

## BAB II

### LANDASAN TEORI

#### 2.1. Sistem Panel Surya (*Photovoltaic System*)

##### 2.1.1. Prinsip Dasar Sistem Fotovoltaik

Sistem fotovoltaik bekerja dengan mengubah energi cahaya matahari menjadi energi listrik melalui efek fotovoltaik. Karakteristik arus–tegangan (I–V) dan daya–tegangan (P–V) pada modul PV sangat dipengaruhi oleh variabel cuaca seperti radiasi matahari dan suhu modul. Peningkatan suhu modul dapat menurunkan tegangan *open-circuit*, sehingga berdampak pada berkurangnya daya maksimum yang dihasilkan, sedangkan peningkatan *irradiance* akan meningkatkan arus keluaran dan secara langsung menaikkan daya yang diproduksi [4]. Pemahaman hubungan ini penting karena pola perubahan *irradiance* dan suhu menjadi dasar pembentukan model prediksi ANN untuk menghasilkan estimasi daya yang akurat.

Hubungan antara arus keluaran (*I*) dan tegangan keluaran (*V*) pada sel surya ideal dijelaskan melalui persamaan diode Tunggal Chuluunsaikhan et al., (2021) sebagai berikut:

$$I = I_{ph} - I_0 \left( e^{\frac{V+IR_s}{nV_t}} - 1 \right) - \frac{V + IR_s}{R_{sh}} \quad (1)$$

**Keterangan:**

- $I_{ph}$  : Arus foton (A)
- $I_0$  : Arus saturasi dioda (A)
- $R_s$  : Resistansi seri ( $\Omega$ )
- $R_{sh}$  : Resistansi shunt ( $\Omega$ )
- $V_t$  : Tegangan termal (V)
- $n$  : Faktor idealitas dioda

##### 2.1.2. Karakteristik I-V dan P-V

Kinerja modul fotovoltaik digambarkan secara komprehensif oleh kurva hubungan arus–tegangan (I–V) dan kurva daya–tegangan (P–V). Kurva-kurva ini menunjukkan kombinasi arus dan tegangan yang dapat dihasilkan modul pada kondisi radiasi matahari (*irradiance*) dan suhu sel tertentu; perubahan *irradiance* terutama memengaruhi nilai  $I_{sc}$  dan daya maksimum, sementara peningkatan suhu umumnya

menurunkan Voc dan daya keluaran. (NREL, 2014; PV Education, n.d.; FSEC, n.d.). Daya keluaran maksimum ( $P_{max}$ ) dihitung berdasarkan perkalian antara tegangan pada MPP ( $V_{mp}$ ) dan arus pada MPP ( $I_{mp}$ ) [8]:

$$P_{max} = V_{mp} \times I_{mp} \quad (2)$$

### 2.1.3. Faktor yang Mempengaruhi Daya Keluaran PV

Daya keluaran yang dihasilkan oleh PV dipengaruhi oleh beberapa faktor lingkungan dan operasional utama:

1. Intensitas Radiasi Matahari (*irradiance*): Hubungan antara intensitas radiasi dan daya keluaran bersifat proporsional, peningkatan intensitas radiasi secara langsung akan meningkatkan daya yang dihasilkan.
2. Suhu Lingkungan dan Suhu Sel PV: Peningkatan suhu sel ( $T_c$ ) berbanding terbalik dengan efisiensi modul. Peningkatan suhu menyebabkan penurunan signifikan pada tegangan *open-circuit* ( $V_{oc}$ ) [4].
3. Orientasi dan Sudut Panel: Posisi modul yang optimal (*azimuth and tilt*) sangat menentukan jumlah radiasi matahari total yang dapat diterima oleh permukaan panel.

### 2.1.4. Simulasi Sistem PV

Simulasi sistem fotovoltaik menganalisis perilaku dinamis terhadap perubahan parameter *input* seperti radiasi dan suhu. Dalam penelitian ini, digunakan *silicon polikristalline module (Poly-Si)* dengan memiliki keunggulan dalam stabilitas pada suhu tinggi dan memiliki tingkat efisiensi yang baik (15-18%), yang membuatnya jadi pilihan yang layak untuk iklim tropis.

