

INOVASI DALAM ENERGI TERBARUKAN: JARINGAN SYARAF TIRUAN UNTUK MERAMALKAN DAYA FOTOVOLTAIK

Bagus Tri Kuncoro

Sekolah Tinggi Teknologi Ronggolawe, Cepu, Indonesia

e-mail :btrikuncoro@gmail.com

ABSTRACT

Variations in meteorological conditions cause intermittency, voltage spikes, and feedback power flow, impacting the uncertainty of photovoltaic output, which affects the reliability, stability, and scheduling of photovoltaic operations. Optimal prediction of photovoltaic output power is necessary in the planning and operation of power systems. Photovoltaic technology is utilized to generate electrical energy from direct sunlight. Climatic factors such as cloud cover, humidity, and wind speed also contribute to the electrical energy produced by solar modules. This research discusses a model for predicting photovoltaic output power for the next day using the backpropagation neural network method and multi-factor analysis. In this study, there are 2 different input neurons with 10 predetermined network architectures, a learning rate of 0.1, and a minimum target error of 0.001. The best performance prediction results with the smallest Mean Squared Error (MSE) value were obtained using a backpropagation neural network structure from the 5-20-1 model, which is almost close to the actual value. However, further research is needed to improve the prediction results.

Keywords : photovoltaic output power, meteorology, backpropagation neural network

INTISARI

Variasi dalam keadaan meteorologi menyebabkan intermiten, lonjakan tegangan dan aliran daya balik, berdampak pada ketidakpastian dari keluaran fotovoltaiik yang mempengaruhi keandalan, stabilitas dan penjadwalan operasi fotovoltaiik. Prediksi daya keluaran fotovoltaiik yang optimal diperlukan dalam perencanaan dan pengoperasian sistem tenaga listrik. Teknologi fotovoltaiik dimanfaatkan dalam menghasilkan energi listrik dari sinar matahari langsung. Faktor iklim seperti tutupan awan, kelembaban dan kecepatan angin juga berkontribusi pada energi listrik yang dihasilkan oleh modul surya. Penelitian ini membahas tentang model prediksi daya keluaran fotovoltaiik dalam 1 hari ke depan dengan pendekatan metode jaringan syaraf tiruan backpropagation dan analisis multi-faktor. Dalam penelitian ini terdapat 2 input neuron yang berbeda dengan 10 arsitektur jaringan yang telah ditentukan, learning rate 0,1 dan target error minimum 0,001. Hasil prediksi kinerja terbaik nilai Mean Squared Error (MSE) terkecil diperoleh dengan struktur jaringan syaraf backpropagation dari model 5-20-1 hampir mendekati nilai aktualnya, namun masih diperlukan penelitian lebih lanjut agar hasil prediksi dapat lebih baik lagi.

Kata kunci : daya keluaran fotovoltaiik, meteorology, jaringan syaraf tiruan backpropagation

1. PENDAHULUAN

Energi terbarukan semakin menjadi perhatian global seiring dengan peningkatan kebutuhan energi yang berkelanjutan dan pengurangan emisi gas rumah kaca. Salah satu sumber energi terbarukan yang paling berkembang adalah fotovoltaiik, yang memanfaatkan energi matahari untuk menghasilkan listrik. Namun, teknologi fotovoltaiik menghadapi tantangan utama berupa variabilitas daya yang sangat dipengaruhi oleh kondisi cuaca. Kondisi cuaca alami seperti paparan sinar matahari, suhu dan kecepatan angin memiliki dampak yang signifikan terhadap daya keluaran fotovoltaiik, di mana kuantitas radiasi matahari yang dapat diserap oleh pembangkit listrik tenaga surya sangat bergantung pada panel surya itu sendiri (NurHidayat et al., 2021). Daya listrik yang dihasilkan bervariasi tergantung pada intensitas matahari, dimana energi surya dengan intensitas tinggi menghasilkan lebih banyak daya dibandingkan dengan intensitas rendah.

