

# Pemodelan dan Simulasi MPPT pada Sistem PLTS Menggunakan Metode DNN

Edi Leksono<sup>1</sup>, Robi Sobirin<sup>2</sup>, Reza Fauzi Iskandar<sup>3</sup>, Putu Handre Kertha Utama<sup>4</sup>, Mochammad Iqbal Bayeqi<sup>5</sup>, Muhammad Fatih Hasan<sup>6</sup>, Irsyad Nashirul Haq<sup>7</sup>, Justin Pradipta<sup>8</sup>

<sup>1,2,3,4,5,6,7,8</sup>Program Studi Teknik Fisika Fakultas Teknik Industri Institut Teknologi Bandung, Bandung 40132 INDONESIA, (tel.: 022-2504424; fax: 022-2506281, email: <sup>1</sup>edi@tf.itb.ac.id, <sup>2</sup>robisobirin15@gmail.com, <sup>3</sup>rezafauzi@gmail.com, <sup>4</sup>handre.kerthautama@gmail.com, <sup>5</sup>iqbalbayeqi54@gmail.com, <sup>6</sup>fatihasan029@gmail.com, <sup>7</sup>irsyad.n@office.itb.ac.id, <sup>8</sup>justinpradipta@office.itb.ac.id)

<sup>3</sup>Program Studi Teknik Fisika Fakultas Teknik Elektro Universitas Telkom, Bandung 40257 INDONESIA (tel.: 022-756s4108; fax: 022-7562721, email: rezafauzi@gmail.com)

[Diterima: 25 Mei 2023, Direvisi: 12 September 2023]

Corresponding Author: Edi Leksono

**INTISARI** — Fitur *maximum power point tracking* (MPPT) pada sistem pembangkit listrik tenaga surya (PLTS) merupakan suatu fungsi yang penting dalam meningkatkan efisiensi produksi listrik. Algoritma *incremental conductance* (InC) berfungsi mengontrol MPPT yang ditujukan untuk memaksimalkan daya keluaran panel *photovoltaic* (PV) dan meningkatkan efisiensi sistem PLTS. Meskipun algoritma InC termasuk sederhana dan praktis, sayangnya algoritma ini cenderung kurang mendukung kecepatan *switching* secara presisi, sensitif terhadap tingkat presisi pengukuran, dan kurang mampu menghilangkan osilasi daya akibat siklus *switching* yang ketat. Algoritma *deep neural network* (DNN) memiliki potensi untuk menjawab tantangan dinamika MPPT tersebut. Kemampuan pembelajaran DNN memungkinkan pengontrol lebih mengenali dinamika pergeseran nilai daya maksimum, sehingga dapat memberikan aktuasi *switching* yang lebih sesuai. Masukan bagi DNN merupakan *duty ratio* yang dihasilkan oleh algoritma InC. Algoritma DNN diimplementasikan pada tiga topologi konverter daya DC ke DC, yaitu *buck*, *boost*, dan *buck-boost*, untuk mengetahui kinerja MPPT pada kondisi uji standar dan kondisi lingkungan nyata. DNN terbukti mampu mengurangi efek osilasi, mempercepat waktu *steady state*, dan meningkatkan efisiensi. Pada uji kondisi lingkungan nyata, diperoleh hasil bahwa konverter *buck* secara konsisten menghasilkan daya tertinggi, yang selanjutnya diikuti oleh konverter *boost* dan konverter *buck-boost*. Dalam hal efisiensi kinerja, capaian tertinggi terjadi pada konverter *buck*, yakni sebesar 94,58%, diikuti konverter *boost* sebesar 90,79%, dan efisiensi terendah pada konverter *buck-boost* sebesar 79,34%.

**KATA KUNCI** — PLTS, MPPT, Konverter DC/DC, DNN.

## I. PENDAHULUAN

Energi bersih merupakan suatu kebutuhan yang sangat mendesak dan sangat besar pengaruhnya terhadap keberlangsungan lingkungan dan kehidupan manusia pada umumnya. Komitmen akan Perjanjian Paris tahun 2016 mengenai persetujuan kerangka kerja Perserikatan Bangsa-Bangsa (PBB) tentang perubahan iklim merupakan bukti atas urgensi setiap negara untuk menekan emisi gas CO<sub>2</sub> yang ditimbulkan oleh penggunaan bahan bakar fosil [1]. Berbagai upaya ditempuh, yang salah satunya adalah dengan membuka akses terhadap pemanfaatan energi terbarukan, termasuk dengan menggalakkan penyediaan energi listrik berbasis *photovoltaic* (PV). Dapat diperhatikan bahwa dukungan terhadap pemanfaatan energi surya makin kondusif. Harga panel PV, perangkat elektronika daya, dan baterai cenderung makin ekonomis dari tahun ke tahun. Namun demikian, upaya dalam peningkatan efisiensi masih menjadi isu penting dalam meminimalkan rugi-rugi sistem. Isu tersebut makin mencuat ketika dihadapkan pada faktor sumber energi yang berubah-ubah dan topologi sistem PV yang makin kompleks. Berdasarkan kondisi tersebut, jelas bahwa peran teknologi *maximum power point tracking* (MPPT) menjadi salah satu kunci penting bagi peningkatan efisiensi sistem PV.

Kinerja PV dipengaruhi oleh faktor lingkungan, seperti iradiansi matahari dan temperatur udara. Kedua faktor ini akan memengaruhi kinerja modul PV dalam memproduksi energi listrik karena implikasinya terhadap suplai arus, tegangan, maupun daya listrik yang ada pada sistem PV. Hal ini berhubungan dengan kurva karakteristik arus dan tegangan atau kurva arus-tegangan (I-V) pada panel PV, yang untuk setiap kondisi iradiansi matahari yang berbeda, akan

menghasilkan titik daya maksimum atau *maximum power point* (MPP) yang berbeda pula. Oleh karena itu, di sinilah urgensi sistem PLTS memerlukan sebuah perangkat pengontrol MPPT untuk memaksimalkan nilai keluaran dari panel PV dan meningkatkan efisiensi sistem PLTS pada setiap kondisi cuaca yang dihadapi [2].

Pengontrol MPPT yang digunakan pada sistem PV pada dasarnya terdiri atas suatu algoritma pengontrol tertentu dan sebuah konverter daya [3]. Algoritma yang umum digunakan adalah algoritma konvensional, seperti algoritma *perturb-observe* (PO), logika *fuzzy*, maupun *incremental conductance* (InC). Algoritma ini bertugas mengontrol mekanisme *switching* pada konverter daya membentuk suatu fungsi yang disebut sebagai *charge controller* atau regulator arus, tegangan, dan daya listrik. Konverter daya akan melengkapi algoritma kontrol untuk mencapai target tegangan atau daya dengan pemilihan topologi rangkaian dengan fitur tertentu sesuai kebutuhan. Akan tetapi, dalam konteks pengontrol MPPT, algoritma konvensional tersebut belum mampu secara paripurna menyelesaikan permasalahan nonlinieritas dan osilasi yang disebabkan oleh cepatnya perubahan kondisi lingkungan, dalam hal ini perubahan iradiansi matahari dan temperatur udara [2]. InC cenderung sederhana dan praktis untuk diterapkan, tetapi perlu dipertimbangkan pula bahwa metode tersebut kurang mendukung kecepatan pensaklaran secara presisi [4] dan sensitif terhadap tingkat presisi pengukuran [5]. Demikian halnya dengan PO, dengan efisiensi yang cenderung menurun, khususnya dalam menghadapi kondisi perubahan iradiansi dan temperatur yang cepat akibat perubahan cuaca [6], kecepatan penjejakan lambat, dan masalah osilasi *steady state* [7]. Isu osilasi juga patut menjadi

pertimbangan. Strategi kontrol yang tepat seharusnya mampu menekan seminimal mungkin timbulnya osilasi daya akibat siklus pensaklaran yang ketat [8].

