

Optimasi Prediksi Kecepatan Angin Harian dengan Jaringan Saraf Tiruan: Implementasi pada Jalur Maritim Gresik–Bawean

Muhammad Imamul Khoiri, Sri Harini*, and Achmad Nashichuddin

Program Studi Matematika Fakultas Sains dan teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang

Abstrak

Penelitian ini memodelkan kecepatan angin harian pada jalur penyeberangan Gresik–Bawean periode Desember 2020 hingga November 2023 menggunakan Jaringan Saraf Tiruan (JST) dengan algoritma backpropagation. Data yang digunakan meliputi kecepatan angin, tinggi gelombang rata-rata, panjang gelombang, periode gelombang, dan tinggi maksimum gelombang. Model dievaluasi dengan skema *walk-forward validation* dan dibandingkan dengan model baseline seperti *persistence* dan SARIMA. Kinerja diukur menggunakan metrik MAE, RMSE, sMAPE, dan MASE dengan interval kepercayaan bootstrap, serta pengujian signifikansi menggunakan uji Diebold–Mariano. Hasil menunjukkan bahwa arsitektur terbaik JST (5–3–2–1) mampu menurunkan RMSE secara signifikan dibandingkan baseline ($p < 0.05$), dengan nilai MAE sebesar 1.87, RMSE 2.41, sMAPE 15.8%, dan MASE 0.92 pada data uji Juli–November 2023. Prediksi out-of-sample untuk Desember 2023 hingga Januari 2024 memperlihatkan kondisi angin relatif stabil tanpa indikasi gelombang ekstrem, meskipun model masih kesulitan menangkap lonjakan tajam musiman. Temuan ini menegaskan bahwa JST dapat digunakan sebagai alat bantu prediksi untuk mendukung mitigasi risiko dan keselamatan pelayaran, dengan catatan perlunya integrasi variabel eksogen tambahan (curah hujan, indeks iklim) untuk meningkatkan generalisasi.

Kata Kunci: Prediksi, Kecepatan Angin, Jaringan Saraf Tiruan, *Backpropagation*.

Abstract

This study models daily wind speed along the Gresik–Bawean ferry route from December 2020 to November 2023 using an Artificial Neural Network (ANN) with the backpropagation algorithm. The dataset includes wind speed, average wave height, wavelength, wave period, and maximum wave height. The model was evaluated using a walk-forward validation scheme and compared against baseline models such as persistence and SARIMA. Performance was assessed with MAE, RMSE, sMAPE, and MASE metrics with bootstrap confidence intervals, and significance was tested using the Diebold–Mariano test. Results show that the best ANN architecture (5–3–2–1) significantly reduced RMSE compared to baselines ($p < 0.05$), achieving MAE of 1.87, RMSE of 2.41, sMAPE of 15.8%, and MASE of 0.92 on the July–November 2023 test set. Out-of-sample forecasts for December 2023 to January 2024 indicated relatively stable wind conditions with no signs of extreme wave events, although the model struggled to capture sharp seasonal spikes. These findings highlight that ANN can serve as a predictive tool to support maritime safety and risk mitigation, while future improvements should integrate additional exogenous variables (rainfall, climate indices) to enhance generalization.

Keywords: Prediction, Wind Speed, Artificial Neural Network, Backpropagation.

Copyright © 2025 by Authors, Published by JRMM Group. This is an open access article under the CC BY-SA License (<https://creativecommons.org/licenses/by-sa/4.0>)

*Corresponding author. E-mail: sriharini@mat.uin-malang.ac.id

1 Pendahuluan

Indonesia merupakan negara kepulauan dengan dua pertiga wilayahnya berupa perairan, sehingga transportasi laut memiliki peran vital sebagai penghubung antarpulau dan penopang kegiatan ekonomi [1]. Salah satu jalur strategis adalah penyeberangan kapal Gresik–Bawean, yang sering dipengaruhi kondisi cuaca ekstrem seperti angin kencang dan gelombang tinggi [2]. Fluktuasi kecepatan angin berdampak signifikan terhadap pembentukan gelombang laut [3] dan keselamatan pelayaran [4]. Oleh karena itu, prediksi kecepatan angin menjadi kebutuhan penting dalam mitigasi risiko transportasi laut.

