


Terbit *online* pada laman: <http://jurnal.utu.ac.id/JTI>

Jurnal Teknologi Informasi

|ISSN (Online): 2829-8934|



Pemodelan Daya Photovoltaic Berdasarkan Distribusi Termal Menggunakan Algoritma Support Vector Regression

Isyatur Raziah¹, Andri Novandri^{2*}, Cut Mutia³, Yuwaldi Away⁴

^{1,3} Teknologi Informasi, Universitas Teuku Umar, Meulaboh, Indonesia

² Teknik Komputer, Universitas Serambi Mekkah, Banda Aceh, Indonesia

⁴ Teknik Elektro dan Komputer, Universitas Syiah Kuala, Banda Aceh, Indonesia

Email: ¹isyaturraziah@utu.ac.id, ²andri.novandri@serambimekkah.ac.id*, ³cutmutia@utu.ac.id, ⁴yuwaldi@usk.ac.id,

* corresponding author

INFORMASI ARTIKEL

ABSTRAK

Sejarah Artikel:
Diterima:
Revisi:
Diterbitkan:

Kata Kunci:
Photovoltaic
Temperatur
SVR
RBF

Kinerja photovoltaic (PV) sangat dipengaruhi oleh karakteristik termal, terutama temperatur yang berdampak langsung terhadap daya keluaran. Pada kondisi nyata, distribusi temperatur pada permukaan panel tidak selalu seragam, sehingga pemodelan berbasis temperatur rata-rata sering kali kurang akurat. Penelitian ini bertujuan untuk memodelkan daya keluaran PV berdasarkan distribusi temperatur menggunakan algoritma Support Vector Regression (SVR). Variabel input yang digunakan meliputi temperatur atas dan bawah panel, irradianse matahari serta kelembapan udara, sementara daya keluaran PV dijadikan sebagai variabel target. Model SVR diterapkan dengan fungsi kernel Radial Basis Function (RBF) untuk menangkap hubungan nonlinier antara variabel input dan output. Hasil pengujian menunjukkan bahwa akurasi model meningkat seiring dengan bertambahnya jumlah dan variasi dataset, dengan performa terbaik diperoleh pada dataset 10 hari yang menghasilkan nilai error rendah serta nilai R^2 dan R yang tinggi. Temuan ini menunjukkan bahwa SVR efektif dan andal dalam memprediksi daya keluaran PV berbasis distribusi temperatur panel.

Copyright © 2026 Jurnal Teknologi Informasi UTU
All rights reserved

1. Pendahuluan

Meningkatnya kebutuhan energi terbarukan telah mendorong pemanfaatan energi surya secara luas. Dalam sistem ini, kinerja Photovoltaic (PV) sangat dipengaruhi oleh karakteristik termal panel yang berdampak langsung terhadap daya keluaran [1]. Oleh karena itu, pemodelan daya keluaran PV menjadi aspek krusial dalam perencanaan, pengoperasian, dan optimasi sistem energi surya. Salah satu faktor utama yang memengaruhi performa panel adalah temperatur [2], [3]. Peningkatan temperatur umumnya menyebabkan penurunan tegangan keluaran sel surya, yang berakibat pada berkurangnya daya yang dihasilkan. Meskipun demikian, distribusi temperatur pada panel tidak selalu seragam. Gradien temperatur antara bagian atas dan bawah panel dapat terjadi akibat variasi irradianse matahari, sirkulasi udara, serta kondisi pemasangan [4].

Berbagai penelitian terdahulu telah mengkaji pengaruh karakteristik termal terhadap performa PV, terutama irradianse dan temperatur panel [5]. Model konvensional umumnya menggunakan temperatur rata-rata panel atau temperatur lingkungan sebagai variabel input dalam memprediksi daya keluaran. Namun, pendekatan tersebut belum sepenuhnya mampu menggambarkan distribusi panas pada panel


surya. Hal itu disebabkan karena perbedaan suhu antara bagian atas dan bawah panel sering kali diabaikan, padahal perbedaan ini dapat memengaruhi efisiensi konversi energi secara signifikan [6]. Disisi lain, irradiance juga menjadi faktor dominan yang menentukan besarnya energi yang dihasilkan. Semakin tinggi nilai irradiance yang diterima permukaan panel, semakin besar potensi daya listrik yang dihasilkan. Namun, hubungan antara irradiance dan daya keluaran PV bersifat nonlinier, terutama ketika dikombinasikan dengan efek temperatur panel [7], [8]. Faktor lain yang turut memengaruhi kinerja sistem PV adalah kelembapan udara. Kelembapan dapat memengaruhi proses perpindahan panas di sekitar panel serta intensitas radiasi matahari yang mencapai permukaan panel akibat adanya hamburan dan penyerapan di atmosfer. Selain itu, kelembapan yang tinggi dalam jangka panjang juga dapat berdampak pada karakteristik material panel surya, sehingga berpotensi memengaruhi performa sistem secara keseluruhan [9].