Pendekatan pembelajaran mesin memiliki potensi untuk menjawab tantangan dinamika MPPT, seperti *artificial neural network* (ANN) ataupun *deep neural network* (DNN). Algoritma ini menirukan mekanisme kerja jaringan saraf otak manusia dan tersusun dari banyak neuron dan *node*. Algoritma ANN merupakan algoritma yang *robust* dan efisien, bekerja pada titik optimal tanpa menimbulkan osilasi yang berarti [9], walaupun terdapat risiko, yaitu implementasinya cenderung lebih kompleks. DNN memberikan keuntungan dalam mengatasi permasalahan efisiensi yang lebih baik karena peningkatan akurasi dan kecepatan komputasi algoritmanya [2]. Algoritma MPPT dengan pembelajaran mesin ini akan menahan daya keluaran di titik tertinggi dengan kombinasi pengukuran arus dan tegangan dengan umpan *duty ratio* pensaklaran [10]. Pada tahun 2020, telah berhasil dimodelkan dan didemonstrasikan algoritma untuk pengontrol MPPT berbasis DNN untuk sistem energi angin dan gabungan PV/angin [10]. Referensi [11] pada tahun 2020 berhasil mengembangkan algoritma MPPT berbasis DNN menggunakan MATLAB untuk meningkatkan kualitas daya keluaran yang dihasilkan menggunakan gabungan PV dan sistem *fuel cell*. Selanjutnya, pada tahun 2022 sebuah penelitian memanfaatkan algoritma DNN dalam aplikasi MPPT untuk mengurangi kehilangan daya yang tidak sesuai, sehingga mampu mendapatkan titik daya maksimum yang efektif dengan waktu kesalahan komputasi yang lebih sedikit [12].

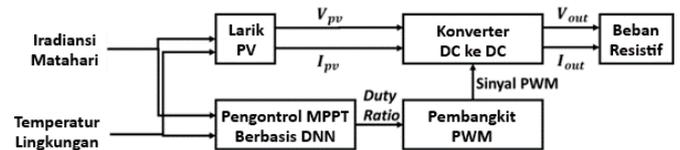
Makalah ini berfokus pada pengembangan MPPT menggunakan metode DNN dengan sasaran kontribusi pada upaya meminimalkan osilasi konverter dan pemilihan konverter dengan tingkat efisiensi terbaik. Selain itu, struktur DNN diharapkan mampu mereduksi rutinitas iterasi dan kecepatan komputasi. Sistematika penulisan terdiri atas empat bagian pokok, yaitu Pendahuluan, Metodologi, Pengujian dan Analisis, serta Kesimpulan. Pada bagian Pendahuluan disampaikan tinjauan pustaka mengenai persoalan MPPT secara umum dan meletakkan urgensi DNN dalam MPPT. Bagian Metodologi menjelaskan tahap persiapan data, pemodelan sistem, dan cara mengukur kinerja sistem. Bagian Pengujian dan Analisis menjelaskan hasil dan analisis dari simulasi MPPT dalam kondisi *standard test condition* (STC) dan lingkungan nyata, masing-masing pada mode *buck*, *boost*, dan *buck-boost*. Bagian Kesimpulan menjelaskan capaian efisiensi MPPT-DNN pada ketiga mode tersebut.

## II. METODOLOGI

### A. PEMAHAMAN DATA DAN PERSIAPAN DATA

Tahapan ini bertujuan untuk memahami konfigurasi data yang digunakan serta proses persiapan data dengan penyeleksian dan pengolahan data. Pemodelan PLTS terdiri atas model larik (*array*) PV dan perancangan sistem MPPT. Model larik PV menggunakan modul PV Skytech Solar SIM 210. Modul PV dimodelkan sebagai sebuah *user defined array* dengan susunan 2 paralel dan 16 seri. Komponen *datasheet* yang digunakan disesuaikan dengan blok parameter pada MATLAB, yaitu *rated power*, tegangan hubung terbuka, arus hubung singkat, tegangan pada MPP, arus pada MPP, dan koefisien temperatur.

Sementara itu, data yang diolah sebagai masukan dihimpun dari hasil pengukuran cuaca di sekitar area pengukuran dan disimpan dalam basis data MySQL pada laman phpMyAdmin.



Gambar 1. Konfigurasi sistem.

TABEL I  
SPESIFIKASI SKYTECH SOLAR SIM-210

Properti	Nilai
Daya maksimum	210 W
Tegangan hubung terbuka ( $V_{oc}$ )	30,58 V
Arus hubung singkat ( $I_{sc}$ )	8,8 A
Tegangan pada MPP	25,58 V
Arus pada MPP	8,26 A
Koefisien temperatur dari $V_{oc}$	-0,16%/°C
Koefisien temperatur dari $I_{sc}$	0,065%/°C

Data yang digunakan adalah temperatur udara dan iradiansi matahari.

### B. PEMODELAN

Pemodelan sistem PLTS dengan MPPT dilakukan dengan Simulink pada MATLAB. Sistem yang dibangun tersusun atas larik PV, konverter daya DC ke DC, algoritma kontrol, dan beban resistif yang bernilai konstan, seperti ditunjukkan pada Gambar 1.

Masukan sistem berupa data temperatur udara dan iradiansi matahari yang sudah diolah. Dengan data temperatur udara dan iradiansi matahari, nilai temperatur sel PV dapat diaproksimasi dengan (1) sebagai berikut.

$$T_c = T_a + (T_{NOCT} - 20) \left( \frac{G}{800} \right) \quad (1)$$

dengan  $T_c$  merupakan temperatur permukaan sel yang akan dihitung,  $T_a$  merupakan temperatur lingkungan yang hendak dikonversi,  $NOCT$  merupakan *nominal operating cell temperature*, yang nilainya sama dengan 45 °C, serta  $G$  merupakan iradiansi matahari pada temperatur lingkungan yang hendak dikonversi [13]-[14]. Persamaan (1) dapat direpresentasikan sebagai subsistem berupa diagram blok fungsi. Model larik PV menggunakan data spesifikasi teknis dari Skytech Solar SIM-210, seperti pada Tabel I.

Selanjutnya, perancangan konverter daya DC ke DC dilakukan menggunakan tiga topologi konverter, yaitu *buck*, *boost*, dan *buck-boost*. Dipilih diode Schottky dan MOSFET sebagai pengatur sakelar. Penentuan nilai parameter induktans dan kapasitans konverter untuk tiap topologi diuraikan pada persamaan-persamaan berikut [8], [15], [16].

Induktans konverter *buck*:

$$L_{min\_buck} = \frac{D_{mpp}(1-D_{mpp})V_{mpp}}{f_s \Delta I_L} \quad (2)$$

induktans konverter *boost*:

$$L_{min\_boost} = \frac{D_{mpp}V_{mpp}}{2f_s \Delta I_L} \quad (3)$$

induktans konverter *buck-boost*:

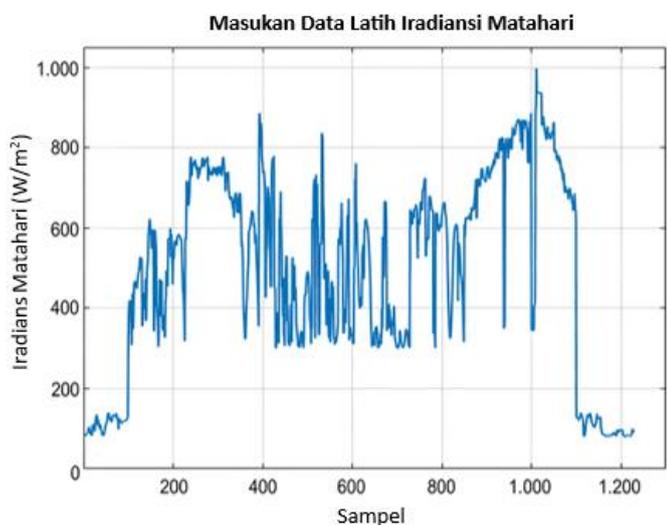
$$L_{min\_buck-boost} = \frac{D_{mpp}V_{mpp}}{f_s \Delta I_L} \quad (4)$$

kapasitans konverter *buck*:

