

PEMODELAN POTENSI ENERGI MATAHARI DENGAN MENGGUNAKAN JARINGAN SARAF TIRUAN (STUDI KASUS: INDONESIA)

ALIF SEPTIAN BAGASKORO¹, HARRY NUGROHO¹

¹Teknik Geodesi, Institut Teknologi Nasional Bandung
Email: Alif Septian Bagaskoro@mhs.itenas.ac.id

ABSTRAK

Penelitian ini bertujuan merancang model Jaringan Saraf Tiruan (JST) untuk memprediksi potensi energi matahari di Indonesia. Latar belakangnya diperkuat oleh pembangunan Pembangkit Listrik Tenaga Surya (PLTS), serta kendala kelangkaan data radiasi matahari. Model JST dihasilkan dengan menggunakan data input meliputi radiasi matahari global, suhu udara, kelembaban udara, durasi matahari harian, lintang, bujur, dan bulan dengan rentang tahun dari 1984 – 2019. Proses pelatihan menggunakan arsitektur Multilayer Perceptron dengan algoritma optimasi ADAM menghasilkan model terbaik dengan 20 neuron di hidden layer. Penerapan model pada tahun 2020 dan 2021 mengungkapkan fluktuasi potensi energi matahari nasional. Pulau Kalimantan tetap menonjol, sementara pola sebaran potensi energi matahari cenderung serupa setiap tahun. Potensi energi matahari nasional pada tahun 2020 dan 2021, dengan total potensi mencapai 827,70 GW dan 928,66 GW secara berturut-turut. Penerapan model pada tahun 2020 dan 2021 mengungkapkan fluktuasi potensi energi matahari nasional. Pulau Kalimantan tetap menonjol, sementara pola sebaran potensi energi matahari cenderung serupa setiap tahun. Penelitian ini diharapkan memberikan wawasan yang mendukung kebijakan berkelanjutan, dan membuka jalan bagi pengembangan infrastruktur energi matahari di Indonesia.

Kata kunci: Jaringan Saraf Tiruan, Radiasi Matahari Global

1. PENDAHULUAN

Sebagai negara kepulauan terbesar, Indonesia memiliki luas wilayah mencapai 7,81 juta km². Besarnya luas wilayah ini memiliki pengaruh terhadap tingginya populasi penduduk serta berdampak pada kebutuhan energi, termasuk kebutuhan akan sumber energi listrik. Saat ini, pasokan listrik di Indonesia masih didominasi dengan bahan bakar dari fosil (Fadlullah dkk., 2023). Tercatat penggunaan bahan bakar fosil sebagai pasokan listrik tahun 2018 sampai 2022 selalu mengalami kenaikan. Pada tahun 2022 penggunaan bahan bakar batubara sebesar 70 juta ton dan bahan bakar minyak 2 juta kilo liter (PT. PLN, 2023). Peningkatan penggunaan bahan bakar fosil dalam pembangkit listrik di Indonesia mengakibatkan intensitas emisi gas rumah kaca, khususnya emisi karbon (CO₂) yang berpotensi menyebabkan pemanasan global semakin meningkat (Basyiran, 2017).

Pemerintah Indonesia telah mengeluarkan Kebijakan Energi Nasional (KEN) dengan target penggunaan energi terbarukan sebesar 23% pada tahun 2025 (PP No. 79 Tahun 2014 tentang KEN). Salah satu fokusnya adalah pengembangan Pembangkit Listrik Tenaga Surya (PLTS) (RUEN). Data yang akurat mengenai radiasi matahari global sangat krusial dalam perencanaan

dan desain sistem konversi energi matahari, termasuk untuk mengembangkan PLTS. (Prastawa dkk., 2015). Di Indonesia, pengukuran radiasi matahari global dengan alat pynometer yang handal dan terkalibrasi masih belum tersedia secara luas atau hanya tersedia di lokasi yang terbatas (Rumbayan dkk., 2012). Oleh karena itu, untuk memperoleh data yang diperlukan mengenai radiasi matahari global, alternatif yang sangat penting adalah melalui teknik pemodelan dengan data meteorologi.

