

Identifikasi Parameter Ekuivalen Modul Fotovoltaik Berbasis Metaheuristik dari Pengukuran Lapangan Terbatas pada MPPT Incremental Conductance

Giovanni Dimas Prenata^{1*}, Ahmad Ridho'i²

^{1,2}Universitas 17 Agustus 1945 Surabaya, Indonesia

email: gprenata@untag-sby.ac.id*

Abstrak

Ketersediaan parameter modul fotovoltaik yang akurat diperlukan untuk pemodelan, pemantauan kondisi, dan evaluasi kinerja sistem, tetapi informasi tersebut tidak selalu tersedia pada instalasi lapangan. Penelitian ini mengembangkan metode identifikasi parameter ekuivalen modul fotovoltaik menggunakan Algoritma Genetika, Particle Swarm Optimization, dan Grey Wolf Optimizer dari pengukuran lapangan terbatas pada sistem MPPT Incremental Conductance. Parameter yang diidentifikasi meliputi tegangan rangkaian terbuka, arus hubung singkat, tegangan dan arus titik daya maksimum pada kondisi standar, koefisien temperatur arus, koefisien temperatur tegangan, dan koefisien pengaruh iradiasi terhadap tegangan. Evaluasi menggunakan 81 observasi dari tiga modul fotovoltaik selama lima hari, validasi leave-one-day-out secara terpisah pada setiap modul, dan sepuluh running independen. Hasil identifikasi dinilai berdasarkan rekonstruksi V_{oc} , I_{sc} , V_{mp} , I_{mp} dan P_{MPP} . Secara keseluruhan, PSO menghasilkan skor komposit terendah sebesar 11,2254, lebih baik 15,28% dibandingkan baseline median sebesar 13,2498. Pada modul P3 yang spesifikasinya tidak diketahui, GA memberikan skor komposit terbaik sebesar 17,1909, sedangkan PSO menghasilkan rekonstruksi daya terbaik dengan RMSE 11,3957 W, MAE 8,9664 W, dan R^2 sebesar 0,7808. Parameter utama P3 yang diperoleh GA meliputi $V_{oc,STC}^{eq}=20,2034\pm0,1702$ V, $I_{sc,STC}^{eq}=4,5315\pm0,2281$ A, $V_{mp,STC}^{eq}=16,2734\pm0,1371$ V, $I_{mp,STC}^{eq}=4,1168\pm0,2033$ A, dan $P_{max,STC}^{eq}=66,9872\pm3,2084$ W. Uji Wilcoxon menunjukkan bahwa perbedaan GA dan PSO pada P3 tidak signifikan, sedangkan keduanya secara signifikan lebih baik daripada GWO. Hasil penelitian menunjukkan bahwa parameter listrik utama dapat diidentifikasi secara konsisten, tetapi koefisien temperatur memiliki ketidakpastian lebih tinggi. Parameter yang diperoleh harus dipahami sebagai parameter ekuivalen hasil estimasi lapangan, bukan spesifikasi pasti dari pabrikan.

Kata Kunci: Algoritma Genetika; Grey Wolf Optimizer; identifikasi parameter; Incremental Conductance; modul fotovoltaik; parameter ekuivalen; Particle Swarm Optimization.

Abstract

Accurate photovoltaic module parameters are essential for system modeling, condition monitoring, and performance evaluation; however, complete manufacturer specifications are not always available for field-installed modules. This study proposes a metaheuristic-based method for identifying equivalent photovoltaic module parameters from limited field measurements obtained under Incremental Conductance maximum power point tracking.

Genetic Algorithm, Particle Swarm Optimization, and Grey Wolf Optimizer were employed to estimate the equivalent open-circuit voltage, short-circuit current, maximum-power-point voltage and current at standard test conditions, current and voltage temperature coefficients, and an irradiance-related voltage coefficient. The evaluation used 81 observations collected from three photovoltaic modules over five measurement days. A module-wise leave-one-day-out validation scheme and ten independent runs were applied to assess cross-day generalization and optimization stability. Identification performance was evaluated by reconstructing V_{oc} , I_{sc} , V_{mp} , I_{MP} and P_{MPP} . Overall, PSO achieved the lowest composite score of 11.2254, representing a 15.28% improvement over the median baseline score of 13.2498. For module P3, whose manufacturer specifications were unavailable, GA produced the best composite score of 17.1909, whereas PSO achieved the best power reconstruction, with an RMSE of 11.3957 W, an MAE of 8.9664 W, and an R^2 of 0.7808. The principal GA-estimated parameters for P3 were $V_{oc,STC}^{eq}=20,2034\pm0,1702$ V, $I_{sc,STC}^{eq}=4,5315\pm0,2281$ A, $V_{mp,STC}^{eq}=16,2734\pm0,1371$ V, $I_{mp,STC}^{eq}=4,1168\pm0,2033$ A, and $P_{max,STC}^{eq}=66,9872\pm3,2084$ W. Wilcoxon testing showed no significant difference between GA and PSO for P3, while both significantly outperformed GWO. The results indicate that the principal electrical parameters can be identified consistently, although the temperature-related coefficients exhibit greater uncertainty. The identified values should therefore be interpreted as field-estimated equivalent parameters rather than exact manufacturer specifications.

Keywords: *equivalent parameter identification; Genetic Algorithm; Grey Wolf Optimizer; Incremental Conductance MPPT; limited field measurements; Particle Swarm Optimization; photovoltaic module.*

I. LATAR BELAKANG

Sistem fotovoltaik bekerja pada karakteristik arus–tegangan yang berubah secara nonlinear terhadap iradiasi, temperatur, teknologi sel, dan kondisi operasi. Representasi matematis yang akurat diperlukan agar perilaku modul dapat disimulasikan pada kondisi yang berbeda dari kondisi pengujian awal. Model fotovoltaik umumnya ditentukan oleh sejumlah parameter fisik atau ekuivalen yang mengendalikan bentuk kurva arus–tegangan, posisi titik daya maksimum, serta perubahan daya akibat variasi iradiasi dan temperatur. Model satu dioda, model lima parameter, dan berbagai bentuk penyederhanaannya telah banyak digunakan karena mampu merepresentasikan karakteristik listrik modul dengan kompleksitas yang masih dapat dikelola [1] [2].