Mengingat kompleksitas dan sifat nonlinier hubungan antara daya PV dan karakteristik termal, diperlukan pendekatan pemodelan yang adaptif. Support Vector Regression (SVR) merupakan salah satu algoritma machine learning yang efektif untuk menjawab tantangan tersebut. Berbagai studi menunjukkan bahwa SVR memiliki kemampuan generalisasi yang tinggi, ketahanan terhadap overfitting, serta andal dalam menangani data berdimensi tinggi maupun data dengan jumlah terbatas. Oleh karena itu, penelitian ini bertujuan membangun model prediksi daya PV yang akurat berbasis variabel karakteristik termal panel, guna mendukung peningkatan efisiensi dan keandalan sistem PV.

2. Metodologi Penelitian

2.1. Karakteristik Termal pada Photovoltaic

Temperatur PV merupakan salah satu faktor penting yang secara signifikan memengaruhi daya keluaran yang dihasilkan. Seperti yang ditunjukkan pada Gambar 1, ketika temperatur panel meningkat, energi termal pada material semikonduktor sel surya juga meningkat, yang menyebabkan penurunan celah pita energi. Kondisi ini mengakibatkan penurunan tegangan open-circuit, sementara arus hanya mengalami peningkatan yang relatif kecil. Akibatnya, daya keluaran panel surya secara keseluruhan cenderung menurun seiring dengan kenaikan temperatur panel [10], [11].



Gambar 1. Efek termal pada keluaran photovoltaic [8]

Selain dapat memengaruhi karakteristik listrik, peningkatan temperatur juga berdampak pada efisiensi konversi energi panel surya. Pada kondisi temperatur tinggi, rugi-rugi daya akibat rekombinasi pembawa muatan menjadi lebih besar, sehingga kemampuan panel dalam mengonversi radiasi matahari menjadi energi listrik berkurang. Fenomena ini menjelaskan mengapa daya keluaran panel sering kali lebih rendah dibandingkan daya nominal yang biasanya ditentukan pada Standard Test Conditions (STC). Distribusi temperatur yang tidak merata pada permukaan panel juga dapat memperburuk kinerja sistem PV. Perbedaan temperatur antara bagian atas dan bawah panel dapat menimbulkan gradien termal, yang berpotensi menyebabkan ketidaksesuaian karakteristik listrik antar sel. Kondisi ini dapat memicu terjadinya penurunan daya keluaran secara keseluruhan [12].

2.2. Support Vector Regression


Support Vector Regression (SVR) merupakan metode regresi yang dikembangkan dari konsep Support Vector Machine (SVM) dan digunakan untuk memodelkan fungsi regresi $f(x)$ yang merepresentasikan hubungan antara variabel input dan variabel output [13]. Fungsi SVR dirumuskan sebagai berikut,

$$f(x) = \sum_{i=1}^n w_i \cdot K(x_i, x) + b \quad (1)$$

dimana, w merepresentasikan bobot vektor, K adalah fungsi kernel, b merupakan bias, dan n menyatakan jumlah support vector [14]. Pada pemodelan ini digunakan fungsi kernel Radial Basis Function (RBF) yang dirumuskan sebagai berikut,

$$K(x_i, x) = e^{(-\gamma \|x_i - x\|^2)} \quad (2)$$

dimana, $\gamma > 0$ merupakan parameter skala yang berfungsi mengendalikan luas pengaruh setiap titik data terhadap fungsi prediksi.



