

Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi)

DOI: <https://doi.org/10.35870/jtik.v9i3.3480>

Prediksi Potensi Suatu Wilayah Menggunakan *Machine Learning*

Tarwoto ¹, Ratri Ismayanti ², Vita Dwi Utami ³, Vellyn Chalista Elfanza ^{4*}

^{1,2,3,4*} Program Studi Sistem Komputer, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto, Kabupaten Banyumas, Provinsi Jawa Tengah, Indonesia.

article info

Article history:

Received 10 December 2024

Received in revised form

20 December 2024

Accepted 15 January 2025

Available online Juli 2025.

Keywords:

Linier Regression; Lasso Regression; Ridge Regression; Support Vector Regression.

Kata Kunci:

Regresi Linier; Regresi Lasso; Regresi Ridge; Regresi Vektor Pendukung.

abstract

Electricity has become a basic need for some human beings because all activities are almost related to electricity. Indonesia has several power plant projects and the largest power plant is generated from PLTU which can have an impact that we feel is greenhouse gas emissions and bad air pollution and also relies heavily on coal while the natural resources are not renewable with this fact if we reduce the use of coal it will be a boomerang for Indonesia itself. This research aims to predict areas that can potentially become Solar Power Plants with a machine learning regression model approach. So hopefully this research can be a reference in the development of Solar Power Plants in Indonesia. The methods used are Linear Regression (LR), Lasso Regression (LR), Ridge Regression (RR), and Support Vector Regression (SVR). The R2 coefficients for solar radiation were 0.924; 0.910; 0.917; 0.949; and 0.987, respectively.

abstrak

Listrik sudah menjadi kebutuhan pokok sebagian umat manusia karena semua aktivitas hampir berhubungan dengan listrik. Indonesia memiliki beberapa proyek Pembangkit Listrik dan Pembangkit Listrik yang terbesar dihasilkan dari PLTU yang mana bisa dampak yang kita rasakan adalah emisi gas rumah kaca dan polusi udara yang buruk dan juga sangat bergantung pada batu bara sedangkan SDA tersebut tidak bisa diperbarui dengan fakta tersebut jika kita mengurangi penggunaan batu bara maka akan menjadi boomerang bagi Indonesia sendiri. Penelitian ini bertujuan untuk memprediksi wilayah yang dapat berpotensi menjadi Pemangkit Listrik Tenaga Surya dengan pendekatan model regresi machine learning. Sehingga diharapkan penelitian ini bisa menjadi acuan dalam pengembangan Pembangkit Listrik Tenaga Surya di Indonesia. Metode yang digunakan adalah Linier Regression (LR), Lasso Regression (LR), Ridge Regression (RR), dan Support Vector Regression (SVR). Koefisien R2 untuk radiasi sinar matahari berturut-turut adalah 0.924; 0.910; 0.917; 0.949; dan 0.987.

Corresponding Author. Email: vellynchalista630@gmail.com ^{4}.

Copyright 2025 by the authors of this article. Published by Lembaga Otonom Lembaga Informasi dan Riset Indonesia (KITA INFO dan RISET). This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License. 



ACM Computing Classification System (CCS)

EBSCOhost

Communication and Mass Media Complete (CMMC)

1. Pendahuluan

Seiring dengan meningkatnya kesadaran akan pentingnya perlindungan lingkungan, peran energi terbarukan, khususnya *Pembangkit Listrik Tenaga Surya* (PLTS), semakin vital. PLTS dianggap sebagai solusi utama untuk mengurangi dampak negatif dari pembangkit listrik konvensional berbasis bahan bakar fosil. Namun, untuk mencapai implementasi yang efektif, diperlukan pemahaman yang mendalam mengenai potensi energi surya di wilayah tertentu. Penelitian ini bertujuan untuk mengidentifikasi dan mengevaluasi potensi energi surya yang dapat dimanfaatkan dalam pembangunan PLTS di daerah tertentu. Faktor-faktor yang dipertimbangkan dalam analisis meliputi kondisi cuaca, intensitas sinar matahari, dan topografi wilayah. Pergeseran menuju sumber energi terbarukan memiliki urgensi yang besar untuk mengurangi emisi gas rumah kaca dan mengatasi perubahan iklim global. PLTS, sebagai bagian dari portofolio energi terbarukan, memiliki potensi besar. Namun, untuk merealisasikan pemanfaatan maksimal, diperlukan kajian yang teliti terhadap potensi energi surya di suatu wilayah. Dengan pemahaman yang tepat, sistem PLTS dapat dirancang dengan efisien, memaksimalkan penggunaan energi surya, dan meningkatkan keberlanjutan proyek energi terbarukan.

