

Prediksi Energi Keluaran PLTS Off-Grid Berbasis Jaringan Syaraf Tiruan Backpropagation

¹Muhammad Ilham Amba, ^{2*}Tony KoerniawanAndi, Dyah Harum Hardyanti³

^{1,3} Fakultas Ketenagalistrikan dan Energi Terbarukan, Institut Teknologi PLN

² Sekolah Vokasi, Institut Teknologi PLN

*Corresponding Author e-mail: tony.koerniawan@itpln.ac.id

Received: May 2026; Revised: Juny 2026; Published: August 2026

Abstrak

Pembangkit Listrik Tenaga Surya (PLTS) off-grid memiliki tantangan dalam menjaga ketersediaan energi akibat fluktuasi produksi yang dipengaruhi oleh kondisi cuaca. Oleh karena itu, diperlukan metode prediksi energi yang dapat membantu memperkirakan ketersediaan energi pada periode berikutnya. Penelitian ini bertujuan mengembangkan model prediksi energi keluaran PLTS off-grid menggunakan metode Backpropagation Feed Forward Neural Network. Data yang digunakan berupa energi keluaran PLTS, suhu lingkungan, dan iradiasi matahari yang dikumpulkan dari PLTS off-grid di IT-PLN selama tiga hari berturut-turut dengan interval pengukuran 15 menit pada rentang waktu pukul 09.00–15.00 WIB. Model jaringan syaraf tiruan dibangun menggunakan 75 neuron input yang terdiri atas data energi, suhu, dan iradiasi, satu hidden layer, serta 25 neuron output. Penentuan jumlah neuron pada hidden layer dan nilai learning rate dilakukan menggunakan metode trial and error. Hasil pelatihan menunjukkan konfigurasi terbaik diperoleh pada learning rate sebesar 0,2 dan jumlah neuron hidden layer sebanyak 20 neuron dengan nilai Mean Squared Error (MSE) sebesar 0,0000116. Pengujian model dilakukan secara terbatas menggunakan data hari ketiga dan menghasilkan nilai Mean Absolute Percentage Error (MAPE) sebesar 2,6158%. Nilai error terkecil diperoleh sebesar 0,00334% pada pukul 12.00, sedangkan error terbesar mencapai 24,322% pada pukul 09.15. Hasil tersebut menunjukkan bahwa metode Backpropagation Feed Forward Neural Network memiliki potensi untuk digunakan dalam prediksi jangka pendek energi keluaran PLTS off-grid pada data pengujian yang digunakan. Namun, karena data penelitian hanya mencakup tiga hari pengamatan dan validasi dilakukan pada satu hari pengujian, hasil yang diperoleh masih bersifat studi awal (*pilot study*) dan belum dapat digeneralisasi untuk berbagai kondisi cuaca maupun musim. Penelitian lanjutan dengan data yang lebih panjang dan beragam diperlukan untuk mengevaluasi keandalan model secara lebih komprehensif.

Kata kunci: Plts Off-Grid, Energi Keluaran, Peramalan, Mape, Backpropagation Neural.

Prediction of Energy Output from An Off-Grid Solar Power Plant Based on Backpropagation Artificial Neural Network

Abstract

Off-grid Photovoltaic (PV) systems face challenges in maintaining energy availability due to fluctuations in power generation caused by changing weather conditions. Therefore, an energy forecasting method is required to estimate energy availability for future periods. This study aims to develop an energy output forecasting model for an off-grid PV system using the Backpropagation Feed Forward Neural Network method. The dataset consisted of PV energy output, ambient temperature, and solar irradiance collected from the off-grid PV system at IT-PLN over three consecutive days with a 15-minute sampling interval between 09:00 and 15:00. The neural network architecture comprised 75 input neurons representing energy, temperature, and irradiance data, one hidden layer, and 25 output neurons. The number of hidden neurons and learning rate were determined through a trial-and-error approach. The training results indicated that the optimal configuration was achieved with a learning rate of 0.2 and 20 hidden neurons, resulting in a Mean Squared Error (MSE) of 0.0000116. Model testing was conducted using data from the third day and produced a Mean Absolute Percentage Error (MAPE) of 2.6158%. The smallest prediction error was 0.00334% at 12:00, while the largest error reached 24.322% at 09:15. These findings indicate that the Backpropagation Feed Forward Neural Network method shows potential for short-term forecasting of off-grid PV energy output under the testing conditions used in this study. However, since the dataset covered only three days of observation and validation was performed on a single testing day, the results should be considered a preliminary pilot study and cannot yet be generalized across different weather conditions or seasonal variations. Further studies employing longer and more diverse datasets are required to evaluate the robustness and generalizability of the proposed model.

Keywords: off-grid solar power plant, energy output, prediction, MAPE, Backpropagation, Neural Network

How to Cite: Amba, M. I. ., Koerniawan, T. ., & Hardyanti, A. D. H. . (2026). Prediksi Energi Keluaran PLTS Off-Grid Berbasis Jaringan Syaraf Tiruan Backpropagation. *Journal of Authentic Research*, 5(3), 4003-4017. <https://doi.org/10.36312/2zvn8v57>



<https://doi.org/10.36312/jar.v3i2.2025>

Copyright© 2026, Amba et al.