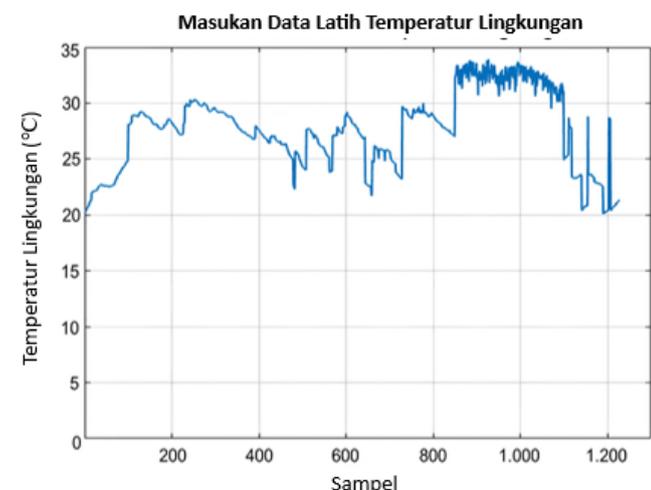
$$C_{min\_buck} = \frac{D_{mpp}(1-D_{mpp})V_{mpp}}{8f_s^2 L \Delta V_c} \quad (5)$$

TABEL II  
 PARAMETER LARIK PV DAN KONVERTER PADA SIMULASI

Larik PV					Konverter Buck			Konverter Boost			Konverter Buck-Boost		
$V_{mpp}$ (V)	$I_{mpp}$ (A)	$P_{mpp}$ (kW)	$R$ ( $\Omega$ )	$f_s$ (kHz)	$L$ (mH)	$C$ ( $\mu$ F)	$D_{mpp}$ (-)	$L$ (mH)	$C$ ( $\mu$ F)	$D_{mpp}$ (-)	$L$ (mH)	$C$ ( $\mu$ F)	$D_{mpp}$ (-)
409,3	16,52	6,761	200	30	0,5	20	0,898	2	30	0,648	4	62	0,739



Gambar 2. Set masukan data latih iradiansi matahari yang digunakan untuk data latih algoritma pembelajaran mesin.



Gambar 3. Set masukan data latih temperatur lingkungan yang digunakan untuk data latih algoritma pembelajaran mesin.

kapasitansi konverter *boost*:

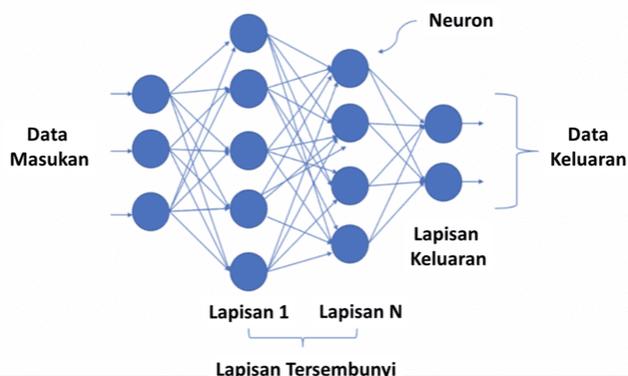
$$C_{min\_boost} = \frac{D_{mpp} V_{out}}{2 f_s R \Delta V_c} \quad (6)$$

kapasitansi konverter *buck-boost*:

$$C_{min\_buck-boost} = \frac{D_{mpp} V_{out}}{f_s R \Delta V_c} \quad (7)$$

dengan  $L_{min}$  adalah induktansi minimum,  $C_{min}$  adalah kapasitansi minimum,  $D_{mpp}$  adalah nilai *duty ratio* saat MPP,  $V_{out}$  adalah tegangan keluaran konverter,  $f_s$  adalah frekuensi *switching*,  $R$  adalah hambatan resistor,  $\Delta V_c$  adalah *ripple* tegangan kapasitor, dan  $\Delta I_L$  adalah *ripple* arus induktor.

Dengan menggunakan (2) hingga (7), diperoleh parameter kapasitansi dan induktansi dari tiap topologi konverter seperti pada Tabel II. Setelah melakukan perancangan model larik PV dan konverter DC ke DC, tahap selanjutnya adalah membangun model algoritma kontrol MPPT. Penelitian ini membandingkan dua algoritma kontrol, yaitu algoritma InC dan DNN.



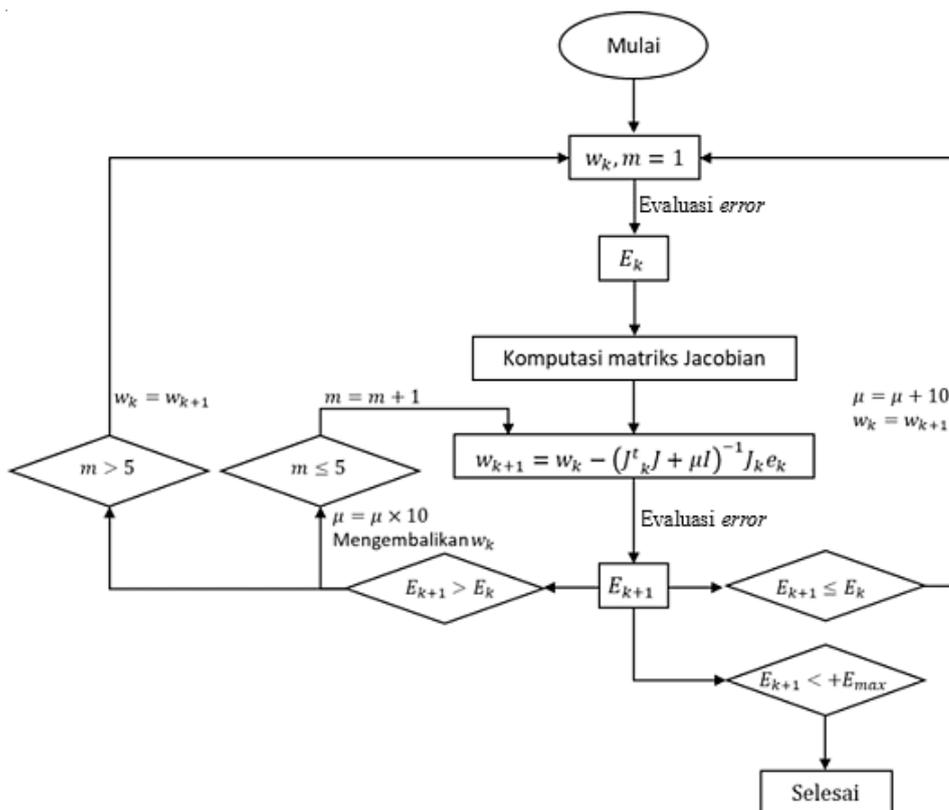
Gambar 4. Arsitektur DNN.

Algoritma InC dengan metode *hill climbing* (HC) dikombinasikan dengan blok fungsi filter *simple moving average* (SMA) untuk membangkitkan matriks data latih yang digunakan dalam memodelkan algoritma pembelajaran mesin [17]. Data latih yang dibangkitkan oleh algoritma InC dapat dilihat pada *plot* data dalam Gambar 2 dan Gambar 3.

Data tersebut merupakan iradiansi matahari ( $W/m^2$ ) dan temperatur lingkungan ( $^{\circ}C$ ) pada modul PV yang sudah terhubung dengan pengontrol InC. Selanjutnya, InC membentuk *duty ratio* dan PWM sebagai sinyal *switching* yang diperlukan oleh konverter untuk mencapai titik daya maksimum.

Gambar 4 memperlihatkan arsitektur DNN. Dapat dilihat bahwa data masukan akan dijadikan sebagai masukan untuk neuron pada lapisan pertama yang akan menyediakan keluaran untuk neuron-neuron lain pada lapisan-lapisan selanjutnya sampai menghasilkan suatu keluaran akhir. Keluaran tersebut berupa prediksi yang direpresentasikan oleh probabilitas (ya atau tidak). Setiap lapisan dapat terdiri atas satu atau lebih neuron. Masing-masing neuron tersebut akan melakukan komputasi suatu fungsi tertentu, seperti fungsi aktivasi. Fungsi aktivasi tersebut akan meniru sinyal untuk diteruskan sebagai masukan ke neuron yang terhubung pada lapisan berikutnya. Hubungan antarneuron dan lapisan yang berturut-turut akan memiliki sebuah asosiasi yang disebut sebagai bobot (*weight*). Terminologi bobot ini mendefinisikan pengaruh masukan ke keluaran untuk neuron berikutnya dan akhirnya untuk keluaran akhir secara keseluruhan. Dari susunan struktur pada DNN mulai dari neuron, lapisan, bobot, masukan dan keluaran, serta fungsi aktivasi, terdapat juga mekanisme pembelajaran atau *optimizer* yang akan membantu jaringan saraf (*neural network*, NN) secara bertahap memperbarui bobot, sehingga sesuai untuk membantu melakukan prediksi yang tepat dari keluaran akhir yang dihasilkan.