Penelitian ini diharapkan dapat memberikan panduan teknis dan solusi aplikatif untuk pembangunan PLTS yang efisien dan berkelanjutan di daerah yang diteliti, serta berkontribusi terhadap pengembangan infrastruktur energi terbarukan. Solusi yang diusulkan, ENBAS: Potensi Energi pada Suatu Wilayah dalam Pembangunan PLTS, memanfaatkan *kecerdasan buatan* (AI) untuk menghitung dan memvisualisasikan potensi energi surya. Dengan mengintegrasikan data topografi, cuaca, dan faktor-faktor relevan lainnya, dashboard AI yang dikembangkan akan memberikan informasi mengenai lokasi yang paling optimal untuk pembangunan PLTS. Solusi ini diharapkan dapat menggantikan metode perencanaan manual, meningkatkan efisiensi dalam perencanaan proyek PLTS, serta mendukung pencapaian tujuan energi terbarukan. Keberhasilan implementasi solusi ini akan memberikan dampak positif dalam menghadapi tantangan energi dan lingkungan global.

Model *pembelajaran mesin* (ML) memungkinkan identifikasi hubungan non-linier antara variabel dependen dan independen. Sebagai contoh, Gufron *et al.* (2022) mengembangkan model peramalan produksi energi pada PLTS 1 kWp ITENAS berdasarkan data produksi energi harian dalam deret waktu untuk memprediksi periode berikutnya. Algoritma *Support Vector Machine* (SVM) digunakan dalam *pembelajaran mesin* untuk membangun model yang dapat memprediksi kondisi di masa depan. Dengan perkembangan SVM, analisis regresi berkembang menjadi *Support Vector Regression* (SVR), yang dikenal unggul dalam mengklasifikasikan data non-linier dibandingkan metode lainnya (Shi *et al.*, dalam Gufron *et al.*, 2022). Terdapat berbagai faktor yang memengaruhi produksi energi surya, seperti radiasi sinar matahari, tutupan awan, suhu, kelembaban, tekanan atmosfer, dan kecepatan angin (Wang *et al.*, 2020). Model *machine learning* berbasis algoritma regresi *random forest* (RF) dikembangkan untuk memprediksi Efisiensi Energi Konversi (PCE) menggunakan deskriptor elektronik, seperti tingkat energi orbital molekuler dan celah pita dari donor dan akseptor (Lee *et al.*, dalam Shutur, 2023). Penelitian ini menggunakan empat algoritma untuk memperoleh prediksi yang lebih akurat mengenai wilayah yang berpotensi menjadi PLTS. Adapun empat algoritma yang digunakan dalam penelitian ini adalah:

1) Regresi Linier

Regresi linier digunakan untuk memodelkan hubungan linier antara berbagai faktor, seperti lokasi geografis, kondisi cuaca, dan topografi, dengan potensi energi surya di wilayah tersebut. Dengan memanfaatkan data historis atau pengamatan, model regresi linier dapat dibangun untuk memprediksi potensi energi surya di wilayah tersebut. Regresi dilakukan dengan menganalisis hubungan antara dua atau lebih variabel independen, yang dikenal juga sebagai *predictor* atau variabel bebas (Luthfiarta *et al.*, 2020). Penggunaan atribut relevan seperti suhu, kelembapan udara, tekanan udara, dan kecepatan angin diharapkan menghasilkan pola yang lebih detail dan prediksi yang lebih akurat.

2) Lasso Regression dan Ridge Regression

Kedua metode ini berguna untuk menangani masalah *overfitting* yang dapat terjadi akibat banyaknya faktor yang mempengaruhi potensi energi. Regresi Lasso dan Ridge membantu

memilih variabel yang paling relevan atau mengatasi masalah *multikolinearitas*. Regresi Ridge digunakan untuk mengurangi *overfitting* dengan memasukkan hukuman berupa jumlah kuadrat koefisien ke dalam fungsi tujuan, sementara Lasso Regression menggunakan hukuman berupa jumlah mutlak koefisien pada fungsi tujuan (Wijayanti, 2023).


