

Peramalan Keluaran Photovoltaic Kapasitas 120WP Menggunakan Metode Neural Network

Imam Wahyudi Farid^{1*}, Joko Priambodo², Irfan Hamzah Fansuri³, Lucky Putri Rahayu⁴, Faiza Alif Fakhрина⁵

^{1,2,3,4,5}Departemen Teknik Elektro Otomasi, Fakultas Vokasi, Institut Teknologi Sepuluh Nopember Surabaya
Email: ¹iwf@its.ac.id, ²joko.priambodo@its.ac.id, ³wahyudteo@gmail.com, ⁴lucky.putri@its.ac.id,

⁵alif.fakhrina@its.ac.id

*Penulis Korespondensi

Abstract— Photovoltaic (PV) is the main component in Solar Power Plants (PLTS) that convert solar energy into electricity. However, PV power is fluctuating, unlike conventional power plants that have constant power. To balance power needs and production, additional power plants called load tracking power plants are needed. Forecasting PV power output is important to ensure that the load tracking power plant can respond quickly and accurately. This study focuses on PV power forecasting using the Neural Network (NN) algorithm, which has been proven to have high accuracy. The tested PV has a maximum efficiency of 13.16% at a light intensity of 82,574.66 Lux with a power of 60.67 W. At a light intensity of 15,432.43 Lux, the efficiency reaches 15.48% with a power of 13.34 W. The experiment was conducted with 6 scenarios, resulting in the smallest Mean Absolute Percentage Error (MAPE) value of 1.22% when 80% of the data was used for training with two hidden layers. The forecasting results for the three days of testing showed MAPE values of 9.43% (first day), 6.11% (second day), and 21.33% (third day). The average MAPE value was 12.29%. Input data in the form of solar radiation, temperature, and humidity from the previous four weeks were used to train the NN model.

Keywords— Solar Panel Plant, PV, Neural Network, Forecasting, MAPE.

Intisari— Photovoltaic (PV) adalah komponen utama dalam Pembangkit Listrik Tenaga Surya (PLTS) yang mengubah energi matahari menjadi listrik. Namun, daya PV bersifat fluktuatif, berbeda dengan pembangkit konvensional yang memiliki daya konstan. Untuk menyeimbangkan kebutuhan daya dan produksi, diperlukan pembangkit tambahan yang disebut *load tracking power plant*. Peramalan keluaran daya PV menjadi penting untuk memastikan *load tracking power plant* dapat merespons secara cepat dan akurat. Penelitian ini memfokuskan pada peramalan daya PV menggunakan algoritma *Neural Network* (NN), yang terbukti memiliki akurasi tinggi. PV yang diuji memiliki efisiensi maksimum 13,16% pada intensitas cahaya 82.574,66 Lux dengan daya 60,67 W. Dalam intensitas cahaya 15.432,43 Lux, efisiensinya mencapai 15,48% dengan daya 13,34 W. Percobaan dilakukan dengan 6 skenario, menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) terkecil 1,22% saat 80% data digunakan untuk *training* dengan dua *hidden layer*. Hasil peramalan untuk tiga hari pengujian menunjukkan nilai MAPE sebesar 9,43% (hari pertama), 6,11% (hari kedua), dan 21,33% (hari ketiga). Nilai MAPE rata-rata adalah 12,29%. *Input* data berupa radiasi matahari, suhu, dan kelembapan dari empat minggu sebelumnya digunakan untuk melatih model NN.

Kata Kunci— PLTS, PV, Neural Network, Peramalan, MAPE.

I. PENDAHULUAN

PV adalah komponen dari pembangkit listrik tenaga surya yang berfungsi untuk mengubah energi radiasi matahari menjadi energi listrik. Namun, karena daya yang dihasilkan oleh PV tidak stabil dan daya yang dihasilkan oleh pembangkit listrik konvensional bersifat konstan, diperlukan pembangkit listrik tambahan yang dapat merespons perubahan permintaan daya serta keluaran PV yang diperkirakan dengan menyeimbangkan total permintaan daya dengan total produksi daya. Pembangkit listrik ini disebut sebagai pembangkit listrik pelacak beban. Namun, peramalan keluaran PV tetap diperlukan untuk menentukan perkiraan jumlah daya yang akan dihasilkan oleh pembangkit listrik tenaga surya pada hari berikutnya setiap menitnya, sehingga pembangkit listrik pelacak beban dapat dengan cepat dan akurat menyeimbangkan daya yang dihasilkan sebagai suplai dari pembangkit listrik konvensional dan keluaran PV yang diperkirakan terhadap total permintaan beban [1].

Peramalan dilakukan setiap menit karena ketika awan bergerak dan menutupi permukaan PV dari sinar matahari dalam hitungan menit, radiasi yang diterima oleh PV akan mengalami fluktuasi nonlinier yang signifikan [2]. Semakin besar kapasitas pembangkit listrik tenaga surya, semakin serius dampak buruk fluktuasi ini terhadap jaringan listrik. Peramalan daya PV yang akurat dalam skala waktu per menit berkontribusi pada stabilitas operasional sistem kelistrikan dan konsumsi daya PV [3]. Selain itu, produksi energi yang bergantung pada cuaca memerlukan layanan manajemen jaringan yang baik untuk memastikan ketersediaan, stabilitas, dan kualitas energi yang dihasilkan [4].