Penelitian-penelitian terdahulu di bidang pemodelan radiasi matahari global telah secara konsisten menunjukkan efektivitas model Jaringan Saraf Tiruan (JST) dalam memprediksi radiasi matahari. Dalam berbagai konteks geografis seperti Cina, Maroko, Turki, dan Libya, penerapan JST telah menghasilkan hasil yang mengesankan. Yingni Jiang (2009) mencatat bahwa model JST memiliki kesesuaian yang baik dengan data terukur dan bahkan lebih unggul dibandingkan dengan model empiris lainnya. Kutucu (2016) melakukan penelitian untuk memprediksi potensi tenaga surya di Libya menggunakan model jaringan syaraf tiruan multilayer. Penelitian ini mencakup berbagai variasi dalam topologi hidden layer dan jumlah neuron, serta menggunakan input dari data meteorologi dan geografis (garis bujur, garis lintang, dan ketinggian, bulan, durasi sinar matahari rata-rata, suhu rata-rata, dan kelembapan relatif). Data training (50%), validasi (25%), dan testing (25%) digunakan untuk melatih dan menguji model. Hasil penelitian menunjukkan bahwa model dengan lapisan tersembunyi tunggal yang memiliki 15 neuron dan dilatih dengan algoritma LM memberikan performa terbaik.

Secara keseluruhan, penelitian-penelitian terdahulu menunjukkan bahwa model JST memiliki potensi besar dalam memprediksi radiasi matahari global dengan akurasi yang tinggi. Penelitian ini bertujuan untuk membuat model potensi energi matahari di Indonesia dengan memanfaatkan hasil dari model jaringan saraf tiruan (JST). Model JST akan disusun dengan berbagai skenario untuk memperoleh model yang optimal. Hasil akhir dari penelitian ini akan memberikan informasi distribusi potensi energi matahari secara spasial di Indonesia.2. metodologi

1. METODOLOGI

2.1 Penentuan Titik Sampling

Pada tahap awal penelitian, jumlah titik sampling data yang diperlukan untuk membangun model Jaringan Saraf Tiruan (JST) yang dapat mengestimasi radiasi matahari global di seluruh wilayah Indonesia akan ditentukan. Metode simple random sampling akan digunakan untuk memastikan distribusi titik lokasi secara merata di seluruh wilayah Indonesia dengan pendekatan grid berdasarkan resolusi data NASA, yaitu setiap 1° lintang dan 1° bujur. Grid ini akan dibuat menggunakan tool "create grid" dalam perangkat lunak QGIS, menghasilkan grid dengan titik tengah pada setiap grid, yang mencakup seluruh wilayah Indonesia dengan jumlah titik sampling sebanyak 152 titik. Selanjutnya, titik sampling akan dibagi menjadi dua kelompok seimbang, yaitu 50% untuk titik model yang digunakan dalam pembuatan model, dan 50% untuk titik prediksi yang akan digunakan untuk melakukan estimasi radiasi matahari global. Dengan pembagian ini, terdapat 76 titik lokasi sampling untuk data model dan 76 titik untuk data prediksi.

2.2 Pengumpulan Data

Proses pengumpulan data dilakukan melalui layanan NASA Power Project dengan menggunakan Application Programming Interfaces (API). Data yang berhasil dihimpun terbagi menjadi dua kelompok, yakni data model dan data prediksi, yang mencakup informasi seperti suhu rata-rata, kelembapan relatif, durasi penyinaran matahari rata-rata, radiasi matahari

global, serta parameter geografis seperti lintang, bujur, ketinggian, dan bulan. Rentang waktu pengumpulan data berlaku mulai dari tahun 1984 hingga 2021 dan didasarkan pada titik model untuk data model serta titik prediksi untuk data prediksi sesuai dengan tahapan penentuan titik sampling sebelumnya. Proses permintaan API dimulai dengan impor pustaka "requests," yang digunakan untuk menjalankan permintaan melalui protokol HTTP. Skrip kemudian memproses setiap pasangan nilai lintang dan bujur yang telah ditentukan dalam daftar koordinat, membangun URL yang ditujukan ke API NASA POWER Project, dan melakukan permintaan HTTP GET. Respons dari server dianalisis untuk memeriksa keberhasilan permintaan, dan data yang diterima dalam format CSV disimpan dengan nama file sesuai dengan koordinat titik yang bersangkutan. Dalam kasus hambatan saat berinteraksi dengan API, skrip akan mencatat pesan mengenai masalah yang muncul, serta mencetak informasi terkait status kode respons dan isi respons dari server, sehingga memberikan pemahaman yang lebih mendalam mengenai hasil respons yang diperoleh dari API.