3) *Support Vector Regression (SVR)*

SVR dapat digunakan untuk membangun model regresi yang menangani pola non-linier dalam data. Jika hubungan antara variabel dan potensi energi surya bersifat non-linier, *SVR* merupakan pilihan yang tepat. Metode ini telah digunakan untuk mendekati analisis teknik yang kompleks (Aeni, 2020). *SVM* diterapkan pada situasi regresi dan data non-linier yang melibatkan jumlah data input besar (Caraka, 2017).

4) *Decision Tree Regression (DTR)*

Decision Tree dapat membantu mengidentifikasi pola dan interaksi kompleks antara berbagai faktor yang mempengaruhi potensi energi surya. Teknik ini memungkinkan pembuatan pohon keputusan untuk memahami faktor-faktor yang paling berpengaruh. *Decision Tree* dikenal efektif dalam klasifikasi dan prediksi data (Muzakir, 2016).

data pelatihan dan data pengujian, untuk melakukan validasi silang dan menghindari *overfitting* model. Proses pengembangan model melibatkan implementasi *Linear Regression* untuk mengevaluasi hubungan linier antara variabel-variabel, *Lasso* dan *Ridge* untuk melakukan *regularization*, *SVR* untuk menangani non-linearitas, serta *Decision Tree Regression* untuk mengatasi struktur data yang kompleks. Terakhir, kinerja model dievaluasi dengan menggunakan sejumlah metrik, termasuk *Mean Squared Error (MSE)*, *Mean Absolute Error (MAE)*, dan *Root Mean Squared Error (RMSE)*, untuk mengukur sejauh mana model mampu memprediksi radiasi sinar matahari. Secara keseluruhan, tahapan-tahapan ini digambarkan melalui diagram alir yang terdapat pada Gambar 1.



Gambar 1. Diagram alir

2. Metodologi Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan yang terstruktur dengan baik. Pertama, data dikumpulkan dari sumber resmi *NASA* untuk memastikan integritas dan kualitas data yang digunakan, yang sangat penting untuk mendukung analisis yang akurat dan sah. Setelah data terkumpul, proses *preprocessing* dilakukan, yang mencakup normalisasi data guna memastikan konsistensi serta meminimalkan pengaruh *outlier*. Dalam langkah ini, teknik-teknik seperti *Linear Regression*, *Lasso Regression*, dan *Ridge Regression* digunakan untuk mengatasi masalah *multicollinearity* dan memperbaiki model. Selanjutnya, untuk menangani nilai yang hilang, metode imputasi data yang canggih, seperti *Support Vector Regression (SVR)*, digunakan agar nilai yang hilang dapat diatasi secara efisien dan penggunaan data dapat dioptimalkan. Setelah itu, dataset dibagi menjadi dua bagian, yaitu

1) Dataset

Dataset diperoleh melalui website resmi *NASA* yang dimana didalam dataset tersebut sudah terdapat factor data yang dibutuhkan seperti; suhu udara, kelembapan permukaan, intensitas radiasi, fluks gelombang pendek masuk permukaan, total ozon kolom, total uap air yang dapat jatuh sebagai presipitasi, dan kecepatan angin.

2) Model Prediksi Linear Regression

Model Prediksi Linear Regression adalah metode statistik yang digunakan untuk menemukan hubungan linier antara variabel dependen (output) dan satu atau lebih variabel independen (input). $y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$, di mana y adalah variabel dependen, $x_1, x_2, \dots, x_n$ adalah variabel independen, dan $b_0, b_1, b_2, \dots, b_n$ adalah koefisien regresi. Lasso Regression adalah variasi dari regresi linear dengan penambahan regularisasi L1, yang membantu mencegah *overfitting* dan dapat menghasilkan model yang lebih sederhana. y