Gambar 2. Support vector regression dengan kernel non-linear (a) pemetaan data, (b) loss function pada sample data [15]

Pada Gambar 2 ditunjukkan kurva regresi yang dibentuk menggunakan metode SVR, dengan ϵ sebagai batas toleransi kesalahan. Selama hasil prediksi berada di dalam rentang margin ϵ , deviasi tersebut tidak diperhitungkan sebagai kesalahan. Sebaliknya, apabila nilai prediksi berada di luar margin ϵ , maka akan dikenakan penalti. Variabel ξ dan ξ^* berperan sebagai variabel slack yang memungkinkan sebagian titik data berada di luar batas margin ϵ . Variabel ξ merepresentasikan pelanggaran margin untuk titik data di atas batas ϵ , sedangkan ξ^* merepresentasikan pelanggaran margin untuk titik data di bawah batas ϵ . Titik data yang tepat berada pada batas margin ϵ disebut sebagai support vectors karena titik-titik tersebut berkontribusi dalam menentukan bentuk hyperplane regresi. Untuk memperoleh kesalahan prediksi yang minimum, dilakukan proses optimasi dengan mencari nilai minimum dari parameter w , b , ξ , dan ξ^* yang dirumuskan sebagai berikut,

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3)$$

dengan syarat,

$$y_i - f(x_i) \leq \epsilon + \xi_i; f(x_i) - y_i \leq \epsilon + \xi_i^*; \xi_i, \xi_i^* \geq 0 \quad (4)$$

dimana, C merupakan parameter regularisasi yang berfungsi untuk mengendalikan tingkat noise serta mengatur keseimbangan antara kompleksitas model dan besarnya kesalahan. Fungsi objektif ini

bertujuan untuk menentukan kombinasi optimal dari parameter w dan b sehingga diperoleh model dengan kesalahan prediksi (ξ, ξ^*) yang minimal sekaligus mempertahankan margin yang optimal [16]–[18].

2.3. Metode Analisis

Penelitian ini mengevaluasi kinerja model yang dikembangkan melalui serangkaian metrik statistik guna memberikan gambaran komprehensif mengenai akurasi prediksi. Instrumen evaluasi yang digunakan meliputi Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). MAE digunakan untuk merepresentasikan rata-rata galat absolut secara keseluruhan antara nilai prediksi dan aktual. Sementara itu, MSE dan RMSE berfungsi untuk mengukur deviasi kuadrat, dengan RMSE memberikan sensitivitas lebih tinggi terhadap kesalahan besar. Selain itu, MAPE diterapkan untuk menyajikan tingkat kesalahan dalam skala persentase, sehingga memudahkan interpretasi akurasi model secara relatif. Formulasi dari masing-masing metrik tersebut didefinisikan sebagai berikut,

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{5}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{6}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{7}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\% \tag{8}$$

Variabel n menunjukkan total data uji, dengan y_i sebagai nilai aktual dan \hat{y}_i sebagai hasil prediksi model. Evaluasi performa model regresi ini diperkuat dengan analisis korelasi (R) dan koefisien determinasi (R^2). Koefisien R memberikan gambaran mengenai linearitas hubungan antarvariabel, di mana nilai yang mendekati 1 atau -1 mengindikasikan hubungan kuat, sementara nilai mendekati 0 menunjukkan ketiadaan hubungan linear. Sementara itu, R^2 berfungsi sebagai indikator efektivitas model dalam menjelaskan variabilitas data, dengan nilai 1 sebagai representasi akurasi sempurna. Seluruh parameter evaluasi tersebut dihitung berdasarkan persamaan di bawah ini.

$$R = \frac{n \sum_{i=1}^n y_i \hat{y}_i - (\sum_{i=1}^n y_i)(\sum_{i=1}^n \hat{y}_i)}{\sqrt{[n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2][n \sum_{i=1}^n \hat{y}_i^2 - (\sum_{i=1}^n \hat{y}_i)^2]}} \tag{9}$$