Keakuratan model sangat ditentukan oleh parameter yang digunakan. Nilai parameter yang tidak sesuai dapat menyebabkan kesalahan pada kurva I–V, kurva P–V, estimasi daya maksimum, perancangan konverter, serta evaluasi sistem MPPT. Metode numerik klasik telah dikembangkan untuk memperoleh parameter sel dari data pengukuran, tetapi proses identifikasi merupakan masalah nonlinear, saling terikat, dan dapat memiliki beberapa kombinasi parameter yang menghasilkan kesalahan model yang hampir sama [3]. Kondisi tersebut menjadi lebih sulit ketika data yang tersedia terbatas, tidak mencakup keseluruhan kurva I–V, atau dikumpulkan pada iradiasi dan temperatur yang berubah.

Sebagian besar penelitian identifikasi parameter fotovoltaik menggunakan data kurva I–V laboratorium, data modul standar, atau informasi lengkap dari lembar data pabrik. Pendekatan berbasis differential evolution telah digunakan untuk mengidentifikasi parameter

model fotovoltaiik pada kondisi lingkungan yang berbeda dengan menambahkan penalti agar solusi tetap memenuhi batas fisik [4]. Algoritma Genetika juga telah digunakan untuk mengidentifikasi parameter sel dan modul serta menentukan titik daya maksimum berdasarkan model yang dihasilkan [5]. Penelitian tersebut menunjukkan bahwa optimasi populasi dapat menangani hubungan nonlinear tanpa memerlukan turunan analitis fungsi objektif.

Pendekatan lain menggunakan kecerdasan kawanan. Artificial bee swarm optimization digunakan untuk memperoleh parameter model satu dan dua dioda dengan mencari kombinasi yang meminimalkan selisih antara karakteristik model dan data eksperimen [6]. Particle Swarm Optimization kemudian dikembangkan dengan strategi mutasi adaptif untuk meningkatkan keseimbangan eksplorasi dan eksploitasi dalam ekstraksi parameter sel maupun modul fotovoltaiik [7]. Perkembangan tersebut menunjukkan bahwa kualitas hasil identifikasi tidak hanya ditentukan oleh bentuk model, tetapi juga oleh kemampuan optimizer dalam menemukan solusi yang akurat dan stabil pada ruang pencarian berdimensi banyak.

Data lapangan memberikan tantangan yang berbeda dari pengujian laboratorium. Pengukuran dipengaruhi perubahan cuaca, keterbatasan sensor, kondisi konverter, pola pembebanan, serta ketidaklengkapan informasi modul. Identifikasi parameter berbasis GA dan PSO dari data eksperimen pada berbagai iradiasi dan temperatur telah menunjukkan bahwa optimasi dapat digunakan untuk memperoleh model PV yang mendekati karakteristik sistem aktual [8]. Metode berbasis data pabrikan juga dikembangkan untuk memperoleh parameter model pada modul yang hanya memiliki beberapa titik karakteristik standar [9]. Sementara itu, pengembangan hibrida GWO–SCA menunjukkan bahwa GWO dapat diperluas untuk meningkatkan pencarian parameter rangkaian ekuivalen fotovoltaiik [10].

Ketiadaan atau ketidakakuratan data teknis tidak hanya terjadi pada modul individual, tetapi juga pada instalasi fotovoltaiik yang telah beroperasi. Parameter sistem seperti kapasitas puncak, orientasi, lokasi, dan karakteristik termal dapat diidentifikasi kembali dari deret waktu daya dan data lingkungan. Penelitian berbasis PSO menunjukkan bahwa pengukuran historis dapat dimanfaatkan untuk memperoleh parameter terbaik yang cocok terhadap perilaku sistem, meskipun parameter tersebut harus dipahami sebagai parameter model hasil pencocokan dan bukan selalu nilai fisik asli dari pabrikan [11]. Prinsip ini relevan untuk modul dengan informasi spesifikasi yang tidak lengkap.

Dalam kelompok metaheuristik, PSO menggerakkan kandidat solusi berdasarkan pengalaman terbaik masing-masing partikel dan solusi terbaik global [12]. GWO menggunakan tiga kandidat terbaik alpha, beta, dan delta untuk mengarahkan perubahan posisi populasi [13]. Keduanya mempunyai mekanisme pencarian yang berbeda dari GA, yang menggunakan seleksi, crossover, dan mutasi. Perbandingan ketiga algoritma pada data yang sama diperlukan karena tidak ada satu optimizer yang selalu memberikan performa terbaik untuk seluruh struktur data dan seluruh parameter.

Penerapan metaheuristik pada beberapa penelitian terbaru juga menunjukkan bahwa kinerja optimizer perlu dievaluasi secara empiris dan tidak dapat diasumsikan selalu unggul pada setiap struktur data. Pada prediksi breakdown voltage minyak transformator menggunakan data eksperimen terbatas, perbandingan pelatihan DFFNN berbasis gradien, GA, dan GWO

menunjukkan bahwa GWO dapat memberikan konvergensi yang stabil, tetapi akurasi terbaik tetap bergantung pada karakteristik data dan metode yang digunakan [16]. Pada prediksi konsumsi energi listrik, evaluasi DFFNN-GA dan DFFNN-GWO dengan sliding-window cross-validation menunjukkan bahwa performa model dan generalisasinya dipengaruhi oleh skenario validasi temporal [17]. Studi pada data ECG terbatas yang membandingkan GA, PSO, GWO, dan kombinasi GA+GWO melalui running berulang juga menunjukkan bahwa metaheuristik terutama berperan dalam meningkatkan stabilitas optimasi, sedangkan kemampuan generalisasi tetap dipengaruhi oleh ukuran dan keragaman data [18]. Selain itu, perbandingan ANN yang dioptimalkan GA/PSO dengan SVR pada prediksi konsumsi energi memperlihatkan bahwa model yang lebih kompleks tidak selalu memberikan keuntungan generalisasi dibandingkan pendekatan yang lebih stabil dan mudah direproduksi [19]. Temuan-temuan tersebut menguatkan kebutuhan untuk membandingkan beberapa optimizer, menggunakan running independen, dan menerapkan validasi terstruktur ketika parameter fotovoltaik diidentifikasi dari pengukuran lapangan yang terbatas.

Data penelitian ini berasal dari sistem fotovoltaik yang dioperasikan menggunakan MPPT Incremental Conductance. Metode tersebut menentukan arah pergeseran titik operasi berdasarkan hubungan incremental conductance dan instantaneous conductance. Walaupun dapat mempertahankan operasi di sekitar titik daya maksimum, nilai $V_{mp,est}$ dan $I_{mp,est}$ yang tersedia tetap dipengaruhi respons kontrol, perubahan lingkungan, dan resolusi pengukuran [14]. Oleh karena itu, parameter yang diidentifikasi dari data ini merepresentasikan perilaku ekuivalen modul pada kondisi lapangan dan pengoperasian Incremental Conductance, bukan hasil pengujian standar melalui penyapuan kurva I–V.

