda silang menunjukkan hasil prediksi model. Secara umum, terlihat pola yang konsisten di mana efisiensi panel meningkat seiring bertambahnya intensitas radiasi, menunjukkan korelasi positif. Garis *hyperplane* dari SVR secara implisit direpresentasikan oleh sebaran titik prediksi yang mengikuti arah tren data aktual, menunjukkan bahwa model cukup berhasil memetakan hubungan intensitas radiasi matahari terhadap efisiensi panel. Ketidaksesuaian kecil antara titik aktual dan prediksi menunjukkan adanya *noise* atau variabilitas alami pada data, namun secara keseluruhan, model mampu memberikan estimasi yang baik.



Gambar 6. Hasil model algoritma SVR

Evaluasi Model Algoritma

Evaluasi dilakukan dengan mengukur beberapa metrik kinerja, yaitu *mean squared error* (MSE), *root mean square error* (RMSE), *mean absolute error* (MAE), koefisien determinasi (R^2), dan akurasi model. Hasil evaluasi ini menjadi dasar dalam menilai sejauh mana model dapat merepresentasikan hubungan antara variabel input dan output secara efektif. Kemudian dibandingkan model mana yang mampu menangkap pola dalam data dengan nilai akurasi paling tinggi dengan tingkat kesalahan yang lebih rendah. Sehingga didapatkan nilai evaluasi pada algoritma *Naïve Bayes* dan *Support Vector Regression* ditampilkan pada tabel 3.

Tabel 3. Hasil evaluasi model algoritma

Metode Evaluasi	SVR <i>Train</i>	SVR <i>Test</i>	<i>Naïve Bayes Train</i>	<i>Naïve Bayes Train</i>
RSME	0.78	0.70	0.20	0.03
MSE	0.61	0.49	0.40	0.18
MAE	0.19	0.20	0.04	0.03
R^2 (Koefisein Determinasi)	0.99	0.99	0.94	0.95
Akurasi	80 %	80 %	95.89 %	96.71 %

Berdasarkan hasil evaluasi pada tabel 7, model *Naïve Bayes* menunjukkan performa yang lebih baik dibandingkan *Support Vector Regression* (SVR). Hal ini terlihat dari nilai RMSE, MSE, dan MAE pada data uji yang jauh lebih rendah, masing-masing sebesar 0.03, 0.18, dan 0.03 untuk *Naïve Bayes*, dibandingkan 0.70, 0.49, dan 0.20 untuk *Support Vector Regression*. Selain itu, *Naïve Bayes* juga memiliki nilai akurasi yang lebih tinggi, yaitu 96.71%, dibandingkan dengan *Support Vector Regression* yang hanya mencapai 80%. Meskipun nilai koefisien determinasi (R^2), *Support Vector Regression* sangat tinggi (0.99), hal ini tidak diikuti oleh kesalahan prediksi yang rendah, yang menunjukkan kemungkinan *overfitting*. *Overfitting* adalah kondisi dalam pembelajaran mesin di mana suatu model terlalu menyesuaikan diri dengan data latih, sehingga kehilangan kemampuan untuk menangkap pola terhadap data baru (data uji). Sehingga dapat disimpulkan, *Naïve Bayes* dinilai lebih efektif dan andal dalam analisis intensitas radiasi matahari terhadap efisiensi panel surya ditunjukkan pada data uji yang memiliki *error* yang sangat rendah dan akurasi yang tinggi yaitu 96.71%