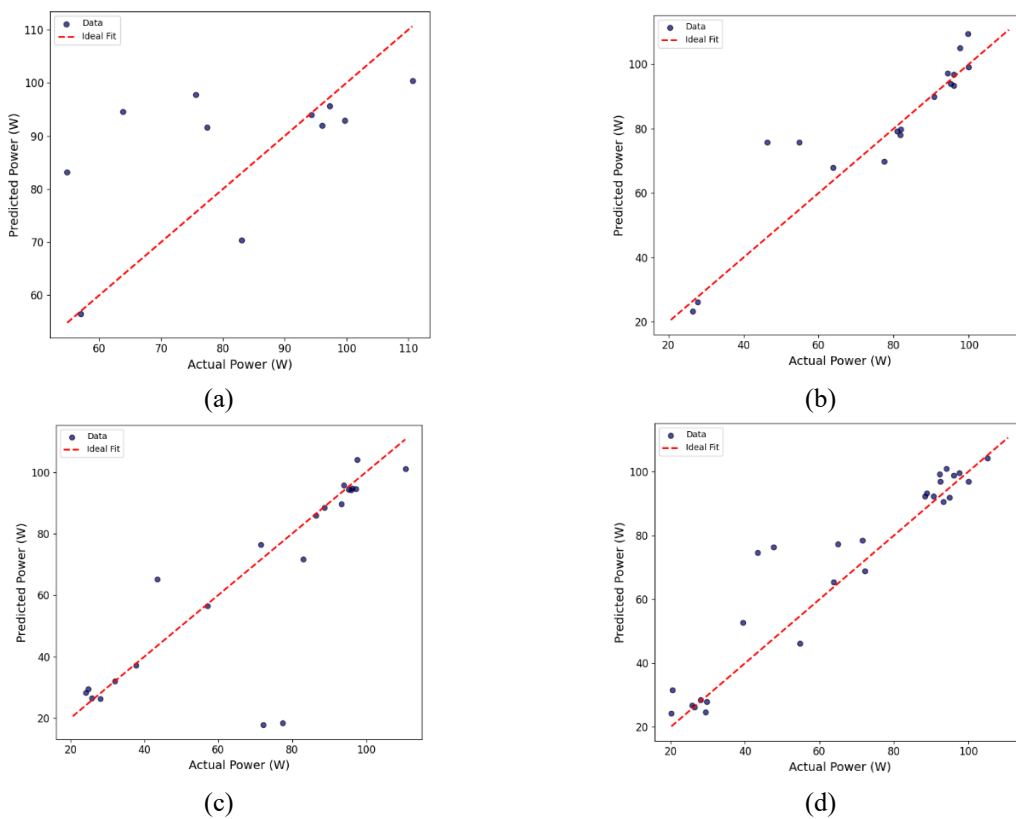
$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{10}$$

3. Hasil dan Pembahasan

3.1. Analisis Model SVR dengan $\varepsilon = 0,1$

Pada Gambar 3 menunjukkan pola kinerja yang konsisten terhadap variasi jumlah dataset. Berdasarkan Tabel 1, model yang menggunakan dataset 4 hari masih menghasilkan tingkat kesalahan

yang relatif tinggi dengan nilai R^2 yang rendah, yang mengindikasikan bahwa model belum mampu merepresentasikan hubungan antara variabel input dan daya keluaran secara memadai akibat keterbatasan data. Hal ini juga terlihat dari sebaran titik prediksi yang cukup jauh dari garis ideal. Pada dataset 6 hari, terjadi peningkatan kinerja model yang signifikan. Nilai MAE, RMSE, dan MAPE menurun, sementara nilai R^2 dan koefisien korelasi R meningkat secara tajam. Sebaran titik prediksi semakin mendekati garis ideal, menunjukkan bahwa penambahan variasi data meningkatkan kemampuan model dalam melakukan generalisasi. Pada dataset 8 hari, performa model sedikit menurun yang ditandai dengan meningkatnya nilai error dan penurunan nilai R^2 , yang mengindikasikan adanya variasi kondisi lingkungan yang lebih kompleks dan sulit dimodelkan secara optimal dengan parameter $\epsilon = 0,1$. Kinerja terbaik diperoleh pada dataset 10 hari, dengan nilai error yang relatif rendah serta nilai R^2 dan R tertinggi dibandingkan variasi lainnya. Hasil ini menunjukkan bahwa penggunaan dataset yang lebih panjang dan representatif mampu meningkatkan akurasi prediksi daya PV. Secara keseluruhan, pemodelan SVR dengan $\epsilon = 0,1$ efektif dalam memprediksi daya keluaran PV, khususnya ketika didukung oleh jumlah data yang bervariasi.