Selain pemilihan optimizer, strategi validasi menentukan kekuatan kesimpulan. Pembagian acak per baris dapat menempatkan pengukuran dari hari yang sama pada data identifikasi dan pengujian, sehingga hasil terlihat lebih baik karena model hanya melakukan interpolasi pada kondisi harian yang serupa. Nested atau grouped cross-validation diperlukan ketika pemilihan parameter dan evaluasi akhir harus dipisahkan secara ketat [15]. Pada penelitian ini, parameter diidentifikasi menggunakan empat hari dan diuji pada satu hari lain melalui leave-one-day-out secara terpisah untuk setiap modul.

Berdasarkan kajian tersebut, masih terdapat ruang penelitian pada identifikasi parameter ekuivalen dari pengukuran lapangan terbatas yang tidak menyediakan kurva I–V lengkap dan memuat modul dengan spesifikasi tidak diketahui. Penelitian ini menawarkan empat kontribusi utama. Pertama, tujuh parameter ekuivalen diidentifikasi secara simultan dari V_{oc} , I_{sc} , $V_{mp,est}$, $I_{mp,est}$, iradiasi, dan temperatur. Kedua, GA, PSO, dan GWO dibandingkan dengan baseline median dalam ruang pencarian dan data yang sama. Ketiga, validasi dilakukan antarhari dan diulang sepuluh kali untuk menilai generalisasi serta stabilitas stokastik. Keempat, modul P3 diperlakukan sebagai modul dengan spesifikasi tidak diketahui, dan hasilnya dinyatakan secara hati-hati sebagai parameter ekuivalen hasil estimasi lapangan.

II. METODE PENELITIAN

A. Data dan Parameter yang Diidentifikasi

Penelitian menggunakan 81 observasi yang diperoleh dari modul P1, P3, dan P5 selama lima hari. Data setiap baris memuat hari pengukuran, identitas modul, iradiasi G, temperatur

T, tegangan rangkaian terbuka V_{oc} , arus hubung singkat I_{sc} , tegangan titik daya maksimum estimasi $V_{mp,est}$, dan arus titik daya maksimum estimasi $I_{mp,est}$. Daya MPP acuan dihitung sebagai

$$P_{MPP,est,i} = V_{mp,est,i} I_{mp,est,i} \quad (1)$$

Pengukuran terdiri atas tiga modul dan lima hari serta dievaluasi melalui sepuluh running independen dengan leave-one-day-out pada setiap modul. Program mencatat bahwa tidak ada referensi datasheet yang dimuat pada running ini sehingga hasil identifikasi tidak dibandingkan secara numerik dengan spesifikasi pabrikan.

Vektor parameter yang dicari untuk setiap modul didefinisikan sebagai

$$\theta = [V_{oc,STC}^{eq}, I_{sc,STC}^{eq}, V_{mp,STC}^{eq}, I_{mp,STC}^{eq}, \alpha_I^{eq}, \beta_V^{eq}, k_G^{eq}] \quad (2)$$

Empat parameter pertama menggambarkan kondisi listrik ekuivalen pada Standard Test Condition, sedangkan α_I^{eq} , β_V^{eq} dan k_G^{eq} mengatur perubahan arus dan tegangan akibat temperatur dan iradiasi. Parameter tersebut bukan parameter rangkaian satu dioda seperti R_s , R_{sh} , atau arus saturasi, tetapi parameter makroskopis yang secara langsung berhubungan dengan titik-titik karakteristik modul. Bentuk ini dipilih karena data yang tersedia tidak memuat penyapuan kurva I–V lengkap.

Tabel 1. Batas pencarian parameter ekuivalen

Parameter	Batas minimum	Batas maksimum	Satuan
$V_{oc,STC}^{eq}$	15,0	30,0	V
$I_{sc,STC}^{eq}$	3,0	10,0	A
$V_{mp,STC}^{eq}$	12,0	25,0	V
$I_{mp,STC}^{eq}$	2,5	9,5	A
α_I^{eq}	0	0,0025	$^{\circ}C^{-1}$
β_V^{eq}	-0,008	-0,001	$^{\circ}C^{-1}$
k_G^{eq}	0	0,10	—

Parameter turunannya dihitung sebagai

$$P_{max,STC}^{eq} = V_{mp,STC}^{eq} I_{mp,STC}^{eq} \quad (3)$$

$$FF^{eq} = \frac{V_{mp,STC}^{eq} I_{mp,STC}^{eq}}{V_{oc,STC}^{eq} I_{sc,STC}^{eq}} \quad (4)$$

dan pendekatan koefisien temperatur daya

$$\gamma_P^{eq} = \alpha_I^{eq} + \beta_V^{eq} \quad (5)$$

Penggunaan titik karakteristik STC, fill factor, dan koefisien perubahan terhadap lingkungan mengikuti prinsip bahwa perilaku modul pada kondisi operasi lain dapat diturunkan dari parameter acuan dan hubungan semiempiris terhadap iradiasi serta temperatur [1] [2].

B. Model Ekuivalen dan Fungsi Objektif

Untuk observasi ke-i, rasio iradiasi dan perubahan temperatur dihitung menggunakan

$$r_{G,i} = \max\left(\frac{G_i}{G_{STC}}, 0,05\right), \quad G_{STC} = 1000 \text{ W/m}^2 \quad (6)$$

$$\Delta T_i = T_i - T_{STC}, \quad T_{STC} = 25^\circ\text{C} \quad (7)$$

Faktor koreksi arus dan tegangan dinyatakan sebagai

$$f_{I,i} = \max(1 + \alpha_I^{\text{eq}} \Delta T_i, 0,05) \quad (8)$$

$$f_{V,i} = \max[1 + \beta_V^{\text{eq}} \Delta T_i + k_G^{\text{eq}} \ln(r_{G,i}), 0,05] \quad (9)$$

Nilai karakteristik yang direkonstruksi selanjutnya dihitung melalui

$$\hat{V}_{oc,i} = V_{oc,STC}^{\text{eq}} f_{V,i} \quad (10)$$

$$\hat{I}_{sc,i} = I_{sc,STC}^{\text{eq}} r_{G,i} f_{I,i} \quad (11)$$

$$\hat{V}_{mp,i} = V_{mp,STC}^{\text{eq}} f_{V,i} \quad (12)$$

$$\hat{I}_{mp,i} = I_{mp,STC}^{\text{eq}} r_{G,i} f_{I,i} \quad (13)$$

dan

$$\hat{P}_{MPP,i} = \hat{V}_{mp,i} \hat{I}_{mp,i} \quad (14)$$

Model tersebut mempertahankan hubungan arus yang hampir proporsional terhadap iradiasi dan perubahan tegangan yang lebih sensitif terhadap temperatur serta komponen logaritmik iradiasi. Bentuk semiempiris digunakan agar jumlah parameter tetap sebanding dengan keterbatasan data, sehingga identifikasi tidak menjadi terlalu kompleks.