2.3 Proses Pembuatan Model

Tahapan pembuatan model bertujuan untuk menghasilkan model JST optimal. Proses pembuatan model akan dilakukan dengan menggunakan software MATLAB. Proses pembuatan model terdiri dari tahapan preprocessing, proses pelatihan, proses uji, pemilihan model JST. Pada tahap preprocessing, data model dinormalisasi menggunakan metode Min-Max untuk mengubah skala data menjadi rentang antara 0.1 hingga 0.9. Selanjutnya, data input dan target dipilih dari data model, yang terdiri dari suhu rata-rata, kelembapan relatif, durasi penyinaran matahari rata-rata, lintang, bujur, ketinggian, dan bulan. Data ini dibagi menjadi tiga subset yang berbeda untuk keperluan pelatihan, validasi, dan pengujian model, dengan proporsi data pelatihan sebesar 50%, data validasi sebesar 25%, dan data pengujian sebesar 25%.

Proses pelatihan merupakan tahapan di mana model JST belajar dari data pelatihan untuk mengoptimalkan bobot dan bias pada setiap neuron dalam jaringan. Model JST menggunakan arsitektur Multilayer Perceptron (MLP) yang terdiri dari input layer, hidden layer, dan output layer. Proses pelatihan melibatkan eksperimen dengan jumlah neuron dalam hidden layer yang 5 hingga 20 dengan interval 5. Fungsi aktivasi relu digunakan pada input layer ke hidden layer, dan purelin digunakan pada hidden layer ke output layer. Proses pelatihan berhenti jika terpenuhi salah satu dari dua kondisi, yaitu jika nilai validation performance check lebih besar dari 6 atau jika jumlah epoch mencapai batas 1000. Proses pelatihan menggunakan algoritma ADAM untuk memperbaiki nilai bobot dan bias pada setiap pelatihannya.

Proses uji model dilakukan setelah melatih model JST dan menguji kemampuannya menggunakan data uji. Tujuan dari proses ini adalah untuk mengukur sejauh mana model yang telah dilatih mampu melakukan prediksi yang akurat terhadap data yang belum pernah dilihat sebelumnya. Proses uji melibatkan penghitungan Mean Absolute Percentage Error (MAPE) sebagai metrik evaluasi model. Terdapat 8 model terlatih berdasarkan jumlah neuron pada hidden layer, dan model dengan MAPE terendah dianggap sebagai model JST optimal yang akan digunakan untuk proses prediksi.

2.4 Proses Prediksi

Setelah mendapatkan model JST optimal melalui proses pelatihan, langkah selanjutnya adalah melakukan prediksi radiasi matahari global dari data prediksi yang telah dinormalisasi dengan metode Min-Max. Proses feedforward mengirimkan data prediksi ke model JST optimal, yang menghasilkan prediksi radiasi matahari global. Setelah itu, dilakukan denormalisasi untuk mengembalikan nilai prediksi ke dalam skala aslinya dengan metode Min-Max dengan rentang 0.1 – 0.9.

2.4 Proses Visualisasi Model Prediksi

Setelah mendapatkan nilai prediksi radiasi matahari global dari data prediksi, langkah selanjutnya adalah mengintegrasikannya ke dalam bentuk peta yang akan disajikan berdasarkan bulan. Proses ini dimulai dengan *plotting* data prediksi radiasi matahari global ke aplikasi QGIS. Dalam QGIS, data tersebut dimasukan dan ditampilkan dalam bentuk peta. Setelah itu, dilakukan proses interpolasi data menggunakan metode IDW dengan menggunakan titik-titik yang berisi nilai prediksi radiasi matahari global. Metode IDW ini membantu menghasilkan perkiraan kepadatan radiasi matahari global di seluruh wilayah, termasuk di lokasi yang tidak memiliki data prediksi. Hasil interpolasi tersebut ditampilkan dalam bentuk peta yang disesuaikan untuk setiap bulan.