This is an open-access article under the CC-BY-SA License.



PENDAHULUAN

Penggunaan teknologi Pembangkit Listrik Tenaga Surya (PLTS) merupakan salah satu solusi yang tepat dalam memanfaatkan potensi energi surya yang melimpah dan ramah lingkungan (Subandi dkk., 2015). PLTS banyak diminati karena fleksibilitas penerapannya pada berbagai sektor, mulai dari industri, gedung komersial, hingga rumah tinggal. Perkembangan pemanfaatan PLTS tersebut mendorong perlunya kajian yang lebih mendalam untuk memperoleh hasil yang komprehensif dari aspek teknis maupun operasional sistem (Ubaidillah dkk., 2012). Secara global, peningkatan kapasitas PV menunjukkan bahwa teknologi ini terus menjadi komponen penting dalam transisi energi; kapasitas kumulatif PV dunia dilaporkan telah melampaui 2.260 GW pada akhir 2024 (International Energy Agency Photovoltaic Power Systems Programme, 2025).

Salah satu konfigurasi PLTS yang banyak digunakan untuk daerah yang belum terjangkau jaringan listrik adalah PLTS off-grid. Sistem ini mengandalkan energi yang dihasilkan panel surya dan disimpan pada baterai untuk memenuhi kebutuhan beban listrik. Namun demikian, PLTS off-grid memiliki tantangan utama berupa ketidakpastian produksi energi akibat fluktuasi kondisi cuaca, terutama pada musim penghujan. Variasi intensitas radiasi matahari menyebabkan energi yang dihasilkan panel surya tidak selalu mampu memenuhi kebutuhan beban harian. Kondisi tersebut berpotensi menimbulkan defisit energi pada malam hari ketika tidak tersedia sumber energi alternatif. Oleh karena itu, diperlukan suatu metode yang mampu memprediksi ketersediaan energi secara akurat sehingga pengguna dapat merencanakan penggunaan energi dan menghindari terjadinya gangguan pasokan listrik. Pada sistem stand-alone dan hibrida, informasi prakiraan iradiasi atau energi dapat menjadi masukan penting untuk strategi pengendalian charge controller dan pengelolaan baterai (Mellit & Pavan, 2010).

Peramalan merupakan suatu kegiatan untuk memperkirakan kejadian atau kondisi yang akan terjadi pada masa mendatang berdasarkan informasi yang tersedia saat ini. Secara umum, metode peramalan dapat dibedakan menjadi metode konvensional dan metode berbasis kecerdasan buatan, salah satunya adalah Jaringan Syaraf Tiruan (JST). Metode konvensional umumnya memerlukan proses pemodelan matematis dan identifikasi sistem yang cukup kompleks untuk menggambarkan hubungan antara variabel masukan dan keluaran. Pada pendekatan tersebut, diperlukan asumsi serta aturan tertentu untuk menjelaskan perilaku sistem yang diamati (Kurniawan M.A., 2017). Dalam konteks PV, akurasi peramalan menjadi penting karena keluaran PV sangat bergantung pada variasi iklim, geografi, dan kondisi atmosfer setempat (Ahmed et al., 2020; Diagne et al., 2013).

Dalam praktiknya, data hasil pengukuran lapangan sering kali memiliki karakteristik nonlinier dan sulit direpresentasikan menggunakan fungsi matematis yang sederhana. Jaringan Syaraf Tiruan menawarkan solusi terhadap permasalahan tersebut karena mampu mempelajari pola hubungan antarvariabel secara langsung dari data tanpa memerlukan model matematis eksplisit. Melalui proses pelatihan, jaringan dapat mengenali karakteristik data historis dan menggunakannya untuk melakukan prediksi pada kondisi yang akan datang (Kurniawan M.A., 2017). Oleh karena itu, metode JST dinilai sesuai untuk digunakan dalam peramalan energi yang dihasilkan sistem photovoltaic. Kajian sebelumnya juga menunjukkan bahwa teknik kecerdasan buatan dapat digunakan untuk pemodelan, prediksi, dan pengendalian

sistem PV karena mampu menangani data nonlinier dan tidak lengkap (Mellit & Kalogirou, 2008; Voyant et al., 2017).

Data produksi energi PLTS termasuk ke dalam data deret waktu (time series) yang memiliki pola tertentu berdasarkan urutan waktu pengamatan. Salah satu model JST yang banyak digunakan untuk menangani permasalahan peramalan adalah Feed Forward Neural Network (FFNN). Model ini terdiri atas lapisan masukan (input layer), lapisan tersembunyi (hidden layer), dan lapisan keluaran (output layer), yang masing-masing tersusun atas sejumlah neuron untuk memproses informasi dan meminimalkan kesalahan prediksi (Kurniawan M.A., 2017). Kinerja FFNN dipengaruhi oleh berbagai parameter, seperti jumlah neuron pada hidden layer, bobot jaringan, serta algoritma pelatihan yang digunakan. Salah satu algoritma yang banyak diterapkan adalah backpropagation karena mampu mempercepat proses pembelajaran jaringan dan melakukan penyesuaian bobot secara efektif untuk menghasilkan tingkat error yang lebih rendah (Kurniawan M.A., 2017).

