

BAB III

METODE PENELITIAN

3.1. Jenis dan Pendekatan Penelitian

3.1.1. Jenis Penelitian: Eksperimen

Penelitian ini termasuk dalam kategori penelitian eksperimen kuantitatif berbasis komputasi yang bertujuan untuk mengembangkan dan mengevaluasi model prediksi daya keluaran panel surya menggunakan Jaringan Syaraf Tiruan (*Artificial Neural Network*, atau ANN). Data yang digunakan berupa data numerik hasil pengukuran cuaca lokal yang diperoleh dari *Global Solar Atlas* (GSA). Seluruh proses pengolahan, pelatihan, dan evaluasi model dilakukan menggunakan perangkat lunak MATLAB. Hasil eksperimen dievaluasi menggunakan parameter kuantitatif seperti *Mean Squared Error* (MSE), *Root Mean Square Error* (RMSE), dan Koefisien Determinasi (R^2).

3.1.2. Pendekatan Penelitian

Pendekatan yang digunakan adalah komputasi-prediktif, yang melibatkan pembuatan model matematika berdasarkan algoritma kecerdasan buatan (*Artificial Intelligence*) untuk memprediksi daya keluaran panel surya berdasarkan data lokal. Simulasi dilakukan menggunakan program lunak MATLAB/Simulink untuk menganalisis data numerik seperti iradiasi, suhu lingkungan, suhu modul PV, dan waktu pengukuran. Model ANN dengan komparasi 2 *Layer* dan 3 *Layer*, 32 *neuron* dan 64 *neuron* yang dikembangkan untuk menganalisis pola nonlinier antara *input* dan *output* sehingga dapat menghasilkan prediksi daya keluaran yang akurat dan representatif terhadap kondisi aktual di lapangan.

3.2. Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada bulan September 2025 hingga Januari 2026 di Laboratorium Terpadu, Universitas Muhammadiyah Surabaya, yang secara geografis terletak pada koordinat 7,25° LS dan 112,75° BT. Pada penelitian ini dilakukan untuk mengumpulkan data cuaca lokal, merancang dan mensimulasikan model ANN di MATLAB/Simulink, lalu menganalisis hasil prediksi daya keluaran panel surya untuk menilai tingkat akurasinya.

3.3. Jadwal Penelitian

Tabel 3. 1 Jadwal Penelitian

No	Kegiatan Penelitian	Bulan															
		September				Oktober				November				Desember			
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1.	Studi Literatur & Pengumpulan Data Cuaca																
2	Perancangan dan Permodelan Sistem ANN																
3	Pelatihan & Validasi Model ANN (<i>Training-Testing</i>)																
4	Analisis Hasil dan Evaluasi Kinerja																
5	Penyusunan dan Revisi Laporan Skripsi																

3.4. Spesifikasi Dataset *Global Solar Atlas*

3.4.1. Sumber Data Cuaca Penelitian

Data cuaca dan parameter meteorologi yang digunakan dalam penelitian ini sepenuhnya bersumber dari database makro platform *Global Solar Atlas* (GSA) 2025. Data ditarik secara spesifik menggunakan koordinat geografis lokasi penelitian guna memastikan akurasi karakteristik iklim lokal. Spesifikasi teknis, resolusi, serta karakteristik dataset yang diekstraksi dijabarkan secara rinci sebagai berikut: [11]

a. Karakteristik Spesifikasi Dataset GSA :

Dataset yang digunakan memiliki karakteristik sebagai berikut:

- Sumber Database : *Global Solar Atlas* (GSA) 2025
- Koordinat Pengambilan : 7,259882° LS dan 112,789721° BT (Gedung Laboratorium Terpadu)

- Rentang Waktu Data: Januari – Desember 2025 (1 tahun penuh)
- Resolusi Temporal: *Hourly* (Profil rata-rata harian per jam dalam tiap bulan)
- Resolusi Spasial: ± 1 km
- Format Ekstensi File: *Comma-Separated Values* (.csv)
- Total Sampel (N) : 288 *record* data