Model simulasi dengan *polycrystalline silicon module (Poly-Si)* berkapasitas 100Wp per panel. Data di ukur secara *real-time* di Laboratorium Terpadu.

**Tabel 2. 1** Parameter Modul PV *Polycrystalline (Poly-Si)*

| Parameter                    | Simbol    | Nilai | Satuan |
|------------------------------|-----------|-------|--------|
| Daya Maksimum                | $P_{max}$ | 100   | W      |
| Tegangan MPP                 | $V_{mp}$  | 17.8  | V      |
| Arus MPP                     | $I_{mp}$  | 5.62  | A      |
| Tegangan <i>Open Circuit</i> | $V_{oc}$  | 21.8  | V      |
| Arus <i>Short circuit</i>    | $I_{sc}$  | 6.05  | A      |

## 2.2. Parameter Cuaca Lokal sebagai Variabel Input

Parmeter cuaca yang relevan digunakan sebagai variabel *input* dalam model ANN meliputi: [5]

### 2.2.1 Radiasi Matahari (*Irradiance*)

Radiasi matahari total ( $G_t$ ) yang diterima bilang panel merupakan gabungan dari tiga komponen utama: radiasi langsung ( $G_b$ ) radiasi difus ( $G_d$ ), dan radiasi pantulan (*reflektif*) dari tanah ( $G_r$ ) [5].

$$G_t = G_b + G_d + G_r \quad (3)$$

### 2.2.2 Suhu Lingkungan dan Suhu Modul

Suhu sel surya ( $T_c$ ) memiliki korelasi dengan suhu lingkaran ( $T_a$ ) dan intensitas radiasi ( $G_t$ ). Hubungkan matematis untuk memperkirakan suhu sel didasarkan pada parameter *Nominal Operating cell Temperature* (NOCT) [5]:


$$T_c = T_a + \frac{G_t}{800}(NOCT - 20) \quad (4)$$

dimana  $T_c$  adalah suhu sel dalam *Celcius* ( $^{\circ}\text{C}$ ),  $T_a$  adalah suhu udara dalam *Celcius* ( $^{\circ}\text{C}$ ), dan  $800 \text{ W/m}^2$  adalah nilai referensi radiasi pada kondisi NOCT.

## 2.3. Jaringan Syaraf Tiruan (*Artificial Neural Network-ANN*)

### 2.3.1. Konsep Dasar ANN

*Artificial Neural Network* (ANN) atau Jaringan Syaraf Tiruan merupakan paradigma pemrosesan informasi yang arsitektur komputasinya diadopsi dari struktur jaringan Syaraf biologis makhluk hidup. Karakteristik utama dari sistem ini terletak pada kemampuannya untuk melakukan pemrosesan data secara paralel (*parallel processing*) serta mengidentifikasi hubungan non-linear yang kompleks antara variabel masukan (*input*) dan luaran (*output*) melalui proses pembelajaran (*learning/training*). Melalui mekanisme adaptasi tersebut, ANN memiliki keunggulan dalam mengenali pola, melakukan klasifikasi, serta memproyeksikan estimasi nilai dari sekumpulan data yang memiliki tingkat kedinamisan tinggi tanpa memerlukan pemodelan matematis fisis yang rigid dari sistem nyata.



Gambar 2. 1 Struktur Dasar ANN

Struktur dasar dari ANN dibentuk oleh sekumpulan elemen pemrosesan diskret yang saling terhubung secara intensif, yang dikenal sebagai *neuron* buatan (*artificial neuron* atau *processing element*). Dalam arsitektur jaringan syaraf, seluruh *neuron* tersebut

diorganisasikan ke dalam beberapa lapisan (*Layer*) fungsional, yang umumnya terdiri dari tiga komponen utama:

1. Lapisan Masukan (*Input Layer*): Berfungsi sebagai gerbang awal untuk menerima stimulus atau data eksternal dari luar sistem tanpa melakukan perubahan nilai, di mana pada penelitian ini direpresentasikan oleh variabel meteorologi harian.
2. Lapisan Tersembunyi (*Hidden Layer*): Merupakan inti dari proses komputasi, di mana satu atau beberapa lapisan bertugas mengeksplorasi dan mengekstraksi fitur-fitur penting yang terkandung di dalam dataset masukan secara *non-linear*.
3. Lapisan Keluaran (*Output Layer*): Berfungsi menyajikan hasil akhir pemrosesan informasi dari jaringan yang merepresentasikan variabel target estimasi.