Diketahui bahwa daya keluaran fotovoltaiik berkorelasi erat dengan radiasi matahari dari modul fotovoltaiik. Menurut penelitian (Putri et al., 2022), jumlah intensitas cahaya matahari memiliki pengaruh besar terhadap daya listrik yang dihasilkan panel surya. Selain itu, faktor iklim lainnya seperti suhu sekitar, kelembaban relatif, kecepatan angin dan pengendapan debu juga mempengaruhi efisiensi fotovoltaiik (Khandakar et al., 2019). Sementara itu, penelitian (Mahendra et al., 2021) mengenai prediksi daya pembangkitan fotovoltaiik menggunakan *machine learning* menunjukkan bahwa parameter seperti *irradiance*, suhu fotovoltaiik, suhu *ambient* dan waktu memiliki peran penting dalam memprediksi produksi fotovoltaiik. Penelitian (Anggreni et al., 2018) menganalisis pengaruh penutupan awan terhadap radiasi matahari di Kota Pontianak, menunjukkan bahwa tutupan awan dapat mengurangi intensitas radiasi yang diterima, yang selanjutnya mempengaruhi daya keluaran sistem fotovoltaiik.

Penelitian oleh (Utami & Daud, 2021) juga menekankan pentingnya intensitas cahaya matahari sebagai faktor utama dalam produksi energi oleh panel surya, di mana tutupan awan secara implisit mempengaruhi analisis ini. Selain itu, penelitian (Johan et al., 2022), mengkaji berbagai faktor yang mempengaruhi kinerja panel surya, termasuk pengaruh tutupan awan. Penelitian (Khairunnisa, 2020) menyoroti faktor-faktor seperti radiasi matahari, suhu, kelembaban dan tutupan awan signifikan mempengaruhi efisiensi daya yang dihasilkan panel surya. Terakhir, (Dahliya et al., 2021) mengamati pentingnya mempertimbangkan variabilitas cuaca, termasuk tutupan awan, dalam perencanaan dan pengoperasian sistem fotovoltaik. Dengan demikian, tutupan awan diakui sebagai faktor yang mempengaruhi daya keluaran fotovoltaik secara signifikan.


Berdasarkan penelitian, kondisi cuaca, terutama radiasi matahari dan suhu, sangat mempengaruhi daya keluaran sistem fotovoltaik. Faktor iklim lain seperti tutupan awan, kelembaban dan kecepatan angin juga berkontribusi pada efisiensi panel surya. Penting untuk memahami variabilitas cuaca agar prediksi daya keluaran fotovoltaik dan stabilitas operasional sistem tenaga surya dapat ditingkatkan. Namun, masih ada kekurangan dalam penelitian yang mengintegrasikan berbagai faktor cuaca dalam model prediksi komprehensif. Sebagian besar studi sebelumnya lebih fokus pada satu atau dua variabel, seperti radiasi atau suhu, tanpa mempertimbangkan interaksi semua faktor. Penelitian ini menawarkan kebaruan dengan mengembangkan model prediksi yang menggabungkan metode jaringan syaraf tiruan *backpropagation* dan analisis multi-faktor. Faktor-faktor yang digunakan seperti radiasi matahari, suhu, kelembaban dan tutupan awan yang dapat mempengaruhi efisiensi panel surya, untuk estimasi daya keluaran fotovoltaik yang lebih akurat. Penelitian ini diharapkan dapat memperkaya literatur dan memberikan kontribusi praktis dalam perencanaan dan pengoperasian sistem energi terbarukan.

1.1 Jaringan syaraf tiruan

Jaringan syaraf tiruan (JST) adalah sistem koneksionis yang didasarkan pada jaringan syaraf biologis otak manusia, yang memiliki kemampuan untuk mempelajari, mengingat dan menghubungkan data. *Neuron* adalah blok dasar penyusun JST yang terhubung ke *neuron* lain melalui faktor pembobotan untuk menentukan kekuatan koneksi (Shuvho et al., 2019).