Lima keluaran digunakan secara simultan dalam fungsi objektif:

$$\mathbf{y}_i = [V_{oc,i}, I_{sc,i}, V_{mp,est,i}, I_{mp,est,i}, P_{MPP,est,i}] \quad (15)$$

Galat ternormalisasi untuk keluaran ke-q adalah

$$e_{i,q} = \frac{\hat{y}_{i,q} - y_{i,q}}{s_q} \quad (16)$$

dengan s_q dihitung dari rentang nilai pada data identifikasi. Batas minimum skala ditetapkan sebesar 1 V untuk keluaran tegangan, 0,2 A untuk keluaran arus, dan 5 W untuk daya, sehingga fungsi objektif tidak menjadi tidak stabil ketika rentang salah satu keluaran relatif sempit. Galat pada hari ke-d dihitung sebagai

$$E_d = \sqrt{\frac{1}{N_d} \sum_{i \in d} \sum_{q=1}^5 w_q e_{i,q}^2} \quad (17)$$

dengan bobot

$$\mathbf{w} = [0,15, 0,15, 0,20, 0,20, 0,30] \quad (18)$$

Bobot terbesar diberikan pada daya MPP, diikuti tegangan dan arus MPP, karena ketiga keluaran tersebut paling langsung merepresentasikan titik operasi Incremental Conductance. Fitness akhir dirumuskan sebagai

$$J(\theta) = \bar{E}_d + 0,10s_{E_d} + P_{\text{fisik}} \quad (19)$$

Komponen pertama meminimalkan galat rata-rata antarhari, komponen kedua mengurangi solusi yang hanya baik pada hari tertentu, dan P_fisik memberikan penalti apabila kandidat parameter melanggar hubungan dasar:

$$V_{mp,STC}^{eq} < V_{oc,STC}^{eq}, \quad I_{mp,STC}^{eq} < I_{sc,STC}^{eq} \quad (20)$$

$$0,65 \leq \frac{V_{mp,STC}^{eq}}{V_{oc,STC}^{eq}} \leq 0,95 \quad (21)$$

$$0,70 \leq \frac{I_{mp,STC}^{eq}}{I_{sc,STC}^{eq}} \leq 0,995 \quad (22)$$

$$0,45 \leq FF^{eq} \leq 0,90 \quad (23)$$

dan

$$-0,010 \leq \gamma_p^{eq} \leq 0,001 \quad (24)$$

Penambahan batas fisik pada fungsi objektif mengikuti prinsip penalty-based parameter extraction, yaitu mencegah optimizer memilih kombinasi yang mempunyai kesalahan numerik kecil tetapi tidak konsisten dengan karakteristik modul fotovoltaik [4].

C. Optimasi Metaheuristik dan Validasi Antarhari

Empat pendekatan dibandingkan. Baseline dibentuk melalui median nilai STC yang dikoreksi balik dari data identifikasi dengan $\alpha_I=0,0005$, $\beta_V=-0,0035$, dan $k_G=0,03$. Tiga pendekatan lainnya mengoptimasi ketujuh parameter menggunakan GA, PSO, dan GWO.

GA menggunakan populasi 20 kromosom dan 80 generasi. Kandidat dipilih melalui turnamen, dua kandidat terbaik dipertahankan melalui elitisme, peluang crossover ditetapkan 0,85, dan peluang mutasi 0,15. Amplitudo mutasi dikurangi secara bertahap agar pencarian awal lebih eksploratif dan pencarian akhir lebih terarah. Mekanisme seleksi–crossover–mutasi sesuai dengan prinsip identifikasi parameter berbasis evolusi [5] [8].

PSO menggunakan 20 partikel dan 80 iterasi. Kecepatan partikel diperbarui melalui

$$v_i^{t+1} = w^t v_i^t + c_1 r_1 (p_i - x_i^t) + c_2 r_2 (g - x_i^t) \quad (25)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (26)$$

dengan $c_1=c_2=1,7$, sedangkan bobot inersia turun dari 0,9 menuju 0,4. Posisi p_i merupakan solusi terbaik partikel, sedangkan g adalah solusi terbaik seluruh populasi [12]. GWO menggunakan 20 serigala dan 80 iterasi. Posisi baru kandidat ditentukan dari tiga solusi terbaik, yaitu alpha, beta, dan delta:

$$D_k = |C_k X_k - X| \quad (27)$$


$$X'_k = X_k - A_k D_k \quad (28)$$

$$X^{t+1} = \frac{X'_\alpha + X'_\beta + X'_\delta}{3} \quad (29)$$

Koefisien eksplorasi a diturunkan dari 2 menuju 0 untuk menggeser perilaku optimizer dari eksplorasi menuju eksploitasi [13].

Validasi dilakukan secara leave-one-day-out pada masing-masing modul. Empat hari digunakan untuk mengidentifikasi parameter dan satu hari ditahan sepenuhnya sebagai data uji. Prosedur tersebut diulang sampai kelima hari menjadi data uji. Keseluruhan lima fold kemudian diulang sepuluh kali dengan seed berbeda untuk GA, PSO, dan GWO. Dengan

demikian, setiap optimizer menghasilkan 50 estimasi parameter per modul, yaitu lima fold dikalikan sepuluh running. Urutan kerja program dirangkum sebagai berikut:



Gambar 1. Blok diagram tahapan kerja identifikasi parameter ekuivalen menggunakan PV parameter

D. Evaluasi Performa dan Ketidakpastian Parameter

Evaluasi dilakukan untuk setiap keluaran menggunakan RMSE, MAE, R^2 , nRMSE, WAPE, dan MBE. Skor komposit akhir merupakan rata-rata berbobot nRMSE:

$$S_{\text{komposit}} = 0,15 \text{ nRMSE}_{V_{oc}} + 0,15 \text{ nRMSE}_{I_{sc}} + 0,20 \text{ nRMSE}_{V_{mp}} + 0,20 \text{ nRMSE}_{I_{mp}} + 0,30 \text{ nRMSE}_{P_{MPP}} \quad (30)$$

Nilai yang lebih rendah menunjukkan rekonstruksi multivariabel yang lebih baik. RMSE dan R^2 dihitung sebagai

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (31)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (32)$$

Stabilitas parameter dievaluasi menggunakan koefisien variasi:

$$CV = \frac{s_{\theta}}{|\bar{\theta}|} \times 100\% \quad (33)$$

Perbedaan performa antarooptimizer diuji menggunakan Wilcoxon signed-rank pada sepuluh skor running. Nilai $p < 0,05$ digunakan sebagai indikator perbedaan yang signifikan.