Pemilihan resolusi *hourly* dilakukan karena *irradiance* dan suhu modul merupakan parameter yang sangat fluktuatif, terutama pada wilayah tropis. Resolusi yang lebih rapat diperlukan agar model ANN mampu belajar pola perubahan yang cepat tersebut dan menghasilkan prediksi daya yang akurat. Pendekatan resolusi *hourly* juga sejalan dengan penelitian Mahendra et al. (2021) yang menggunakan data *irradiance* dan parameter suhu harian untuk pelatihan model ANN.

b. Logika Perhitungan Matematis Dataset

Penetapan jumlah sampel sebesar 288 *record* data didasarkan pada metode representasi data meteorologi standar yang dikenal sebagai Profil Rata-Rata Jam-ke-Jam Bulanan (*Monthly Average Hourly Profile*). Formulasi perhitungan total ukuran data (N) dirumuskan melalui Persamaan (3.1):

$$N = t \times M \quad (12)$$

Dimana:

- t = resolusi waktu pengamatan dalam satu siklus harian penuh (24 titik jam).
- M = jumlah periode bulan dalam satu tahun pengamatan (12 bulan).

Melalui substitusi nilai parameter tersebut, diperoleh kalkulasi *linear* sebagai berikut:

$$N = 24 \times 12 = 288 \text{ record data}$$

Struktur penyusunan baris dan kolom dataset di dalam ruang komputasi MATLAB diatur dalam bentuk matriks dua dimensi berukuran 24×12

3.4.2. Parameter yang Digunakan

Tabel 3. 2 Parameter Dataset GSA

No	Parameter	Satuan	Keterangan
1	<i>Global Horizontal Irradiance (GHI)</i>	W/m ²	Sumber energi utama PV
2	<i>Ambient Temperature</i>	°C	Suhu Lingkungan
3	<i>Module/Cell Temperature</i>	°C	Menentukan V_{oc} & P_{max}
4	<i>Timestamp</i>	-	Penanda waktu pengukuran

Dataset yang digunakan dalam penelitian ini terdiri atas empat parameter utama, yaitu:

- ***Global Horizontal Irradiance (GHI) [W/m²]***
Merupakan komponen energi radiasi matahari yang diterima secara horizontal dan menjadi penentu utama besarnya arus keluaran panel PV.
- ***Ambient Temperature [°C]***
Mempengaruhi suhu modul secara tidak langsung melalui proses pemanasan lingkungan.
- ***Module/Cell Temperature [°C]***
Variabel paling signifikan yang mempengaruhi tegangan *open-circuit* (V_{oc}) dan daya maksimum (P_{max}). Peningkatan suhu modul umumnya menurunkan performa modul PV.
- ***Timestamp (Waktu Pengukuran)***
Digunakan sebagai penanda urutan data untuk *aligning*, *Preprocessing*, dan pelatihan ANN berbasis *time-series*.

Pemilihan ketiga parameter cuaca utama *irradiance*, suhu lingkungan, dan suhu modul merujuk pada temuan Mahendra et al. (2021), yang menunjukkan bahwa ketiga variabel tersebut merupakan faktor paling dominan dalam menentukan daya keluaran panel surya berdasarkan model ANN. Parameter *timestamp* diperlukan untuk menjaga integritas data sesuai urutan waktu sebelum dilakukan normalisasi dan pembagian data *training-testing*.