Beberapa penelitian terdahulu telah menerapkan metode kecerdasan buatan maupun analisis kinerja pada sistem PLTS. Aas Wasri Hasanah dkk. (2017) melakukan kajian terhadap kinerja PLTS off-grid 1 kWp di IT-PLN dengan fokus pada evaluasi parameter operasional sebelum dan sesudah pemeliharaan menggunakan data arus, tegangan, daya photovoltaic, dan iradiasi matahari (Hasanah dkk., 2017). Namun, penelitian tersebut belum membahas aspek peramalan energi yang dihasilkan sistem. Selanjutnya, Abderrazzak Elamim dkk. (2018) mengembangkan model prediksi daya keluaran photovoltaic menggunakan Feed Forward Neural Network dengan memanfaatkan data iradiasi matahari dan suhu lingkungan sebagai variabel masukan (Elamim dkk., 2018). Penelitian lain yang dilakukan oleh Can Wan dkk. (2015) membahas berbagai metode peramalan sumber daya surya dan daya photovoltaic untuk mendukung manajemen energi pada sistem smart grid (Can Wan dkk., 2015). Meskipun demikian, sebagian besar penelitian tersebut berfokus pada sistem skala besar, sistem terhubung jaringan (grid-connected), atau menggunakan data meteorologi sebagai variabel utama, sehingga belum secara spesifik mengkaji prediksi energi pada PLTS off-grid skala kecil berdasarkan data operasional lokal di lingkungan tropis.

Berdasarkan kajian literatur tersebut, masih terdapat celah penelitian (research gap) terkait pengembangan model prediksi energi pada PLTS off-grid skala kecil yang beroperasi pada kondisi iklim tropis dengan karakteristik iradiasi yang fluktuatif. Selain itu, penelitian yang memanfaatkan data historis energi hasil produksi PLTS lokal sebagai dasar prediksi jangka pendek masih relatif terbatas. Oleh karena itu, penelitian ini difokuskan pada pengembangan model prediksi energi listrik menggunakan metode Backpropagation Feed Forward Neural Network berdasarkan data produksi energi PLTS Off-Grid di IT-PLN. Kebutuhan data lokal menjadi relevan karena akurasi peramalan surya dipengaruhi oleh skala lokasi, horizon prediksi, dan ketersediaan data meteorologi setempat (Diagne et al., 2013; Yang et al., 2017).


Kontribusi penelitian ini terletak pada penerapan model prediksi jangka pendek selama 6 jam ke depan menggunakan data operasional lokal PLTS Off-Grid IT-PLN sebagai studi awal (pilot study) untuk mendukung pengelolaan energi pada sistem PLTS skala kecil. Berbeda dengan penelitian sebelumnya yang umumnya berfokus pada prediksi daya keluaran berbasis parameter meteorologi atau aplikasi pada sistem skala besar, penelitian ini menitikberatkan pada prediksi energi yang

tersedia bagi pengguna PLTS off-grid sebagai dasar pengambilan keputusan penggunaan beban listrik harian. Dengan demikian, hasil penelitian diharapkan dapat memberikan informasi mengenai kemampuan metode Backpropagation Feed Forward Neural Network dalam memprediksi energi PLTS pada kondisi iradiasi yang berubah-ubah.

Berdasarkan latar belakang tersebut, tujuan penelitian ini adalah: (1) membangun model prediksi energi listrik PLTS Off-Grid menggunakan metode Backpropagation Feed Forward Neural Network, (2) menentukan konfigurasi jaringan yang mampu menghasilkan tingkat kesalahan prediksi yang rendah, dan (3) mengevaluasi akurasi hasil prediksi energi terhadap data aktual pada horizon prediksi 6 jam.

METODE

Penelitian ini memanfaatkan fasilitas Pembangkit Listrik Tenaga Surya (PLTS) off-grid yang berada di Institut Teknologi PLN (IT-PLN) sebagai lokasi pengambilan data. Penelitian dilakukan melalui pengukuran langsung terhadap parameter operasional sistem PLTS untuk memperoleh data yang dibutuhkan dalam pengembangan model prediksi energi. Pengambilan data dilaksanakan pada tanggal 16–18 Juni 2021 selama tiga hari berturut-turut. Penelitian ini berangkat dari permasalahan operasional PLTS off-grid, yaitu kebutuhan untuk memperkirakan produksi energi pada periode waktu tertentu guna mendukung pengelolaan energi yang lebih efisien, mengurangi risiko kekurangan energi saat kondisi cuaca buruk, serta mengoptimalkan pemanfaatan energi yang tersedia. Alur penelitian dalam pengembangan model prakiraan energi PLTS ditunjukkan pada Gambar 1. Diagram alir tersebut menggambarkan tahapan penelitian mulai dari identifikasi masalah, studi pustaka, pengumpulan data energi, suhu, dan iradiasi, pre-processing dan normalisasi data, pembentukan arsitektur jaringan, proses pelatihan, pengujian, sampai implementasi model prediksi. Dengan alur ini, setiap tahap pengolahan data dan evaluasi model dilakukan secara sistematis.