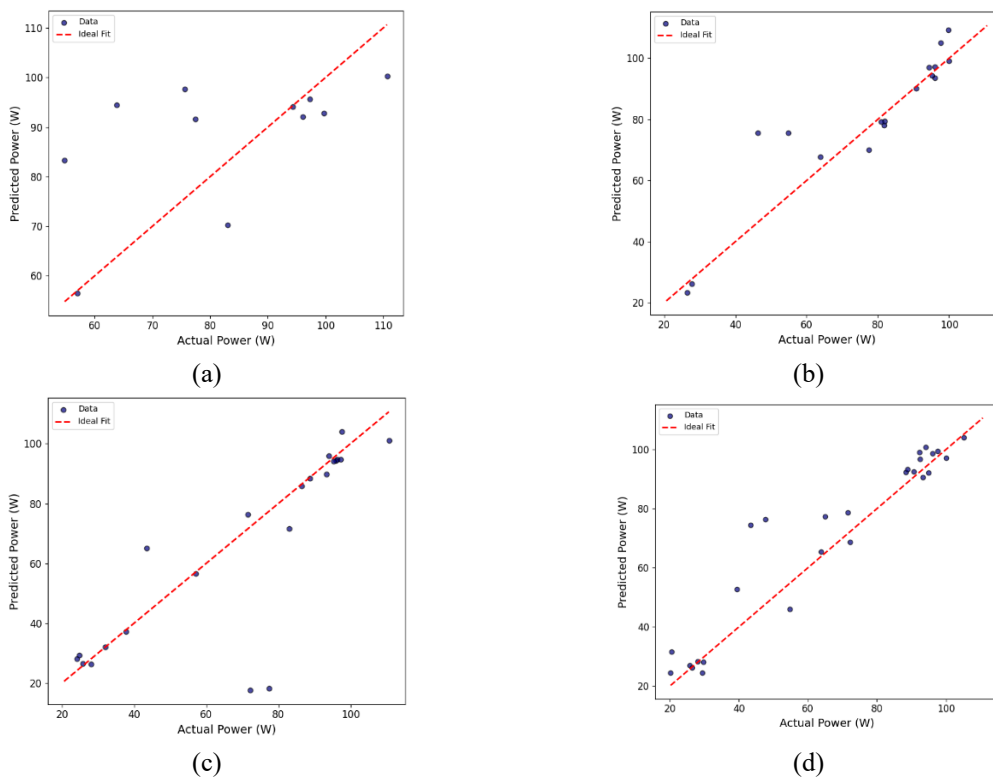
Gambar 3. Hasil kinerja model dengan $\epsilon = 0,1$ berdasarkan variasi dataset: (a) 4 hari, (b) 6 hari, (c) 8 hari, (d) 10 hari

Tabel 1. Hasil perbandingan model dengan $\epsilon = 0,1$

	4 hari	6 hari	8 hari	10 hari
MAE	12,005	5,901	8,772	6,359
MSE	252,932	92,676	331,089	96,856
RMSE	15,904	9,627	18,196	9,842
MAPE	16,957%	10,082%	13,563%	13,519%
R^2	0,199	0,837	0,603	0,887
R	0,56	0,925	0,829	0,954

3.2. Analisis Model SVR dengan $\epsilon = 0,2$

Pada Gambar 4 menunjukkan bahwa kinerja model dipengaruhi oleh jumlah variasi dataset yang digunakan. Berdasarkan Tabel 2, model yang menggunakan dataset 4 hari, menunjukkan performa yang masih rendah, ditandai dengan nilai error yang tinggi dan nilai R^2 yang kecil, sehingga model belum mampu merepresentasikan hubungan antara variabel input dan daya keluaran secara baik. Hal ini disebabkan oleh keterbatasan jumlah data yang digunakan untuk pelatihan. Peningkatan kinerja terlihat pada dataset 6 hari, dengan penurunan nilai MAE, RMSE, dan MAPE serta peningkatan nilai R^2 dan koefisien korelasi R . Sebaran titik prediksi semakin mendekati garis ideal, menunjukkan kemampuan generalisasi model yang lebih baik. Pada dataset 8 hari, kinerja model sedikit menurun akibat adanya variasi data yang lebih kompleks, yang tercermin dari meningkatnya nilai error dan menurunnya nilai R^2 . Model SVR menunjukkan performa terbaik pada dataset 10 hari, dengan nilai error yang relatif rendah serta nilai R^2 dan R yang paling tinggi. Hasil ini mengindikasikan bahwa penambahan variasi data mampu meningkatkan akurasi prediksi, sehingga SVR efektif digunakan untuk memodelkan daya keluaran PV ketika didukung oleh dataset yang cukup dan representatif.