1.2 Algoritma *Backpropagation*

Backpropagation (BP) merupakan teknik pelatihan untuk jaringan syaraf buatan yang memiliki struktur berlapis (Catur Wijaya et al., 2023). Jenis model *artificial neural network* (ANN) ini paling umum digunakan karena teknik ini efektif untuk menangani isu-isu yang rumit dan cocok untuk aplikasi yang memerlukan pengendalian, karena proses pembelajarannya bergantung pada keterkaitan yang mudah dipahami. Kelebihan dari teknik ini termasuk kemampuannya untuk menyesuaikan pembelajaran secara adaptif dalam jaringan multilapis, serta kemampuannya untuk secara progresif menyesuaikan bobot dalam jaringan guna mengurangi kesalahan (Huang & Wu, 2017).

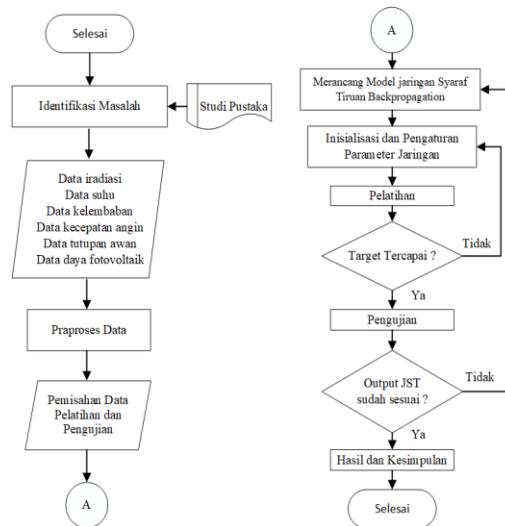


Gambar 1. Struktur Jaringan Syaraf BP (Hao, 2018)

Gambar 1, menunjukkan *neuron* lapisan input x_1, x_2, \dots, x_n , *neuron* lapisan tersembunyi h_1, h_2, \dots, h_n dan *neuron* lapisan output o_1, o_2, \dots, o_n . w_{ij} adalah bobot neuron i di lapisan input terhadap *neuron* j di lapisan tersembunyi. w_{jk} adalah bobot dari *neuron* j di lapisan tersembunyi terhadap *neuron* k di lapisan output (Gu et al., 2018).

2. METODE PENELITIAN

Dalam penelitian ini, disusun melalui beberapa tahap yang ditunjukkan pada Gambar 2.



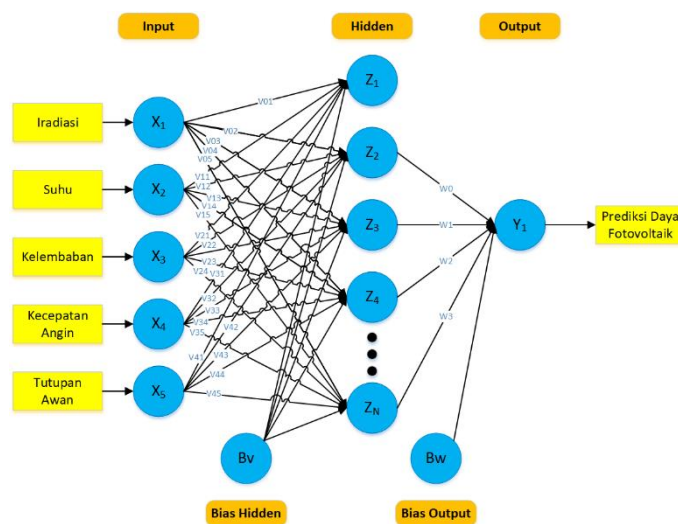
Gambar 2. Diagram Alir Penelitian

Proses penelitian dimulai dari melakukan studi pustaka untuk mempelajari penelitian-penelitian terdahulu yang berhubungan dengan penelitian saat ini. serta pemilihan judul, algoritma untuk peramalan dan metode yang digunakan dari berbagai sumber, jurnal dan buku yang berhubungan dengan pembahasan fotovoltaik, *machine learning* dan jaringan syaraf tiruan *backpropagation*. Identifikasi masalah dari rencana penelitian ini diperlukan untuk mengetahui kinerja fotovoltaik yang bergantung pada iradiasi cahaya matahari. Data sekunder yang digunakan dalam penelitian ini diambil dari *website Kaggle*, di Kerala Negara bagian India pada tanggal 1 Mei – 30 Juni 2024. Pemilihan India sebagai lokasi penelitian panel surya karena India merupakan salah satu negara penghasil emisi karbon dioksida terbesar di dunia, terutama karena ketergantungannya yang besar pada pembangkit listrik tenaga batu bara (Simarmata et al., 2023).