Gambar 1. Diagram Alir Model Prakiraan Energi PLTS

Penelitian ini merupakan studi awal (*pilot study*) yang bertujuan untuk mengevaluasi potensi penerapan metode Backpropagation Feed Forward Neural Network dalam prediksi energi PLTS off-grid berbasis data lokal. Oleh karena itu, hasil yang diperoleh lebih diarahkan untuk menunjukkan kelayakan awal metode dibandingkan menghasilkan model prediksi yang telah teruji pada berbagai kondisi cuaca dan musim. Keterbatasan utama penelitian ini adalah jumlah data yang relatif terbatas sehingga hasil penelitian perlu diinterpretasikan secara hati-hati dan dapat dikembangkan lebih lanjut menggunakan data dengan rentang waktu yang lebih panjang.

Data yang digunakan diperoleh melalui pengamatan langsung pada sistem PLTS off-grid IT-PLN setiap 15 menit mulai pukul 09.00 hingga 15.00 WIB selama tiga hari berturut-turut. Variabel yang dikumpulkan meliputi energi listrik yang dihasilkan PLTS, suhu lingkungan, dan iradiasi matahari. Pemilihan ketiga variabel tersebut didasarkan pada hubungan fisik terhadap performa sistem photovoltaic. Iradiasi matahari merupakan faktor utama yang menentukan besarnya energi yang dapat dihasilkan panel surya, sedangkan suhu lingkungan berpengaruh terhadap efisiensi modul photovoltaic. Adapun energi historis digunakan sebagai representasi

kondisi operasional sistem pada waktu sebelumnya sehingga dapat membantu jaringan syaraf tiruan mengenali pola perubahan energi dari waktu ke waktu.


Perlu dicatat bahwa data energi yang digunakan berasal dari sistem PLTS off-grid yang terintegrasi dengan baterai dan charge controller. Oleh karena itu, energi yang diamati tidak hanya dipengaruhi oleh kondisi cuaca dan performa modul photovoltaic, tetapi juga dipengaruhi oleh karakteristik sistem penyimpanan energi serta kondisi operasional sistem secara keseluruhan. Dengan demikian, model yang dikembangkan pada penelitian ini memprediksi energi keluaran sistem PLTS off-grid, bukan semata-mata daya keluaran modul photovoltaic.

Sebelum digunakan dalam proses pelatihan jaringan, seluruh data melewati tahap *pre-processing*. Pada tahap ini dilakukan normalisasi data ke dalam rentang 0-1 untuk menghindari dominasi variabel tertentu selama proses pelatihan jaringan serta meningkatkan stabilitas proses pembelajaran. Transformasi dilakukan tanpa mengubah informasi yang terkandung dalam data asli. Persamaan normalisasi yang digunakan ditunjukkan pada Persamaan (1).

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (BA - BB) + BB$$

Data yang telah dinormalisasi kemudian dibagi menjadi data pelatihan (*training*) dan data pengujian (*testing*). Pada penelitian ini, data hari pertama digunakan sebagai pasangan input-target untuk proses pelatihan jaringan, sedangkan data hari kedua digunakan sebagai data masukan untuk menghasilkan prediksi yang selanjutnya dibandingkan dengan data aktual hari ketiga. Dengan demikian, model diuji menggunakan data yang tidak digunakan pada proses pelatihan. Namun demikian, karena jumlah data yang tersedia terbatas, penelitian ini belum menerapkan metode validasi silang (*cross validation*) maupun pembagian data *training-validation-testing* yang lebih komprehensif sebagaimana umum dilakukan pada penelitian machine learning skala besar.

Struktur jaringan syaraf tiruan yang digunakan adalah Feed Forward Neural Network dengan algoritma pelatihan backpropagation. Arsitektur jaringan terdiri atas tiga lapisan, yaitu lapisan input, lapisan tersembunyi (*hidden layer*), dan lapisan output. Lapisan input terdiri atas 75 neuron yang merepresentasikan 25 data energi historis, 25 data suhu historis, dan 25 data iradiasi historis. Lapisan output terdiri atas 25 neuron yang merepresentasikan hasil prediksi energi pada periode berikutnya. Jumlah neuron pada hidden layer ditentukan melalui proses *trial and error* untuk memperoleh konfigurasi jaringan yang menghasilkan tingkat kesalahan prediksi paling rendah.



Gambar 2. Struktur Jaringan Syaraf Tiruan

Fungsi aktivasi yang digunakan pada hidden layer adalah sigmoid biner dengan rentang keluaran 0–1. Seluruh bobot awal jaringan diinisialisasi secara acak oleh perangkat lunak MATLAB 2017a sebelum proses pelatihan dimulai. Algoritma pembelajaran yang digunakan adalah backpropagation dengan pendekatan pembelajaran terawasi (*supervised learning*), di mana jaringan melakukan penyesuaian bobot secara iteratif berdasarkan error yang dihasilkan antara keluaran jaringan dan target yang diinginkan.

Penentuan parameter jaringan dilakukan menggunakan metode *trial and error* dengan variasi jumlah neuron hidden layer mulai dari 2 hingga 50 neuron dengan interval 2 neuron. Selain itu, nilai *learning rate* divariasikan pada rentang 0,01 hingga 0,50 untuk memperoleh kombinasi parameter yang menghasilkan performa terbaik. Evaluasi performa model dilakukan menggunakan indikator Mean Squared Error (MSE) dan Mean Absolute Percentage Error (MAPE).