Setelah data latih terkumpul, model algoritma pembelajaran mesin dapat dirancang. Algoritma pembelajaran mesin yang digunakan adalah algoritma berbasis NN dengan metode Levenberg-Marquardt (LM) [18]. Dalam proses pelatihan algoritma, set data latih dibagi menjadi tiga kategori berdasarkan *rule of thumb*, yaitu 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Selama proses



Gambar 5. Diagram alir untuk pelatihan algoritma NN dengan metode LM.

pelatihan berlangsung, nilai *sum square error* (SSE) dihitung dengan persamaan berikut.

$$E(x, w) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \quad (8)$$

dengan  $x$  merupakan vektor masukan;  $w$  merupakan vektor bobot;  $p$  merupakan indeks dari *pattern*, dari 1 hingga  $P$ , dengan  $P$  merupakan jumlah *pattern*;  $m$  merupakan indeks dari keluaran, dari 1 hingga  $M$ , dengan  $M$  merupakan jumlah keluaran; dan  $e_{p,m}$  merupakan *error* pelatihan pada keluaran  $m$  ketika menggunakan *pattern*  $p$  yang didefinisikan oleh (9).

$$e_{p,m} = d_{p,m} - o_{p,m} \quad (9)$$

dengan  $d$  merupakan vektor dari keluaran yang diharapkan dan  $o$  adalah vektor dari keluaran aktual.

Nilai SSE tersebut digunakan pada algoritma *steepest descent*, yaitu algoritma orde satu yang berfungsi untuk mencari nilai minimum dalam *error space*. Dalam memodelkan algoritma NN dengan metode LM, digunakan aturan pembaruan (*update rule*) sebagai berikut.

$$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k \quad (10)$$

dengan  $w_k$  adalah bobot saat ini,  $w_{k+1}$  adalah bobot bersih,  $e_k$  adalah *error* keseluruhan terakhir,  $J_k$  adalah matriks Jacobian,  $I$  adalah matriks identitas, dan  $\mu$  disebut *combination coefficient* yang selalu bernilai positif. Aturan pembaruan metode LM ini menggunakan komputasi matriks Jacobian dengan diagram blok pelatihan ditunjukkan pada Gambar 4.

Gambar 5 menunjukkan proses pelatihan menggunakan algoritma LM yang diawali dengan memberikan nilai bobot yang acak, kemudian menggunakan aturan pembaruan untuk memperoleh SSE yang diinginkan. Algoritma LM dikombinasikan dengan fungsi aktivasi bipolar *sigmoid* (*tansig*) yang menerima matriks berisi vektor masukan kemudian

mengembalikannya menjadi matriks yang masukan sebelumnya ditekan menjadi [-1 1] [19].

Secara matematis, fungsi ini tidak jauh berbeda dengan fungsi transfer *tanh*. Fungsi *tansig* ini dapat bekerja dengan lebih cepat daripada fungsi *tanh*, tetapi hasil yang didapatkan hanya memberikan perbedaan kecil secara numerik. Fungsi *tansig* ini baik digunakan pada kasus NN, yang lebih mementingkan kecepatan komputasi dibandingkan dengan bentuk eksak dari fungsi transfer tersebut [20].

### C. SKENARIO PENGUJIAN KINERJA

Pada tahap validasi dan evaluasi terhadap pemodelan dan simulasi yang dilakukan, hal utama yang perlu diperhatikan adalah kedekatan nilai daya yang dibangkitkan oleh larik PV yang menggunakan MPPT berbasis DNN dengan nilai daya pada MPP. Efisiensi suatu MPPT dapat dihitung dengan mengevaluasi perbandingan antara nilai daya keluaran terhadap daya MPP [21], yang secara matematis dapat ditulis sebagai

$$\eta = \frac{P_{beban}}{V_{mpp} \times I_{mpp}} \quad (11)$$

dengan  $\eta$  adalah efisiensi,  $P_{beban}$  adalah daya beban,  $V_{mpp}$  adalah tegangan saat MPP, dan  $I_{mpp}$  adalah arus saat MPP. Makin tinggi efisiensi, makin baik pula MPPT yang dibangun. Efisiensi yang tinggi menandakan rendahnya rugi-rugi yang terjadi pada saat MPPT mengatur tegangan.

Parameter evaluasi lain yang perlu diperhatikan selain efisiensi adalah ketepatan algoritma dalam melacak MPP, kecepatan komputasi algoritma MPPT, kecepatan konverter mencapai *steady state*, ada tidaknya osilasi pada kondisi *steady state*, dan besarnya *undershoot* atau *overshoot* yang terjadi ketika ada perubahan masukan [22].

Ketepatan algoritma dapat dihitung dengan membandingkan besar tegangan PV yang diatur terhadap tegangan MPP, sehingga *error* dapat dihitung dengan (12).

$$error = \frac{|V_{pv} - V_{mpp}|}{V_{mpp}} \quad (12)$$

dengan  $V_{pv}$  adalah tegangan PV.

Kecepatan komputasi dari algoritma MPPT dapat diketahui dengan melihat waktu komputasi yang dilakukan sampai MPPT memperoleh *duty ratio* referensi, sehingga tegangan dapat dijaga pada nilai tertentu. Berbeda dengan kecepatan komputasi, kecepatan konverter mencapai *steady state* tidak bergantung pada algoritma MPPT, tetapi pada jenis topologinya.

Setelah model dibangun dan parameter evaluasi ditentukan, langkah selanjutnya adalah menguji model larik PV dan MPPT. Pengujian dibagi menjadi dua kasus dengan menerapkan tiga topologi konverter daya DC-ke-DC yang dibangun, yaitu konverter *buck*, konverter *boost*, dan konverter *buck-boost*. Kedua kasus tersebut adalah sebagai berikut.

- Pengujian dilakukan dalam kondisi pengujian standar (*standard test conditions, STC*) pada iradiansi matahari 1.000 W/m<sup>2</sup> dan suhu sel 25 °C.
- Pengujian iradiansi matahari dan suhu lingkungan yang diukur di Bandung pada hari Sabtu tanggal 11 Juni 2022 mulai pukul 07:00 sampai dengan 14:30.

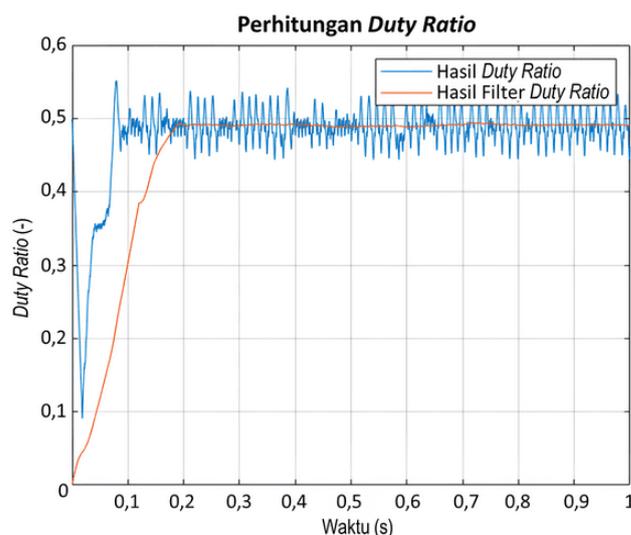
### III. HASIL DAN PEMBAHASAN

#### A. HASIL PERHITUNGAN DUTY RATIO

Sebelum dapat melakukan simulasi menggunakan MPPT berbasis DNN, perlu dilakukan simulasi menggunakan metode HC dengan algoritma InC untuk memperoleh nilai *duty ratio* sebagai keluaran data latih. Namun, MPPT berbasis algoritma InC memberikan perhitungan *duty ratio* yang fluktuatif. Filter sederhana berupa SMA dimanfaatkan untuk menghilangkan fluktuasi dan memperoleh satu nilai *duty ratio* yang dapat digunakan sebagai keluaran pada data latih. Gambar 4 mengilustrasikan hasil simulasi berupa perhitungan *duty ratio* untuk larik PV dengan MPPT berbasis algoritma InC dan konverter daya *buck* pada kondisi iradiansi matahari sebesar 320 W/m<sup>2</sup> dan temperatur lingkungan 28,1 °C yang disimulasikan selama 1 s.