2.5 Estimasi Rata- Rata Total Energi Tahunan untuk Setiap Provinsi

Data radiasi matahari global bulanan yang telah dihasilkan melalui IDW digunakan untuk mengestimasi potensi energi matahari setiap tahun di masing-masing provinsi, disajikan dalam satuan GW. Langkah ini memberikan gambaran konkret mengenai potensi energi matahari yang dapat dimanfaatkan di setiap provinsi Indonesia. Selain itu, integrasi hasil prediksi radiasi matahari dengan informasi geografis provinsi bertujuan mendukung perencanaan energi terbarukan yang berkelanjutan. Keseluruhan, bab ini memberikan kontribusi dalam menyediakan pemahaman yang lebih mendalam tentang potensi energi matahari di Indonesia dan dapat menjadi landasan untuk pengembangan strategi energi terbarukan yang efektif.

3. HASIL

3.1 Evaluasi Model JST

Terdapat lima model JST yang dihasilkan dari proses pelatihan, dengan jumlah neuron di hidden layer yang berbeda, mulai dari 5 hingga 40 dengan interval 5 neuron. Model-model ini kemudian dievaluasi menggunakan data uji, dan hasil evaluasi ditunjukkan pada Tabel 1 di bawah ini:

Tabel 1. Evaluasi Model JST pada Data Uji


Model JST	Jumlah Neuron Hidden Layer	MAPE
Model 1	5	5.95%
Model 2	10	5.88%
Model 3	15	5.89%
Model 4	20	5.54%

Tabel 1 menunjukkan hasil evaluasi performa kelima model JST pada data uji, diukur dengan Mean Absolute Percentage Error (MAPE). MAPE adalah metrik yang mengukur sejauh mana prediksi model mendekati nilai aktual. Semakin kecil nilai MAPE, semakin baik performa model dalam memprediksi data uji.

Dari hasil evaluasi tersebut, dapat disimpulkan bahwa Model 4, yang memiliki 20 neuron di hidden layer, menunjukkan MAPE uji terendah sebesar 5.54%. Hal ini mengindikasikan bahwa Model 5 adalah model JST yang paling optimal, mampu memberikan prediksi radiasi matahari global paling akurat berdasarkan data uji. Oleh karena itu, Model 5 dipilih sebagai model yang akan digunakan dalam proses prediksi radiasi matahari global di wilayah Indonesia. Model ini memiliki tingkat akurasi yang tinggi dan akan menjadi alat yang sangat berguna dalam perencanaan dan pengembangan energi terbarukan di Indonesia.


3.2 Potensi Energi Matahari

Hasil prediksi radiasi matahari global model JST terbaik pada tahun 2020 disajikan dalam sebuah model seperti pada lampiran 1. Pada gambar tersebut merupakan hasil interpolasi dengan metode *Inverse Distance Weighted (IDW)*. Interpolasi ini bertujuan untuk menyusun model potensi matahari di seluruh wilayah Indonesia perbulan pada tahun 2020 dan 2021. Model tersebut memiliki nilai kepadatan radiasi matahari dalam satuan W/m^2 . Berdasarkan gambar 4.2 pola dari hasil pemodelan pada tahun 2020 dan 2021 terjadi peningkatan yang signifikan di bulan Agustus pada Indonesia bagian selatan seperti Pulau Jawa dan Kepulauan Nusa Tenggara. Mulai dari bulan Agustus sampai Bulan Oktober pola peningkatannya bergerak ke arah Timur Indonesia.