Untuk meningkatkan transparansi hasil penelitian, seluruh kombinasi parameter yang diuji perlu dilaporkan secara sistematis dalam bentuk tabel perbandingan sehingga proses pemilihan parameter optimal dapat diverifikasi. Tabel tersebut memuat informasi mengenai jumlah neuron hidden layer, nilai *learning rate*, jumlah epoch pelatihan, nilai MSE pelatihan, dan nilai MAPE pengujian.

Pada penelitian ini diperoleh konfigurasi terbaik berupa hidden layer sebanyak 20 neuron dan *learning rate* sebesar 0,2 yang menghasilkan nilai MSE terkecil. Namun, karena jumlah data pelatihan relatif terbatas, hasil tersebut perlu dipandang sebagai hasil awal yang masih memerlukan validasi menggunakan data yang lebih banyak dan mencakup berbagai kondisi cuaca untuk memastikan kemampuan generalisasi model dalam aplikasi nyata.

HASIL DAN PEMBAHASAN

Hasil Pengembangan Model Jaringan Syaraf Tiruan

Model Jaringan Syaraf Tiruan (JST) yang dikembangkan pada penelitian ini menggunakan arsitektur *multilayer feed forward neural network* dengan metode pembelajaran terawasi (*supervised learning*). Pada proses pelatihan, jaringan diberikan pasangan data masukan (*input*) dan target (*output*) untuk mempelajari hubungan antara variabel energi, suhu lingkungan, dan iradiasi matahari terhadap energi yang dihasilkan sistem PLTS off-grid.



Gambar 3. Blok Diagram Model Jaringan Syaraf Tiruan

Pemilihan variabel masukan didasarkan pada karakteristik fisik sistem photovoltaic. Energi yang dihasilkan panel surya dipengaruhi secara langsung oleh intensitas iradiasi matahari yang diterima permukaan modul, sedangkan suhu lingkungan digunakan sebagai variabel pendukung yang berkaitan dengan kondisi termal sistem. Oleh karena itu, data energi, suhu, dan iradiasi digunakan secara bersamaan sebagai masukan model JST.

Tabel 1. Input Model Jaringan


Input Model JST (X_n)	Keterangan
$X_1, \dots, X_{25}$	Data energi hari ini per 15 menit selama 6 jam, 25 neuron input.
$X_{26}, \dots, X_{50}$	Data suhu udara hari ini per 15 menit selama 6 jam, 25 neuron input.
$X_{51}, \dots, X_{75}$	Data iradiasi hari ini per 15 menit selama 6 jam, 25 neuron input.

Tabel 2. Output Model Jaringan


Output Model JST (Y_n)	Keterangan
$Y_1, \dots, Y_{25}$	Keluaran model JST berupa energi besok (prakiraan) per 15 menit selama 6 jam, 25 neuron output

Data pengukuran kemudian dibagi menjadi data pelatihan dan data pengujian. Data energi, suhu, dan iradiasi pada hari pertama digunakan sebagai input pelatihan dengan target energi hari kedua. Selanjutnya, data hari kedua digunakan sebagai input pengujian untuk memprediksi energi pada hari ketiga. Dengan pendekatan tersebut, model diuji menggunakan data yang tidak digunakan selama proses pelatihan.

Proses pelatihan dilakukan menggunakan algoritma backpropagation dengan variasi jumlah neuron pada *hidden layer* dan nilai *learning rate*. Berdasarkan hasil *trial and error*, konfigurasi terbaik diperoleh pada jumlah neuron *hidden layer* sebanyak 20 neuron dan *learning rate* sebesar 0,2. Konfigurasi tersebut menghasilkan nilai Mean Squared Error (MSE) pelatihan sebesar 0,0000116 pada epoch ke-16.



Gambar 4. Progress Neural Network Training



Gambar 5. All Regression JST


Untuk meningkatkan transparansi hasil penelitian, parameter pelatihan yang telah diuji sebaiknya dilaporkan secara lengkap dalam bentuk tabel yang memuat kombinasi jumlah neuron, *learning rate*, jumlah epoch, MSE pelatihan, serta nilai error pengujian.

Tabel 3. Tabel Perbandingan Energi Peramalan dengan Pengukuran

NO	Jam	Suhu (oC)	Iradiasi (W/m2)	Energi Real Pengukuran (Wh)	Energi Peramalan (Wh)	Nilai Selisih (Wh)	Error JST (%)
1	09.00	29	331,7	2,412	2,406749	0,005251	0,2182
2	09.15	30	454,4	2,25675	2,982043	-0,72529	24,322
3	09.30	31	491,6	4,5645	4,396822	0,167678	3,8136
4	09.45	32	593,7	4,263	4,287116	-0,02412	0,563
5	10.00	34	812,2	3,294	3,357567	-0,06357	1,893
6	10.15	33	807,1	1,513	1,524929	-0,01193	0,782
7	10.30	34	877,8	1,0595	1,075491	-0,01599	1,487
8	10.45	34	882,7	0,8635	0,95342	-0,08992	9,431
9	11.00	33	825	0,828	0,766778	0,061222	7,9843
10	11.15	30	433	1,027	0,945014	0,081986	8,6756
11	11.30	29	302,3	2,01025	1,912665	0,097585	5,102
12	11.45	26	74,4	4,45	4,448317	0,001683	0,0378
13	12.00	26	77,5	4,485	4,484851	0,000149	0,00334
14	12.15	26	69,6	5,841	5,857193	-0,01619	0,276
15	12.30	24	45,9	3,79225	3,909862	-0,11761	3,008
16	12.45	25	19,8	3,864	3,85908	0,00492	0,1275
17	13.00	25	59,4	5,57925	5,578552	0,000698	0,0125
18	13.15	25	54,7	6,3985	6,405214	-0,00671	0,105
19	13.30	27	130	2,4645	2,331746	0,132754	5,6933
20	13.45	30	150,3	2,695	2,682845	0,012155	0,00453
21	14.00	27	125,6	1,99875	2,013823	-0,01507	0,748
22	14.15	27	124,5	2,871	2,875187	-0,00419	0,146
23	14.30	28	169,2	3,762	3,99952	-0,23752	5,939
24	14.45	27	170,5	2,412	2,564387	-0,15239	5,942
25	15.00	27	165,5	2,89275	2,902563	-0,00981	0,338