Akurasi dan efisiensi peramalan energi surya telah meningkat secara dramatis dengan penggunaan kecerdasan buatan (AI) dalam peramalan fotovoltaik (PV). Untuk menghasilkan proyeksi keluaran daya yang akurat, metode kecerdasan buatan (AI) seperti pembelajaran mesin (*machine learning*) dan pembelajaran mendalam (*deep learning*) menganalisis suhu, iradiasi matahari, dan tren cuaca sebelumnya. Peramalan ini meningkatkan integrasi instalasi PV ke dalam jaringan listrik, meminimalkan ketidakstabilan jaringan, dan mengoptimalkan manajemen energi. Penyedia energi dapat meningkatkan keandalan dan kelayakan ekonomi secara keseluruhan dengan menggunakan model berbasis AI untuk memprediksi variasi dalam pembangkitan tenaga surya. Optimasi Bayesian digunakan untuk jangka waktu sangat pendek [5-6], Global and Local Feature Fusion Network (GLFFNet) [7], peramalan beban probabilistik melalui rata-rata regresi kuantil [8], long short-term memory (LSTM) [9],

convolutional neural network (CNN) [10], dan pembelajaran mendalam [11].

Jika kebutuhan daya adalah 200MW dan daya dari generator konvensional diatur pada 150MW, maka ketika keluaran PV yang diperkirakan adalah 40MW, pembangkit listrik pelacak beban harus menghasilkan minimal 10MW untuk memastikan total produksi daya memenuhi permintaan beban. Namun, ketika keluaran PV yang diperkirakan melebihi 50MW, produksi daya dari pembangkit listrik pelacak beban dapat diminimalkan, dan kelebihan produksi daya dari sistem PV dapat disimpan dalam baterai sebagai cadangan pasokan daya saat dibutuhkan. Dengan demikian, penggunaan bahan bakar fosil atau sumber energi tak terbarukan dari pembangkit listrik konvensional dapat dikurangi, dari yang awalnya harus menghasilkan daya sebesar 200W menjadi hanya 150W. Peramalan sendiri dibagi menjadi empat kategori: peramalan jangka sangat pendek dengan periode mulai dari satu menit hingga satu jam, peramalan jangka pendek dengan periode mulai dari satu jam hingga satu minggu, peramalan jangka menengah dengan periode mulai dari satu minggu hingga satu tahun, dan peramalan jangka panjang dengan periode lebih dari satu tahun.

Penelitian ini berfokus pada pembuatan peramalan keluaran daya PV untuk menghasilkan algoritma jaringan saraf (NN) dengan akurasi terbaik sebagai pertimbangan dalam operasi pembangkit listrik pelacak beban [12], [13]. Peramalan yang dibuat adalah peramalan yang dapat memprediksi keluaran daya PV dalam jangka sangat pendek, yaitu setiap menit. Hal ini dilakukan karena ketika daya keluaran dari pembangkit listrik tenaga surya meningkat atau menurun secara tajam, pembangkit listrik pelacak beban harus segera merespons dengan meningkatkan atau menurunkan pasokan daya yang diberikan ke jaringan [14]. Peramalan daya PV untuk setiap menit ke depan memungkinkan pembangkit listrik pelacak beban merespons perubahan daya secara tepat waktu [1], [14], dan [16]. Peramalan daya PV dilakukan dengan merujuk pada beberapa penelitian sebelumnya berdasarkan parameter input dan metode yang digunakan.


Sistem ini pertama-tama akan merekam data menggunakan Arduino sebagai pengontrol utama, dan data yang direkam akan digunakan sebagai input untuk sistem peramalan. Metode yang digunakan adalah Neural Network, di mana dalam metode ini, 70%-80% data yang diperoleh dari rekaman akan digunakan untuk melatih sistem peramalan agar dapat belajar dan meningkatkan akurasi seiring waktu. Setelah itu, sistem peramalan akan diuji menggunakan 20%-30% dari data yang direkam untuk menentukan apakah algoritma NN telah mencapai tingkat akurasi yang diinginkan [6]. Selanjutnya, algoritma NN ini akan digunakan untuk membuat peramalan selama tiga hari uji, dan diharapkan akurasi peramalan ini berada di atas 85%.

II. METODE PENELITIAN

A. Flowchart Pengujian Karakteristik PV

Pengujian yang dilakukan pada gambar 1 dengan menyiapkan 10 variasi beban, PV, voltmeter, dan amperemeter terlebih dahulu. Selain itu juga disiapkan sensor intensitas cahaya, suhu, dan kelembaban. Selanjutnya PV dihubungkan dengan beban untuk diketahui keluaran PV untuk setiap variasi beban yang digunakan. Voltmeter dihubungkan secara paralel

terhadap rangkaian untuk mengukur keluaran tegangan, sedangkan amperemeter dihubungkan secara seri terhadap rangkaian untuk mengukur arus dari PV. Data yang terbaca oleh setiap alat ukur dicatat dalam catatan kami yaitu excel beserta data intensitas cahaya matahari, suhu, dan juga kelembaban. Dari data tersebut, nantinya akan diketahui terkait efisiensi dari PV serta besar daya yang dapat dikeluarkan pada setiap variasi beban. Selain itu juga dapat diketahui pengaruh dari intensitas cahaya matahari, suhu, dan kelembaban terhadap jumlah daya yang mampu dihasilkan PV.




Gambar 1. Flowchart Pengujian Karakteristik PV

B. Flowchart Pengujian Sistem Peramalan Keluaran Daya PV

Gambar 2 adalah flowchart dari pengujian sistem peramalan yang telah dibuat. Sistem tersebut dimulai dari saat alat diaktifkan. Selanjutnya nilai tegangan dan arus dari keluaran PV, serta suhu, kelembaban, dan intensitas cahaya akan terbaca oleh sensor lalu dikirim ke arduino uno. Data yang sudah didapat oleh arduino, kemudian akan dikirimkan ke modul micro SD card lalu menuju database lokal MySQL.