Average hourly profiles


Direct normal irradiation [Wh/m²]

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
0 - 1												
1 - 2												
2 - 3												
3 - 4												
4 - 5												
5 - 6	15	6	6	11	12	9		14	41	69	62	22
6 - 7	143	123	143	181	210	220	209	270	340	284	218	134
7 - 8	225	234	280	306	364	377	427	470	510	436	330	217
8 - 9	306	317	351	387	463	473	536	591	628	545	399	291
9 - 10	356	352	402	469	538	551	615	680	702	620	468	335
10 - 11	354	373	448	525	599	600	671	737	745	651	497	345
11 - 12	336	353	442	525	607	623	687	753	743	637	460	321
12 - 13	295	327	395	460	566	609	675	736	713	588	373	262
13 - 14	238	268	309	349	488	548	624	687	645	469	277	198
14 - 15	164	181	214	242	371	441	540	591	539	388	199	127
15 - 16	108	128	140	172	261	334	419	457	402	278	144	80
16 - 17	80	87	93	106	116	179	239	273	228	140	82	53
17 - 18	24	28	13	7		3	14	18	12	5	4	6
18 - 19												
19 - 20												
20 - 21												
21 - 22												
22 - 23												
23 - 24												
Sum	2,644	2,775	3,237	3,741	4,595	4,969	5,656	6,277	6,247	5,110	3,514	2,391

Gambar 3. 1 Direct normal irradiation



3.5. Diagram Alir Metode Penelitian



Gambar 3. 2 Diagram Alir Metode Penelitian

Penjelasan Diagram Alir Metode Penelitian :


1. Memulai dengan langkah awal untuk memastikan arah penelitian sesuai dengan permasalahan yang akan diselesaikan.
2. Identifikasi Masalah dan Studi Literatur bertujuan untuk mengidentifikasi permasalahan serta meninjau teori dan penelitian terdahulu terkait *Artificial Neural Network* (ANN) sebagai dasar konseptual.
3. Pengumpulan Data yang akan digunakan dalam pelatihan dan pengujian model ANN, dapat berupa variabel masukan (*input*) seperti suhu, dan *irradiance*, serta variabel keluaran (*output*) berupa daya panel surya. Pengumpulan data dapat dilakukan melalui pengukuran lapangan, sumber sekunder, atau basis data institusi terkait.
4. *Preprocessing* Data yang diperoleh selanjutnya diproses untuk memastikan kualitas dan konsistensi. Proses *Preprocessing* meliputi: membersihkan data dari nilai hilang (*missing values*) dan data anomali; normalisasi atau standarisasi data agar sesuai dengan rentang nilai yang seragam; dan membagi dataset menjadi data pelatihan dan pengujian.
5. Perancangan Model ANN dilakukan untuk merancang empat variasi arsitektur (kombinasi 2/3 *hidden Layer* dan 32/64 *neuron*) yang dilatih dan dievaluasi secara paralel untuk menentukan konfigurasi optimal dengan menentukan:
 - Jumlah lapisan (*input, hidden, dan output Layer*).
 - Jumlah *neuron* pada setiap lapisan tersembunyi.
 - Fungsi aktivasi yang digunakan.
 - Algoritma pelatihan dan parameter seperti *learning rate* serta jumlah *epoch*.
6. Proses optimasi model ANN yang telah dirancang pada tahap sebelumnya kemudian dilatih menggunakan data latih melalui algoritma *backpropagation*, di mana bobot dan bias pada setiap neuron diperbarui secara iteratif pada setiap *epoch* untuk meminimalkan kesalahan antara output prediksi model dan nilai aktual, dengan besarnya kesalahan

tersebut diukur menggunakan *Mean Squared Error* (MSE) sebagai indikator performa pelatihan.