III. HASIL DAN PEMBAHASAN


Hasil ensemble menunjukkan bahwa seluruh metode metaheuristik memperbaiki skor komposit baseline. Baseline median menghasilkan skor 13,2498, sedangkan GA, PSO, dan GWO masing-masing memperoleh 11,4310, 11,2254, dan 12,1678. Dengan demikian, PSO

memberikan penurunan skor sebesar 15,28% terhadap baseline, lebih besar daripada GA sebesar 13,73% dan GWO sebesar 8,17%.

Tabel 2. Performa ensemble keseluruhan

Metode	Skor komposit	RMSE V_{oc} (V)	RMSE I_{sc} (A)	RMSE V_{mp} (V)	RMSE I_{mp} (A)	RMSE P_{MPP} (W)	R^2_{MPP}
Baseline median	13,2498	0,5681	0,7039	0,4591	0,6458	10,2563	0,8740
GA	11,4310	0,4208	0,6660	0,3388	0,6106	9,7629	0,8858
PSO	11,2254	0,4039	0,6594	0,3260	0,6068	9,7098	0,8870
GWO	12,1678	0,4676	0,6950	0,3768	0,6313	10,1512	0,8765

PSO tidak hanya menghasilkan skor komposit terendah, tetapi juga RMSE terendah pada kelima keluaran. Peningkatannya paling jelas pada rekonstruksi tegangan. RMSE V_{oc} turun dari 0,5681 V menjadi 0,4039 V, sedangkan RMSE V_{mp} turun dari 0,4591 V menjadi 0,3260 V. Pada rekonstruksi daya, perbedaannya lebih kecil karena baseline median sudah menghasilkan R^2 sebesar 0,8740. PSO tetap meningkatkan R^2 menjadi 0,8870 dan menurunkan RMSE dari 10,2563 menjadi 9,7098 W.




Gambar 2. Perbandingan skor komposit identifikasi parameter secara keseluruhan.

Hasil tersebut menunjukkan bahwa keuntungan optimasi tidak hanya terletak pada penyesuaian daya. Fungsi objektif multikeluaran mendorong optimizer menghasilkan kombinasi parameter yang secara bersamaan mampu merekonstruksi V_{oc} , I_{sc} , V_{mp} , I_{mp} , dan P_{MPP} . PSO memberikan kompromi keseluruhan terbaik, sedangkan GA berada sangat dekat. GWO tetap memperbaiki baseline, tetapi hasilnya lebih lemah dan lebih berubah antar-running.

Kurva konvergensi memperkuat temuan tersebut. Rata-rata fitness GA turun dari 0,18405 pada iterasi pertama menjadi 0,13994 pada iterasi ke-80, atau berkurang 23,97%. PSO turun dari 0,18424 menjadi 0,12900, setara dengan penurunan 29,98%. GWO hanya turun dari 0,18491 menjadi 0,16038 atau 13,27%. Nilai akhir PSO yang paling rendah menunjukkan bahwa mekanisme pembaruan berbasis personal best dan global best lebih efektif pada ruang pencarian tujuh parameter penelitian ini. Perbedaan konvergensi tidak berarti GWO selalu lebih buruk untuk seluruh fold. Pada beberapa kombinasi hari dan running, GWO dapat mendekati GA atau PSO. Namun, pola hasil running menunjukkan GWO lebih sering berhenti pada fitness yang lebih tinggi, khususnya pada P1 dan P5. Sebagai contoh, pada

running pertama untuk P5, fitness PSO berada antara 0,1103–0,1659, sedangkan GWO berada antara 0,1839–0,2284.



Gambar 3. Konvergensi rata-rata GA, PSO, dan GWO selama 80 iterasi.

Identifikasi Parameter Ekuivalen Modul P3

P3 merupakan fokus utama karena tidak mempunyai referensi spesifikasi yang digunakan dalam running. Tabel 3 menyajikan parameter listrik utamanya. Nilai yang diperoleh ketiga optimizer saling berdekatan, terutama pada arus, daya maksimum, dan fill factor. Hal ini penting karena menunjukkan bahwa solusi tidak sepenuhnya bergantung pada satu jenis algoritma.


Tabel 3. Parameter ekuivalen hasil estimasi lapangan untuk modul P3

Parameter	GA, mean $\pm$ SD	PSO, mean $\pm$ SD	GWO, mean $\pm$ SD
$V_{oc,STC}^{eq}$ (V)	20,2034 $\pm$ 0,1702	19,7483 $\pm$ 0,3846	19,7496 $\pm$ 0,5699
$I_{sc,STC}^{eq}$ (A)	4,5315 $\pm$ 0,2281	4,5090 $\pm$ 0,2176	4,4886 $\pm$ 0,3178
$V_{mp,STC}^{eq}$ (V)	16,2734 $\pm$ 0,1371	15,9098 $\pm$ 0,3095	15,9121 $\pm$ 0,4601
$I_{mp,STC}^{eq}$ (A)	4,1168 $\pm$ 0,2033	4,0925 $\pm$ 0,1961	4,0857 $\pm$ 0,2935
$P_{max,STC}^{eq}$ (W)	66,9872 $\pm$ 3,2084	65,0899 $\pm$ 2,8926	64,9805 $\pm$ 4,6587
FF^{eq}	0,7318 $\pm$ 0,0037	0,7313 $\pm$ 0,0053	0,7334 $\pm$ 0,0137

Sumber nilai parameter P3 adalah 50 estimasi per metode, yang berasal dari lima fold dan sepuluh running.

GA menghasilkan $V_{oc,STC}^{eq}$ dan $V_{mp,STC}^{eq}$ sedikit lebih tinggi dibandingkan PSO dan GWO. Namun, rentang antarmetode hanya sekitar 2,28% untuk $V_{oc,STC}^{eq}$ dan 2,23% untuk $V_{mp,STC}^{eq}$. Perbedaan pada arus lebih kecil, yaitu sekitar 0,95% untuk $I_{sc,STC}^{eq}$ dan 0,75% untuk $I_{mp,STC}^{eq}$. Nilai $P_{max,STC}^{eq}$ berada pada rentang 64,9805–66,9872 W, sedangkan fill factor hanya berada pada rentang 0,7313–0,7334.