Data yang telah disimpan, akan digunakan sebagai bahan dalam proses pembuatan algoritma dari sistem peramalan dengan metode NN. Data akan dinormalisasi terlebih dahulu untuk menyamakan range data yang digunakan, karena bobot pada jaringan saraf cenderung lebih banyak dipengaruhi oleh fitur dengan range data yang lebih besar. Dengan normalisasi, data dapat dibawa ke range data yang serupa, sehingga memastikan setiap fitur memiliki kontribusi yang seimbang dalam pelatihan jaringan. Setelah dilakukan normalisasi data, maka selanjutnya data tersebut akan dibagi menjadi data training dan juga data testing. Data training digunakan untuk melatih jaringan saraf untuk dapat menghasilkan output sesuai dengan data yang diinginkan, sedangkan data testing digunakan untuk menguji algoritma yang sudah didapat dari proses training data. Dalam arsitektur NN juga ditentukan

jumlah node hidden layer serta nilai weight dan bias. Selanjutnya dilakukan proses training data, setelah didapat algoritma dengan akurasi di atas 85%, maka selanjutnya adalah proses testing. Jika akurasi dari data testing juga di atas 85%, maka algoritma ini sudah dapat digunakan untuk proses peramalan.



Gambar 2. Flowchart Pengujian Sistem Peramalan Keluaran Daya PV

C. Metode Perhitungan dan Pengolahan Data Peramalan Daya PV




Gambar 3. Struktur NN

Dari gambar 3 dapat dilihat untuk *input* NN yang digunakan berjumlah 3, yaitu radiasi matahari, suhu, dan juga kelembaban. Sedangkan untuk *output* berupa daya PV. Setelah didapatkan algoritma metode NN dengan *error* terkecil, maka selanjutnya adalah melakukan *testing* pada data yang sudah dibagi untuk menguji algoritma dari hasil *training*. Setelah algoritma diuji dan didapat *error* di bawah 15%, maka

algoritma NN sudah dapat digunakan untuk proses peramalan. Di bawah ini merupakan 6 skenario peramalan yang dilakukan menggunakan NN:

1. Skenario Peramalan 1


Percobaan I menggunakan variasi *input* sebesar 70% untuk data *training* dan 30% untuk data *testing* dari total jumlah data. Pengambilan data dimulai dari tanggal 9 Juni 2023 sampai 6 Juli 2023. Pada proses *training* dari data *input*, struktur NN meliputi 1 *hidden layer* yang memiliki 10 *node*. Gambar 4 merupakan struktur NN dengan 1 *hidden layer* dan 10 *node*.



Gambar 4. Skenario Peramalan 1

2. Skenario Peramalan 2


Percobaan II menggunakan variasi *input* sebesar 70% untuk data *training* dan 30% untuk data *testing* dari total jumlah data. Pengambilan data dimulai dari tanggal 9 Juni 2023 sampai 6 Juli 2023. Pada proses *training* dari data *input*, struktur NN meliputi 2 *hidden layer* yang masing-masing memiliki 10 *node*. Gambar 5 merupakan gambar dari struktur NN dengan 2 *hidden layer* dan 10 *node*.



Gambar 5. Skenario Peramalan 2

3. Skenario Peramalan 3


Percobaan III menggunakan variasi *input* sebesar 75% untuk data *training* dan 25% untuk data *testing* dari total jumlah data. Pengambilan data dimulai dari tanggal 9 Juni 2023 sampai 6 Juli 2023. Pada proses *training* dari data *input*, struktur NN meliputi 1 *hidden layer* yang memiliki 10 *node*. Gambar 6 merupakan gambar dari struktur NN dengan 1 *hidden layer* dan 10 *node*.



Gambar 6. Skenario Peramalan 3

4. Skenario Peramalan 4


Percobaan IV menggunakan variasi *input* sebesar 75% untuk data *training* dan 25% untuk data *testing* dari total jumlah data. Pengambilan data dimulai dari tanggal 9 Juni 2023 sampai 6 Juli 2023. Pada proses *training* dari data *input*, struktur NN meliputi 2 *hidden layer* yang masing-masing memiliki 10 *node*. Gambar 7 merupakan gambar dari struktur NN dengan 2 *hidden layer* dan 10 *node*.



Gambar 7. Skenario Peramalan 4

5. Skenario Peramalan 5


Percobaan V menggunakan variasi *input* sebesar 80% untuk data *training* dan 20% untuk data *testing* dari total jumlah data. Pengambilan data dimulai dari tanggal 9 Juni 2023 sampai 6 Juli 2023. Pada proses *training* dari data *input*, struktur NN meliputi 1 *hidden layer* yang memiliki 10 *node*. Gambar 8 merupakan struktur NN dengan 1 *hidden layer* dan 10 *node*.



Gambar 8. Skenario Peramalan 5

6. Skenario Peramalan 6

Percobaan VI menggunakan variasi *input* sebesar 80% untuk data *training* dan 20% untuk data *testing* dari total jumlah data. Pengambilan data dimulai dari tanggal 9 Juni 2023 sampai 6 Juli 2023. Pada proses *training* dari data *input*, struktur NN meliputi 2 *hidden layer* yang masing-masing memiliki 10 *node*. Gambar 9 merupakan gambar dari struktur NN dengan 2 *hidden layer* dan 10 *node*.