Hasil Pengujian Model

Tahap pengujian dilakukan menggunakan data energi, suhu, dan iradiasi tanggal 17 Juni 2021 sebagai data masukan, sedangkan data energi tanggal 18 Juni 2021 digunakan sebagai target pengujian. Hasil prediksi energi kemudian dibandingkan dengan data aktual hasil pengukuran.



Gambar 6. Kurva Energi Real dan Peramalan

Secara keseluruhan diperoleh nilai Mean Absolute Percentage Error (MAPE) sebesar 2,6158%. Nilai tersebut menunjukkan bahwa model mampu menghasilkan prediksi yang relatif dekat dengan data aktual pada data pengujian yang digunakan. Namun demikian, interpretasi terhadap nilai MAPE tersebut perlu dilakukan secara hati-hati mengingat data pelatihan dan pengujian yang digunakan masih sangat terbatas, yaitu hanya mencakup periode pengamatan selama tiga hari dengan satu hari pengujian. Oleh karena itu, nilai MAPE yang rendah belum dapat digunakan sebagai bukti bahwa model memiliki kemampuan generalisasi yang baik pada kondisi cuaca dan musim yang berbeda.

Dalam penelitian awal ini, data pada pukul 09.15 memiliki nilai error tertinggi sebesar 24,322%. Pada penelitian sebelumnya, data tersebut dianggap sebagai *outlier* dan tidak dimasukkan dalam perhitungan error rata-rata. Namun, secara metodologis penghapusan data tersebut memerlukan justifikasi statistik atau teknis yang kuat. Oleh karena itu, seluruh data pengujian sebaiknya tetap dilaporkan agar pembaca dapat menilai performa model secara objektif.

Untuk meningkatkan transparansi hasil, penelitian ini merekomendasikan pelaporan dua nilai MAPE, yaitu MAPE yang dihitung menggunakan seluruh data pengujian dan MAPE setelah penghapusan data yang teridentifikasi sebagai *outlier*. Dengan demikian, pengaruh data tersebut terhadap performa model dapat dievaluasi secara lebih jelas.

Analisis Error Prediksi

Error terbesar yang terjadi pada pukul 09.15 menunjukkan bahwa model masih mengalami kesulitan dalam memprediksi kondisi tertentu secara akurat. Pada waktu tersebut nilai energi aktual sebesar 2,25675 Wh, sedangkan hasil prediksi mencapai 2,982043 Wh. Perbedaan yang relatif besar ini diduga berkaitan dengan perubahan kondisi lingkungan yang tidak sepenuhnya dapat ditangkap oleh model.

Salah satu kemungkinan penyebabnya adalah fluktuasi iradiasi matahari akibat pergerakan awan pada pagi hari. Pada sistem photovoltaic, perubahan iradiasi yang terjadi secara cepat dapat menyebabkan perubahan energi keluaran yang signifikan dalam waktu singkat. Karena model dikembangkan menggunakan jumlah data yang sangat terbatas, kemampuan jaringan dalam mempelajari pola perubahan mendadak tersebut menjadi terbatas.

Selain itu, energi yang diamati pada penelitian ini berasal dari sistem PLTS off-grid yang terhubung dengan baterai dan charge controller. Dengan demikian, energi yang terukur tidak hanya dipengaruhi oleh kondisi cuaca, tetapi juga oleh dinamika sistem penyimpanan energi. Faktor-faktor tersebut berpotensi menyebabkan hubungan yang lebih kompleks antara variabel input dan output sehingga meningkatkan tingkat kesalahan prediksi pada kondisi tertentu.

Untuk memperoleh gambaran performa model yang lebih komprehensif, penelitian selanjutnya disarankan melaporkan metrik evaluasi tambahan seperti Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Squared Error (MSE) pengujian sehingga karakteristik error model dapat dianalisis lebih mendalam.