Kajian prediksi kecepatan angin di Indonesia sebagian besar masih mengandalkan metode statistik klasik seperti ARIMA atau SARIMA, yang efektif untuk pola linier namun kurang optimal dalam menangkap dinamika nonlinier, efek musiman, serta interaksi antar variabel oseanografi [5]. Seiring berkembangnya *machine learning*, Jaringan Saraf Tiruan (JST) dengan algoritma backpropagation menjadi alternatif yang lebih fleksibel karena mampu mengenali pola kompleks dan hubungan nonlinier pada data deret waktu [6]. Metode ini juga terbukti efektif di berbagai domain lain, misalnya pada penilaian tingkat kerusakan bangunan pascabencana menggunakan prediksi JST backpropagation [7]. Lebih lanjut, performa JST dapat ditingkatkan melalui integrasi metode optimasi heuristik, misalnya Particle Swarm Optimization (PSO), sebagaimana ditunjukkan dalam klasifikasi radar [8]. Sejumlah penelitian lain juga membuktikan keberhasilan JST dalam berbagai konteks, misalnya prediksi konsumsi energi [9], harga komoditas [10], nilai tukar petani [11], dan nilai impor [12]. Namun, penerapannya untuk prediksi angin laut di jalur penyeberangan domestik masih jarang diteliti secara sistematis.

Gap penelitian yang diidentifikasi adalah sebagai berikut. Pertama, studi prediksi angin laut di jalur pelayaran Indonesia umumnya belum mengintegrasikan variabel oseanografi (seperti tinggi gelombang, panjang gelombang, dan periode gelombang) sebagai prediktor. Kedua, validasi model sering menggunakan pembagian data acak yang berisiko *data leakage*, sementara evaluasi berbasis waktu (*time-series split*) masih jarang digunakan. Ketiga, sedikit penelitian yang membandingkan performa JST dengan model baseline sederhana (misalnya *persistence* atau SARIMA), sehingga belum jelas keunggulan nyata JST dalam konteks prediksi angin laut. Keempat, aspek praktis seperti pengelompokan hasil prediksi ke dalam kategori Skala Beaufort untuk mendukung interpretasi maritim belum banyak dieksplorasi.

Berdasarkan hal tersebut, penelitian ini memiliki tiga tujuan utama: (1) mengembangkan model JST berbasis backpropagation untuk memprediksi kecepatan angin harian pada jalur penyeberangan Gresik–Bawean, (2) membandingkan performa JST dengan baseline model statistik melalui evaluasi berbasis *walk-forward validation*, dan (3) mengklasifikasikan kondisi angin laut hasil prediksi ke dalam kategori Skala Beaufort sebagai dasar informasi praktis bagi pemangku kepentingan.

Adapun struktur paper ini adalah sebagai berikut. Bagian 2 menjelaskan metodologi penelitian, termasuk jenis data, variabel, dan tahapan analisis. Bagian 3 menyajikan hasil eksperimen dan pembahasan performa model. Bagian terakhir memuat kesimpulan serta saran untuk penelitian mendatang.

2 Metode Penelitian

Bagian ini menjelaskan rancangan penelitian yang dilakukan, mulai dari pendekatan yang digunakan, data dan sumbernya, hingga teknik analisis yang diterapkan. Uraian ini disusun agar proses penelitian dapat direplikasi secara sistematis.

2.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif karena berfokus pada analisis data numerik secara sistematis dan objektif melalui metode statistik. Kajian literatur didukung oleh referensi

dari jurnal ilmiah dan buku.

2.2 Data dan Sumber Data

Penelitian ini menggunakan data sekunder berupa data deret waktu harian kecepatan angin di jalur penyeberangan kapal Gresik–Bawean dari 1 Desember 2020 hingga 30 November 2023 sebanyak 1095 baris data. Data diperoleh dari arsip BMKG Maritim Tanjung Perak Surabaya pada 31 Juli 2024 dan diolah menggunakan RStudio.