7. Evaluasi Konvigurasi MSE (Apakah model optimal?) Tahap ini merupakan proses pengujian konvergensi terhadap hasil pelatihan model, di mana model dinyatakan optimal apabila nilai MSE pelatihan telah stabil dan tidak lagi mengalami penurunan yang signifikan pada epoch berikutnya; apabila nilai MSE masih fluktuatif atau belum stabil, maka proses pelatihan diulang dengan menyesuaikan arsitektur jaringan atau parameter pelatihan, sedangkan apabila MSE telah konvergen, proses dilanjutkan ke tahap evaluasi kinerja menggunakan data uji.
8. Evaluasi Kinerja yang telah mencapai kriteria *MSE minimum* kemudian dievaluasi menggunakan data uji untuk mengukur tingkat akurasi dan keandalannya. Parameter evaluasi yang digunakan dapat meliputi *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, *Mean Absolute Error (MAE)*, dan *Coefficient of Determination (R^2)*. Hasil evaluasi ini menjadi dasar dalam menilai performa model secara kuantitatif.
9. Pembahasan dan hasil seluruh data yang telah diproses dan dilatih melalui arsitektur ANN di evaluasi secara mendalam. Dengan 3 aspek 1. Analisis karakteristik data dan pola cuaca lokal, 2. Evaluasi dan validasi, 3. Transformasi hasil prediksi menjadi rekomendasi aplikatif.
10. Kesimpulan dan Saran berisi interpretasi terhadap hasil evaluasi kinerja model serta penarikan kesimpulan berdasarkan temuan penelitian. Dan memberikan saran untuk penelitian lanjutan, seperti pengembangan arsitektur ANN, penambahan variabel *input*, atau penerapan metode optimasi untuk meningkatkan akurasi prediksi.
11. Selesai setelah seluruh tahapan dilalui dan hasil analisis disusun dalam bentuk laporan ilmiah.

3.6. Perancangan Sistem

Penyusunan alur kerja penelitian dilakukan dengan menyusun setiap tahapan proses seperti ditunjukkan pada Gambar 3.3.



Gambar 3.3 Diagram Blok Sistem Perancangan

Alur kerja penelitian ini dimulai dengan pengambilan data dari Global Solar Atlas, yang menyediakan parameter utama berupa radiasi matahari, suhu lingkungan, dan suhu modul. Data tersebut kemudian masuk ke tahap Preprocessing, yaitu proses pembersihan, pengaturan format, dan normalisasi agar siap digunakan dalam pemodelan.

Selanjutnya dilakukan perancangan arsitektur Artificial Neural Network (ANN) struktur optimal ditentukan melalui komparasi empat variasi arsitektur (kombinasi 2 dan 3 hidden Layer dengan 32 dan 64 neuron per Layer), dievaluasi berdasarkan nilai R^2 , RMSE, MAPE, serta kompleksitas parameter. Setelah arsitektur dirancang, data diproses pada tahap training dan testing ANN guna melatih model dan mengevaluasi akurasi.

Tahap akhir menghasilkan output prediksi daya panel surya, yaitu estimasi daya keluaran berdasarkan variasi radiasi dan temperatur yang digunakan sebagai input model.

3.6.1. Sistem Input Data

Proses pemodelan Jaringan Syaraf Tiruan (ANN) dalam penelitian ini diawali dengan tahapan pengumpulan dan penyusunan

struktur data masukan (*input Layer*). Informasi meteorologi diperoleh secara legal dari platform resmi *Global Solar Atlas (GSA) 2025* yang menyajikan parameter cuaca dalam bentuk numerik berbasis profil harian rata-rata jam-ke-jam (*hourly*) bulanan. Struktur penataan ini menghasilkan total ruang data masukan sebesar 288 *record* yang tersusun secara kronologis dari bulan Januari hingga Desember 2025, yang diperoleh melalui perhitungan matematis 24 jam pengamatan harian dikalikan dengan 12 bulan periode tahunan.

Variabel masukan kontrol utama yang digunakan sebagai input neuron berjumlah 3 parameter meteorologi fisik, yaitu Global Horizontal Irradiance (GHI) dalam satuan W/m^2 , Ambient Temperature (T_a) dalam satuan $^{\circ}C$, dan Module Temperature (T_c) dalam satuan $^{\circ}C$. Sementara itu, parameter waktu pengamatan (time/timestamp) dalam sistem ini diintegrasikan sebagai instrumen sinkronisasi kronologis untuk menyelaraskan urutan pencatatan data cuaca harian tersebut. Ketiga variabel kontrol fisik ini dipetakan secara terstruktur untuk memengaruhi satu variabel target pada lapisan keluaran (output Layer), yaitu nilai estimasi daya maksimum (Pmax) panel surya dalam satuan Watt (W).