2.1 Alat Penelitian

Alat dan bahan yang dibutuhkan dalam penelitian ini adalah sebagai berikut:

- Perangkat Keras : Laptop Asus VivoBook 14 inci
- Perangkat Lunak : MATLAB R2013a dan microsoft excel
- Processor : AMD Ryzen 3 3200U with Radeon Vega Mobile Gfx 2.60 GHz
- RAM : 12 GB
- Harddisk : 1 TB



Gambar 3. Tampilan Arsitektur *backpropagation* pada penelitian

Di mana:
 X_1 ke X_4 = Lapisan masukan
 Z_1 ke Z_N = Lapisan tersembunyi

V01-V45 = Bobot dari lapisan masukan ke lapisan tersembunyi
W0-W3= Bobot dari lapisan tersembunyi ke lapisan keluaran
Bv = Bobot bias dari lapisan masukan ke lapisan tersembunyi
Bw = Bobot bias dari lapisan tersembunyi ke lapisan keluaran
Y1 = Hasil keluaran (*output*)

Pada Gambar 3 adalah arsitektur jaringan syaraf tiruan yang akan dibangun menggunakan perangkat lunak Matlab R2013a. Untuk membuat jaringan menggunakan algoritma *Levenberg-Marquardt* untuk meramalkan daya keluaran sistem fotovoltaik, gunakan perintah berikut di Matlab:

```
net = newff(minmax(data_latih),[8 1],{'tansig','purelin'},'trainlm');
```

Pada perintah tersebut terdapat arsitektur model yang terdiri dari hidden layer, terdapat 8 *neuron* dan *output* layer terdapat 1. Sebelum dilakukan pelatihan, dilakukan inialisasi dan pengaturan parameter jaringan untuk mengetahui MSE atas perubahan parameter yang telah ditentukan dan agar diperoleh hasil yang optimal, seperti pada Tabel 1.

Tabel 1. Parameter dalam Pelatihan ANN *Backpropagation*

Karakteristik	Spesifikasi
<i>Neuron Input</i>	4 & 5
<i>Neuron Hidden</i>	8, 10, 12, 20, 36
<i>Neuron Layer Output</i>	1
<i>Training Function</i>	<i>Levenberg-Marquard</i>
<i>Performance Function</i>	<i>Mean Square Error (MSE)</i>

2.2 Menentukan Input dan Target

Data sekunder dalam penelitian ini diambil dari *website Kaggle*, di Kerala Negara bagian India pada tanggal 1 Mei – 30 Juni 2024. Data meteorologi dan data daya fotovoltaik kemudian diolah dengan jaringan syaraf tiruan metode *backpropagation*. Data latih untuk input penelitian ini terdiri dari iradiasi sinar matahari (W/m^2), suhu ($^{\circ}C$), kelembaban (%), kecepatan angin (mph) dan tutupan awan (%). Data target pelatihan merupakan daya keluaran fotovoltaik pada tanggal 1 Mei – 30 Mei 2024.

Data pengujian untuk input penelitian ini terdiri dari iradiasi sinar matahari (W/m^2), suhu ($^{\circ}C$), kelembaban (%) dan kecepatan angin (mph) dan tutupan awan (%). Data target pengujian adalah daya keluaran fotovoltaik pada tanggal 1 Juni – 30 Juni 2024. Data latih dan pengujian ini nantinya akan dilakukan dengan menggunakan rotasi putar, istilah ini biasanya merujuk pada teknik augmentasi data atau pengolahan data, di mana data yang ada diputar atau dimodifikasi untuk menciptakan variasi baru, sehingga data set memiliki peluang yang sama untuk mencapai target.