Adapun variabel yang digunakan adalah sebagai berikut:

- $Y_{(t+1)}$: Kecepatan angin periode selanjutnya (knot)
- $X_{1(t)}$: Kecepatan angin saat ini (knot)
- $X_{2(t)}$: Tinggi gelombang rata-rata (meter)
- $X_{3(t)}$: Panjang gelombang (meter)
- $X_{4(t)}$: Periode gelombang (detik)
- $X_{5(t)}$: Tinggi maksimum gelombang (meter)

Seluruh variabel independen diambil pada waktu t (saat ini), sedangkan variabel dependen diambil pada waktu $t + 1$ (sehari setelahnya).

2.3 Teknik Analisis Data

Adapun langkah-langkah penelitian yang dilakukan adalah sebagai berikut:

1. Pengumpulan data.

Pengumpulan data kecepatan angin di jalur penyeberangan kapal Gresik-Bawean pada 1 Desember 2020 hingga 30 November 2023 dari arsip yang tersimpan di BMKG Maritim Tanjung Perak Surabaya.

2. Penentuan data pelatihan dan pengujian, serta arsitektur jaringan.

Data dibagi menjadi dua bagian, yaitu data pelatihan dan data pengujian, dengan variasi proporsi data pelatihan sebesar 50% hingga 99%, sedangkan sisanya digunakan sebagai data pengujian. Arsitektur jaringan saraf tiruan terdiri dari 5 neuron pada *input layer* dan 1 neuron pada *output layer*. Kombinasi *hidden layer* yang digunakan meliputi [3,2], [4,2], dan [4,3], yang ditentukan melalui pendekatan *trial and error* untuk memperoleh performa model terbaik.

3. Normalisasi data.

Setelah proporsi data ditentukan, dilakukan proses normalisasi pada data latih menggunakan Pers. 1 untuk memastikan semua data berada dalam rentang 0 hingga 1 sehingga sesuai untuk digunakan dalam model prediksi.

$$x'_k = \frac{x_k - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

$$\hat{x}_k = x'_k (x_{\max} - x_{\min}) + x_{\min}. \quad (2)$$

4. Penginisialisasian bobot awal.

Penginisialisasian bobot dan bias awal dilakukan dengan acak.

5. Propagasi maju.

Setiap unit masukan menerima sinyal input dan menyalurkan ke semua unit lapisan tersembunyi. Unit lapisan tersembunyi pertama memproses sinyal menggunakan bobot Pers. 3.

$$o_{\text{net}_j} = \sum_{k=1}^K x'_k \cdot w_{kj} + \beta_j \quad (3)$$

Untuk menghitung sinyal output-nya menggunakan fungsi aktivasi pada Pers. 4.

$$o_j = f(o_{\text{net}_j}) = \frac{1}{1 + e^{-o_{\text{net}_j}}} \quad (4)$$

Kemudian hasilnya akan dikirimkan ke semua unit pada lapisan *output*. Setiap unit keluaran (y_i , $i = 1, 2, \dots, I$) memproses sinyal output dengan perhitungan bobot menggunakan Pers. 5:

$$y_{\text{net}_i} = \sum_{j=1}^J o_j u_{ji} + \gamma_i \quad (5)$$

Untuk menghitung sinyal *output*-nya digunakan fungsi aktivasi pada Pers. 6:

$$y'_i = f(y_{\text{net}_i}) = \frac{1}{1 + e^{-y_{\text{net}_i}}} \quad (6)$$

6. Propagasi mundur.

Masuk ke tahap propagasi mundur, setiap unit keluaran y_i menerima target sesuai dengan sinyal input pelatihan, kemudian menghitung error menggunakan Pers. 7.

$$\delta_i = (y_i - y'_i) \cdot f'(y'_i) \quad (7)$$

di mana y_i adalah target output ke- i . Untuk memperbaiki nilai bobot u_{ji} , maka dihitung koreksi bobot menggunakan Pers. 8.