Gambar 4. 1 Pemodelan Radiasi Matahari Global daerah Jawa dan Nusa Tenggara

Berdasarkan analisis gambar 4.4, dapat disimpulkan bahwa selama periode bulan November hingga Desember pada tahun 2020 dan 2021, Pulau Sumatera bagian utara menunjukkan tingkat radiasi matahari yang lebih rendah daripada daerah-daerah di Indonesia bagian timur, seperti Papua. Perbedaan ini mencerminkan variasi intensitas sinar matahari antar wilayah tersebut selama dua tahun berturut-turut.



Gambar 4. 2 Pemodelan Radiasi Matahari Global daerah Jawa dan Papua

Nilai kepadatan pada model merepresentasikan intensitas matahari yang diterima di masing-masing provinsi. Selanjutnya, luas wilayah provinsi menjadi faktor penentu penting dalam mengukur potensi energi matahari yang dapat dihasilkan. Dengan mengalikan nilai kepadatan radiasi dengan luas wilayah, dapat mengestimasi total ener Hasil perhitungan tersebut disajikan pada gambar di lampiran 3 dan tabel 4.2 yang merupakan data potensi energi matahari tahun 2020 sedangkan untuk tahun 2021 disajikan pada tabel 4.3

Tabel 1 Potensi Energi Matahari tahun 2020

No	Provinsi	GW	No	Provinsi	GW
1	Kalimantan Tengah	77,19	20	Sumatera Barat	34,37
2	Kalimantan Barat	72,56	21	Jawa Barat	16,25
3	Kalimantan Timur	63,19	22	Jawa Tengah	14,53
4	Papua Selatan	31,84	23	Papua Barat Daya	9,37
5	Riau	30,60	24	Kalimantan Selatan	14,57
6	Sumatera Selatan	75,05	25	Sulawesi Tenggara	9,43
7	Papua	25,87	26	Lampung	9,38
8	Kalimantan Utara	35,21	27	Maluku Utara	9,06
9	Sumatera Utara	51,31	28	Nusa Tenggara Barat	5,72
10	Sulawesi Tengah	28,53	29	Bengkulu	8,20
11	Papua Barat	18,94	30	Sulawesi Barat	5,79
12	Papua Tengah	15,57	31	Kepulauan Bangka Belitung	2,85
13	Papua Pegunungan	15,89	32	Sulawesi Utara	3,94
14	Aceh	63,52	33	Gorontalo	2,18
15	Jawa Timur	20,53	34	Banten	1,84
16	Jambi	4,86	35	Kepulauan Riau	1,05
17	Nusa Tenggara Timur	13,64	36	Bali	0,65
18	Sulawesi Selatan	20,68	37	Daerah Istimewa Yogyakarta	1,27
19	Maluku	12,24	38	DKI Jakarta	0,03
Total Potensi Energi Matahari Indonesia Tahun 2020					
827,70 GW					

Berdasarkan analisis pada tabel 4.2, Hasil pemodelan tersebut mencatat total potensi energi matahari nasional pada tahun 2020 sebesar 827,70 GW, memunculkan pola dan dinamika yang mencerminkan keragaman potensi energi terbarukan di seluruh negeri. Pulau Kalimantan menjadi fokus utama dengan Kalimantan Tengah sebagai provinsi dengan potensi tertinggi, mencapai 77,19 GW. Pemodelan JST juga menyoroti kontribusi signifikan dari Kalimantan Barat dan Kalimantan Timur, menggambarkan potensi energi matahari yang besar di wilayah tersebut.

Sumatera, sebagai pulau terbesar di Indonesia, menunjukkan potensi energi matahari sebesar 226,93 GW pada tahun 2020. Provinsi Riau menonjol sebagai yang memiliki potensi tertinggi di Sumatera, menandakan variasi potensi yang signifikan di pulau ini. Pulau Jawa, yang memiliki kepadatan penduduk tinggi, mencatat total potensi energi matahari sebesar 89,15 GW pada tahun 2020. Jawa Timur menjadi provinsi dengan potensi tertinggi di pulau ini, sementara DKI Jakarta, sebagai wilayah administratif utama, menunjukkan potensi terendah sepanjang tahun tersebut dengan hanya 0,03 GW.