Gambar 4. Hasil kinerja model dengan $\epsilon = 0,2$ berdasarkan variasi dataset: (a) 4 hari, (b) 6 hari, (c) 8 hari, (d) 10 hari

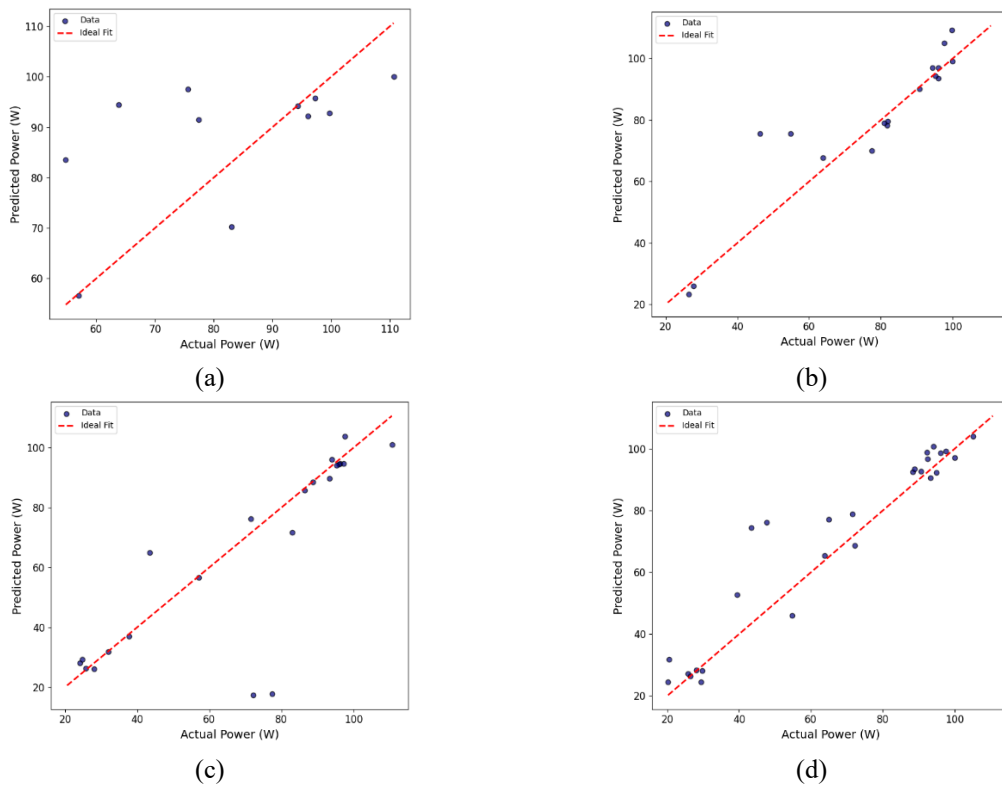
Tabel 2. Hasil perbandingan model dengan $\epsilon = 0,2$

	4 hari	6 hari	8 hari	10 hari
MAE	11,975	5,899	8,777	6,345
MSE	252,941	92,272	333,371	96,416
RMSE	15,904	9,606	18,258	9,819
MAPE	16,921%	10,093%	13,55%	13,514%
R^2	0,198	0,838	0,6	0,888
R	0,56	0,925	0,829	0,954

3.3. Analisis Model SVR dengan $\epsilon = 0,3$

Pada Gambar 5 menunjukkan tren kinerja yang relatif konsisten terhadap variasi jumlah dataset. Berdasarkan Tabel 3, model yang menggunakan dataset 4 hari masih menghasilkan tingkat kesalahan

yang cukup tinggi dan nilai R^2 yang rendah. Hasil tersebut mengindikasikan bahwa model belum mampu merepresentasikan hubungan antara variabel input dan daya keluaran secara optimal akibat keterbatasan data latih. Sebaran titik prediksi juga terlihat cukup jauh dari garis ideal. Kinerja model meningkat secara signifikan pada dataset 6 hari, ditandai dengan penurunan nilai MAE, RMSE, dan MAPE serta peningkatan nilai R^2 dan koefisien korelasi R . Hal ini menunjukkan bahwa penambahan variasi data mampu meningkatkan kemampuan generalisasi model SVR. Pada dataset 8 hari, performa model kembali mengalami sedikit penurunan yang tercermin dari meningkatnya nilai error dan menurunnya nilai R^2 , mengindikasikan bahwa variasi kondisi lingkungan pada periode ini lebih kompleks dan belum sepenuhnya dapat dimodelkan secara optimal dengan parameter $\epsilon = 0,3$. Performa terbaik diperoleh pada dataset 10 hari, dengan nilai kesalahan yang relatif rendah serta nilai R^2 dan R tertinggi dibandingkan variasi lainnya. Sebaran titik prediksi pada Gambar 5(d) terlihat paling mendekati garis ideal, yang menunjukkan akurasi prediksi yang baik. Secara keseluruhan, hasil ini menegaskan bahwa pemodelan SVR dengan $\epsilon = 0,3$ mampu memberikan prediksi daya PV yang andal ketika didukung oleh dataset yang cukup dan representatif, meskipun sensitivitas model terhadap variasi data tetap perlu diperhatikan.