$$\Delta u_{ji} = \alpha \delta_i o_j \quad (8)$$

di mana α adalah *learning rate*. Untuk memperbaiki nilai bias γ_i , dihitung koreksi bias menggunakan Pers. 9

$$\Delta \gamma_i = \alpha \delta_i \quad (9)$$

Selanjutnya, nilai δ_i juga digunakan untuk mengirimkan *error* δ_k ke lapisan sebelumnya. Setiap unit dari lapisan tersembunyi (o_j) memproses semua sinyal *input* dari lapisan *output* menggunakan Pers. 10.

$$\delta_{\text{net}_j} = \sum_{i=1}^I \delta_i u_{ji} \quad (10)$$

Untuk menghitung error, maka dikalikan dengan turunan fungsi aktivasi:

$$\delta_j = f'(o_{\text{net}_j}) \cdot \delta_{\text{net}_j} = o_j(1 - o_j) \sum_{i=1}^I \delta_i u_{ji} \quad (11)$$

Kemudian menghitung koreksi bobot untuk memperbaiki nilai w_{kj} :

$$\Delta w_{kj} = \alpha \delta_j x'_k \quad (12)$$

Menghitung koreksi bias untuk memperbaiki nilai β_j :

$$\Delta \beta_j = \alpha \delta_j \quad (13)$$

7. Perubahan bobot dan bias.

Masuk ke tahap perubahan bobot dan bias, setiap unit tersembunyi (o_j) dilakukan perubahan bobot:

$$w_{kj}^{(\text{baru})} = w_{kj}^{(\text{lama})} + \Delta w_{kj} \quad (14)$$

Setiap unit keluaran dilakukan perubahan bobot:

$$u_{ji}^{(\text{baru})} = u_{ji}^{(\text{lama})} + \Delta u_{ji} \quad (15)$$

Perubahan tiap bias di lapisan tersembunyi:

$$\beta_j(\text{baru}) = \beta_j(\text{lama}) + \Delta\beta_j \quad (16)$$

Perubahan tiap bias di lapisan keluaran:

$$\gamma_i(\text{baru}) = \gamma_i(\text{lama}) + \Delta\gamma_i \quad (17)$$

Apabila nilai *error* telah sesuai, maka kondisi penghentian pelatihan dipenuhi.

8. Pengujian model.

Model terbaik yang diperoleh dari tahap pelatihan digunakan dalam tahap pengujian untuk mengevaluasi tingkat kesalahan. Apabila nilai kesalahan yang dihasilkan rendah, maka model dinyatakan layak digunakan untuk prediksi.

9. Pengujian tingkat akurasi model.

Pengujian tingkat akurasi model dilakukan menggunakan nilai MAPE dan MSE. Perhitungan nilai MAPE menggunakan Pers. 18 [13]:

$$\text{MAPE} = \frac{1}{I} \sum_{i=1}^I \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (18)$$

Berikut kategori nilai MAPE [5].

Tabel 1: Kategori Nilai MAPE

Nilai MAPE	Keterangan
$\text{MAPE} \leq 10\%$	Sangat akurat
$10\% < \text{MAPE} \leq 20\%$	Akurat
$20\% < \text{MAPE} \leq 50\%$	Cukup akurat
$\text{MAPE} > 50\%$	Tidak akurat

Perhitungan MSE menggunakan Pers. 19 [13]:

$$\text{MSE} = \frac{1}{I} \sum_{i=1}^I (y_i - y'_i)^2 \quad (19)$$

10. Prediksi.

Model terbaik yang didapatkan digunakan untuk memprediksi kecepatan angin.

11. Pengelompokan gelombang laut.

Prediksi kecepatan angin yang telah diperoleh dibulatkan dengan ketentuan sebagai berikut: nilai desimal kurang dari 0.5 dibulatkan ke bawah, sedangkan nilai desimal lebih besar atau sama dengan 0.5 dibulatkan ke atas. Berdasarkan hasil pembulatan tersebut, kecepatan angin selanjutnya diklasifikasikan ke dalam kategori skala Beaufort untuk menentukan kondisi angin dan potensi gelombang air laut. Skala Beaufort disajikan pada Tabel 2 [14].