Gambar 9. Skenario Peramalan 6

III. HASIL DAN PEMBAHASAN

A. Pengujian Karakteristik PV

Pengujian karakteristik ini dilakukan pada PV dengan merk SUNASIA berkapasitas 120WP. Pengujian dilakukan dengan menghubungkan PV terhadap beberapa variasi beban. Hal ini dilakukan untuk dapat mengetahui karakteristik PV berupa daya yang dihasilkan terhadap beban yang terpasang untuk setiap jamnya. Tabel 1 merupakan data yang didapat dari pengujian yang dilakukan pada Hari Selasa, 20 Juni 2023.

Tabel 1. Data Uji Karakteristik PV


Pukul (WIB)	Hambatan (Ohm)	Tegangan (V)	Arus (A)	Daya (W)	Intensitas Matahari (Lux)	Suhu (°C)	Kelembaban (%)
09.00	1,25	5,1	3,97	20,247	68.716,9	30,1	63,4
	2,5	9,9	3,88	38,412			
	4,166	15,3	3,59	54,927			
	6,666	18	2,66	47,88			
	10	18,8	1,84	34,592			
	15	19,9	1,29	25,671			
	25	20,6	0,8	16,48			
	35	20,8	0,58	12,064			
	45	21	0,45	9,45			
	55	21	0,37	7,77			
10.00	1,25	5,4	4,2	22,68	73.548,6	38,3	46,9
	2,5	10,7	4,1	43,87			
	4,166	15,6	3,79	59,124			
:	:	:	:	:	:	:	:
15.00	35	20,2	0,58	11,716	7.208,53	33,7	44,1
	45	20,3	0,45	9,135			
	55	20,4	0,36	7,344			

Data yang dicatat adalah berupa waktu pengambilan data, hambatan, tegangan, arus, intensitas cahaya matahari, suhu, dan juga kelembaban. Sedangkan untuk daya merupakan hasil perkalian antara arus dan tegangan. Dari data Tabel 1 dapat diketahui jika keluaran daya PV sangat dipengaruhi oleh intensitas cahaya matahari yang diterima. Saat pagi dan sore hari dimana intensitas cahaya matahari tidak terlalu terik, daya yang dihasilkan PV berkisar antara 50W ke bawah. Sedangkan saat siang hari dimana intensitas cahaya matahari cukup tinggi, daya yang dihasilkan PV dapat mencapai 60,672W. Ini menunjukkan jika intensitas cahaya matahari sangat berpengaruh terhadap keluaran daya PV.

Suhu dan kelembaban di sekitar PV cukup berkaitan dengan intensitas cahaya matahari yang diterima oleh PV. Saat pagi dan sore hari yaitu ketika intensitas cahaya matahari rendah, tingkat suhu di sekitar PV juga ikut rendah berkisar antara 30°C-34°C, namun untuk kelembaban di sekitar cukup tinggi diantara 45-65%. Hal ini berbanding terbalik dengan saat siang hari yaitu ketika intensitas cahaya matahari tinggi, suhu di sekitar PV cukup tinggi hingga 45,4°C, namun untuk kelembaban cukup rendah hingga 25%. Berikut merupakan grafik V-I *photovoltaic* dengan radiasi matahari berbeda untuk setiap variasi beban.

Berdasarkan gambar 10 kurva hubungan antara tegangan dan arus, dapat diketahui jika hubungan keduanya awalnya lurus lalu membentuk garis parabola. Dimana ketika beban minimum maka tegangan awal juga minimum, namun arus yang dihasilkan akan maksimum. Sedangkan ketika resistansi beban ditambah, nilai tegangan juga akan terus meningkat dan arus akan cenderung menurun secara bertahap. Hal ini

disebabkan oleh karakteristik semikonduktor bahan yang digunakan dalam panel surya. Arus yang dihasilkan oleh panel surya dipengaruhi oleh intensitas cahaya yang diterima dan sifat semikonduktor tersebut. Ketika cahaya matahari mengenai panel surya, elektron-elektron di dalam bahan semikonduktor terlepas dan menghasilkan arus.



Gambar 10. Kurva Karakteristik V-I Modul Photovoltaic 120WP

Namun, terdapat batasan fisik pada jumlah elektron yang dapat dilepaskan dan berkontribusi pada arus. Ini menyebabkan penurunan tegangan efektif yang terukur pada panel surya. Sehingga ketika tegangan meningkat, mengakibatkan penurunan arus yang dihasilkan. Hal ini sesuai dengan teori yang ditulis oleh [4] terkait dengan karakteristik internal panel surya dan resistansi internalnya. Dimana semakin tinggi arus yang mengalir melalui panel surya, semakin besar resistansi internal yang harus diatasi PV, yang pada gilirannya mengurangi tegangan yang dihasilkan. Jadi, ketika diberi hambatan minimum, maka nilai arus akan maksimum sedangkan nilai tegangan minimum.

B. Pengujian Algoritma Neural Network (NN)

Pengujian ini dilakukan untuk mendapatkan algoritma NN dengan nilai MAPE terendah yang kemudian algoritma tersebut akan digunakan untuk meramalkan keluaran daya PV. Pengambilan data dilakukan dengan menggunakan 4 sensor yaitu sensor cahaya, sensor suhu dan kelembaban serta sensor tegangan dan sensor arus untuk mengukur keluaran dari PV dengan kapasitas 120WP. Data dari sensor-sensor tersebut akan dibaca oleh arduino uno. Selanjutnya data dari arduino akan dikirimkan menuju esp8266 untuk kemudian data tersebut akan dikirimkan menuju *database* lokal MySQL setiap 1 menit. Dalam pelaksanaannya, terdapat beberapa masalah yang dialami kami dalam proses pengambilan data seperti kondisi jaringan yang kurang memadai dan lokasi pengambilan data yang cukup jauh dari sumber AC. Hal ini dikarenakan sistem masih membutuhkan sumber AC sebagai *power* dari mikrokontroler yang digunakan. Berikut adalah hasil pembacaan sensor yang tersimpan pada *micro SD* dan *database* lokal MySQL.