Kesepakatan yang tinggi pada fill factor menunjukkan bahwa rasio antara titik daya maksimum dan produk $V_{oc}I_{sc}$ dapat diidentifikasi secara konsisten walaupun optimizer mencapai kombinasi tegangan dan arus yang sedikit berbeda. Dengan kata lain, terdapat beberapa kombinasi parameter yang menghasilkan bentuk karakteristik ekuivalen hampir sama. Kondisi ini lazim pada masalah identifikasi dengan data terbatas karena beberapa parameter dapat saling mengompensasi.



Gambar 4. Nilai rata-rata dan simpangan baku daya maksimum ekuivalen modul P3.

GA menghasilkan $P_{max,STC}^{eq}$ tertinggi, yaitu 66,9872 W, sedangkan PSO dan GWO masing-masing menghasilkan 65,0899 W dan 64,9805 W. Namun, simpangan baku GA sebesar 3,2084 W masih lebih besar daripada PSO sebesar 2,8926 W. GWO memiliki simpangan baku terbesar, yaitu 4,6587 W. Oleh sebab itu, pemilihan “parameter utama” tidak cukup hanya berdasarkan nilai rata-rata. Kestabilan dan kemampuan rekonstruksi juga perlu diperhatikan.

Parameter utama mempunyai CV relatif rendah. Pada GA, CV $V_{oc,STC}^{eq}$, $V_{mp,STC}^{eq}$, $P_{max,STC}^{eq}$, dan FF^{eq} masing-masing hanya 0,84%, 0,84%, 4,79%, dan 0,51%. PSO menghasilkan CV 1,95%, 1,95%, 4,44%, dan 0,73% untuk parameter yang sama. GWO menghasilkan ketidakpastian lebih tinggi, terutama pada $P_{max,STC}^{eq}$ dengan CV 7,17%. Sebaliknya, koefisien temperatur dan iradiasi lebih sulit diidentifikasi. Pada GA, CV α_I^{eq} mencapai 42,26% dan CV β_V^{eq} 33,56%. Pada PSO, CV keduanya meningkat menjadi 67,40% dan 94,84%. GWO menghasilkan CV α_I^{eq} sebesar 82,64%, β_V^{eq} sebesar 43,56%, dan k_G^{eq} sebesar 35,94%.



Gambar 5. Koefisien variasi parameter ekuivalen modul P3.

Perbedaan tersebut menunjukkan adanya tingkat identifiability yang tidak sama. Tegangan, arus, daya maksimum, dan fill factor didukung langsung oleh titik karakteristik yang tersedia pada setiap observasi. Sebaliknya, pengaruh temperatur harus dipisahkan dari

perubahan iradiasi dan variasi harian, padahal jumlah hari dan rentang kondisi hanya terbatas. Oleh karena itu, parameter listrik utama lebih layak digunakan untuk karakterisasi P3, sedangkan α_I^{eq} , β_V^{eq} , k_G^{eq} dan γ_P^{eq} harus diperlakukan sebagai estimasi sekunder dengan ketidakpastian lebih tinggi.

Berdasarkan kombinasi kestabilan dan skor komposit, hasil GA dapat digunakan sebagai representasi parameter ekuivalen utama P3. Namun, ini tidak berarti GA selalu memberikan prediksi terbaik untuk setiap keluaran. PSO tetap menghasilkan rekonstruksi daya yang sedikit lebih akurat, sebagaimana dibahas pada bagian berikutnya.


A. Rekonstruksi Daya dan Generalisasi Antar-Modul

Kemampuan parameter dalam merekonstruksi data yang tidak digunakan saat identifikasi merupakan validasi utama. Pada P3, seluruh optimizer memperbaiki rekonstruksi daya terhadap baseline median.

Tabel 4. Rekonstruksi $P_{MPP,est}$ pada modul P3

Metode	Skor komposit	RMSE (W)	MAE (W)	R ²
Baseline median	18,7887	12,5604	10,2639	0,7336
GA	17,1909	11,4508	9,0003	0,7786
PSO	17,2475	11,3957	8,9664	0,7808
GWO	17,8698	11,7792	9,3066	0,7657

GA menurunkan skor komposit P3 sebesar 8,50% dibandingkan baseline dan menghasilkan skor keseluruhan terbaik pada modul tersebut. PSO memberikan skor sedikit lebih tinggi, tetapi menghasilkan RMSE, MAE, dan R² daya terbaik. GWO menghasilkan MBE paling dekat dengan nol, tetapi RMSE dan MAE-nya masih lebih besar. Nilai tersebut berasal dari prediksi ensemble 27 observasi P3.




Gambar 6. RMSE dan MAE rekonstruksi daya MPP pada modul P3.

Penurunan RMSE PSO terhadap baseline mencapai sekitar 9,27%, sedangkan MAE turun sekitar 12,64%. Perbaikannya tidak sangat besar karena baseline median telah menghasilkan hubungan daya yang cukup baik. Keuntungan utama optimizer terlihat pada kemampuannya menyesuaikan lima keluaran secara serentak, bukan hanya pada daya.

Pada rekonstruksi I_{sc} dan I_{mp} , PSO menghasilkan R² masing-masing 0,7948 dan 0,7944. Pada V_{oc} dan V_{mp} , nilai R² masih negatif, yaitu -0,1347 dan -0,1337. Hasil ini tidak berarti besarnya kesalahan tegangan sangat tinggi; RMSE V_{oc} hanya 0,5668 V dan RMSE V_{mp}

0,4564 V. Nilai R^2 negatif terutama menunjukkan bahwa variasi tegangan antarobservasi relatif sempit, sehingga error yang tidak terlalu besar masih lebih tinggi dibandingkan variasi terhadap nilai rata-ratanya.




Gambar 7. Profil daya MPP acuan dan hasil rekonstruksi ensemble pada modul P3.

Kurva hasil identifikasi mengikuti pola naik-turun daya P3, tetapi masih terdapat selisih pada beberapa kondisi daya tinggi. PSO dan GA hampir berhimpitan pada sebagian besar observasi, sesuai dengan kedekatan RMSE keduanya. GWO menghasilkan profil yang lebih bervariasi karena parameter antar-running-nya mempunyai simpangan lebih besar. Perbedaan perilaku optimizer juga terlihat pada panel lain.