= $b_0 + b_1 x_1 + b_2 x_2 + \dots + b_n x_n + \lambda \sum_{i=1}^n b_i^2$ dimana λ adalah parameter pinalti. *Support Vector Regression* adalah metode regresi yang menggunakan *Support Vector Machines* (SVM) untuk memprediksi nilai kontinu. Tujuannya adalah menemukan hyperplane yang memiliki deviasi maksimum dari data target. *Decision Tree* menggunakan struktur pohon keputusan untuk memodelkan hubungan antara input dan output. Pohon dibagi berdasarkan kondisi pada fitur-fitur input. Dalam evaluasi performa model, dua metrik umum yang digunakan adalah *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE). Untuk mengukur ketepatan prediksi, MSE dan MAE dihitung sebagai berikut: *Mean Squared Error* (MSE) : $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ (1) Dimana y_i adalah nilai actual, $\hat{y}_i$ adalah nilai prediksi, dan n adalah jumlah observasi. *Mean Absolute Error* (MAE) : $\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$ (2) Dimana y_i adalah nilai actual, $\hat{y}_i$ adalah nilai prediksi, dan n adalah jumlah observasi.

3. Hasil dan Pembahasan


Hasil

Berdasarkan Gambar 2, dataset yang ditampilkan merupakan data yang dibutuhkan untuk melakukan pemodelan dan menentukan algoritma yang tepat dalam pembuatan *machine learning*. Data tersebut mencakup berbagai faktor yang relevan untuk analisis potensi energi surya, yang selanjutnya digunakan untuk memilih algoritma yang sesuai guna menghasilkan model prediksi yang akurat. Pemilihan algoritma yang tepat sangat bergantung pada karakteristik dataset, yang mencakup variabel-variabel yang berhubungan dengan kondisi cuaca, intensitas radiasi matahari, serta faktor-faktor lainnya yang mempengaruhi potensi energi surya di wilayah yang diteliti.


time and date	air temperature	surface humidity	radiance intensity	surface incoming short wave flux	total column ozone	total precipitable water vapour	wind speed
0 8/12/2019 0:00	20.732210	0.055703	330.418793	2.05332	269.778154	19.257727	6.949305
1 8/12/2019 1:00	20.816028	0.055002	333.328033	107.12500	268.794729	19.676240	6.920405
2 8/12/2019 2:00	20.968157	0.054196	330.668790	320.00000	268.444751	19.980542	7.402035
3 8/12/2019 3:00	23.989126	0.052887	330.868411	545.50000	269.155510	17.480548	7.384719
4 8/12/2019 4:00	26.353357	0.050308	343.027130	747.00000	270.538889	17.188787	7.045732
...	...	...	...	...	...	...	...
12147 1/26/2021 19:00	1.807454	0.081604	190.881537	0.00000	251.786577	2.521886	3.676206
12148 1/26/2021 20:00	2.280206	0.081546	200.430287	0.00000	251.132255	2.380464	3.625965
12149 1/26/2021 21:00	2.690760	0.081436	203.228104	0.00000	250.384811	2.647078	3.611343
12150 1/26/2021 22:00	3.168584	0.081430	204.468835	0.00000	249.648493	2.747614	3.606008
12151 1/26/2021 23:00	3.624536	0.081296	207.033763	0.00000	248.758105	3.057217	3.613473

Gambar 2. Dataset

Korelasi yang terjadi antara dataset intensitas radiasi dan suhu udara dapat dilihat melalui grafik *heat map* yang ditampilkan pada Gambar 3. Grafik tersebut mengilustrasikan nilai koefisien korelasi antara intensitas radiasi dengan beberapa faktor, seperti suhu udara, kelembapan permukaan, fluks gelombang pendek masuk permukaan, total kolom ozon, total uap air yang dapat diendapkan, dan kecepatan angin. Nilai koefisien korelasi untuk masing-masing faktor adalah 0,5 untuk suhu udara, 0,81 untuk kelembapan permukaan, 0,044 untuk fluks gelombang pendek, -0,086 untuk kolom ozon, 0,84 untuk total uap air yang dapat diendapkan, dan 0,05 untuk kecepatan angin. Koefisien-koefisien ini memberikan gambaran tentang seberapa kuat hubungan antara faktor-faktor tersebut dengan intensitas radiasi, yang menjadi indikator utama dalam pemodelan potensi energi surya.