Selain itu, kepulauan Nusa Tenggara, Sulawesi, Maluku, dan Papua juga menunjukkan variasi yang signifikan dalam potensi energi matahari mereka, memberikan wawasan mendalam tentang keragaman potensi energi terbarukan di Indonesia.

Tabel 4. 2 Potensi Energi Matahari 2021

No	Provinsi	GW	No	Provinsi	GW
1	Kalimantan Tengah	76,05	20	Sumatera Barat	19,65
2	Kalimantan Barat	71,73	21	Jawa Barat	18,95
3	Kalimantan Timur	61,74	22	Jawa Tengah	18,38

4	Papua Selatan	56,56	23	Papua Barat Daya	18,14
5	Riau	42,94	24	Kalimantan Selatan	18,13
6	Sumatera Selatan	42,41	25	Sulawesi Tenggara	17,16
7	Papua	41,09	26	Lampung	16,93
8	Kalimantan Utara	34,69	27	Maluku Utara	15,48
9	Sumatera Utara	33,98	28	NTB	9,81
10	Sulawesi Tengah	32,01	29	Bengkulu	9,77
11	Papua Barat	30,01	30	Sulawesi Barat	8,32
12	Papua Tengah	28,78	31	Kepulauan Bangka Belitung	8,3
13	Papua Pegunungan	27,76	32	Sulawesi Utara	7,26
14	Aceh	26,35	33	Gorontalo	6,08
15	Jawa Timur	25,6	34	Banten	4,73
16	Jambi	23,85	35	Kepulauan Riau	3,07
17	NTT	23,51	36	Bali	2,71
18	Sulawesi Selatan	23,33	37	DI Yogyakarta	1,6
19	Maluku	21,41	38	DKI Jakarta	0,39
Total Potensi Energi Matahari Indonesia Tahun 2021					
928,66 GW					

Berdasarkan tabel 4.3 Kalimantan Tengah, sebagai provinsi dengan potensi tertinggi, mencatatkan 76,05 GW pada tahun 2021. Sementara itu, Sumatera Barat muncul sebagai sorotan pada tahun ini, menjadi provinsi dengan potensi tertinggi di pulau Sumatera dengan nilai mencapai 19,65 GW. Pemodelan JST memperlihatkan dinamika distribusi potensi yang terus berubah di berbagai wilayah di Indonesia.

Pulau Jawa, dengan total potensi energi matahari sebesar 75,93 GW pada tahun 2021, menunjukkan Jawa Barat sebagai provinsi dengan potensi tertinggi. Meskipun demikian, DKI Jakarta tetap memiliki potensi terendah, mencapai 0,39 GW, menunjukkan tantangan dalam pengembangan energi matahari di kawasan perkotaan. Pulau-pulau lainnya, termasuk Sulawesi, Maluku, dan Papua, juga memberikan kontribusi yang signifikan terhadap potensi energi matahari nasional pada tahun 2021, mencerminkan keragaman dan potensi yang luas di seluruh negeri.

Dalam melihat perbandingan antara tahun 2020 dan 2021, terdapat perubahan yang signifikan dalam hasil pemodelan JST. Total potensi energi matahari nasional mengalami peningkatan sebesar 100,96 GW. Kalimantan Tengah, meskipun tetap menjadi provinsi dengan potensi tertinggi di kedua tahun, mengalami penurunan potensi dari 77,19 GW pada tahun 2020 menjadi 76,05 GW pada tahun 2021. Sementara itu, Sumatera Barat mengalami lonjakan signifikan dari 34,37 GW pada tahun 2020 menjadi 19,65 GW pada tahun 2021, menjadikannya provinsi dengan potensi tertinggi pada tahun terakhir. DKI Jakarta, sebagai provinsi dengan potensi terendah di kedua tahun, mengalami peningkatan dari 0,03 GW pada tahun 2020 menjadi 0,39 GW pada tahun 2021, meskipun tetap menjadi yang terendah.