Tabel 2. Data Pelatihan

Tanggal	Data Input					Target
	Iradiasi (W/m^2)	Suhu ($^{\circ}C$)	Kelembaban (%)	Kecepatan angin (mph)	Tutupan Awan (%)	
01/05/2024	718,466	29,459	87,419	2,089	51,967	851,1
02/05/2024	497,764	31,042	87,235	1,677	57,496	557,816
03/05/2024	723,152	32,86	79,695	2,278	53,298	931,559
...
30/05/2024	495,558	34,465	86,193	2,291	75,256	971,59

Tabel 3. Data Pengujian

Tanggal	Data Input					Target
	Iradiasi (W/m^2)	Suhu ($^{\circ}C$)	Kelembaban (%)	Kecepatan angin (mph)	Tutupan Awan (%)	
01/06/2024	784,4	32,745	86,135	1,732	44,348	625,8

02/06/2024	552,29	29,125	81,605	1,313	47,149	845,181
03/06/2024	520,897	35,216	84,405	2,062	58,993	913,66
...
30/06/2024	656,182	35,801	92,443	2,351	64,541	660,956

2.3 Normalisasi Data

$$x^1 = \frac{0,8(x - a)}{b - a} + 0,1 \quad \dots\dots\dots(1)$$

Dimana:

x^1 = Hasil normalisasi dimana nilainya dari 0 - 1

x = Nilai yang akan dinormalisasi

a = Nilai terendah dari suatu data

b = Nilai tertinggi dari suatu data

Berdasarkan Tabel 2, data pada tanggal 1 Mei – 30 Mei 2024 setelah dilakukan normalisasi digunakan sebagai data latih, sedangkan data pada Tabel 3 pada tanggal 1 Juni – 30 Juni 2024 setelah dilakukan normalisasi digunakan untuk data uji. Pada data latih, nilai maksimum (b) latih adalah 976,1. Nilai minimum (a) adalah 1,038. Data dinormalisasi menggunakan Persamaan (1) fungsi sigmoid sebagai berikut:

$$x^1 = \frac{0,8(718,466 - 1,038)}{971,6 - 1,038} + 0,1 \quad \dots\dots\dots(2)$$

Persamaan 2 merupakan hasil normalisasi data latih pada iradiasi tanggal 1 Mei 2024 akan menjadi 0,691356671 dan seterusnya. Sedangkan untuk data uji, nilai maksimum (b) pengujian adalah 952,9. Sedangkan nilai minimum (a) adalah 1,006. Dengan menggunakan rumus yang sama, maka akan diperoleh data uji pada iradiasi tanggal 1 Juni 2024 yaitu 0,758404194 dan seterusnya hingga normalisasi selesai.

2.4 Pelatihan

Pada tahap pelatihan, model dilatih untuk meminimalkan nilai kesalahan sehingga model jaringan sesuai dan dapat digunakan untuk prediksi. Jika kinerja jaringan tidak sesuai harapan, bobot dan bias akan diatur ulang dan jaringan dilatih ulang hingga mencapai hasil yang memuaskan.

2.5 Pengujian

Pengujian pada model yang dibangun akan dilakukan simulasi untuk mengetahui hasil keakuratan, ketelitian dan nilai *output* dengan cara membandingkan data asli dengan data aktual. Apabila nilai *output* jaringan jauh dari target, maka proses akan diulang kembali dari perancangan arsitektur jaringan syaraf tiruan dan diinisialisasi ulang, kemudian jaringan dilatih kembali hingga nilai *Mean Square Error* (MSE) kecil. Sehingga diharapkan nilai prediksi dapat mendekati nilai aktual.