Gambar 5. Hasil kinerja model dengan $\epsilon = 0,3$ berdasarkan variasi dataset: (a) 4 hari, (b) 6 hari, (c) 8 hari, (d) 10 hari

Tabel 3. Hasil perbandingan model dengan $\epsilon = 0,3$

	4 hari	6 hari	8 hari	10 hari
MAE	11,943	5,864	8,783	6,354
MSE	252,917	91,763	335,689	96,375
RMSE	15,903	9,579	18,322	9,817
MAPE	16,883%	10,067%	13,578%	13,548%
R^2	0,199	0,838	0,597	0,888
R	0,56	0,926	0,828	0,954

4. Kesimpulan

Penelitian ini telah berhasil mengembangkan model prediksi daya keluaran PV berbasis karakteristik termal menggunakan algoritma SVR. Hasil penelitian menunjukkan bahwa temperatur panel,

khususnya distribusi temperatur yang tidak merata antara bagian atas dan bawah panel, memiliki pengaruh signifikan terhadap daya keluaran PV. Pendekatan ini mampu merepresentasikan hubungan nonlinier antara variabel termal dan daya keluaran dengan baik, yang tidak dapat ditangkap secara optimal oleh model konvensional berbasis temperatur rata-rata. Evaluasi kinerja model menunjukkan bahwa akurasi prediksi sangat dipengaruhi oleh jumlah dan keragaman dataset yang digunakan. Model dengan dataset 10 hari secara konsisten menghasilkan performa terbaik, ditandai dengan nilai MAE, RMSE, dan MAPE yang lebih rendah serta nilai R^2 dan R yang tinggi. Sebaliknya, penggunaan dataset yang terbatas menyebabkan tingginya kesalahan prediksi dan rendahnya kemampuan generalisasi model. Secara keseluruhan, hasil penelitian ini menegaskan bahwa algoritma SVR dengan kernel RBF efektif dan andal untuk memodelkan daya keluaran PV berbasis distribusi temperatur panel, terutama ketika didukung oleh dataset yang cukup dan representatif. Model yang dikembangkan berpotensi digunakan sebagai alat bantu dalam perencanaan, pemantauan, dan optimasi sistem PV, serta dapat menjadi dasar untuk pengembangan penelitian lanjutan dengan penambahan variabel lingkungan lain atau periode pengamatan yang lebih panjang.