Gambar 3. Grafik Heat map




Gambar 4. Menampilkan grafik regresi non linier menggambarkan hubungan antara solar radiasi dengan data setiap 5 menit

Tabel 1. Perhitungan Evaluasi Model Prediksi Radiasi Sinar Matahari

Model	RMSE Data Training	RMSE Data Testing	R ² Score
Linier	12.62336974801681	16.22972648106027	0.924
Lasso	13.754860653128372	17.649528642943594	0.910
Ridge	13.198284229649001	17.170457815302107	0.917
SVR	10.608602166809204	12.31692185637924	0.949
DTR	0.0	12.13256143166338	0.987


Hasil algoritma yang digunakan dalam penelitian ini sebagai berikut:




Gambar 5. Model Prediksi Terhadap Real Data Regresi ANN

Dalam Gambar 3, terlihat bahwa koefisien korelasi antara dataset intensitas radiasi dan dataset perubahan cuaca memiliki hubungan yang paling kuat. Setelah melakukan percobaan menggunakan data uji pada model *Linear Regression*, *Lasso Regression*, *Ridge Regression*, *Support Vector Regression* (SVR), dan *Decision Tree Regression* (DTR), nilai RMSE dan R² yang diperoleh dapat dilihat pada Tabel 1. Model linier menunjukkan tingkat kesalahan yang relatif rendah baik pada data pelatihan maupun pengujian, dengan R² yang tinggi, menandakan bahwa model ini cukup baik dalam menjelaskan variasi data. Model *Lasso* menunjukkan tingkat kesalahan yang sedikit lebih tinggi dibandingkan model linier pada kedua data tersebut, namun R² yang tinggi menunjukkan bahwa model ini juga mampu memberikan penjelasan yang baik terhadap variasi dalam data. Model *Ridge* memberikan hasil yang serupa dengan model *Lasso*, dengan tingkat kesalahan yang sedikit lebih tinggi pada data pengujian. Meskipun demikian, R² yang tinggi menunjukkan kemampuan model ini dalam menjelaskan variasi data dengan baik. Model *SVR* menunjukkan tingkat kesalahan yang lebih

rendah pada kedua data pelatihan dan pengujian dibandingkan dengan model linier, *Lasso*, dan *Ridge*. R² yang tinggi pada model ini menunjukkan bahwa *SVR* sangat efektif dalam menjelaskan variasi data. Model *DTR* cenderung mengalami *overfitting* karena RMSE pada data pelatihan adalah 0.0, yang menunjukkan bahwa model hampir sempurna dalam memprediksi data pelatihan. Sebagai solusi, dapat dilakukan pemangkasan pohon (*pruning*) dengan mengatur parameter seperti kedalaman maksimum pohon, jumlah minimum sampel untuk membagi node, dan jumlah minimum sampel di setiap daun untuk mengendalikan kompleksitas model dan mencegah *overfitting*. Visualisasi model pada data pengujian dapat dilihat pada Gambar 6 dan Gambar 7.



Gambar 6. Hasil Prediksi dari Data Testing



Gambar 7. Visualisasi Watt per-Jam

Pada Gambar 6 dan Gambar 7 dapat dilihat bahwa model yang digunakan membuat data testing terprediksi dengan baik sehingga bisa dikatakan bahwa model yang dirancang berhasil.

Pembahasan

Berdasarkan hasil percobaan yang dilakukan dengan berbagai model regresi, dapat dilihat bahwa setiap model memiliki kelebihan dan kekurangan dalam menangani prediksi radiasi sinar matahari. Model *Linear Regression* menunjukkan hasil yang memadai dengan tingkat kesalahan yang relatif rendah pada data pelatihan dan pengujian, serta R^2 yang tinggi, menandakan kemampuan model ini dalam menjelaskan variasi data dengan baik. Hal ini sesuai dengan temuan Luthfiarta *et al.* (2020), yang menunjukkan bahwa *linear regression* dapat digunakan untuk memodelkan hubungan linier antara variabel cuaca dan parameter lainnya dalam sistem prediksi. Model ini cocok untuk analisis yang tidak memerlukan kompleksitas tinggi dan dapat memberikan gambaran dasar yang efektif (Luthfiarta *et al.*, 2020). Di sisi lain, model *Lasso Regression* dan *Ridge Regression* menunjukkan hasil yang serupa dengan model *Linear Regression*, namun dengan tingkat kesalahan yang sedikit lebih tinggi pada data pelatihan dan pengujian. Kedua model ini menggunakan teknik *regularization* untuk menangani masalah *multicollinearity* dan memberikan solusi terhadap model yang terlalu kompleks.