Tabel 5. Skor komposit rata-rata sepuluh running pada setiap modul

Modul	GA	PSO	GWO
P1	10,0951 ±	9,9985 ±	14,1858 ±
	0,1895	0,1081	1,7608
P3	17,1975 ±	17,2567 ±	18,1843 ±
	0,0755	0,0706	0,8723
P5	17,0215 ±	15,1668 ±	18,8463 ±
	0,2797	0,1240	1,0619

Nilai rata-rata dan simpangan baku sepuluh running menunjukkan bahwa PSO paling baik dan paling stabil pada P1 serta P5, sedangkan GA sedikit lebih baik pada P3. GWO mempunyai simpangan baku jauh lebih tinggi pada ketiga modul.



Gambar 8. Perbandingan skor komposit ensemble pada modul P1, P3, dan P5.

P1 merupakan modul yang paling mudah direkonstruksi. Skor ensemble PSO hanya 9,9810 dengan $R_{P_{MPP}}^2 = 0,9325$. P3 lebih sulit, dengan skor terbaik 17,1909 dan R^2 daya sekitar 0,78. Pada P5, PSO memberikan skor 15,1346 dan $RR_{P_{MPP}}^2 = 0,9025$. Perbedaan ini

menunjukkan bahwa tingkat kesulitan identifikasi tidak hanya dipengaruhi jumlah data, karena setiap modul memiliki 27 observasi, tetapi juga dipengaruhi rentang operasi, konsistensi pengukuran, dan kesesuaian model ekuivalen terhadap karakteristik masing-masing modul.

Hasil P1 dan P5 tidak dapat digunakan sebagai validasi terhadap nilai pabrikan karena file referensi datasheet tidak dimuat dalam running. Dengan demikian, keberhasilan model dinilai melalui rekonstruksi antahhari dan kestabilan parameter. Pernyataan bahwa parameter yang diperoleh “mendekati datasheet” tidak dapat dibuat berdasarkan hasil saat ini.

B. Bukti Statistik, Ketidakpastian, dan Implikasi Penelitian

Uji Wilcoxon digunakan untuk menentukan apakah perbedaan skor running bersifat konsisten.

Tabel 6. Hasil uji Wilcoxon skor komposit

Modul	Perbandingan	(p)-value	Interpretasi
P1	GA-PSO	0,2213	Tidak signifikan
P1	GA-GWO	0,0059	Signifikan
P1	PSO-GWO	0,0059	Signifikan
P3	GA-PSO	0,1263	Tidak signifikan
P3	GA-GWO	0,0144	Signifikan
P3	PSO-GWO	0,0191	Signifikan
P5	GA-PSO	0,0059	Signifikan
P5	GA-GWO	0,0108	Signifikan
P5	PSO-GWO	0,0059	Signifikan

Seluruh nilai uji berasal dari sepuluh skor running per modul. Pada P1 dan P3, perbedaan GA dan PSO tidak signifikan. Artinya, keunggulan kecil salah satu metode belum cukup konsisten untuk menyatakan superioritas statistik. Pada P3, GA memperoleh skor komposit lebih rendah, sedangkan PSO memperoleh RMSE daya lebih rendah. Kedua temuan tidak saling bertentangan karena skor komposit memperhitungkan lima keluaran, sedangkan RMSE daya hanya mengevaluasi P_{MPP} .

GA dan PSO secara signifikan lebih baik daripada GWO pada P1 dan P3. Pada P5, PSO secara signifikan lebih baik daripada GA dan GWO. Temuan statistik ini konsisten dengan kurva konvergensi serta simpangan baku skor. GWO tidak hanya menghasilkan skor rata-rata lebih tinggi, tetapi juga lebih sensitif terhadap inisialisasi populasi.

Secara metodologis, hasil penelitian menunjukkan dua tingkatan keberhasilan. Tingkat pertama adalah predictive identifiability, yaitu kemampuan parameter untuk merekonstruksi keluaran pada hari yang ditahan. PSO unggul pada tingkatan ini secara keseluruhan dan pada rekonstruksi daya P3. Tingkat kedua adalah parameter stability, yaitu konsistensi nilai parameter pada fold dan running yang berbeda. GA memberikan kestabilan kuat untuk parameter utama P3, terutama tegangan dan fill factor.

Keterbatasan utama terletak pada koefisien lingkungan. Nilai CV yang tinggi menunjukkan bahwa perubahan temperatur dan iradiasi dalam lima hari belum cukup untuk memisahkan pengaruh α_I^{eq} , β_V^{eq} , k_G^{eq} secara kuat. Parameter tersebut masih berfungsi dalam model sebagai faktor koreksi, tetapi tidak memiliki tingkat kepastian yang sama dengan parameter STC utama.

Keterbatasan kedua adalah tidak tersedianya referensi datasheet pada proses running. Oleh karena itu, istilah yang tepat adalah parameter ekuivalen hasil estimasi lapangan. Parameter tersebut menggambarkan kombinasi yang paling sesuai dengan model dan data, bukan pemulihan nilai asli pabrikan. Program juga secara eksplisit memberikan catatan bahwa parameter P3 tidak boleh disebut sebagai spesifikasi pabrikan yang pasti.

Meskipun demikian, validasi antarhari memberikan bukti yang lebih kuat daripada sekadar kesesuaian pada data identifikasi. Setiap observasi diuji oleh parameter yang diperoleh tanpa menggunakan data dari hari yang sama. Hasil R_{PMP}^2 sebesar 0,7808 pada P3 menunjukkan bahwa parameter ekuivalen mampu menjelaskan sebagian besar variasi daya acuan pada hari yang tidak terlibat dalam optimasi.

IV. KESIMPULAN

1. PSO memberikan performa keseluruhan terbaik dengan skor komposit 11,2254, atau 15,28% lebih rendah daripada baseline median. PSO juga menghasilkan konvergensi tercepat dan nilai fitness akhir terendah di antara ketiga optimizer.
2. Pada modul P3, GA menghasilkan skor komposit terbaik sebesar 17,1909 dan parameter utama yang stabil, sedangkan PSO memberikan rekonstruksi daya terbaik dengan RMSE 11,3957 W, MAE 8,9664 W, dan $R^2=0,7808$. Perbedaan GA dan PSO tidak signifikan, tetapi keduanya signifikan lebih baik daripada GWO.
3. Estimasi utama P3 berada di sekitar $V_{oc,STC}^{eq}=20,2034$ V, $I_{sc,STC}^{eq}=4,5315$ A, $V_{mp,STC}^{eq}=16,2734$ V, $I_{mp,STC}^{eq}=4,1168$ A, $P_{max,STC}^{eq}=66,9872$ W, dan $FF^{eq}=0,7318$ berdasarkan hasil GA. Parameter tegangan, arus, daya, dan fill factor lebih stabil daripada koefisien temperatur serta iradiasi.
4. Parameter yang diperoleh merupakan parameter ekuivalen hasil estimasi lapangan, bukan spesifikasi pabrikan. Penambahan data dengan rentang temperatur dan iradiasi yang lebih luas serta penyediaan datasheet atau hasil penyapuan kurva I–V diperlukan untuk memperkuat validasi parameter fisik pada penelitian berikutnya.