4. SIMPULAN

Model algoritma *Naïve Bayes* terbukti lebih efektif dan andal dibandingkan *Support Vector Regression* (SVR) dalam menganalisis pengaruh intensitas radiasi matahari terhadap efisiensi panel surya. Hal ini ditunjukkan oleh nilai akurasi *Naïve Bayes* yang tinggi yaitu 96,71% serta kesalahan prediksi (RMSE, MSE, MAE) yang jauh lebih rendah pada data uji dibandingkan SVR. Meskipun SVR memiliki nilai R^2 yang sangat tinggi, hal ini disertai dengan kesalahan prediksi yang besar, mengindikasikan potensi *overfitting*. Oleh karena itu, *Naïve Bayes* lebih direkomendasikan karena mampu memberikan hasil yang lebih stabil, akurat, dan general terhadap data baru. Analisis korelasi juga menunjukkan nilai yang kuat dan tinggi antara intensitas radiasi matahari terhadap efisiensi panel surya yaitu sebesar 97%. Hal ini menunjukkan bahwa intensitas radiasi matahari dan efisiensi panel surya memiliki nilai yang positif dan signifikan. Sehingga dapat disimpulkan bahwa semakin tinggi intensitas radiasi matahari yang diterima, maka efisiensi panel surya juga cenderung meningkat. Hasil ini memberikan dasar yang kuat dalam pemilihan variabel untuk model prediktif berbasis *Machine Learning*.

5. DAFTAR PUSTAKA

- [1] Mahdie, M. F., Rianawati, F., Nisa, K., & Fitriani, A. (2022). *Klimatologi Hutan*. Banjarbaru: CV Banyubening Cipta Sejahtera.
- [2] Alim, M. S., Thamrin, S., & Laksmono, R. W. (2023). Pemanfaatan Pembangkit Listrik Tenaga Surya sebagai Alternatif Ketahanan Energi Nasional Masa Depan. *Jurnal Pengabdian kepada Masyarakat Nusantara (JPkMN)*, 4(3), e-ISSN: 2745-4053. Doi: <https://doi.org/10.55338/jpkmn.v4i2.1480>
- [3] Kharisma, A., Pinandita, S., & Jayanti, A. E. (2024). Literature Review: Kajian Potensi Energi Surya Alternatif Energi Listrik. *Jurnal Energi Baru dan Terbarukan*, 5(2), e-ISSN:145-154. <https://doi.org/10.14710/jebt.2024.23956>
- [4] Jacobus, L., Setyowati, E., Patty, E. N. S., & Bokol, F. (2023). Desain Sistem Pompa Air Tenaga Surya. *Elektriase: Jurnal Sains dan Teknologi Elektro*, 13(1), e-ISSN: 2830-3512X. Doi: <https://doi.org/10.47709/elektriase.v13i1.2283>
- [5] Putra, D. A. M., Paradita, Y., Ridwang, & Adriani. (2024). Pengembangan Prototype Sistem Pengusir Hama Menggunakan Smart Panel Surya, Lampu UV dan Gelombang Ultrasonik Pada Perkebunan. *Vertex: Jurnal Ilmiah Teknik Elektro, Teknik Informatika, dan Sistem Informasi*, 16(2), e-ISSN: 2714-7487. Doi: <https://journal.unismuh.ac.id/index.php/vertex/article/view/15707>
- [6] Saputra, S., Widyastuti, E. A., Riantiarna, R., & Kurniawati, W. (2024). Efektivitas Panel Surya Sebagai Cadangan Pengganti Energi Listrik Skala Rumahan. *TEKTONIK: Jurnal Ilmu Teknik*, 1(2), 256–260, e-ISSN: 3026-4103. <https://doi.org/10.62017/tektionik>.
- [7] Rio, A. R., Siahaan, B. M., & Gani, E. (2024). Pemetaan Potensi Energi Matahari di Sulawesi Utara menggunakan *Machine Learning K-Means*. *Jurnal MIPA*, 14(2), 1–5. Doi: <https://doi.org/10.35799/jm.v14i2.57778>.
- [8] Heryadi, Yaya, and Teguh Wahyono. (2024). *Machine Learning: Konsep dan Implementasi*. Yogyakarta: Universitas Teknologi Yogyakarta.
- [9] Alief, R., & Nurmiati, E. (2022). Penerapan Kecerdasan Buatan Dan Teknologi Informasi Pada Efisiensi Manajemen Pengetahuan. *Jurnal Masyarakat Informatika*, 13(1), e-ISSN: 2777-0648. Doi: <https://journal.ildikti4.id/index.php/jmi/article/view/43760>.
- [10] Ananda, J. S., Fendriani, Y., & Pebralia, J. (2024). Classification Analysis of Brain Tumor Disease in Radiographic Images Using Support Vector Machines (SVM) with Python. *Jurnal JoP*, 9(3), 110–115. ISSN: 2502-2016. <https://doi.org/10.22437/jop.v9i3.36270>
- [11] Pebralia, J. (2022). Analisis Curah Hujan Menggunakan Machine Learning Metode Regresi Linier Berganda Berbasis Python dan Jupyter Notebook. *Jurnal Ilmu Fisika dan Pembelajarannya*, 6(2), 23–30. ISSN: 2549-6158. <http://jurnal.radenfatah.ac.id/index.php/jifp/article/view/15883>
- [12] Amanda, D. R., Samsidar, & Pebralia, J. (2024). Analysis of Machine Learning Algorithm Performance in Predicting Ultisol Soil Nutrients Based on Impedance Values. *Jurnal JoP*, 9(2), 94–101. ISSN: 2502-2016.
- [13] Arumsari, N., & Pamuji, F. A. (2017). Peramalan Irradiance Cahaya Matahari pada Sel Surya untuk Memenuhi Kebutuhan Energi Listrik dengan Metode *Support Vector*