Sebelum dataset diimplementasikan ke dalam arsitektur ANN, seluruh data diekstraksi dan dikonversi ke format yang sesuai (Comma-Separated Values / .csv) agar dapat diproses di dalam lingkungan pemrograman MATLAB. Tahapan praproses (Preprocessing) melibatkan pemeriksaan kualitas data untuk membersihkan nilai anomali dan data hilang (missing values). Selanjutnya, seluruh variabel data dinormalisasi menggunakan metode Min–Max Scaling untuk memastikan bahwa setiap nilai numerik berada secara seragam dalam rentang skala [0–1]. Penerapan metode transformasi ini bertujuan untuk mengeliminasi dominasi nilai numerik antar variabel akibat perbedaan satuan fisik (seperti skala ratusan pada nilai GHI dan skala puluhan pada suhu) sekaligus meningkatkan stabilitas komputasi dan mempercepat proses konvergensi selama pelatihan jaringan.

Pemilihan parameter input meteorologi ini secara empiris merujuk pada penelitian Mahendra et al. (2021), yang membuktikan bahwa kombinasi irradiance, suhu udara, dan suhu modul merupakan faktor paling signifikan dan deterministik dalam memprediksi daya keluaran panel surya berbasis ANN. Pendekatan serupa juga diperkuat oleh penelitian Harmini et al. (2021), yang menunjukkan bahwa integrasi parameter cuaca lokal yang rapat dan konsisten mampu

memberikan basis data pelatihan yang kuat bagi jaringan cerdas, sehingga menghasilkan nilai Mean Squared Error (MSE) yang rendah serta tingkat akurasi prediksi yang tinggi saat disimulasikan.

3.6.2. Permodelan Artificial Neural Network (ANN)

Konfigurasi Jaringan Syaraf Tiruan (ANN) pada penelitian ini menggunakan arsitektur *feedforward multiLayer perceptron (MLP)* dengan tiga *neuron* masukan yang merepresentasikan variabel cuaca lokal, yaitu intensitas radiasi matahari (GHI), suhu lingkungan (T_a), dan suhu modul surya (T_c), serta satu *neuron* keluaran berupa estimasi daya keluaran maksimum panel surya (P_{max}).

Penelitian ini menguji empat variasi arsitektur secara komparatif berdasarkan kombinasi jumlah *hidden Layer* dan jumlah *neuron* per *Layer*, yaitu: ANN-2L-32N ($3 \rightarrow [32, 32] \rightarrow 1$), ANN-2L-64N ($3 \rightarrow [64, 64] \rightarrow 1$), ANN-3L-32N ($3 \rightarrow [32, 32, 32] \rightarrow 1$), dan ANN-3L-64N ($3 \rightarrow [64, 64, 64] \rightarrow 1$). Tujuannya adalah mengidentifikasi arsitektur yang memberikan akurasi prediksi terbaik pada data cuaca lokal Surabaya. Fungsi aktivasi *tansig* digunakan pada seluruh *hidden Layer* dan fungsi *purelin* pada *output Layer*, karena target keluaran berupa nilai kontinu. Seluruh arsitektur dilatih menggunakan algoritma *Levenberg-Marquardt* (`trainlm`) dengan pembagian dataset 70% *training*, 15% *validasi*, dan 15% *testing* secara acak menggunakan fungsi *dividerand* MATLAB.

- Lapisan *Input*: Lapisan yang menerima data awal.
- Lapisan Tersembunyi (*Hidden Layer s*): Lapisan yang melakukan pemrosesan antara *input* dan *output*. Lapisan tersembunyi dapat terdiri dari satu atau lebih lapisan
- Lapisan *Output*: Lapisan yang menghasilkan *output* akhir dari jaringan.