Gambar 6 menunjukkan bahwa MPPT berbasis algoritma InC memberikan perhitungan *duty ratio* yang berfluktuasi, dengan rentang nilai dari 0,47 hingga 0,53. Dalam proses pelatihan untuk melatih MPPT berbasis DNN, diperlukan satu nilai keluaran berupa *duty ratio* pada suatu kondisi iradiansi matahari dan temperatur sel tertentu. Selama perhitungan *duty ratio* dilakukan pada simulasi, filter SMA menghitung rata-rata *duty ratio* tersebut dengan jendela sebesar 12.000 hingga diperoleh hasil perhitungan *duty ratio* yang telah difilter, sehingga dihasilkan nilai akhir yang stabil dan dapat diambil sebagai keluaran data latih. Nilai *duty ratio* pada kasus iradiansi matahari 320 W/m<sup>2</sup> dan temperatur sel 28,1 °C yang diperoleh setelah proses filter adalah 0,491.

Ketepatan nilai *duty ratio* yang dihitung akan sangat memengaruhi ketepatan model DNN yang dibangun. Makin banyak dan tepat data yang diambil, makin baik pula model DNN yang dilatih. Ketiga topologi konverter dilatih untuk mendapatkan model DNN yang spesifik. Dengan menggunakan metode HC dengan algoritma InC, 1.228 data latih dikumpulkan dan dibentuk MPPT berbasis DNN berdasarkan data latih tersebut. Data latih tersebut berupa matriks 1.228 × 3 yang berisi data iradiansi matahari, temperatur lingkungan, dan nilai *duty ratio*.



Gambar 6. Perbandingan hasil pengukuran *duty ratio* sebelum dan sesudah difilter.

TABEL III  
 NILAI MSE DAN REGRESI PELATIHAN TIAP TOPOLOGI KONVERTER

Topologi	MSE (× 10 <sup>-5</sup> )	Regresi
Konverter <i>buck</i>	0,22	0,9999
Konverter <i>boost</i>	2,27	0,9985
Konverter <i>buck-boost</i>	0,48	0,9997

Dalam merancang DNN, dibutuhkan tiga lapisan dalam menyusun arsitekturnya, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Sebelum dilakukan pemilihan jumlah lapisan tersembunyi, dilakukan pengujian terlebih dahulu pada model DNN dengan jumlah lapisan tersembunyi dari 2 hingga 12.

Hasil pelatihan yang baik memiliki nilai *mean square error* (MSE) terkecil dan nilai regresi yang mendekati 1. Nilai MSE terkecil untuk pelatihan sebesar 2,25 × 10<sup>-5</sup>, validasi sebesar 2,27 × 10<sup>-5</sup>, dan untuk pengujian sebesar 2,08 × 10<sup>-5</sup>. Ketiga nilai MSE terkecil tersebut diperoleh dari hasil pengujian sepuluh lapisan tersembunyi. Sementara itu, hasil regresi yang terdekat dengan 1 untuk pelatihan sebesar 0,9984 dan validasi sebesar 0,9885. Hasil tersebut diperoleh dari hasil pengujian dengan sepuluh lapisan tersembunyi. Namun, nilai regresi terbaik untuk pengujian sebesar 0,9987 diperoleh dari pengujian tiga lapisan tersembunyi, sehingga dipilih DNN dengan sepuluh lapisan tersembunyi. Pelatihan tersebut dilakukan untuk tiap topologi konverter, sehingga diperoleh model DNN yang spesifik untuk ketiga konverter tersebut.

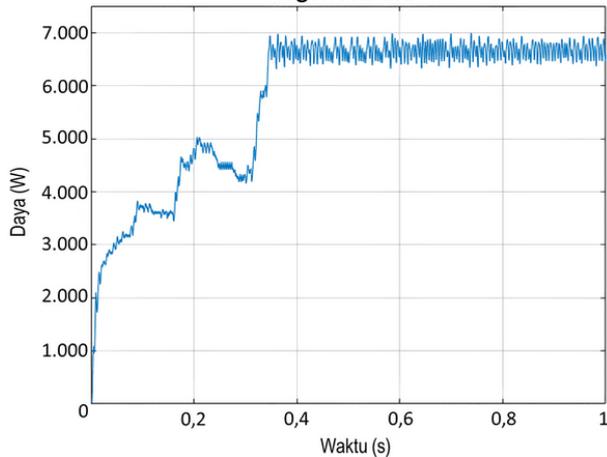
Tabel III memperlihatkan hasil perhitungan MSE yang menunjukkan kinerja validasi model DNN dan regresi keseluruhan tiap konverter. Konverter *buck* memiliki kinerja terbaik.

#### B. SIMULASI PADA KONDISI STC

Simulasi ini dilakukan dengan memberikan nilai masukan pada model larik PV berupa nilai iradiansi matahari yang konstan pada 1.000 W/m<sup>2</sup> dan temperatur sel yang konstan pada 25 °C. Gambar 7 dan Gambar 8 menampilkan hasil pengukuran daya keluaran menggunakan MPPT dengan algoritma InC dan DNN.

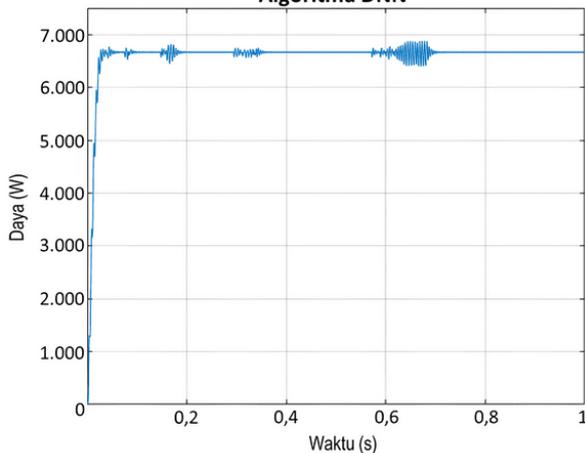
Gambar 7 memperlihatkan bahwa terjadi osilasi yang cukup besar pada MPPT dengan algoritma InC dan osilasi tersebut dapat dikurangi dengan mengubah algoritma menjadi DNN, seperti ditunjukkan pada Gambar 8. Selain

Pengukuran Daya Keluaran pada Sistem PLTS  
Algoritma InC



Gambar 7. Grafik pengukuran daya keluaran MPPT konverter buck dengan algoritma InC.

Pengukuran Daya Keluaran pada Sistem PLTS  
Algoritma DNN



Gambar 8. Grafik pengukuran daya keluaran MPPT konverter buck dengan algoritma DNN.

menghilangkan osilasi, waktu bagi MPPT mencapai *steady state* juga dapat dipersingkat. Terlihat bahwa setelah mencapai *steady state*, konverter buck dapat menjaga PV agar selalu memberikan besar daya yang dijaga pada MPP, yaitu sekitar 6.761 W. Pada algoritma InC, konverter memerlukan waktu yang lebih lama dibandingkan dengan algoritma DNN. Hal ini disebabkan algoritma InC yang harus mengevaluasi terlebih dahulu nilai  $\frac{dP}{dV}$  untuk mencari nilai *duty ratio* yang tepat. Karena algoritma DNN hanya memberikan satu nilai *duty ratio* ke konverter, osilasi yang terjadi dapat hilang secara signifikan.

Sama seperti konverter buck, konverter boost dapat menjaga PV agar selalu memberikan besar daya pada MPP, yaitu sekitar 6.761 W, setelah mencapai *steady state*. Pada perubahan iradiansi matahari yang cukup ekstrim, seperti pada kasus uji STC ini yang memberikan perubahan iradiansi matahari dari 0 W/m<sup>2</sup> menjadi 1.000 W/m<sup>2</sup>, konverter boost memberikan *ripple* yang cukup besar sebelum mencapai *steady state* yang hingga akhirnya *ripple* yang ada berkurang secara signifikan.