V. REFERENSI

- [1] M. G. Villalva, J. R. Gazoli, dan E. Ruppert Filho, "Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays," *IEEE Transactions on Power Electronics*, vol. 24, no. 5, pp. 1198–1208, 2009, doi: 10.1109/TPEL.2009.2013862.
- [2] W. De Soto, S. A. Klein, dan W. A. Beckman, "Improvement and Validation of a Model for Photovoltaic Array Performance," *Solar Energy*, vol. 80, no. 1, pp. 78–88, 2006, doi: 10.1016/j.solener.2005.06.010.
- [3] T. Easwarakhanthan, J. Bottin, I. Bouhouch, dan C. Boutrit, "Nonlinear Minimization

- Algorithm for Determining the Solar Cell Parameters with Microcomputers,” *International Journal of Solar Energy*, vol. 4, no. 1, pp. 1–12, 1986, doi: 10.1080/01425918608909835.
- [4] K. Ishaque, Z. Salam, S. Mekhilef, dan A. Shamsudin, “Parameter Extraction of Solar Photovoltaic Modules Using Penalty-Based Differential Evolution,” *Applied Energy*, vol. 99, pp. 297–308, 2012, doi: 10.1016/j.apenergy.2012.05.017.
- [5] M. Zagrouba, A. Sellami, M. Bouaïcha, dan M. Ksouri, “Identification of PV Solar Cells and Modules Parameters Using the Genetic Algorithms: Application to Maximum Power Extraction,” *Solar Energy*, vol. 84, no. 5, pp. 860–866, 2010, doi: 10.1016/j.solener.2010.02.012.
- [6] A. Askarzadeh dan A. Rezazadeh, “Artificial Bee Swarm Optimization Algorithm for Parameters Identification of Solar Cell Models,” *Applied Energy*, vol. 102, pp. 943–949, 2013, doi: 10.1016/j.apenergy.2012.09.052.
- [7] M. Merchaoui, A. Sakly, dan M. F. Mimouni, “Particle Swarm Optimisation with Adaptive Mutation Strategy for Photovoltaic Solar Cell/Module Parameter Extraction,” *Energy Conversion and Management*, vol. 175, pp. 151–163, 2018, doi: 10.1016/j.enconman.2018.08.081.
- [8] M. Bechouat, A. Younsi, M. Sedraoui, Y. Soufi, L. Yousfi, I. Tabet, dan K. Touafek, “Parameters Identification of a Photovoltaic Module in a Thermal System Using Meta-Heuristic Optimization Methods,” *International Journal of Energy and Environmental Engineering*, vol. 8, pp. 331–341, 2017, doi: 10.1007/s40095-017-0252-6.
- [9] S. Tajjour, S. S. Chandel, H. Malik, M. A. Alotaibi, dan T. S. Ustun, “A Novel Metaheuristic Approach for Solar Photovoltaic Parameter Extraction Using Manufacturer Data,” *Photonics*, vol. 9, no. 11, Art. no. 858, 2022, doi: 10.3390/photonics9110858.
- [10] R. Devarapalli, B. V. Rao, dan A. Al-Durra, “Optimal Parameter Assessment of Solar Photovoltaic Module Equivalent Circuit Using a Novel Enhanced Hybrid GWO-SCA Algorithm,” *Energy Reports*, vol. 8, pp. 12282–12301, 2022, doi: 10.1016/j.egyr.2022.09.069.
- [11] P. Danner dan H. de Meer, “Location and Solar System Parameter Extraction from Power Measurement Time Series,” *Energy Informatics*, vol. 4, Art. no. 14, 2021, doi: 10.1186/s42162-021-00176-2.
- [12] J. Kennedy dan R. Eberhart, “Particle Swarm Optimization,” dalam *Proceedings of the IEEE International Conference on Neural Networks*, Perth, Australia, vol. 4, pp. 1942–1948, 1995, doi: 10.1109/ICNN.1995.488968.
- [13] S. Mirjalili, S. M. Mirjalili, dan A. Lewis, “Grey Wolf Optimizer,” *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [14] I. Owusu-Nyarko, M. A. Elgenedy, I. Abdelsalam, dan K. H. Ahmed, “Modified Variable Step-Size Incremental Conductance MPPT Technique for Photovoltaic Systems,” *Electronics*, vol. 10, no. 19, Art. no. 2331, 2021, doi: 10.3390/electronics10192331.
- [15] S. Varma dan R. Simon, “Bias in Error Estimation When Using Cross-Validation for Model Selection,” *BMC Bioinformatics*, vol. 7, Art. no. 91, 2006, doi: 10.1186/1471-

- 2105-7-91.
- [16]G. D. Prenata, “Predicting Breakdown Voltage of Transformer Oil under Copper/Iron Contamination: A Comparative Study of Gradient vs Metaheuristic Training,” *ELKHA: Jurnal Teknik Elektro*, vol. 18, no. 1, pp. 65–73, Apr. 2026, doi: 10.26418/elkha.v18i1.101026.
- [17]G. D. Prenata, “Evaluasi Komparatif DFFNN, DFFNN yang Dioptimasi GA, DFFNN yang Dioptimasi GWO, dan LSTM untuk Prediksi Konsumsi Energi Listrik Menggunakan Sliding Window Cross-Validation,” *Techné: Jurnal Ilmiah Elektroteknika*, vol. 25, no. 1, pp. 91–104, 2026, doi: 10.31358/techne.v25i1.656.
- [18]G. D. Prenata, A. Ridho’i, dan M. R. Arshad, “Comparative Evaluation of LSTM and Metaheuristic-Optimized Neural Networks for ECG Prediction under Limited Data Conditions,” *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, vol. 8, no. 2, pp. 751–768, Apr. 2026, doi: 10.35882/jeeemi.v8i2.1524.
- [19]G. D. Prenata, “Analisis Perbandingan Kinerja Jaringan Saraf Tiruan (JST) yang Dioptimalkan Metaheuristik dan Regresi Vektor Pendukung untuk Prediksi Konsumsi Energi Listrik,” *CYCLOTRON*, vol. 9, no. 2, pp. 32–37, Jul. 2026, doi: 10.30651/ct.v9i02.30809.