Tabel 3.3 Parameter Arsitektur Model ANN

Parameter	Nilai
Jumlah <i>Neuron Layer Input</i>	3 (<i>GHI</i> , <i>T_a</i> , <i>T_c</i>)
Jumlah <i>Hidden Layer</i>	2 <i>Layer</i> dan 3 <i>Layer</i>
Jumlah <i>Neuron Hidden Layer</i>	32 <i>Neuron</i> dan 64 <i>Neuron</i>
Jumlah <i>Neuron Layer Output</i>	1 (<i>P_{max}</i>)
Algoritma Optimasi	<i>Levenberg–Marquardt (LM)</i>
Fungsi Aktivasi <i>Hidden</i>	<i>tansig</i> — $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$
Fungsi Aktivasi <i>Output</i>	<i>purelin</i> — $f(x) = x$
Fungsi Performa Pelatihan	<i>Mean Square Error (MSE)</i>
Target MSE (<i>goal</i>)	1×10^{-10}
Normalisasi <i>Input/Output</i>	<i>Min-Max Scaling</i> rentang [0,1]
Pembagian Data	70% <i>Training</i> / 15% <i>Validasi</i> / 15% <i>Testing (dividerand)</i>
Metrik Evaluasi Kinerja	MSE, RMSE, R ² , MAPE

Berdasarkan keempat kombinasi arsitektur diuji secara komparatif: ANN-2L-32N (3→[32,32]→1), ANN-2L-64N (3→[64,64]→1), ANN-3L-32N (3→[32,32,32]→1), dan ANN-3L-64N (3→[64,64,64]→1). Pemilihan arsitektur terbaik dilakukan berdasarkan evaluasi MSE, RMSE, dan R² pada data testing.

3.6.3. Pelatihan dan Pengujian *Artificial Neural Network* (ANN)

Pelatihan Jaringan Syaraf Tiruan dilakukan dengan metode *supervised learning*, di mana data *input* dan target *output* digunakan untuk menyesuaikan bobot *neuron* agar selisih antara hasil prediksi dan nilai aktual semakin kecil. Pada tahap awal, bobot dan bias jaringan diinisialisasi secara acak, kemudian dilakukan dua proses utama yaitu *forward propagation* dan *backward propagation*.

Pada tahap *backward propagation*, selisih antara nilai aktual dan hasil prediksi dihitung, lalu digunakan untuk memperbarui bobot dan bias menggunakan algoritma *Levenberg–Marquardt (LM)*. Proses pembaruan bobot berlangsung secara iteratif hingga salah satu dari tiga kriteria penghentian berikut terpenuhi:

1. Nilai MSE training mencapai target minimum yang ditetapkan (*goal* = 1×10^{-10} sebagai batas teoretis),
2. Jumlah *epoch* mencapai batas maksimum yang ditentukan (*epochs* = 1.000), atau
3. Mekanisme *early stopping* aktif, yaitu apabila MSE data validasi tidak mengalami penurunan selama 6 *epoch* berturut-turut (*max_fail* = 6).

Dalam praktiknya, penghentian pelatihan pada penelitian ini dikendalikan terutama oleh mekanisme *early stopping* berbasis validasi (kriteria ketiga), bukan semata-mata oleh nilai MSE absolut. Mekanisme ini mencegah *overfitting* dengan menghentikan pelatihan saat model mulai menghafal pola data training dan kehilangan kemampuan generalisasi. $MSE \leq 1 \times 10^{-3}$ dijadikan sebagai ambang minimum yang harus terpenuhi agar model dinyatakan telah *konvergen*, namun hasil aktual pelatihan menunjukkan nilai MSE yang jauh lebih kecil (10^{-6} hingga 10^{-10}) karena algoritma LM memiliki kecepatan *konvergensi* yang sangat tinggi pada dataset berukuran kecil.