Dari tabel 2 dapat terlihat bahwa jumlah data yang didapat adalah sebanyak 8428. Data tersebut diambil selama 3 minggu dimulai pada tanggal 9 Juni 2023 sampai dengan 6 Juli 2023. Kemudian, data akan dibagi menjadi 2, yaitu data *training* dan *testing*.

Tabel 2. Data Pembacaan Sensor

Data ke-	Hari	Tanggal	Radiasi (W/m ²)	Suhu (°C)	Kelembaban (%)	Tegangan (V)	Arus (A)
1	Jumat	2023-06-9 10:00:00	365,12	38,3	46,9	15,55	2,29
2	Jumat	2023-06-9 10:01:00	364,27	37,9	46,4	15,74	2,29
3	Jumat	2023-06-9 10:02:00	365,49	37,5	47,3	14,96	2,30
4	Jumat	2023-06-9 10:03:00	365,28	36,5	47,1	14,64	2,30
5	Jumat	2023-06-9 10:04:00	364,43	35,7	49,1	15,67	2,29
6	Jumat	2023-06-9 10:05:00	352,19	37,5	50	15,59	2,21
:	:	:	:	:	:	:	:
:	:	:	:	:	:	:	:
8428	Kamis	2023-07-06 15:00:00	38,74	31,65	52,80	13,44	0,24

C. Perbandingan Nilai MAPE Hasil Pengujian Skenario Peramalan 1 hingga 6

1. Nilai MAPE pada skenario peramalan 1

Untuk mengetahui tingkat akurasi dari algoritma yang didapat, kami menggunakan metode MAPE. Dari perhitungan MAPE tersebut didapat nilai *error* sebesar 1,37%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 2528 data *testing*. Di bawah ini merupakan perhitungan untuk mendapatkan nilai MAPE:

$$MAPE = (1/n) \times \sum(|A - F|/A) \times 100\% \quad (1)$$

$$MAPE = (1/2528) \times ((|49,63 - 46,67|/49,63) + \dots + (|3,27 - 3,33|/3,27)) \times 100\%$$

$$MAPE = 1,37\%$$

2. Nilai MAPE pada skenario peramalan 2

Untuk mengetahui tingkat akurasi dari algoritma yang didapat, kami menggunakan metode MAPE sesuai dengan Persamaan (1). Dari perhitungan MAPE tersebut didapat nilai *error* sebesar 1,42%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 2528 data *testing*. Berikut merupakan perhitungan untuk mendapatkan nilai MAPE:

$$MAPE = (1/2528) \times ((|49,63 - 47,47|/49,63) + \dots + (|3,27 - 3,35|/3,27)) \times 100\%$$

$$MAPE = 1,42\%$$

3. Nilai MAPE pada skenario peramalan 3

Untuk mengetahui tingkat akurasi dari algoritma yang didapat, kami menggunakan metode MAPE sesuai dengan Persamaan (1). Dari perhitungan MAPE tersebut didapat nilai *error* sebesar 1,47%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 2107 data *testing*. Berikut merupakan perhitungan untuk mendapatkan nilai MAPE:

$$MAPE = (1/2107) \times ((|34,22 - 33,51|/34,22) + \dots +$$

$$(|3,27 - 3,35|/3,27)) \times 100\%.$$

$$MAPE = 1,47\%$$

4. Nilai MAPE pada skenario peramalan 4

Untuk mengetahui tingkat akurasi dari algoritma yang didapat, kami menggunakan metode MAPE sesuai dengan Persamaan (1). Dari perhitungan MAPE tersebut didapat nilai *error* sebesar 1,33%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 2107 data *testing*. Berikut merupakan perhitungan untuk mendapatkan nilai MAPE:

$$MAPE = (1/2107) \times ((|34,22 - 33,51|/34,22) + \dots + (|3,27 - 3,47|/3,27)) \times 100\%.$$

$$MAPE = 1,33\%$$

5. Nilai MAPE pada skenario peramalan 5

Untuk mengetahui tingkat akurasi dari algoritma yang didapat, kami menggunakan metode MAPE sesuai dengan Persamaan (1). Dari perhitungan MAPE tersebut didapat nilai *error* sebesar 1,35%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 1686 data *testing*. Berikut merupakan perhitungan untuk mendapatkan nilai MAPE:

$$MAPE = (1/1686) \times ((|63,61 - 63,02|/63,61) + \dots + (|3,27 - 3,24|/3,27)) \times 100\%$$

$$MAPE = 1,35\%$$

6. Nilai MAPE pada skenario peramalan 6

Untuk mengetahui tingkat akurasi dari algoritma yang didapat, kami menggunakan metode MAPE sesuai dengan Persamaan (1). Dari perhitungan MAPE tersebut didapat nilai *error* sebesar 1,22%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 1686 data *testing*. Berikut merupakan perhitungan untuk mendapatkan nilai MAPE:

$$MAPE = (1/1686) \times ((|63,61 - 63,92|/63,61) + \dots + (|3,27 - 3,23|/3,27)) \times 100\%.$$

$$MAPE = 1,22\%$$

D. Pengujian Sistem Peramalan

Algoritma NN dari Skenario Peramalan 4 digunakan untuk melakukan peramalan pada tanggal 7-9 juli 2023. Pengujian ini dilakukan untuk menguji algoritma NN dari Skenario Peramalan 4 dalam meramalkan keluaran daya PV untuk setiap menit di hari berikutnya. Kemudian hasil ramalan akan dibandingkan dengan data aktual hasil tersebut untuk mengetahui tingkat akurasinya. Sebagai input untuk proses peramalan ini, digunakan rata-rata dari data hari tersebut pada empat minggu sebelumnya.