Dengan potensi energi matahari sebesar 928,66 GW pada tahun 2021, Indonesia memiliki peluang besar untuk memanfaatkannya secara maksimal. Meskipun terdapat target ambisius pembangunan Pembangkit Listrik Tenaga Surya (PLTS) sebesar 6,5 GW pada tahun 2025 menurut Rencana Umum Energi Nasional (RUEN), potensi yang melimpah ini menunjukkan bahwa Indonesia memiliki landasan yang kuat untuk mencapai dan bahkan melampaui target

tersebut. Maksimalnya pemanfaatan potensi ini dapat memberikan kontribusi besar dalam mendiversifikasi sumber energi, mengurangi emisi karbon, dan menciptakan keberlanjutan dalam sektor energi. Oleh karena itu, akselerasi dalam pengembangan PLTS menjadi krusial untuk membawa Indonesia menuju masa depan yang lebih hijau dan berdaya energi terbarukan.

4. KESIMPULAN

Kesimpulan dari penelitian berjudul "Pemodelan Potensi Energi Matahari dengan Menggunakan Metode Jaringan Saraf Tiruan (Studi Kasus: Indonesia)" ini yaitu

1. Evaluasi model menunjukkan bahwa kinerja model Jaringan Saraf Tiruan (JST) mencapai puncak optimal ketika menggunakan 20 neuron di *hidden layer*. Konfigurasi ini berhasil memberikan tingkat akurasi yang tinggi dalam memprediksi tingkat radiasi matahari global bulanan. Dengan kata lain, penggunaan 20 neuron di *hidden layer* dapat dianggap sebagai pilihan yang efektif untuk mendapatkan hasil prediksi yang akurat terkait dengan radiasi matahari di berbagai bulan.
2. Aplikasi model JST pada penelitian ini memberikan pemahaman yang mendalam terhadap potensi energi matahari di seluruh Indonesia, khususnya pada tahun 2020 dan 2021. Hasil analisis menunjukkan fluktuasi potensi energi matahari nasional, dengan total mencapai 827,70 GW pada tahun 2020 dan 928,66 GW pada tahun 2021. Provinsi Kalimantan Tengah, dengan potensi terbesar, memberikan kontribusi signifikan terhadap total potensi energi matahari nasional. Dengan demikian, penelitian ini tidak hanya berhasil mencapai tujuan pengembangan model JST, tetapi juga memberikan gambaran menyeluruh terkait potensi energi matahari di Indonesia.

DAFTAR RUJUKAN

- Ağbulut, Ü., Gürel, A. E., dan Biçen, Y. (2021). Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 135, 110114. <https://doi.org/10.1016/j.rser.2020.110114>
- Ahsan, M. (2021). Tantangan dan Peluang Pembangunan Proyek Pembangkit Listrik Energi Terbarukan (EBT) di Indonesia. *Sutet*, 11(2), 81–93. <https://doi.org/10.33322/sutet.v11i2.1575>
- Bamehr, S., dan Sabetghadam, S. (2021). Estimation of global solar radiation data based on satellite-derived atmospheric parameters over the urban area of Mashhad, Iran. *Environmental Science and Pollution Research*, 28(6), 7167–7179. <https://doi.org/10.1007/s11356-020-11003-8>