Pembagian dataset dilakukan secara acak menggunakan fungsi *dividerand* MATLAB dengan rasio 70:15:15, memastikan distribusi data Musim Hujan dan Musim Kemarau terwakili secara proporsional di ketiga subset untuk memastikan data training, validasi, dan testing terdistribusi merata, dengan dibagi menjadi tiga bagian, yaitu 70% untuk pelatihan (*training*), 15% untuk validasi (*validation*), dan 15% untuk pengujian (*testing*). Pembagian ini bertujuan agar jaringan dapat diuji dengan data baru serta mencegah *overfitting*. Setelah proses pelatihan selesai, model diuji menggunakan data *testing* untuk menilai kemampuan jaringan dalam melakukan generalisasi terhadap data yang belum pernah dilatih sebelumnya. Nilai hasil prediksi dibandingkan dengan data aktual untuk menilai performa jaringan menggunakan parameter *Mean Squared Error (MSE)*, *Root Mean Square Error (RMSE)*, dan Koefisien Determinasi (R^2). Nilai MSE dan RMSE yang rendah serta R^2 yang mendekati 1 menunjukkan bahwa model ANN memiliki akurasi tinggi dalam memprediksi daya keluaran panel surya berbasis data cuaca lokal di Gedung Laboratorium Terpadu.

3.6.4. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk mengetahui seberapa baik Jaringan Syaraf Tiruan (JST) yang dikembangkan dalam penelitian ini mampu memprediksi daya keluaran panel surya dengan tingkat ketepatan yang tinggi dan kesalahan prediksi yang minimal. Tahap ini bertujuan untuk menilai sejauh mana model dapat memahami hubungan antara variabel cuaca lokal seperti intensitas radiasi matahari, suhu lingkungan, dan suhu modul terhadap daya keluaran sistem fotovoltaik secara akurat. Melalui evaluasi ini, dapat diketahui apakah model yang dihasilkan memiliki kemampuan generalisasi yang baik, yaitu mampu memberikan hasil prediksi yang akurat terhadap data baru yang tidak digunakan selama proses pelatihan.

Hasil evaluasi model kemudian dibandingkan dengan data aktual lapangan yang diperoleh dari pengukuran daya keluaran panel surya di Gedung Laboratorium Terpadu, serta dengan data estimasi irradiansi dari Global Solar Atlas (GSA). Perbandingan ini dilakukan untuk menguji konsistensi dan ketepatan model ANN dalam menggambarkan kondisi sebenarnya di lapangan. Dengan cara ini, hasil evaluasi tidak hanya menunjukkan kinerja numerik model, tetapi juga mencerminkan sejauh mana model mampu beradaptasi terhadap data dari berbagai sumber.

Proses evaluasi dilakukan menggunakan empat parameter statistik utama, yaitu Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Koefisien Determinasi (R^2), dan Mean Absolute Percentage Error (MAPE). Keempat parameter ini dipilih karena memberikan gambaran menyeluruh mengenai tingkat ketelitian dan akurasi model dalam menghasilkan prediksi daya keluaran panel surya. Nilai MSE dan RMSE digunakan untuk mengukur besarnya rata-rata kesalahan prediksi antara nilai aktual dan hasil keluaran model. Semakin kecil nilai kedua parameter ini, semakin baik kinerja model dalam menghasilkan prediksi yang mendekati nilai sebenarnya.

Sementara itu, Koefisien Determinasi (R^2) digunakan untuk menilai seberapa kuat hubungan antara hasil prediksi dan data aktual. Nilai R^2 yang mendekati 1 menunjukkan bahwa model ANN memiliki kemampuan prediksi yang sangat baik dan dapat menjelaskan sebagian besar variasi yang terdapat pada data target. Dengan demikian, kombinasi ketiga parameter ini memberikan pemahaman yang komprehensif terhadap kinerja model, baik dari sisi kesalahan numerik maupun kekuatan korelasi antara hasil prediksi dengan data aktual daya keluaran panel surya.

Rumus Perhitungan Evaluasi Kinerja Model [18]:

$$\begin{aligned}MSE &= \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \\RMSE &= \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \\R^2 &= 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \\MAPE &= \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%\end{aligned}$$

(13)

Keterangan Variabel:

- y_i : nilai aktual (data target)
- $\hat{y}_i$: hasil prediksi model
- $\bar{y}$: rata-rata nilai aktual
- N : jumlah total data pengamatan