1. Pengujian Sistem Peramalan 7 Juli 2023

Tabel 3 Perbandingan Data Peramalan dan Data Aktual 7 juli 2023

Data ke-	Pukul (WIB)	Daya Aktual PV (Watt)	Daya Peramalan PV (Watt)	Persentase Selisih (%)
1	10.00	46,57	33,31	28,47
2	10.01	53,89	48,55	9,89
3	10.02	51,81	47,03	9,21
4	10.03	48,50	41,16	15,12

Data ke-	Pukul (WIB)	Daya Aktual PV (Watt)	Daya Peramalan PV (Watt)	Persentase Selisih (%)
5	10.04	52,63	49,37	6,18
6	10.05	42,02	27,50	34,54
⋮	⋮	⋮	⋮	⋮
301	15.00	5,11	10,08	97,31

Tabel 3 menampilkan perbandingan antara data daya peramalan dengan data daya aktual. Data daya peramalan adalah hasil dari proses peramalan untuk tanggal 7 Juli 2023, yaitu Hari Jumat. Peramalan ini diperoleh melalui penggunaan algoritma NN Skenario Peramalan 4 dengan *input* berupa data radiasi matahari, suhu, dan kelembaban sekitar pada Hari Jumat di empat minggu sebelumnya. Hasil perbandingan menunjukkan variasi nilai *error* yang cukup signifikan, dengan rentang mulai dari kurang dari 1% hingga mencapai nilai tertinggi hingga 98%. Perbedaan ini mengindikasikan bahwa hasil peramalan masih mengandung kesalahan yang disebabkan oleh perbedaan kondisi cuaca pada hari pengujian dibandingkan dengan data daya pada empat Hari Jumat di empat minggu sebelumnya.

Perhitungan nilai MAPE dilakukan dengan membandingkan setiap nilai daya peramalan dengan nilai daya aktual pada tanggal 7 juli 2023.

$$MAPE = (1/301) \times ((|46,57 - 33,31|/46,57) + \dots + (|5,11 - 10,08|/5,11)) \times 100\%.$$

$$MAPE = 9,43\%$$

Dari perhitungan MAPE tersebut, didapat nilai *error* sebesar 9,43%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 301 data untuk Hari Jumat.

2. Pengujian Sistem Peramalan 8 Juli 2023

Tabel 4 Perbandingan Data Peramalan dan Data Aktual 8 juli 2023

Data ke-	Pukul (WIB)	Daya Aktual PV (Watt)	Daya Peramalan PV (Watt)	Persentase Selisih (%)
1	10.00	46,20	60,05	29,98
2	10.01	60,52	59,45	1,76
3	10.02	58,17	58,34	0,29
4	10.03	52,37	57,59	9,97
5	10.04	59,30	55,53	6,35
6	10.05	38,71	56,99	47,23
⋮	⋮	⋮	⋮	⋮
301	15.00	3,05	2,79	8,59

Pada tabel 4 terdapat perbandingan antara data daya peramalan dan data daya aktual. Data daya peramalan ini merupakan hasil dari proses peramalan untuk tanggal 8 Juli 2023, yaitu Hari Sabtu. Peramalan tersebut diperoleh melalui penggunaan algoritma NN Skenario Peramalan 4 dengan *input* berupa data radiasi matahari, suhu, dan kelembaban sekitar pada empat Hari Sabtu di empat minggu sebelumnya. Hasil perbandingan menunjukkan variasi nilai *error* yang cukup signifikan, dengan rentang mulai dari kurang dari 1% hingga mencapai nilai tertinggi sebesar 46%. Variasi ini mengindikasikan bahwa hasil peramalan masih mengandung kesalahan yang disebabkan oleh perbedaan

signifikan, dengan rentang mulai dari kurang dari 1% hingga mencapai nilai tertinggi sebesar 81%. Variasi ini mengindikasikan bahwa hasil peramalan masih mengandung kesalahan yang disebabkan oleh perbedaan kondisi cuaca pada hari pengujian dengan data daya pada empat Hari Sabtu di empat minggu sebelumnya.

Untuk mengukur tingkat akurasi algoritma yang digunakan, metode yang digunakan adalah *Mean Absolute Percentage Error* (MAPE). Perhitungan nilai MAPE dilakukan dengan membandingkan setiap nilai daya peramalan dengan nilai daya aktual pada tanggal 8 Juli 2023. Selanjutnya, selisih absolut antara nilai peramalan dan nilai aktual dihitung, kemudian hasilnya dibagi dengan nilai aktual, dan akhirnya dikalikan dengan 100% untuk mendapatkan nilai persentase kesalahan relatif.

$$MAPE = (1/301) \times ((|46.20 - 60.05|/46.20) + \dots + (|3.05 - 2.79|/3.05)) \times 100\%.$$

$$MAPE = 6,11\%$$

Dari perhitungan MAPE tersebut, didapat nilai *error* sebesar 6,11%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 301 data untuk Hari Sabtu. Nilai MAPE yang didapat untuk peramalan Hari Sabtu lebih kecil dibandingkan dengan nilai MAPE pada peramalan Hari Jumat. Sehingga dapat dikatakan jika akurasi hasil peramalan Hari Sabtu lebih tinggi dibandingkan hasil peramalan Hari Jumat.