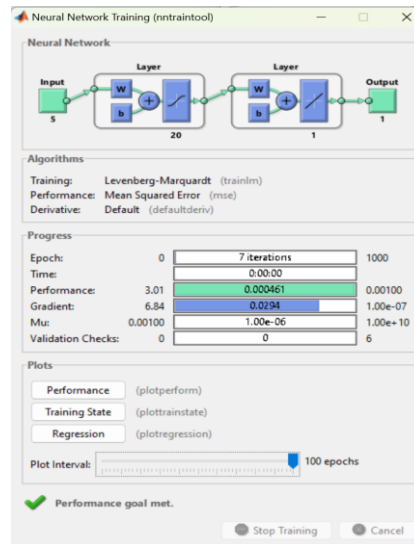
3. HASIL DAN PEMBAHASAN

3.1 Analisis

Pada penelitian ini digunakan 10 model arsitektur, antara lain: 4-8-1, 4-10-1, 4-12-1, 4-20-1, 4-36-1, 5-8-1, 5-10-1, 5-12-1, 5-20-1 dan 5-36-1. Model arsitektur jaringan ini menggunakan 1 *hidden layer*, *neuron input* = 4 dan 5, target *error* minimum 0,001. Sedangkan fungsi pelatihan yang digunakan adalah *trainlm*. *Hidden layer* menggunakan fungsi aktivasi sigmoid bipolar (*tansig*) dan *output* layer menggunakan fungsi aktivasi *purelin*.

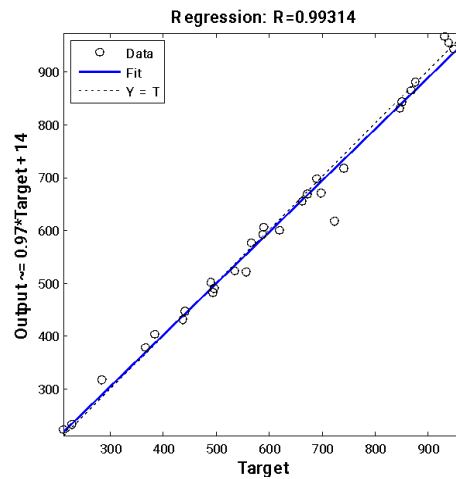
3.2 Hasil

Hasil pengolahan data pelatihan dan pengujian model arsitektur jaringan menggunakan fungsi sigmoid bipolar dan fungsi identitas linier ditunjukkan pada gambar berikut.



Gambar 4. Hasil Pelatihan Model 5-20-1

Gambar 4 merupakan hasil data pelatihan terbaik dengan model arsitektur 5-20-1 yang diperoleh menggunakan *software* Matlab. Nilai *mean squared error* (MSE) yaitu 0,00046146 dan proses pelatihan berhenti pada iterasi ke-7.



Gambar 5. Grafik Regresi Output dengan Target

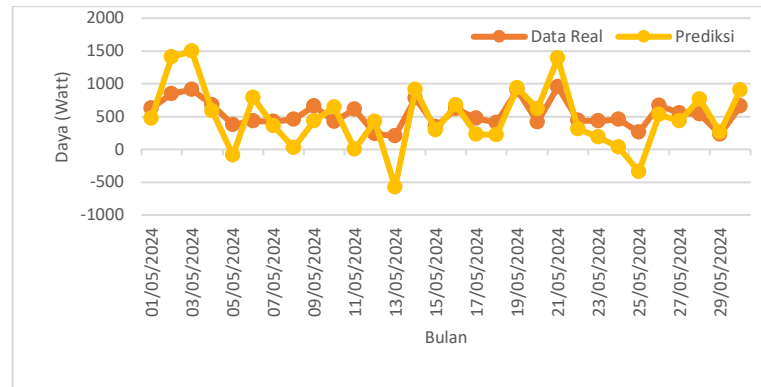
Gambar 5 menunjukkan hubungan antara target dengan *output* jaringan yang hampir sama. Dari *output* jaringan yang mendekati target, hal ini dapat dilihat dari garis diagonal fit yang hampir sama dengan titik data. Indikasi lainnya ditunjukkan oleh korelasi antara input dan target yang dilambangkan dengan koefisien regresi R sebesar 0,99314.

Tabel 4. Perbandingan model arsitektur jaringan

No	Arsitektur	Pelatihan		Pengujian	
		MSE	MSE	MSE	Akurasi
1	4-8-1	0,0009901	0,1373876		3%
2	4-10-1	0,0009815	0,4063223		7%
3	4-12-1	0,0009819	0,2119929		3%
4	4-20-1	0,0007910	0,3294513		0%
5	4-36-1	0,0003658	0,4569296		3%
6	5-8-1	0,0009665	0,3014244		7%
7	5-10-1	0,0008471	0,2309897		3%
8	5-12-1	0,0007244	0,5803602		3%
9	5-20-1	0,0004615	0,1711937		7%
10	5-36-1	0,0003374	0,3421871		3%