Secara mekanis, fungsionalitas sebuah *neuron* tunggal ditentukan oleh akumulasi *linear* dari perkalian antara variabel masukan ( $x$ ) dan bobot ( $w$ ), yang kemudian ditambah dengan parameter bias ( $b$ ) sebagai penggeser nilai menuju titik *konvergensi* optimal. Hasil kombinasi *linear* tersebut selanjutnya ditransformasikan melalui fungsi aktivasi untuk menyuntikkan sifat *non-linearitas* ke dalam jaringan syaraf, sehingga sistem mampu memetakan fenomena fisik yang fluktuatif secara akurat. Dalam penelitian ini, kompleksitas fluktuasi cuaca urban-pesisir akan diakomodasi secara spesifik menggunakan fungsi aktivasi *Hyperbolic Tangent Sigmoid* (*tansig*) pada lapisan tersembunyi dan fungsi *Linear* (*purelin*) pada lapisan keluaran.

Secara matematis, karakteristik penstransformasian sinyal oleh kedua fungsi aktivasi tersebut didefinisikan sebagai berikut:

#### 1 Fungsi Aktivasi *Hyperbolic Tangent* (*tansig*)

Fungsi *tansig* merupakan fungsi *non-linear* kontinu yang memetakan nilai akumulasi masukan berorientasi asimtotik ke dalam rentang interval antara -1 hingga 1. Persamaan matematis dari fungsi *hyperbolic tangent* ini dinyatakan dalam Persamaan :

$$f(v) = \tanh(v) = \frac{2}{1 + e^{-2v}} - 1 \quad (5)$$

Dimana  $v$  merupakan nilai net *input* (kombinasi *linear* masukan terbobot ditambah bias) pada suatu *neuron*. Pemilihan fungsi *tansig* pada lapisan tersembunyi didasarkan pada keunggulannya yang bersifat *zero-centered* (berpusat pada nilai nol). Karakteristik ini menghasilkan nilai turunan (gradien) yang lebih kuat selama fase perambatan mundur (*backward propagation*), sehingga mampu mempercepat proses *konvergensi* pembentukan bobot baru dan meminimalkan risiko fluktuasi gradien saat mengenali pola *non-linear* dari parameter cuaca.

## 2 Fungsi Aktivasi *Linear* (*purelin*)

Fungsi aktivasi *linear* atau *purelin* melakukan transformasi identitas, di mana nilai keluaran dari fungsi merupakan representasi langsung dari nilai masukan yang diterima tanpa mengalami pembatasan rentang (*unbounded*). Persamaan matematis fungsi *purelin* didefinisikan melalui Persamaan:

$$f(v) = v \quad (6)$$

Penerapan fungsi *linear* pada lapisan keluaran (*output Layer*) menjadi prasyarat utama dalam pemodelan ANN yang berorientasi pada kasus regresi atau prediksi nilai kontinu. Melalui fungsi *purelin*, Jaringan Syaraf Tiruan mampu menghasilkan nilai estimasi daya maksimum ( $P_{max}$ ) panel surya dalam skala numerik riil yang dinamis tanpa terikat oleh batasan saturasi nilai  $[0, 1]$  atau  $[-1, 1]$ , sehingga hasil prediksi dapat mencerminkan kapasitas daya aktual dari sistem *Photovoltaic* (PV).

### 2.3.2. Algoritma Backpropagation

Algoritma *backpropagation* adalah metode yang paling sering digunakan dalam pelatihan Jaringan Syaraf tiruan. Algoritma ini bekerja dengan cara menyesuaikan secara berulang-ulang koneksi antar *neuron* untuk meminimalkan selisih antara *output* yang di prediksi oleh model ( $y$ ) dan target ( $t$ ).