Pembahasan

Hasil penelitian menunjukkan bahwa variabel iradiasi matahari memiliki peran dominan terhadap energi yang dihasilkan sistem PLTS. Secara fisik, peningkatan iradiasi matahari akan meningkatkan jumlah energi radiasi yang diterima modul photovoltaic sehingga daya keluaran cenderung meningkat. Sebaliknya, suhu yang semakin tinggi dapat menyebabkan penurunan efisiensi konversi energi pada modul surya. Dalam penelitian ini digunakan suhu lingkungan sebagai salah satu variabel input karena data suhu modul tidak tersedia selama proses pengukuran. Oleh karena itu, suhu lingkungan hanya dapat digunakan sebagai pendekatan terhadap kondisi termal sistem dan belum sepenuhnya merepresentasikan suhu kerja modul photovoltaic. Temuan ini konsisten dengan literatur yang menempatkan iradiasi sebagai masukan utama kinerja PV dan suhu modul sebagai faktor yang memengaruhi efisiensi serta daya keluaran sistem (Skoplaki & Palyvos, 2009; International Electrotechnical Commission, 2021).

Dari sisi metode, penggunaan Backpropagation Feed Forward Neural Network memberikan keuntungan karena mampu mempelajari hubungan nonlinier antara energi, suhu, dan iradiasi tanpa memerlukan model matematis yang kompleks. Namun demikian, performa jaringan syaraf tiruan sangat dipengaruhi oleh jumlah dan keragaman data yang digunakan selama proses pelatihan. Dengan jumlah data yang terbatas, model berpotensi mengalami *overfitting*, yaitu kondisi ketika model mampu mengenali pola data pelatihan dengan baik tetapi kurang mampu melakukan generalisasi pada data baru. Karena itu, penggunaan data yang lebih panjang dan beragam diperlukan agar jaringan dapat mempelajari variasi kondisi cerah, berawan, dan transisi cuaca dengan lebih baik, sebagaimana ditekankan dalam kajian machine learning untuk peramalan radiasi surya (Voyant et al., 2017).

Selain itu, penelitian ini belum melakukan perbandingan dengan metode prediksi lain seperti *persistence model*, *moving average*, regresi linier, maupun ARIMA. Oleh karena itu, belum dapat disimpulkan bahwa model Backpropagation Feed Forward Neural Network merupakan metode terbaik untuk kasus yang diteliti. Penelitian lanjutan perlu melakukan evaluasi komparatif terhadap beberapa metode prediksi sehingga keunggulan relatif model dapat diidentifikasi secara lebih objektif. Dalam studi peramalan PV, model pembanding sederhana seperti *persistence* atau model statistik dasar sering digunakan sebagai baseline untuk menilai peningkatan kinerja model berbasis kecerdasan buatan (Ahmed et al., 2020; Yang et al., 2017).

Dari sisi praktis, hasil prediksi energi berpotensi digunakan sebagai informasi pendukung dalam pengelolaan energi pada sistem PLTS off-grid. Informasi mengenai perkiraan energi yang tersedia dapat membantu pengguna dalam merencanakan penggunaan beban listrik serta mengoptimalkan pemanfaatan kapasitas baterai. Meskipun demikian, penelitian ini belum melakukan simulasi manajemen beban maupun analisis kapasitas baterai secara langsung. Oleh karena itu, klaim bahwa prediksi energi dapat mencegah defisit energi masih bersifat konseptual dan memerlukan penelitian lanjutan yang mengintegrasikan model prediksi dengan strategi pengelolaan energi pada sistem PLTS off-grid. Pada sistem stand-alone, informasi prakiraan juga dapat mendukung pengaturan pengisian baterai dan prioritas beban, sehingga hasil prediksi perlu dihubungkan dengan strategi operasi sistem sebelum digunakan sebagai dasar keputusan praktis (Mellit & Pavan, 2010).

KESIMPULAN

Penelitian ini mengembangkan model prediksi energi keluaran PLTS off-grid menggunakan metode Backpropagation Feed Forward Neural Network dengan memanfaatkan data energi, suhu lingkungan, dan iradiasi matahari sebagai variabel masukan. Tahapan pengembangan model dimulai dari pengumpulan data selama tiga hari berturut-turut, pemisahan data pelatihan dan pengujian, pembentukan arsitektur jaringan yang terdiri atas lapisan input, satu hidden layer, dan lapisan output, serta proses pelatihan menggunakan metode trial and error untuk menentukan parameter jaringan yang optimal. Hasil pelatihan menunjukkan bahwa konfigurasi terbaik diperoleh pada nilai learning rate sebesar 0,2 dan jumlah neuron pada hidden layer sebanyak 20 neuron dengan nilai MSE pelatihan sebesar 0,0000116.

Hasil pengujian menunjukkan bahwa model mampu menghasilkan prediksi energi yang mengikuti pola energi aktual pada data pengujian. Nilai error terkecil diperoleh pada pukul 12.00 sebesar 0,00334%, sedangkan nilai error terbesar terjadi pada pukul 09.15 sebesar 24,322%. Secara keseluruhan diperoleh nilai Mean Absolute Percentage Error (MAPE) sebesar 2,6158%. Nilai tersebut menunjukkan bahwa model memiliki potensi untuk digunakan dalam memprediksi energi keluaran PLTS pada data pengujian yang digunakan dalam penelitian ini.