Wijayanti (2023) menyebutkan bahwa *Ridge* dan *Lasso* sangat berguna untuk mengatasi masalah yang disebabkan oleh *multicollinearity*, yang dapat mengganggu prediksi ketika banyak faktor yang saling berhubungan kuat. Meskipun memiliki tingkat kesalahan lebih tinggi, model ini tetap menunjukkan R^2 yang tinggi, yang berarti mampu memberikan penjelasan yang baik terhadap variasi dalam data. Model *Support Vector Regression (SVR)* menunjukkan performa terbaik dengan tingkat kesalahan yang lebih rendah dibandingkan model lainnya pada kedua data pelatihan dan pengujian. Nilai R^2 yang sangat tinggi pada model ini menunjukkan bahwa *SVR* mampu menangkap pola non-linier dalam data dengan sangat baik. Seperti yang dijelaskan oleh Caraka *et al.* (2017), *SVR* menggunakan *kernel* untuk menangani data non-linier, yang memungkinkan model untuk mengatasi hubungan yang kompleks antara variabel

dengan lebih efektif. Hal ini sejalan dengan penelitian oleh Gufron *et al.* (2022), yang juga menunjukkan bahwa *SVR* dapat memberikan hasil yang lebih akurat dalam prediksi energi terbarukan, khususnya dalam konteks *PLTS*. Model *Decision Tree Regression (DTR)* mengalami masalah *overfitting*, yang terlihat dari nilai RMSE yang sangat rendah pada data pelatihan (0.0) dan perbedaan besar pada data pengujian. Masalah ini menunjukkan bahwa model terlalu menyesuaikan diri dengan data pelatihan, sehingga kurang mampu generalisasi pada data pengujian. Muzakir dan Wulandari (2016) mengungkapkan bahwa meskipun *Decision Tree* merupakan metode yang efektif dalam klasifikasi dan prediksi, model ini rentan terhadap *overfitting*, terutama pada dataset yang memiliki banyak variabel yang berinteraksi kompleks. Untuk mengatasi masalah ini, teknik *pruning* dapat diterapkan, seperti yang disarankan oleh Muzakir dan Wulandari (2016), untuk mengurangi kompleksitas model dan meningkatkan kemampuannya dalam memprediksi data yang belum pernah dilihat sebelumnya. Secara keseluruhan, meskipun setiap model memiliki kekuatan dan kelemahan masing-masing, model *SVR* memberikan hasil yang paling akurat dalam memprediksi radiasi sinar matahari. Model *Linear Regression* tetap berguna untuk analisis sederhana yang melibatkan hubungan linier, sementara *Lasso* dan *Ridge* memberikan keuntungan dalam mengatasi masalah *multicollinearity*. Teknik *pruning* pada *DTR* dapat membantu mengurangi *overfitting* dan meningkatkan performa model ini. Hasil-hasil ini menunjukkan bahwa pemilihan algoritma yang tepat sangat bergantung pada karakteristik data dan tujuan analisis yang dilakukan.

4. Kesimpulan

Dari penelitian ini semoga dapat memberikan inspirasi bagi peneliti lain agar bisa menjadi alternatif yaitu bisa mengurangi menggunakan bahan fosil yang tidak dapat didaur ulang sehingga dapat membantu pembuatan *PLTS* dan bisa menggunakan prediksi *machine learning* yang mana akurasinya mencapai 0.987.