Hasil pelatihan dan pengujian akurasi dari 10 model arsitektur yang digunakan seperti yang disampaikan pada Tabel 4, perbandingan antara arsitektur *neuron input* 4 data latih tanpa tutupan awan terhadap *neuron input* 5 data latih yang menggunakan tutupan awan, menunjukkan perbedaan hasil nilai MSE yang didapat. MSE dengan *neuron input* 5 dari beberapa model cenderung lebih kecil. Arsitektur terbaik yaitu model 5-20-1 dengan tingkat akurasi mencapai 7% serta MSE iterasi sebesar 0,17119 dan epoch yang diperoleh sebanyak 7 iterasi. Model

ini menggunakan fungsi bipolar sigmoid dan fungsi identitas linier. Perbandingan ini menguatkan temuan yang dilakukan oleh (Khairunnisa, 2020) yang menyatakan bahwa penambahan parameter tutupan awan sebagai input terbukti meningkatkan akurasi model prediksi, karena tutupan awan dapat mengurangi intensitas radiasi matahari yang mencapai permukaan panel surya.



Grafik 1. Perbandingan hasil prediksi

Grafik 1 menunjukkan proses pelatihan dan pengujian yang telah dilakukan dengan menggunakan algoritma *backpropagation* dengan optimasi *trainlm*, diperoleh hasil perbandingan daya aktual dan daya prediksi. Hasil perbandingan data tersebut menunjukkan bahwa model dapat digunakan untuk melakukan prediksi. Dimana berguna untuk mengetahui daya keluaran fotovoltaik rata-rata yang akan diperoleh setiap harinya dalam 1 bulan.

4. KESIMPULAN

Hasil prediksi penelitian ini hampir mendekati nilai sebenarnya berdasarkan percobaan yang dilakukan dengan jaringan syaraf tiruan yang memanfaatkan pendekatan *backpropagation* dan analisis multi-faktor, namun masih diperlukan penelitian lebih lanjut agar hasil prediksi lebih baik lagi. Nilai MSE dengan *neuron input* 5 dari beberapa model cenderung lebih kecil dibanding dengan *neuron input* 4. Tingkat akurasi prediksi ini dipengaruhi dari variabel tutupan awan yang ditambahkan sebagai variabel *input* pada *neuron input*. Hal ini dibuktikan dengan hasil yang diperoleh nilai rata-rata MSE terkecil yang didapatkan dari model 5-20-1 sebesar 0,1711937. Faktor lainnya yang berpengaruh terhadap hasil prediksi yaitu model arsitektur jaringan yang dipilih. Untuk mengatasi keterbatasan ini, penelitian lanjutan perlu difokuskan pada pengembangan model JST yang lebih adaptif dan mampu mengintegrasikan berbagai faktor lingkungan secara lebih komprehensif. Misalnya, penggunaan JST berbasis *deep learning* atau *hybrid models*, yang mengombinasikan JST dengan algoritma pembelajaran lainnya, yang berpotensi meningkatkan performa prediksi.

UCAPAN TERIMA KASIH

Terimakasih kepada Ketua Sekolah Tinggi Teknologi Ronggolawe serta ketua LP3M yang telah memberikan pendanaan pelaksanaan kegiatan ini.