Daftar Pustaka

- [1] P. K. Dash and N. C. Gupta, "Effect of Temperature on Power Output from Different Commercially Available Photovoltaic Modules," *J. Eng. Res. Appl. www.ijera.com*, vol. 5, no. 1, pp. 1–4, 2015.
- [2] O. Dupré, R. Vaillon, and M. A. Green, *Thermal Behavior of Photovoltaic Devices*. Cham: Springer International Publishing, 2017.
- [3] I. Raziah, A. Novandri, and Y. Away, "Real-Time Monitoring of Photovoltaic Panel Using Node-RED," *sinkron*, vol. 8, no. 3, pp. 2049–2060, Aug. 2024, doi: 10.33395/sinkron.v8i3.13929.
- [4] T. J. Silverman *et al.*, "Reducing Operating Temperature in Photovoltaic Modules," in *IEEE Journal of Photovoltaics*, Mar. 2018, vol. 8, no. 2, pp. 532–540, doi: 10.1109/JPHOTOV.2017.2779842.
- [5] Asri, Y. Away, Nasaruddin, I. Devi Sara, and A. Novandri, "Enhancement of Photovoltaic Performance With Coolant Calcium Chloride: Experimental and Predictive Modeling," *IEEE Access*, vol. 12, no. July, pp. 112839–112851, 2024, doi: 10.1109/ACCESS.2024.3443695.
- [6] H. G. Teo, P. S. Lee, and M. N. A. Hawlader, "An Active Cooling System for Photovoltaic Modules," *Appl. Energy*, vol. 90, no. 1, pp. 309–315, 2012, doi: 10.1016/j.apenergy.2011.01.017.
- [7] G. Todorov, H. Vasilev, K. Kamberov, T. Ivanov, and Y. Sofronov, "Concept and Virtual Prototyping of Cooling Module for Photovoltaic System," in *6th International Symposium on Environment-Friendly Energies and Applications (EFEA)*, 2021, pp. 3–6, doi: 10.1109/EFEA49713.2021.9406247.
- [8] M. Seapan, Y. Hishikawa, M. Yoshita, and K. Okajima, "Temperature and Irradiance Dependences of the Current and Voltage at Maximum Power of Crystalline Silicon PV Devices," *Sol. Energy*, vol. 204, no. 5, pp. 459–465, 2020, doi: 10.1016/j.solener.2020.05.019.
- [9] S. Kalaiselvan, V. Karthikeyan, G. Rajesh, A. Sethu Kumaran, B. Ramkiran, and P. Neelamegam, "Solar PV Active and Passive Cooling Technologies - A Review," in *International Conference on Computation of Power, Energy, Information and Communication (ICCPEIC)*, Mar. 2018, pp. 166–169, doi: 10.1109/ICCPEIC.2018.8525185.
- [10] Y. Hishikawa *et al.*, "Voltage-Dependent Temperature Coefficient of the I-V Curves of Crystalline Silicon Photovoltaic Modules," *IEEE J. Photovoltaics*, vol. 8, no. 1, pp. 48–53, 2018, doi: 10.1109/JPHOTOV.2017.2766529.
- [11] T. Ozden, D. Tolgay, and B. G. Akinoglu, "Daily and Monthly Module Temperature Variation for 9 Different Modules," in *International Conference on Photovoltaic Science and Technologies (PVCon)*, Jul. 2018, pp. 4849–4854, doi: 10.1109/PVCon.2018.8523878.
- [12] S. Dubey, J. N. Sarvaiya, and B. Seshadri, "Temperature Dependent Photovoltaic (PV) Efficiency and Its Effect on PV Production in the World - A Review," *Energy Procedia*, vol. 33, pp. 311–321, 2013, doi: 10.1016/j.egypro.2013.05.072.
- [13] L. Fan, Y. Ji, and G. Wu, "Research on Temperature Prediction Model in Greenhouse Based on Improved SVR," *J. Phys. Conf. Ser.*, vol. 1802, no. 4, p. 042001, Mar. 2021, doi: 10.1088/1742-6596/1802/4/042001.

- [14] Y. Tao, H. Yan, H. Gao, Y. Sun, and G. Li, "Application of SVR Optimized by Modified Simulated Annealing (MSA-SVR) Air Conditioning Load Prediction Model," *J. Ind. Inf. Integr.*, vol. 15, pp. 247–251, Sep. 2019, doi: 10.1016/j.jii.2018.04.003.
- [15] E. S. Nasution, Y. Away, Syahrial, I. D. Sara, and A. Novandri, "SVR-Optimized ANN Model for Predicting Earthquake Risk in Electrical Substations Based on Disaster Datasets in the Aceh Region, Indonesia," *IEEE Access*, vol. 13, pp. 105027–105043, 2025, doi: 10.1109/ACCESS.2025.3579797.
- [16] Y. Xiang, L. Gou, L. He, S. Xia, and W. Wang, "A SVR–ANN Combined Model Based on Ensemble EMD for Rainfall Prediction," *Appl. Soft Comput.*, vol. 73, pp. 874–883, Dec. 2018, doi: 10.1016/j.asoc.2018.09.018.
- [17] A. Mirarabi, H. R. Nassery, M. Nakhaei, J. Adamowski, A. H. Akbarzadeh, and F. Alijani, "Evaluation of Data-Driven Models (SVR and ANN) for Groundwater-Level Prediction in Confined and Unconfined Systems," *Environ. Earth Sci.*, vol. 78, no. 15, p. 489, Aug. 2019, doi: 10.1007/s12665-019-8474-y.
- [18] Z. Xuan *et al.*, "Multi-variable time series forecasting for thermal load of air-conditioning system on SVR," in *2015 34th Chinese Control Conference (CCC)*, Jul. 2015, vol. 2015-Septe, no. 1, pp. 8276–8280, doi: 10.1109/ChiCC.2015.7260952.