Fungsi kesalahan (*error function*) yang sering digunakan adalah *Mean Squared Error* (MSE), di mana  $E$  dihitung sebagai:

$$E = \frac{1}{2} \sum (t - y)^2 \quad (7)$$

**Keterangan:**

- $\eta$  : *Learning rate* (laju pembelajaran)
- $\delta_j$  : Kesalahan yang dihitung pada *neuron j*
- $x_i$  : *Output* dari *neuron i* (yang menjadi *input* bagi *neuron j*)

Meskipun algoritma *Backpropagation* berbasis *Gradient Descent* efektif dalam meminimalkan galat jaringan, metode ini memerlukan waktu komputasi (*epoch*) yang lama dan rentan terjebak pada kondisi minimum lokal (*local minima*). Guna mengatasi kendala *konvergensi* tersebut, pembaruan bobot dan bias dalam penelitian ini dioptimalkan menggunakan Algoritma Pelatihan *Levenberg-Marquardt* (LM) sebagai variasi perambatan mundur tingkat lanjut. Mekanisme optimasi fungsi kesalahan berbasis algoritma LM tersebut dijabarkan secara rinci pada subbab berikutnya.

Berbeda dengan penelitian terdahulu yang umumnya menggunakan algoritma *Backpropagation* standar, penelitian ini menggunakan varian *Levenberg-Marquardt* (LM) yang lebih stabil dan cepat *konvergen*.

### 2.3.3. Algoritma Optimasi Bobot *Levenberg-Marquardt* (LM)

Algoritma *Levenberg-Marquardt* (LM) merupakan metode optimasi numerik yang dirancang untuk menyelesaikan masalah kuadrat terkecil non-linear (*nonlinear least-squares problems*). Dalam arsitektur Jaringan Syaraf Tiruan (ANN), algoritma ini bertindak sebagai fungsi pelatihan (*training function*) yang dijalankan melalui perintah `trainlm` pada MATLAB untuk memperbarui bobot (*weights*) dan bias secara dinamis selama fase perambatan mundur (*backward propagation*). Daya tarik utama dari algoritma LM terletak pada efisiensinya dalam mengombinasikan kecepatan *konvergensi* metode *Gauss-Newton* dengan stabilitas metode *Gradient Descent*.

Secara matematis, perambatan mundur konvensional mengandalkan pendekatan kalkulus orde pertama (*Gradient Descent*) untuk memperbarui bobot berdasarkan vektor gradien kesalahan ( $g$ ), dengan formulasi sebagai berikut [12]:

$$w_{k+1} = w_k - \alpha g_k \quad (8)$$

Dimana  $w$  adalah parameter bobot jaringan,  $k$  melambangkan indeks iterasi (*epoch*), dan  $\alpha$  menyatakan laju pembelajaran (*learning rate*). Meskipun metode ini menawarkan stabilitas pencarian yang tinggi, laju komputasinya relatif lambat untuk mencapai target kesalahan minimum. Guna mempercepat iterasi, metode *Gauss-Newton* hadir dengan memanfaatkan informasi kelengkungan orde kedua melalui matriks Hessian ( $H$ ), dengan persamaan [12]:

$$w_{k+1} = w_k - H_k^{-1} g_k \quad (9)$$

Sedangkan, metode *Gauss-Newton* memiliki kelemahan mendasar berupa tingginya risiko kegagalan komputasi apabila invers dari matriks Hessian ( $H^{-1}$ ) bersifat singular atau tidak terdefinisi. Algoritma LM berhasil mengatasi kendala tersebut dengan mengintegrasikan kedua pendekatan di atas melalui pengenalan faktor peredam yang disebut parameter damping  $\mu$  ( $\mu$ ). Dalam skema komputasi algoritma LM, matriks Hessian ( $H$ ) didekati secara aproksimasi melalui matriks Jacobian ( $J$ ) berdasarkan Persamaan [12] :

$$H \approx J^T J + \mu I \quad (10)$$

Dimana ( $J$ ) merupakan matriks Jacobian yang berisi turunan parsial pertama dari galat jaringan terhadap seluruh komponen bobot dan bias,  $J^T$  menyatakan transpose dari matriks Jacobian, dan  $I$  melambangkan matriks identitas. Berdasarkan pendekatan tersebut, nilai gradien kesalahan ( $g$ ) dihitung secara simultan menggunakan Persamaan [12]:

$$g = J^T e \quad (11)$$

Dimana  $e$  menyatakan vektor total kesalahan (*error vector*) dari sistem jaringan. Melalui formulasi integratif ini, algoritma LM mampu mengendalikan arah pembaruan bobot secara adaptif mengikuti dinamika nilai  $\mu$  pada setiap *epoch*.