Namun demikian, hasil penelitian perlu diinterpretasikan secara hati-hati karena penelitian hanya menggunakan data pengamatan selama tiga hari dengan validasi yang dilakukan pada satu hari pengujian. Kondisi tersebut menyebabkan kemampuan generalisasi model terhadap variasi cuaca, musim, dan kondisi operasional PLTS yang lebih beragam belum dapat dipastikan. Selain itu, keberadaan data dengan error tinggi pada beberapa waktu pengamatan menunjukkan bahwa model masih memiliki keterbatasan dalam menangkap perubahan kondisi lingkungan yang terjadi secara cepat.

Oleh karena itu, penelitian ini lebih tepat dipandang sebagai studi awal (*pilot study*) yang menunjukkan potensi penggunaan jaringan syaraf tiruan backpropagation untuk prediksi energi PLTS off-grid. Penelitian lanjutan perlu menggunakan data historis yang lebih panjang, mencakup berbagai kondisi cuaca dan musim, menerapkan prosedur validasi yang lebih komprehensif, serta membandingkan performa model dengan metode prediksi lain seperti persistence model, moving average, regresi linier, maupun ARIMA. Dengan demikian, keandalan dan kemampuan generalisasi model dapat dievaluasi secara lebih akurat sebelum diterapkan sebagai dasar pengambilan keputusan dalam pengelolaan energi pada sistem PLTS off-grid.

REFERENSI

- Ahmed, R., Sreeram, V., Mishra, Y., & Arif, M. D. (2020). A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124, 109792. <https://doi.org/10.1016/j.rser.2020.109792>
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2018). *Neural Networks Toolbox: User's guide*. The MathWorks, Inc.
- Chiras, D. D. (2019). *Solar electricity basics: Powering your home or office with solar energy*. Library and Archives Canada.
- Diagne, M., David, M., Lauret, P., Boland, J., & Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids.

- Renewable and Sustainable Energy Reviews*, 27, 65–76.
<https://doi.org/10.1016/j.rser.2013.06.042>
- Elamim, A. (2018). Photovoltaic output power forecast using artificial neural networks. *Journal of Theoretical and Applied Information Technology*, 96(15), 5116–5126.
- Fausett, L. (1994). *Fundamentals of neural networks: Architectures, algorithms, and applications*. Prentice-Hall.
- Hasim, A. (2008). *Prakiraan beban listrik Kota Pontianak dengan jaringan syaraf tiruan (artificial neural network)* (Thesis, Institut Pertanian Bogor).
<https://repository.ipb.ac.id/handle/123456789/41400>
- Heizer, J., & Render, B. (2011). *Operations management* (10th ed.). Pearson.
- International Electrotechnical Commission. (2021). *IEC 61724-1:2021 Photovoltaic system performance – Part 1: Monitoring*.
<https://webstore.iec.ch/en/publication/65561>
- International Energy Agency Photovoltaic Power Systems Programme. (2025). *Trends in photovoltaic applications 2025*. https://iea-pvps.org/trends_reports/trends-2025/
- Kania, D. (2017). *Analisis pengukuran tegangan dan arus untuk menjaga efisiensi output pembangkit listrik tenaga surya* (Skripsi, Institut Teknologi PLN).
<http://repository.itpln.ac.id/>
- Koerniawan, T., & Hasanah, A. W. (2018). Kajian sistem kinerja PLTS off-grid 1 kWp di STT-PLN. *Jurnal Energi & Kelistrikan*, 10(1), 38–44.
- Kurniawan, M. A. (2017). *Penerapan metode feed forward neural network (FFNN) backpropagation untuk meramalkan harga saham* (Skripsi, Universitas Negeri Semarang). <http://lib.unnes.ac.id/32184/>
- Kusumadewi, S. (2004). *Membangun jaringan syaraf tiruan dengan MATLAB dan Excel link*. Graha Ilmu.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan aplikasi peramalan* (Vol. 1, edisi ke-2, U. S. Ardiyanto & A. Basith, Trans.). Erlangga.
- Mellit, A., & Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. *Progress in Energy and Combustion Science*, 34(5), 574–632.
<https://doi.org/10.1016/j.pecs.2008.01.001>
- Mellit, A., & Pavan, A. M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*, 84(5), 807–821.
<https://doi.org/10.1016/j.solener.2010.02.006>
- Siang, J. J. (2005). *Jaringan syaraf tiruan dan pemrogramannya menggunakan MATLAB*. Penerbit ANDI.
- Skoplaki, E., & Palyvos, J. A. (2009). On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations. *Solar Energy*, 83(5), 614–624. <https://doi.org/10.1016/j.solener.2008.10.008>
- Subandi, S. H. (2015). Pembangkit listrik tenaga matahari sebagai penggerak pompa air dengan menggunakan solar cell. *Jurnal Teknologi Technoscienza*.
- Ubaidillah, U., Suyitno, S., Juwana, J., & Wibawa, E. (2012). Pengembangan piranti hibrid termoelektrik-sel surya sebagai pembangkit listrik rumah tangga. *Jurnal Litbang Provinsi Jawa Tengah*.

- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., & Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569–582. <https://doi.org/10.1016/j.renene.2016.12.095>
- Wan, C., et al. (2015). Photovoltaic and solar power forecasting for smart grid energy management. *CSEE Journal of Power and Energy Systems*, 1(4), 38–46.
- Yang, D., Kleissl, J., Gueymard, C. A., Pedro, H. T. C., & Coimbra, C. F. M. (2017). *History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining*. Singapore Institute of Manufacturing Technology.