DAFTAR PUSTAKA

- Anggreni, R., Muliadi, & Adriat, R. (2018). Analisis Pengaruh Tutupan Awan Terhadap Radiasi Matahari di Kota Pontianak. *Prisma Fisika*, 6(3), 214–219. <https://doi.org/10.26418/pf.v6i3.28896>
- Catur Wijaya, F., Lestanti, S., & Faried Rahmat, M. (2023). Penerapan Metode Jst Backpropagation Pada Peramalan Produksi Pastry Di Hyfresh Blitar. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(4), 2629–2635. <https://doi.org/10.36040/jati.v7i4.7393>
- Dahliya, Samsurizal, & Pasra, N. (2021). Efisiensi Panel Surya Kapasitas 100 Wp Akibat Pengaruh Suhu Dan Kecepatan Angin. *Jurnal Ilmiah Sutet*, 11(2), 71–80. <https://doi.org/10.33322/sutet.v11i2.1551>
- Gu, L., Han, Y., Wang, C., Shu, G., Feng, J., & Wang, C. (2018). Inventory prediction based on backpropagation neural network. *NeuroQuantology*, 16(6), 664–673. <https://doi.org/10.14704/nq.2018.16.6.1608>
- Hao, S. (2018). *Using multifactor inputs BP neural network to make power consumption prediction* [Binghamton University]. <https://www.proquest.com/openview/88b031c5a6060e8e6a06a1aabc56b1ad/1?pq-origsite=gscholar&cbl=18750>
- Huang, D., & Wu, Z. (2017). Forecasting outpatient visits using empirical mode decomposition coupled with backpropagation artificial neural networks optimized by particle swarm optimization. *PLoS ONE*, 12(2), 1–17. <https://doi.org/10.1371/journal.pone.0172539>
- Johan, H., Utomo, N., & Wikrama Wardana, R. (2022). Pengaruh Temperatur Udara, Kelembaban Udara, Kecepatan Udara Dan Intensitas Cahaya Terhadap Daya Listrik Panel Surya. *Edu Fisika*, 7(1), 56–61.
- Khairunnisa. (2020). Prediksi Daya Pembangkit Listrik Pv Satu Hari Ke Depan Untuk Memudahkan Manajemen Energi Pada Sistem Menggunakan Neural Network [Institut Teknologi Sepuluh Nopember]. In A-13

- Repository.Its.Ac.Id. https://repository.its.ac.id/73445/1/07111850010003-Master_Thesis.pdf
- Khandakar, A., Chowdhury, M. E. H., Kazi, M. K., Benhmed, K., Touati, F., Al-Hitmi, M., & Gonzales, A. S. P. (2019). Machine Learning Based Photovoltaics (Pv) Power Prediction Using Different Environmental Parameters Of Qatar. *Energies*, 12(14). <https://doi.org/https://doi.org/10.3390/en12142782>
- Mahendra, L., Maknunah, J., Herwono, B., Anggraini, Y., & Nisa, K. (2021). Prediksi Daya Keluaran Pv Berbasis Jaringan Saraf Tiruan Pada Pusat Perbelanjaan Tangerang. In L. Mahendra (Ed.), *Conference on Innovation and Application of Science and Technology (CIASTECH 2021)* (Nomor Ciastech, hal. 335–342). Universitas Widyagama Malang. <https://publishing-widyagama.ac.id/ejournal-v2/index.php/ciastech/article/view/3327/1784>
- NurHidayat, T., Subodro, R., & Sutrisno. (2021). Analisis Output Daya Pada Pembangkit Listrik Tenaga Surya Dengan Kapasitas 10Wp, 20Wp Dan 30Wp. *jurnal CRANKSHAFT*, 4(2), 9–18. <https://doi.org/https://doi.org/10.24176/crankshaft.v4i2.6013>
- Putri, S. W., Marausna, G., & Prasetyo, E. E. (2022). Analisis Pengaruh Intensitas Cahaya Matahari Terhadap Daya Keluaran Pada Panel Surya. *Teknika STTKD*, 8(1), 29–37. <https://doi.org/https://doi.org/10.56521/teknika.v8i1>
- Shuvho, M. B. A., Chowdhury, M. A., Ahmed, S., & Kashem, M. A. (2019). Prediction of solar irradiation and performance evaluation of grid connected solar 80KWp PV plant in Bangladesh. *Energy Reports*, 5, 714–722. <https://doi.org/https://doi.org/10.1016/j.egy.2019.06.011>
- Simarmata, N. P. E., Estefani, Y., Bahri, B. S., & Sibarani, S. S. (2023). Penggunaan Energi Bersih Menggunakan Panel Surya Di India. *Jurnal Energi Baru dan Terbarukan*, 4(3), 274–284. <https://doi.org/10.14710/jebt.2023.21518>
- Utami, S., & Daud, A. (2021). Pengaruh Temperatur Panel Surya Terhadap Efisiensi Panel Surya. *Jurnal Teknik Energi*, 11(1), 7–10. <https://doi.org/10.35313/energi.v11i1.2437>