Ketika nilai parameter  $\mu$  mendekati nol, karakteristik komputasi akan bergeser mengikuti metode *Gauss-Newton* yang memberikan percepatan *konvergensi* ekstrem saat posisi jaringan sudah dekat dengan solusi optimal. Sebaliknya, apabila  $\mu$  membesar,

algoritma akan beradaptasi mengikuti metode *Gradient Descent* dengan laju langkah yang lebih berhati-hati demi menjaga stabilitas pencarian ruang bobot saat posisi jaringan masih jauh dari target kesalahan.

Di dalam simulasi MATLAB, parameter  $\mu$  juga bertindak sebagai jangkar stabilitas selama proses *training*. Apabila suatu *epoch* berhasil menurunkan nilai kesalahan jaringan, nilai  $\mu$  secara otomatis akan diperkecil agar proses pelatihan pada *epoch* berikutnya berjalan lebih agresif. Namun, jika perubahan bobot justru memicu kenaikan kesalahan, nilai  $\mu$  akan ditingkatkan secara signifikan, dan pembaruan bobot pada *epoch* tersebut akan dibatalkan untuk mencegah terjadinya divergensi. Mekanisme adaptasi nilai  $\mu$  inilah yang menjaga stabilitas model ANN dalam memprediksi daya *photovoltaic* tanpa risiko terjebak pada kondisi minimum lokal (*local minima*) [12].

**Tabel 2. 2** Parameter Konfigurasi Algoritma Pelatihan *Levenberg–Marquardt* (LM)

| Parameter LM                 | Nilai               | Keterangan                                                             |
|------------------------------|---------------------|------------------------------------------------------------------------|
| mu ( $\mu_0$ , damping awal) | 0,001               | Nilai damping awal algoritma LM                                        |
| mu_dec                       | 0,1                 | Faktor pengecilan $\mu$ saat MSE turun                                 |
| mu_inc                       | 10                  | Faktor pengecilan $\mu$ saat MSE naik                                  |
| mu_max                       | $1 \times 10^{10}$  | Batas maksimum $\mu$                                                   |
| max_fail                     | 6                   | Jumlah <i>epoch</i> validasi gagal sebelum <i>early stopping</i> aktif |
| epochs                       | 1000                | Batas maksimum iterasi                                                 |
| goal                         | $1 \times 10^{-10}$ | Target MSE minimum teoretis                                            |
| min_grad                     | $1 \times 10^{-7}$  | Batas minimum gradien                                                  |

### 2.3.4. Evaluasi Kinerja ANN

Evaluasi kinerja *Artificial Neural Network* (ANN) merupakan tahapan penting untuk mengukur seberapa baik model yang telah dilatih dalam memprediksi atau mengklasifikasikan data. Evaluasi ini dilakukan dengan membandingkan hasil keluaran (output) model terhadap data aktual (target), baik pada data pelatihan (training) maupun data pengujian (testing). Pemilihan metrik evaluasi bergantung pada jenis permasalahan yang diselesaikan oleh ANN, apakah termasuk permasalahan regresi (prediksi nilai kontinu) atau klasifikasi (prediksi kategori/kelas) [6]. Kinerja prediktif suatu model ANN dievaluasi menggunakan metrik statistik standar, meliputi:

- **MAPE (Mean Absolute Percentage Error):** Mengukur rata-rata persentase kesalahan absolut.

- RMSE (*Root Mean Square Error*): Mengukur deviasi standar dari kesalahan prediksi.
- $R^2$  (*Koefisien Determinasi*): Mengindikasikan proporsi variasi dalam variabel dependen yang dapat dijelaskan oleh model, dengan nilai mendekati 1 menunjukkan kecocokan model yang sangat baik.

## 2.4. Penelitian Terdahulu

Berbagai penelitian telah mengaplikasikan Jaringan Syaraf Tiruan untuk memprediksi daya keluaran PV. Ringkasan hasil studi yang relevan disajikan dalam Tabel 2.2.