- Basyiran, T. B. (2017). Konsumsi Energi Listrik , Pertumbuhan Ekonomi dan Penduduk terhadap Emisi Gas Rumah Kaca Pembangkit Listrik di Indonesia Konsumsi Energi Listrik , Pertumbuhan Ekonomi dan Penduduk terhadap Emisi Gas Rumah Kaca Pembangkit Listrik di Indonesia 1 Semua bahan. May. <https://doi.org/10.13140/RG.2.2.22056.06401>
- Fadlullah, Y. A., dan Setiyawan, B. P. (2023). RANCANG BANGUN PEMBANGKIT LISTRIK TURBINEMINIHYDRO SEBAGAI SUMBER ENERGI RAMAH LINGKUNGAN. 02(05), 314–323.
- Gencay, R., dan Min Qi. (2001). Pricing and hedging derivative securities with neural networks: Bayesian regularization, early stopping, and bagging. *IEEE Transactions on Neural Networks*, 12(4), 726–734. <https://doi.org/10.1109/72.935086>
- Goodfellow, I., Bengio, Y., dan Courville, A. (2016). Deep Learning.
- Hamdi, S. (2013). MENGENAL LAMA PENYINARAN MATAHARI SEBAGAI SALAH SATU PARAMETER KLIMATOLOGI. 7–16.
- Harsanti, E. N., Furqon, M. T., dan Adikara, P. P. (2018). Prediksi Nilai Harga Patokan Batu Bara (HPB) Untuk Merek Dagang Gunung Bayan I dengan Metode Extreme Learning Machine (ELM). ... *Teknologi Informasi dan Ilmu ...*, 2(12), 6527–6534. <http://jptiik.ub.ac.id/index.php/j-ptiik/article/view/3646>
- Haykin, S. (2005). *Neural Networks A Comprehensive Foundation* (hal. 823).FTSP Series : Seminar Nasional dan Diseminasi Tugas Akhir 2021
- Hermawan, A. (2006). Jaringan Saraf Tiruan (Teori dan Aplikasinya).
- Jiang, Y. (2009). Computation of monthly mean daily global solar radiation in China using artificial neural networks and comparison with other empirical models. *Energy*, 34(9), 1276–1283. <https://doi.org/10.1016/j.energy.2009.05.009>
- Kingma, D. P., dan Ba, J. (2014). Adam: A Method for Stochastic Optimization. <http://arxiv.org/abs/1412.6980>
- Ku, C.-S., Khaw, M., dan Chia, K. S. (2007). Comment on: Chang et al. (2007) Association Study of the Genetic Polymorphisms of the Transcription Factor 7-like 2 (TCF7L2) Gene and Type 2 Diabetes in the Chinese Population: *Diabetes* 56:2631–2637. *Diabetes*, 56(12), e22–e22. <https://doi.org/10.2337/db07-1213>
- Kusuma, D., Murdimanto, A., Sukresno, B., dan Jatisworo, D. (2018). Comparison of interpolation methods for sea surface temperature data D. *JFMR-Journal of Fisheries and Marine Research*, 2(2), 103–115. <https://doi.org/10.21776/ub.jfmr.2018.002.02.7>
- McCulloch, W. S., dan Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- Prastawa, A., dan Rinaldy, D. (2015). parameter klimatologi sebagai prediktor model prediksi potensi energi surya.pdf.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Rumbayan, M., dan Nagasaka, K. (2012). Mapping of solar energy potential in Indonesia using artificial neural network and geographical information system. June 2023. <https://doi.org/10.1016/j.rser.2011.11.024>
- Rumelhart, D. E., Hinton, G. E., dan Williams, R. J. (1986). Learning representations by backpropagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>

- Sharma, S., Sharma, S., dan Athaiya, A. (2020). Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 310–316. <https://doi.org/10.33564/ijeast.2020.v04i12.054>
- Singh, J., dan Banerjee, R. (2019). A Study on Single and Multi-layer Perceptron Neural Network. *2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)*, 35–40. <https://doi.org/10.1109/ICCMC.2019.8819775>
- Sukarno, N. M., Wirawan, P. W., dan Adhy, S. (2015). Perancangan Dan Implementasi Jaringan Saraf Tiruan Backpropagation Untuk Mendiagnosa Penyakit Kulit. *Jurnal Masyarakat Informatika*, 5(10), 9–18. <https://doi.org/10.14710/jmasif.5.10.9-18>
- Taud, H., dan Mas, J. F. (2018). Multilayer Perceptron (MLP) (hal. 451–455). https://doi.org/10.1007/978-3-319-60801-3_27
- Wu, Y.-H. (Eva), dan Hung, M.-C. (2016). Comparison of Spatial Interpolation Techniques Using Visualization and Quantitative Assessment. In *Applications of Spatial Statistics*. InTech. <https://doi.org/10.5772/65996>
- Yanto, M., Sovia, R., dan Wiyata, P. (2018). Sistem Irigasi Lahan Pertanian di Kabupaten Pesisir Selatan. *Sebatik*, 111–115.
- Zaim, S., El Ibrahimy, M., Arbaoui, A., Samaouali, A., Tlemcani, M., dan Barhdadi, A. (2023). Using artificial intelligence for global solar radiation m