- Regression (SVR). Jurnal Nasional Teknik Elektro*, 6(1), e-ISSN: 2302-2949. Doi: <https://doi.org/10.20449/jnte.v6i1.367>.
- [14] Kwon, Y., Kwasinski, A., & Kwasinski, A. (2019). Solar Irradiance Forecast Using *Naïve Bayes* Classifier Based on Publicly Available Weather Forecasting Variables. *Jurnal Energi*, 12(8), 1529. e-ISSN: 1996-1073. <https://doi.org/10.3390/en12081529>.
- [15] Raza, M. Q., Aslam, M., Ahmad, S., & Nawaz, M. (2016). Energy analysis of photovoltaic thermal (PVT) system and calculation of convection heat losses. *Renewable and Sustainable Energy Reviews*, 59(1), 1310–1321. ISSN: 1364-0321. <https://doi.org/10.1016/j.rser.2016.01.066>
- [16] Hasrul, Rahmat. (2021). Analisis Efisiensi Panel Surya Sebagai Energi Alternatif. SainETIn: *Jurnal Sains, Energi, Teknologi, dan Industri*, 5(2), 79-87. ISSN: 2548-6888 DOI:10.23917/emitor.v18i01.6251.
- [17] Evita Fitri. (2023). Analisis Perbandingan Metode Regresi Linier, Random Forest Regression dan Gradient Boosted Trees Regression Method untuk Prediksi Harga Rumah. *Journal of Applied Computer Science and Technology (JACOST)*, 4(1), ISSN: 2723-1453. <https://doi.org/10.52158/jacost.491>.
- [18] Hamdanah, F. H., & Fitriyah, D. (2021). Analisis Performansi Algoritma Linear Regression dengan Generalized Linear Model untuk Prediksi Penjualan pada Usaha Mikro, Kecil, dan Menengah. *Jurnal Nasional Pendidikan Teknik Informatika: JANAPATI*, 10(1), 23-32. DOI: <https://doi.org/10.23887/janapati.v10i1.31035>
- [19] Adinda Inez Sang, Edi Sutoyo, & Irfan Darmawan. (2021). Analisis Data Mining untuk Klasifikasi Data Kualitas Udara DKI Jakarta Menggunakan Algoritma Decision Tree dan Support Vector Machine. *e-Proceeding of Engineering*, 8(5), ISSN: 2355-9365. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/15900>