**Tabel 2.3** Ringkasan Penelitian Terdahulu

| NO | Peneliti/<br>Tahun                | Judul/Fokus<br>penelitian                                                                                | Metode/Sistem                                                                                      | Hasil Utama                                                                                                    | Relevansi<br>dengan<br>Penelitian ini                                                                   |
|----|-----------------------------------|----------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------|
| 1. | Prisilia and Siti (2013)          | Perancangan Sistem Prediktor Daya Pada Panel Photovoltaic di Buoy Weather Station                        | Jaringan Syaraf Tiruan (ANN) dengan Algoritma <i>Backpropagation</i> (MLP)                         | Akurasi prediksi mencapai 99,81% (MSE 0,0113) di Surabaya.                                                     | Memberikan fundamental kuat penggunaan ANN- <i>Backpropagation</i> untuk prediksi daya PV di Indonesia. |
| 2. | (Supratno et al. 2021),           | Prediksi <i>Power Solar Energy</i> Melalui SPV Menggunakan ANN-Radial Basis Function (ANN-RBF)           | ANN-Radial Basis Function (ANN-RBF).<br><i>Input</i> : Iradiansi, Suhu, Kelembaban, Tekanan Udara. | Akurasi prediksi tertinggi mencapai 99.98%.                                                                    | Memberikan perbandingan metodologi dan menegaskan pentingnya <i>input</i> data cuaca multi-variabel.    |
| 3  | (Mohd Zaini and Mohamad Nor 2024) | <i>A Comprehensive Review of Artificial Neural Network Techniques for Predicting Photovoltaic Output</i> | Analisis Literatur Sistematis                                                                      | Menegaskan bahwa ANN adalah metode yang paling efektif untuk mengatasi kompleksitas pembangkitan energi surya. | Sumber teoretis utama untuk memvalidasi urgensi dan peran sentral ANN sebagai metode penelitian         |
| 4  | Chuluunsaikhan et al. (2021)      | <i>Predicting the Power Output of Solar Panels based on Weather</i>                                      | <i>Machine Learning</i> (Model Multi-feature)                                                      | Daya PV sangat bergantung pada kondisi lingkungan,                                                             | Memperluas konteks variabel lingkungan yang memengaruhi daya PV.                                        |

| NO | Peneliti/<br>Tahun      | Judul/Fokus<br>penelitian                                                                                              | Metode/Sistem                                                                           | Hasil Utama                                                                                                               | Relevansi<br>dengan<br>Penelitian ini                                                             |
|----|-------------------------|------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------|
|    |                         | <i>and Air Pollution Features using Machine Learning</i>                                                               |                                                                                         | termasuk faktor polusi udara selain cuaca.                                                                                |                                                                                                   |
| 5  | Mahendra et al. (2021)  | Prediksi Daya Keluaran PV Berbasis Jaringan Syaraf Tiruan Pada Pusat Perbelanjaan Tangerang                            | Jaringan Syaraf Tiruan ( <i>Artificial Neural Network-ANN</i> )                         | Menghasilkan prediksi daya PV di Tangerang (lokasi Indonesia).                                                            | Mendukung skripsi Anda dengan topik, metode, dan konteks lokasi Indonesia yang sangat spesifik.   |
| 6  | Silalahi et al. (2023)  | <i>Forecasting Photovoltaic Output Power Based on Environmental Parameters Using Artificial Neural Network Methods</i> | <i>Artificial Neural Network (ANN). Input: Debu, Kecepatan Angin, Kelembaban, Suhu.</i> | Sistem dirancang untuk memprediksi daya keluaran PV dalam jangka pendek ( <i>short-term</i> ).                            | Fokus langsung pada prediksi daya jangka pendek menggunakan parameter lingkungan yang serupa      |
| 7  | Supratno et al. (2021), | <i>Modeling Solar Potential in Semarang, Indonesia Using Artificial Neural Networks</i>                                | ANN dengan Algoritma <i>Backpropagation</i>                                             | Berhasil memodelkan potensi <i>irradiansi</i> matahari (variabel <i>input</i> kunci PV) dengan ANN di Semarang, Indonesia | Memvalidasi penggunaan ANN- <i>Backpropagation</i> untuk pemodelan data cuaca di lokasi Indonesia |

Analisis Penelitian Terdahulu berdasarkan tujuan penelitian terdahulu:

1. Konsistensi Hasil: Mayoritas studi, termasuk Prisilia & Siti (2013) dan Mahendra et al. (2021), menunjukkan bahwa metode ANN *Backpropagation* memiliki Tingkat akurasi prediksi yang sangat tinggi (di atas 95%) untuk *sistem* PV.