Hasil perhitungan dan evaluasi yang lebih rinci disajikan dalam Tabel IV, yang memberikan perbandingan efisiensi, *error* tegangan, osilasi yang terjadi, waktu komputasi algoritma, dan *settling time*. Dapat dicermati bahwa dengan menggunakan algoritma DNN, efisiensi konverter buck pada STC dapat

TABEL IV  
HASIL EVALUASI PADA KONDISI STC

	Buck		Boost		Buck-Boost	
	InC	DNN	InC	DNN	InC	DNN
Efisiensi (%)	98,4	98,5	90,8	91	78,3	86,1
Error tegangan (%)	1,6	1,8	1,1	0,8	6,4	1,8
Osilasi (%)	1,8	0,3	0,4	0,3	3,3	0,3
Waktu komputasi (ms)	347	3	269	3	327	3
Settling time (ms)	361	42,7	295	181	384	316

ditingkatkan sebesar 1% dan waktu mencapai *steady state* dapat dipersingkat sebesar 88,17%. Selain itu, osilasi yang diakibatkan algoritma InC juga dapat dihilangkan sebesar 1,5%, sehingga rugi-rugi yang ditimbulkan juga dapat berkurang. Sementara itu, pada konverter *boost* efisiensi dapat ditingkatkan sebesar 0,2% dan waktu mencapai *steady state* dapat dipersingkat sebesar 38,64%. Osilasi yang terjadi tidak berubah secara signifikan, tetapi memang relatif sudah lebih rendah. Apabila dibandingkan dengan konverter buck, akurasi yang diberikan konverter *boost* lebih baik, sehingga daya PV yang disuplai lebih tinggi dan osilasi yang ada tidak besar. Namun, efisiensi dari topologi ini bukan yang terbaik karena telah menurunkan daya keluaran sebesar 8,8%.

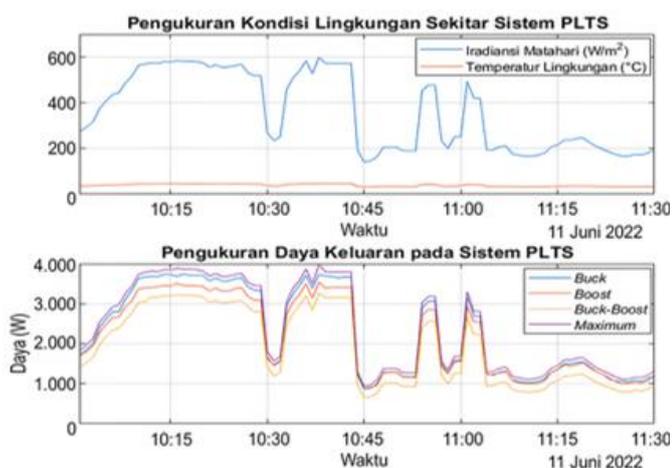
Setelah dilakukan pengujian, diketahui bahwa konverter *buck-boost* tidak bekerja cukup baik apabila MPPT disimulasikan dengan menggunakan algoritma InC. Hal ini disebabkan oleh rentang *duty ratio* topologi ini yang lebih kecil dibandingkan dua topologi lainnya, sehingga penggunaan algoritma InC dengan mengambil langkah (*step*) yang rendah akan mengakibatkan kesalahan dalam mencari *duty ratio* MPP. Di sisi lain, mengambil langkah yang tinggi akan menimbulkan osilasi tegangan yang tidak teratur, sehingga *duty ratio* tidak mudah ditentukan. Algoritma DNN hanya memberikan satu nilai *duty ratio* setelah mengevaluasi kondisi lingkungan. Hasil ini dapat dilihat dari *ripple* besar pada saat *steady state* yang hilang. Oleh karena itu, algoritma DNN lebih cocok diaplikasikan pada konverter *buck-boost*.

Selain itu, dapat dicermati bahwa konverter *buck-boost* memberikan daya keluaran yang cukup stabil, tetapi daya yang dikeluarkan tidak lebih besar dibandingkan dengan dua topologi lainnya. Akibat ketidakcocokan konverter *buck-boost* dengan algoritma InC, penggunaan algoritma DNN memberikan kenaikan efisiensi cukup tinggi, yaitu 7,8%, serta kesalahan nilai tegangan yang diatur juga menurun sebesar 4,6%. Osilasi yang terjadi dapat dikurangi sebesar 3%, sehingga daya keluaran lebih stabil, tetapi waktu yang dibutuhkan konverter *buck-boost* merupakan yang terlama dibandingkan topologi yang lain.

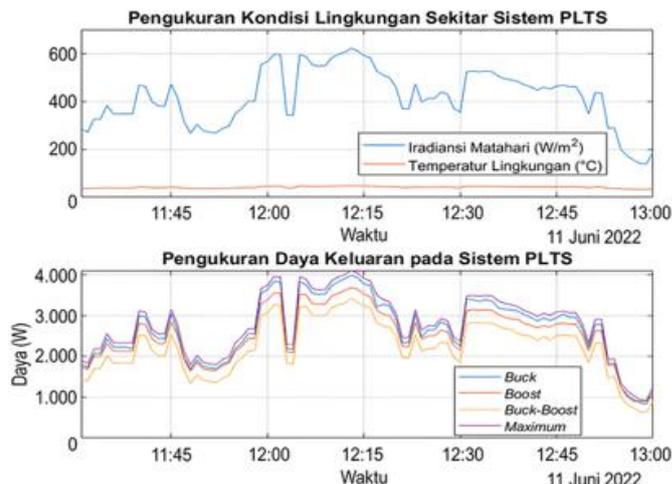
Dapat disimpulkan bahwa efisiensi konverter buck lebih unggul dibandingkan dengan kedua konverter lain, kemudian diikuti oleh konverter boost, lalu konverter *buck-boost*. Tidak hanya efisiensi, kecepatan konverter untuk mencapai *steady state* tercepat dicapai oleh konverter buck, sedangkan kecepatan terendah didapat dari konverter *buck-boost*. Akurasi dan kecepatan komputasi algoritma tidak dipengaruhi oleh perbedaan topologi konverter. Ketiga topologi juga tidak memberikan perbedaan pada stabilitas atau osilasi yang ada.

### C. SIMULASI PADA KONDISI LINGKUNGAN NYATA

Simulasi ini dilakukan dengan memasukkan dua sinyal masukan berupa iradiansi matahari dan temperatur lingkungan



Gambar 9. Pengukuran daya pada pukul 10:00-11:30 WIB.



Gambar 10. Pengukuran daya pada pukul 11:30-13:00 WIB.

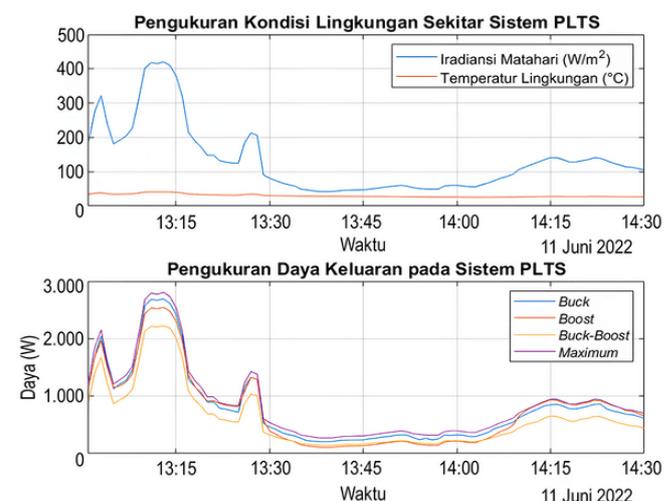
yang diukur sesuai kondisi cuaca pada hari Sabtu, 11 Juni 2022, pada rentang waktu pukul 07:00 hingga 14:30 WIB di Labtek VI Institut Teknologi Bandung. Kondisi lingkungan yang terukur memiliki rentang iradiansi matahari sebesar 42 W/m<sup>2</sup> hingga 622 W/m<sup>2</sup> dan rentang temperatur lingkungan dari 20,4 °C hingga 29,2 °C.