3. Pengujian Sistem Peramalan 9 Juli 2023

Tabel 5 Perbandingan Data Peramalan dan Data Aktual 9 juli 2023

Data ke-	Pukul (WIB)	Daya Aktual PV (Watt)	Daya Peramalan PV (Watt)	Persentase Selisih (%)
1	10.00	52,88	40,45	23,50
2	10.01	53,76	39,55	26,41
3	10.02	53,43	38,21	28,47
4	10.03	53,17	37,39	29,65
5	10.04	35,81	31,44	12,20
6	10.05	53,72	36,89	31,31
⋮	⋮	⋮	⋮	⋮
301	15.00	14,66	12,32	15,93

Dalam tabel 5, terdapat perbandingan antara data daya peramalan dan data daya aktual. Data daya peramalan ini merupakan hasil dari proses peramalan untuk tanggal 9 Juli 2023, yaitu Hari Minggu. Peramalan tersebut diperoleh melalui penggunaan algoritma NN Skenario Peramalan 4 dengan *input* berupa data radiasi matahari, suhu, dan kelembaban sekitar pada Hari Sabtu di empat minggu sebelumnya. Hasil perbandingan menunjukkan variasi nilai *error* yang cukup signifikan, dengan rentang mulai dari kurang dari 1% hingga mencapai nilai tertinggi sebesar 46%. Variasi ini mengindikasikan bahwa hasil peramalan masih mengandung kesalahan yang disebabkan oleh perbedaan

kondisi cuaca pada hari pengujian dengan data daya pada empat Hari Minggu di empat minggu sebelumnya.

Perhitungan nilai MAPE dilakukan dengan membandingkan setiap nilai daya peramalan dengan nilai daya aktual pada tanggal 9 juli 2023.

$$MAPE = (1/301) \times ((|52,88 - 40,45|/52,88) + \dots + (|14,66 - 12,32|/14,66)) \times 100\%.$$

$$MAPE = 21,33\%$$

Dari perhitungan MAPE tersebut, didapat nilai *error* sebesar 21,33%. Nilai *error* ini merupakan nilai rata-rata *error* dari total 301 data untuk Hari Minggu. Nilai MAPE yang didapat untuk peramalan Hari Minggu memiliki nilai MAPE yang cukup besar dibandingkan dengan hasil peramalan dua hari sebelumnya. Ini menandakan jika hasil peramalan pada Hari Minggu tidak cukup akurat dalam memprediksi keluaran daya pada tanggal tersebut jika dibandingkan dengan hasil peramalan pada Hari Jumat dan Sabtu.

Berdasarkan nilai MAPE yang didapat dari tanggal 7–9 Juli 2023. Hasil peramalan untuk Hari Minggu memiliki perbedaan yang cukup tinggi dengan data aktual pada hari tersebut dibandingkan dengan hasil peramalan dua hari sebelumnya. Hal ini dikarenakan, pada Hari Minggu yang merupakan data aktual memiliki kondisi cuaca yang berbeda dengan data Hari Minggu di empat minggu sebelumnya. Dimana pada hari tersebut, kondisi cuaca lebih mendung dibandingkan dengan data empat minggu sebelumnya. Hal ini menyebabkan perbedaan terhadap nilai intensitas cahaya matahari yang didapat serta suhu dan kelembaban di sekitar PV.

Sedangkan, pada Jumat dan Sabtu, data hasil peramalan memiliki perbedaan sekitar 10% dengan data aktual, dimana lebih rendah dibandingkan dengan data hasil peramalan pada Hari Minggu. Hal ini dikarenakan data pada hari pengujian Jumat dan Sabtu memiliki kondisi cuaca yang mirip dengan data empat minggu sebelumnya. Lalu untuk mengukur tingkat kesalahan dari tiga pengujian ini, kami juga menggunakan metode MAPE. Berikut merupakan perhitungan untuk mendapatkan nilai MAPE total dari ketiga pengujian,

$$MAPE = (1/903) \times ((|46,57 - 33,31|/46,57) + \dots + (|14,66 - 12,32|/14,66)) \times 100\%.$$

$$MAPE = 12,29\%$$

Jadi, tingkat rata-rata kesalahan dari ketiga pengujian hasil peramalan ini adalah sebesar 12,29%.

IV. KESIMPULAN

PV yang digunakan hanya mampu menghasilkan daya maksimum sebesar 60,672 W dari spesifikasi daya PV yang berkapasitas 120 WP. Daya tersebut didapat saat tegangan sebesar 15,8 V dan arus sebesar 3,84 A. Efisiensi tertinggi PV didapat saat intensitas cahaya paling kecil dari keseluruhan pengujian, dimana didapat efisiensi sebesar 15,48% saat intensitas cahaya sebesar 15432.43 Lux.