2. Relevansi Lokasi: Studi oleh Mahendra et al. (2021) yang berfokus pada iklim tropis Indonesia memberikan validasi bahwa pendekatan ANN sesuai untuk kondisi cuaca lokal.
3. Model Acuan: Penelitian oleh Mahendra et al. (2021) sangat relevan karena menggunakan *Polycrystalline Silicon Module* (Poly-Si) pada sistem Pembangkit Listrik Tenaga Surya (PLTS) rooftop di QBig BSD City, Tangerang, serta menerapkan Jaringan Syaraf Tiruan (*Artificial Neural Network/ANN*) untuk memprediksi daya keluaran panel surya berdasarkan variabel cuaca seperti radiasi matahari, suhu modul, suhu lingkungan, dan waktu. Penelitian tersebut menjadi landasan teknis dan metodologis dalam pengembangan model prediksi pada studi ini.

Gap Penelitian: Meskipun ANN telah terbukti efektif, masih terbatasnya penelitian yang secara spesifik mengintegrasikan data cuaca local Indonesia dengan variabel (suhu, *irradiance*, dan kelembapan) untuk optimasi model prediksi daya PV.



## 2.5 Kerangka Pemikiran Penelitian

Kerangka pemikiran penelitian ini menggambarkan alur logis dari proses pengumpulan data hingga dihasilkannya model prediksi. Hubungan antar variabel dan tahapan proses dijelaskan pada Gambar 2.2.



**Gambar 2. 2** Diagram kerangka pemikiran

Berikut penjelasan alur diagram (flowchart) metodologi penelitian :

- 1 Mulai  
Titik awal proses penelitian/pengembangan model prediksi daya PV.
- 2 Pengumpulan Data Cuaca Lokal  
Tahap pengambilan data meteorologi aktual dari lokasi penelitian (Gedung Laboratorium Terpadu UM Surabaya), seperti intensitas radiasi matahari, suhu, kelembapan, dan variabel cuaca lain yang memengaruhi daya keluaran panel surya, sekaligus data daya keluaran PV historisnya.
- 3 Pra-pemrosesan Data  
Data mentah yang terkumpul dibersihkan dan disiapkan sebelum digunakan untuk pelatihan model — misalnya menangani data hilang (*missing value*), menghapus data pencilan (*outlier*), normalisasi/standarisasi skala nilai, serta pembagian data menjadi data latih (*training*) dan data uji (*testing*).
- 4 Pelatihan Model  
Data yang sudah diproses digunakan untuk melatih arsitektur ANN, di mana model belajar mengenali pola hubungan nonlinier antara variabel cuaca (input) dan daya keluaran PV (output) melalui proses seperti backpropagation.
- 5 Evaluasi Error  
Setelah pelatihan, dilakukan pengukuran tingkat kesalahan model menggunakan metrik seperti MSE (*Mean Squared Error*), RMSE, atau MAE untuk melihat seberapa jauh prediksi model menyimpang dari data aktual pada tahap pelatihan.
- 6 Pengujian Model  
Model yang telah dilatih diuji menggunakan data uji (data yang belum pernah dilihat model sebelumnya) untuk memastikan model mampu melakukan generalisasi, bukan hanya menghafal data latih (mengecek potensi *overfitting*).
- 7 Evaluasi Kinerja Model  
Penilaian menyeluruh terhadap performa model berdasarkan hasil pengujian biasanya dengan membandingkan beberapa arsitektur/parameter ANN untuk menentukan arsitektur yang paling optimal, sesuai tujuan penelitian Anda mengidentifikasi arsitektur ANN terbaik.

- 8    Prediksi Daya Keluaran  
Model terbaik yang telah dievaluasi digunakan untuk menghasilkan prediksi daya keluaran PV harian berdasarkan input data cuaca, sebagai output akhir dari sistem.
- 9    Selesai  
Akhir dari alur proses penelitian.