5. Daftar Pustaka

- Aeni, U. N., Prasasti, A. L., & Kallista, M. (2020). Prediksi Jumlah Penumpang Dan Penambahan Gerbong Kereta Api Menggunakan Metode Support Vector Regression (svr). *eProceedings of Engineering*, 7(2).
- Akbar, H., Ayomi, M. R., & Haryanto, Y. D. (2023, March). ANALISIS PERBANDINGAN MODEL MACHINE LEARNING DALAM PREDIKSI SUHU PERMUKAAN LAUT MENGGUNAKAN DATA MODEL REANALYSIS ECMWF. In *Prosiding Seminar Nasional Hasil Penelitian Kelautan dan Perikanan* (pp. 96-100).
- Ameliana, W. (2023). PENANGANAN MASALAH MULTIKOLINEARITAS DENGAN REGRESI RIDGE, LASSO, DAN ELASTIC-NET PADA KASUS BALITA STUNTING DI INDONESIA.
- Caraka, R. E., Yasin, H., & Basyiruddin, A. W. (2017). Peramalan crude palm oil (CPO) menggunakan support vector regression kernel radial basis. *J. Mat*, 7(1), 43. <https://doi.org/10.24843/jmat.2017.v07.i01.p81>.
- Faadhilah, A., & Nugroho, H. (2024). Pemetaan Daerah Rawan Longsor di Kabupaten Bandung Barat menggunakan Metode Machine Learning dengan Teknik SVM. *Rekayasa Hijau: Jurnal Teknologi Ramah Lingkungan*, 8(2), 185-199. <https://doi.org/10.26760/jrh.v8i2.185-199>.
- Fitrianah, D., Dwiasnati, S., & Baihaqi, K. A. (2021). Penerapan Metode Machine Learning untuk Prediksi Nasabah Potensial menggunakan Algoritma Klasifikasi Naïve Bayes. *Faktor Exacta*, 14(2), 92-99. <http://dx.doi.org/10.30998/faktorexacta.v14i2.9297>.
- Gufron, H., Rusirawan, D., & Widyawati, L. (2022). Forecasting Produksi Energi PLTS 1 kWp Menggunakan Mesin Pembelajaran Dengan Algoritma Support Vector Machine. *Jurnal Tekno Insentif*, 16(2), 79-91. <https://doi.org/10.36787/jti.v16i2.843>.
- Ismayanti, R., & Baihaqi, W. M. (2024). Prediksi Suatu Wilayah Untuk Menjadi PLTS Dengan Machine Learning. *Journal of Informatics and Interactive Technology*, 1(2), 66-72.
- Isnaeni, A. Y., & Prasetyo, S. Y. J. (2022). Klasifikasi Wilayah Potensi Risiko Kerusakan Lahan Akibat Bencana Tsunami Menggunakan Machine Learning. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1), 33-42. <https://doi.org/10.28932/jutisi.v8i1.4056>.
- Luthfiarta, A., Febriyanto, A., Lestiawan, H., & Wicaksono, W. (2020). Analisa Prakiraan Cuaca dengan Parameter Suhu, Kelembaban, Tekanan Udara, dan Kecepatan Angin Menggunakan Regresi Linear Berganda. *JOINS (Journal of Information System)*, 5(1), 10-17.
- Muzakir, A., & Wulandari, R. A. (2016). Model Data Mining sebagai Prediksi Penyakit Hipertensi Khamilan dengan Teknik Decision Tree. *Scientific Journal of Informatics*, 3(1), 19-26. <https://doi.org/10.15294/sji.v3i1.4610>.
- Noor, M. A., Batubara, R. G., Sewoyo, K. C., Fikri, B. A., & Ardalova, R. (2022). Analisis Prediksi Investasi dengan Machine Learning dan Determinan Investasi di Tingkat Regional Provinsi Indonesia. *Jurnal Manajemen Perbendaharaan*, 3(2), 90-115. <https://doi.org/10.33105/jmp.v3i2.414>.
- Suthar, R., Abhijith, T., Sharma, P., & Karak, S. (2023). Machine learning framework for the analysis and prediction of energy loss for non-fullerene organic solar cells. *Solar Energy*, 250, 119-127. <https://doi.org/10.1016/j.solener.2022.12.029>.
- Tantyoko, H., Sari, D. K., & Wijaya, A. R. (2023). Prediksi potensial gempa bumi Indonesia menggunakan metode random forest dan feature selection. *IDEALIS: Indonesia Journal*

Information System, 6(2), 83-89.

Wang, H., Liu, Y., Zhou, B., Li, C., Cao, G., Voropai, N., & Barakhtenko, E. (2020). Taxonomy research of artificial intelligence for deterministic solar power forecasting. *Energy Conversion and Management*, 214, 112909. <https://doi.org/10.1016/j.enconman.2020.112909>.