Jumlah data yang dilatih dalam rentang 70%, 75%, dan 80% mempengaruhi tingkat akurasi algoritma NN pada jumlah *hidden layer* yang sama. Dengan setiap peningkatan jumlah data *training*, nilai MAPE berubah semakin kecil. Dimana saat *hidden layer* hanya satu, nilai MAPE memiliki nilai yang terkecil adalah saat jumlah data *training* sebanyak 80% yaitu 1,35%. Begitu juga saat *hidden layer* berjumlah dua, nilai MAPE memiliki nilai yang terkecil saat data *training* sebanyak 80% yaitu 1,22%. Menggunakan dua *hidden layer* menghasilkan tingkat akurasi yang lebih baik dibandingkan dengan hanya satu *hidden layer* pada jumlah data yang sama. Dimana pada jumlah data *training* yang sama, nilai MAPE pada data dengan jumlah *hidden layer* sebanyak dua selalu lebih kecil dibandingkan dengan hanya satu *hidden layer*.

Dari percobaan yang dilakukan, didapat algoritma NN dengan nilai MAPE terkecil yaitu sebesar 1,22% saat jumlah data *training* sebanyak 80% dan *hidden layer* sebanyak dua. Sistem peramalan memiliki tingkat kesalahan dalam meramalkan keluaran daya PV dengan nilai MAPE yaitu sebesar 12,29%.

REFERENSI

- [1] L. Hu *et al.*, "Ultra-Short-Term Solar PV Power Forecasting Method Based on Frequency-Domain Decomposition and Deep Learning," 2020 IEEE Ind. Appl. Soc. Annu. Meet. IAS 2020, 2020, doi: 10.1109/IAS44978.2020.9334889.
- [2] M. M. Hasan Shawon, S. Akter, M. K. Islam, S. Ahmed, and M. M. Rahman, "Forecasting PV panel output using prophet time series machine learning model," IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON, vol. 2020-Novem, pp. 1141–1144, 2020, doi: 10.1109/TENCON50793.2020.9293751.
- [3] H. Chai *et al.*, "Convolutional Auto-encoder Based Sky Image Prediction Model for Minutely Solar PV Power Forecasting," 2020 IEEE Ind. Appl. Soc. Annu. Meet. IAS 2020, pp. 0–6, 2020, doi: 10.1109/IAS44978.2020.9334923.
- [4] S. Theocharides, V. Venizelou, G. Makrides, and G. E. Georgiou, "Day-ahead Forecasting of Solar Power Output from Photovoltaic Systems Utilising Gradient Boosting Machines," 2018 IEEE 7th World Conf. Photovolt. Energy Conversion, WCPEC 2018 - A Jt. Conf. 45th IEEE PVSC, 28th PVSEC 34th EU PVSEC, pp. 2371–2375, 2018, doi: 10.1109/PVSC.2018.8547375.
- [5] J. Shi *et al.*, "Bayesian Optimization - LSTM Modeling and Time Frequency Correlation Mapping Based Probabilistic Forecasting of Ultra-short-term Photovoltaic Power Outputs," in IEEE Transactions on Industry Applications, vol. 60, no. 2, pp. 2422–2430, March–April 2024, doi: 10.1109/TIA.2023.3334700.
- [6] Y. Wang, J. Shi, Y. Ma, S. Wang, Z. Fu and J. Gao, "Ultra-short-term interval prediction model for photovoltaic power based on bayesian optimization", Proc. IEEE/IAS Ind. Commercial Power System Asia, pp. 1138–1144, 2022.
- [7] J. Shi, Y. Chen, X. Cheng, M. Yang and M. Wang, "Four-Stage Space-Time Hybrid Model For Distributed Photovoltaic Power Forecasting," in IEEE Transactions on Industry Applications, vol. 59, no. 1, pp. 1129–1138, Jan.-Feb. 2023, doi: 10.1109/TIA.2022.3205570.
- [8] B. Liu, J. Nowotarski, T. Hong and R. Weron, "Probabilistic load forecasting via quantile regression averaging on sister forecasts", IEEE Trans. Smart Grid, vol. 8, no. 2, pp. 730–737, Mar. 2017.
- [9] M. S. Hossain and H. Mahmood, "Short-term photovoltaic power forecasting using an LSTM neural network and synthetic weather forecast", IEEE Access, vol. 8, pp. 172524–172533, Sep. 2020.

- [10] A. Borré et al., "Machine fault detection using a hybrid CNN-LSTM attention-based model", *Sensors*, vol. 9, no. 23, Apr. 2023.
- [11] A. Mellit, A. M. Pavan and V. Lughi, "Deep learning neural networks for short-term photovoltaic power forecasting", *Renewable Energy*, vol. 172, pp. 276-288, Jul. 2021.
- [12] Khairunnisa, *Prediksi Daya Pembangkit Listrik Pv Satu Hari Ke Depan Untuk Memudahkan Manajemen Energi Pada Sistem Menggunakan Neural Network*. 2020.
- [13] K. Nisa', L. Mahendra, H. Eko, and I. W. Farid, "PV Power Forecast Based on Artificial Neural Network at Indonesia Shopping Mall PV Rooftop," *2021 Int. Conf. Adv. Mechatronics, Intell. Manuf. Ind. Autom. ICAMIMIA 2021 - Proceeding*, pp. 335–338, 2021, doi: 10.1109/ICAMIMIA54022.2021.9807694.
- [14] H. T. Yang, C. M. Huang, Y. C. Huang, and Y. S. Pai, "A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output," *IEEE Trans. Sustain. Energy*, vol. 5, no. 3, pp. 917–926, 2014, doi: 10.1109/TSTE.2014.2313600.
- [15] N. Jitratom, G. W. Chang, and G. Y. Li, "A Hybrid Method for Hour-ahead PV Output Forecast with Historical Data Clustering," *Proc. - 2022 IET Int. Conf. Eng. Technol. Appl. IET-ICETA 2022*, pp. 1–2, 2022, doi: 10.1109/IET-ICETA56553.2022.9971576.