Hasil simulasi pada pukul 07:00 – 08:30 WIB menunjukkan bahwa daya yang dibangkitkan oleh larik PV dengan MPPT bertopologi *buck-boost* memiliki efisiensi terendah, sementara MPPT bertopologi *buck* secara konsisten memberikan efisiensi yang tinggi. Berbeda dengan yang lain, MPPT bertopologi *boost* memberikan efisiensi tertinggi dan juga efisiensi terendah. Dapat dicermati bahwa pada kondisi iradiansi matahari di bawah 120 W/m<sup>2</sup>, efisiensi topologi *boost* adalah yang terendah. Hal ini disebabkan oleh keterbatasan rentang kerja yang dimiliki oleh konverter *boost* itu sendiri. Iradiansi yang rendah membuat konverter tidak dapat meningkatkan tegangan hingga mencapai tegangan pada titik daya maksimum. Sebaliknya, ketika iradiansi matahari yang diterima lebih besar dari 120 W/m<sup>2</sup>, konverter *boost* dapat bekerja sesuai dengan kemampuannya dan mengatur tegangan pada titik daya maksimum.

Hal yang sama juga ditemui pada saat pengukuran daya dengan menyimulasikan kondisi lingkungan pada pukul 08:30 – 10:00 WIB. Pada rentang iradiansi matahari sebesar 100 W/m<sup>2</sup> hingga 230 W/m<sup>2</sup>, efisiensi terendah dihasilkan oleh MPPT bertopologi *buck-boost*, sementara efisiensi tertinggi dihasilkan oleh MPPT bertopologi *boost* dan *buck*.

Gambar 9 menunjukkan pengujian pada pukul 10:00 – 11:30 WIB dengan rentang perubahan iradiansi cahaya matahari antara 180 W/m<sup>2</sup> hingga 600 W/m<sup>2</sup>. Berdasarkan observasi pada daya keluaran konverter terhadap daya masuk dalam mode aktif MPPT, dapat ditentukan bahwa topologi *buck* mampu menghasilkan efisiensi yang lebih tinggi. Pada beberapa titik terjadi penurunan iradiansi secara mendadak, seperti pada pukul 10:45 WIB, yaitu konverter *buck* sempat mengalami penurunan daya lebih rendah dari konverter *boost* secara sesaat, kemudian berangsur naik dengan capaian yang sama atau lebih tinggi sedikit. Kondisi ini cukup kontras jika dibandingkan dengan konverter *buck-boost*.

Selanjutnya, dilakukan observasi pada pukul 11:30 – 13:00 WIB. Rentang pengamatan ini menarik mengingat pada interval waktu ini iradiansi matahari berada pada kondisi puncaknya. Iradiansi matahari tertinggi dicapai pada nilai sekitar 622 W/m<sup>2</sup>, yaitu pada pukul 12:13 WIB, seperti ditampilkan pada Gambar 10. Pengukuran daya keluaran untuk



Gambar 11. Pengukuran daya pada pukul 13:00-14:30 WIB.

setiap konverter memberikan informasi bahwa konverter *buck* mampu menghasilkan daya yang lebih mendekati acuan MPP. Bahkan, dapat dikatakan bahwa daya keluaran pada kondisi ini lebih konsisten dibandingkan daya keluaran dengan interval waktu sebelumnya.

Iradiansi matahari berangsur-angsur turun secara signifikan dan tidak berada pada puncaknya lagi setelah waktu melewati pukul 13:00 WIB. Pada Gambar 11 tampak bahwa iradiansi matahari yang rendah ini berdampak pada efisiensi MPPT bertopologi *boost*, yang tidak mampu bekerja pada iradiansi rendah.

Berdasarkan uraian dari Gambar 9 sampai Gambar 11 yang telah disampaikan di atas, pengujian kinerja ketiga konverter telah dilakukan dalam kondisi iradiansi dan temperatur pada jendela waktu antara pukul 10:00 – 14:30 WIB. Konverter *buck* menunjukkan kinerja yang lebih tinggi dari *boost* dan *buck-boost*. Tegangan konverter *buck* menghasilkan nilai yang lebih rendah dari masukan, sehingga secara intrinsik konverter tersebut bekerja dengan *voltage stress* yang lebih rendah dan menurunkan rugi-rugi *switching*. Konverter *boost* dan *buck-boost* cenderung memerlukan pembalik tegangan, sehingga transfer energi dari masukan ke tegangan keluaran yang lebih besar memberikan konsekuensi meningkatkan rugi-rugi dan menurunkan efisiensi.

#### D. EFISIENSI MPPT

Secara kuantitatif, dilakukan perhitungan nilai efisiensi dari MPPT untuk setiap topologi yang beroperasi di bawah kondisi

lingkungan nyata. Nilai efisiensi dihitung menggunakan (12), yakni daya beban dibandingkan terhadap capaian daya pada titik maksimum, atau dengan kata lain besarnya daya keluaran konverter terhadap daya masukannya yang seharusnya dicapai ketika mengaktifkan fitur MPPT. Ketiga topologi konverter yang diujikan berhasil mencapai nilai tertinggi pada interval waktu pukul 11:30 – 13:00 WIB, yakni sebesar 94,58% pada konverter *buck*, sedangkan konverter *boost* sedikit lebih rendah, yaitu sebesar 90,79%. Sementara itu, konverter *buck-boost* hanya sanggup menyentuh efisiensi sebesar 79,34%.

Perlu dicatat bahwa perbedaan nilai efisiensi konverter tersebut murni hanya dilihat berdasarkan kinerjanya saja. Dari perspektif fungsi, tentunya setiap konverter memiliki keunggulan masing-masing. Misalnya, fungsi menaikkan tegangan pada konverter *boost* merupakan fungsi yang tidak dimiliki oleh konverter *buck*. Di sisi lain, konverter *buck-boost* menunjukkan efisiensi yang lebih rendah, tetapi secara fungsi mungkin dinilai lebih menguntungkan bila berhadapan dengan kasus yang membutuhkan tugas *step-up* dan *step-down* tegangan dalam suatu konverter tunggal.

#### IV. KESIMPULAN

MPPT merupakan sistem yang dapat membantu PV untuk melacak titik daya maksimum. Tujuan MPPT direalisasikan melalui konverter daya DC ke DC dengan menerapkan algoritma DNN. Perangkat konverter daya DC ke DC meliputi konverter *buck*, *boost*, dan *buck-boost*. Algoritma konvensional InC digunakan untuk memperoleh 1.228 data latih berupa *duty ratio*, yang didapatkan dengan memberikan sinyal masukan berupa irradiansi matahari dan temperatur lingkungan. Data latih digunakan untuk membangun model pembelajaran mesin DNN untuk setiap topologi konverter yang dimodelkan. Kinerja model DNN divalidasi menggunakan kriteria nilai MSE, baik pada konverter *buck*, *boost*, maupun *buck-boost*, yang masing-masing menunjukkan capaian sebesar  $2,20 \times 10^{-6}$ ,  $2,27 \times 10^{-5}$ , dan  $4,80 \times 10^{-6}$ . Algoritma DNN terbukti mampu mengurangi efek osilasi, mempercepat waktu *steady state*, dan meningkatkan efisiensi. Larik PV yang menggunakan MPPT berbasis DNN disimulasikan pada kondisi tes standar dan kondisi nyata. Konverter *buck* dengan algoritma DNN memperoleh efisiensi MPPT terbaik, sebesar 95,47%. MPPT tersebut dapat secara konsisten memberikan efisiensi tinggi pada irradiansi matahari rendah maupun tinggi. Sementara itu, MPPT dengan konverter *boost* dan konverter *buck-boost* memberikan efisiensi sebesar 90,97% dan 79,34%.

#### KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan dalam penulisan makalah ini.

#### KONTRIBUSI PENULIS

Konseptualisasi, Edi Leksono dan Irsyad Nashirul Haq; metodologi, Robi Sobirin dan Mochammad Iqbal Bayeqi; perangkat lunak, Putu Handre Kertha Utama dan Muhammad Fatih Hasan; validasi, Edi Leksono, Irsyad Nashirul Haq, dan Justin Pradipta; analisis formal, Mochammad Iqbal Bayeqi dan Muhammad Fatih Hasan; investigasi, Reza Fauzi Iskandar dan Putu Handre Kertha Utama; sumber daya, Reza Fauzi Iskandar dan Putu Handre Kertha Utama; kurasi data, Mochammad Iqbal Bayeqi dan Muhammad Fatih Hasan; penulisan—penyusunan draf asli, Robi Sobirin, Mochammad Iqbal Bayeqi, dan Muhammad Fatih Hasan; penulisan—peninjauan dan penyuntingan, Robi Sobirin dan Reza Fauzi Iskandar; visualisasi, Robi Sobirin dan Muhammad Fatih Hasan;

pengawasan, Edi Leksono dan Irsyad Nashirul Haq; administrasi proyek, Mochammad Iqbal Bayeqi dan Muhammad Fatih Hasan; akuisisi pendanaan, Irsyad Nashirul Haq dan Justin Pradipta.

#### UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada BPPT dan LPDP sebagai penyandang dana yang telah memberikan dukungan dalam penelitian ini.

#### REFERENSI

- [1] A. Haryanto, *Energi Terbarukan*, ed. 1. Yogyakarta, Indonesia: Innosain, 2017.
- [2] K. Amara dkk., "Improved Performance of a PV Solar Panel with Adaptive Neuro Fuzzy Inference System ANFIS Based MPPT," *2018 7th Int. Conf. Renew. Energy Res., Appl. (ICRERA)*, 2018, hal. 1098–1101, doi: 10.1109/ICRERA.2018.8566818.
- [3] V. Jatly dkk., "Experimental Analysis of Hill-Climbing MPPT Algorithms under Low Irradiance Levels," *Renew., Sustain. Energy Rev.*, Vol. 150, hal. 1–16, Okt. 2021, doi: 10.1016/j.rser.2021.111467.
- [4] K. Boudaraia, H. Mahmoudi, dan A. Abbou, "MPPT Design Using Artificial Neural Network and Backstepping Sliding Mode Approach for Photovoltaic System under Various Weather Conditions," *Int. J. Intell. Eng., Syst.*, Vol. 12, No. 6, hal. 177–186, Des. 2019, doi: 10.22266/ijies2019.1231.17.
- [5] M. Mao dkk., "Classification and Summarization of Solar Photovoltaic MPPT Techniques: A Review Based on Traditional and Intelligent Control Strategies," *Energy Rep.*, Vol. 6, No. 174, hal. 1312–1327, Nov. 2020, doi: 10.1016/j.egy.2020.05.013.
- [6] R.E. Idrissi, A. Abbou, dan M. Mokhlis, "Backstepping Integral Sliding Mode Control Method for Maximum Power Point Tracking for Optimization of PV System Operation Based on High-Gain Observer," *Int. J. Intell. Eng., Syst.*, Vol. 13, No. 5, hal. 133–144, Okt. 2020, doi: 10.22266/ijies2020.1031.13.
- [7] H. Islam dkk., "Performance Evaluation of Maximum Power Point Tracking Approaches and Photovoltaic Systems," *Energies*, Vol. 11, No. 2, hal. 1–24, Feb. 2018, doi: 10.3390/en11020365.
- [8] R.F. Iskandar, E. Leksono, dan E. Joelianto, "Q-Learning Hybrid Type-2 Fuzzy Logic Control Approach for Photovoltaic Maximum Power Point Tracking under Varying Solar Irradiation Exposure," *Int. J. Intell. Eng., Syst.*, Vol. 14, No. 5, hal. 199–208, Okt. 2021, doi: 10.22266/ijies2021.1031.19.
- [9] J. Chorfi, M. Zazi, dan M. Mansori, "A New Intelligent MPPT Based on ANN Algorithm for Photovoltaic System," *2018 6th Int. Renew., Sustain. Energy Conf. (IRSEC)*, 2018, hal. 1–6, doi: 10.1109/IRSEC.2018.8702858.
- [10] A. Ab-Belkhair, J. Rahebi, dan A.A.M. Nureddin, "A Study of Deep Neural Network Controller-Based Power Quality Improvement of Hybrid PV/Wind Systems by Using Smart Inverter," *Int. J. Photoenergy*, Vol. 2020, hal. 1–22, Des. 2020, doi: 10.1155/2020/8891469.
- [11] A.A.M. Nureddin, J. Rahebi, dan A. Ab-Belkhair, "Power Management Controller for Microgrid Integration of Hybrid PV/Fuel Cell System Based on Artificial Deep Neural Network," *Int. J. Photoenergy*, Vol. 2020, hal. 1–21, Des. 2020, doi: 10.1155/2020/8896412.
- [12] M. Leelavathi dan V.S. Kumar, "Deep Neural Network Algorithm for MPPT Control of Double Diode Equation Based PV Module," *Mater. Today Proc.*, Vol. 62, hal. 4764–4771, Mar. 2022, doi: 10.1016/j.matpr.2022.03.340.
- [13] G. Ciulla, V.L. Brano, dan E. Moreci, "Forecasting the Cell Temperature of PV Modules with an Adaptive System," *Int. J. Photoenergy*, Vol. 2013, hal. 1–10, Sep. 2013, doi: 10.1155/2013/192854.
- [14] V. Sun, A. Asanakhm, T. Deethayat, dan T. Kiatsiriroat, "A New Method for Evaluating Nominal Operating Cell Temperature (NOCT) of Unglazed Photovoltaic Thermal Module," *Energy Rep.*, Vol. 6, hal. 1029–1042, Nov. 2020, doi: 10.1016/j.egy.2020.04.026.
- [15] S. Thakran, J. Singh, R. Garg, dan P. Mahajan, "Implementation of PO Algorithm for MPPT in SPV System," *2018 Int. Conf. Power Energy, Environ., Intell. Control (PEEIC)*, 2018, hal. 242–245, doi: 10.1109/PEEIC.2018.8665588.
- [16] S.K. Kollimalla dan M.K. Mishra, "A Novel Adaptive P&O MPPT Algorithm Considering Sudden Changes in the Irradiance," *IEEE Trans. Energy Convers.*, Vol. 29, No. 3, hal. 602–610, Sep. 2014, doi: 10.1109/TEC.2014.2320930.

- [17] R. Rawat dan S.S. Chandel, "Hill Climbing Techniques for tracking Maximum Power Point in Solar Photovoltaic Systems," *Int. J. Sustain. Develop., Green Econ.*, Vol. 2, No. 1, hal. 90-95, Jan. 2013.
- [18] A. Reynaldi, S. Lukas, dan H. Margaretha, "Backpropagation and Levenberg-Marquardt Algorithm for Training Finite Element Neural Network," *2012 6th UKSim/AMSS Eur. Symp. Comput. Model., Simul.*, 2012, hal. 89-94, doi: 10.1109/EMS.2012.56.
- [19] A. Wanto dkk., "Levenberg-Marquardt Algorithm Combined with Bipolar Sigmoid Function to Measure Open Unemployment Rate in Indonesia," *Proc. 3rd Int. Conf. Comput. Environ. Agric. Soc. Sci. Health Sci. Eng., Technol. (ICEST 2018)*, 2018, hal. 22-28, doi: 10.5220/0010037200220028.
- [20] M. Dorofki dkk., "Comparison of Artificial Neural Network Transfer Functions Abilities to Simulate Extreme Runoff Data," *2012 Int. Conf. Environ. Energy, Biotechnol.*, 2012, hal. 39-44.
- [21] *Electrically Propelled Road Vehicles — Test Specification for Electric Propulsion Components — Part 7: Operating Load Testing of the DC/DC Converter*, ISO 21782-7:2021(E), 2021.
- [22] I. Owusu-Nyarko, M.A. Elgenedy, I. Abdelsalam, dan K.H. Ahmed, "Modified Variable Step-Size Incremental Conductance MPPT Technique for Photovoltaic Systems," *Electron.*, Vol. 10, No. 19, hal. 1-18, Sep. 2021, doi: 10.3390/electronics10192331.