Dengan demikian, seluruh tahapan metode penelitian ini telah dirancang untuk memastikan proses pemodelan berlangsung sistematis, akurat, dan dapat diuji ulang. Tahap selanjutnya adalah menyajikan hasil penerapan metode tersebut pada data kecepatan angin di jalur penyeberangan kapal Gresik–Bawean.

3 Hasil dan Pembahasan

Bagian ini menyajikan hasil penerapan metode yang telah dijelaskan sebelumnya. Analisis dimulai dengan eksplorasi data untuk memahami karakteristik awal variabel, kemudian dilanjutkan dengan pengujian model, evaluasi performa, serta interpretasi hasil prediksi dalam konteks keselamatan pelayaran.

Tabel 2: Skala Beaufort

Skala	Kecepatan Angin (knot)	Deskripsi Angin	Tinggi Gelombang (m)	Deskripsi Laut
0	<1	Tenang (<i>calm</i>)	-	Tenang (<i>glassy</i>)
1	1–3	Angin sepoi sangat lemah (<i>light air</i>)	0.1	Tenang (<i>rippled</i>)
2	4–6	Angin sepoi lemah (<i>light breeze</i>)	0.2	Gelombang halus (<i>wavelets</i>)
3	7–10	Angin sepoi (<i>gentle breeze</i>)	0.6	Sedikit bergelombang (<i>slight</i>)
4	11–16	Angin sepoi sedang (<i>moderate breeze</i>)	1	Sedikit hingga sedang
5	17–21	Angin sepoi segar (<i>fresh breeze</i>)	2	Bergelombang sedang
6	22–27	Angin sepoi kuat (<i>strong breeze</i>)	3	Bergelombang kasar
7	28–33	Angin mendekati kencang (<i>near gale</i>)	4	Kasar hingga sangat kasar
8	34–40	Angin kencang (<i>gale</i>)	5.5	Sangat kasar hingga tinggi
9	41–47	Badai lemah (<i>strong gale</i>)	7	Gelombang tinggi
10	48–55	Badai sedang (<i>storm</i>)	9	Sangat tinggi
11	56–63	Badai kuat (<i>violent storm</i>)	11.5	Sangat tinggi
12	>64	Badai topan (<i>hurricane</i>)	>14	Gelombang fenomenal

3.1 Analisis Data

Deskripsi statistik data penelitian disajikan pada [Tabel 3](#), yang memberikan gambaran umum mengenai rentang, rata-rata, serta kuartil dari setiap variabel. Tabel ini menjadi dasar untuk memahami karakteristik awal data sebelum dilakukan proses pemodelan.


Tabel 3: Deskripsi Statistik Data

Variabel	Min	Mean	Q_1	Median	Q_3	Max
X_1	1.15	10.25604	7.12	10.115	13.23	25.35
X_2	0.0050	0.7897	0.2850	0.7200	1.1625	3.2400
X_3	9.385	30.685	24.965	29.805	35.843	134.155
X_4	2.340	4.234	3.853	4.230	4.638	9.630
X_5	0.010	1.063	0.375	0.955	1.577	4.265
Y	1.15	10.25662	7.12	10.115	13.23	25.35


Selanjutnya, visualisasi data digunakan untuk memperlihatkan pola fluktuasi dan variasi musiman dari variabel-variabel utama. Empat grafik pertama ([Gambar 1](#)) menampilkan kecepatan angin, tinggi rata-rata gelombang, panjang gelombang, dan periode gelombang.

Grafik kecepatan angin ([Gambar 1a](#)) memperlihatkan rentang umum antara 5–20 knot, dengan beberapa puncak melebihi 25 knot terutama pada akhir 2022. Pola musiman terlihat jelas: peningkatan pada awal (Januari–Maret) dan akhir tahun (Oktober–Desember), serta penurunan pada pertengahan tahun (Mei–Agustus). Grafik tinggi rata-rata gelombang laut ([Gambar 1b](#)) menunjukkan nilai umumnya di bawah 2 meter, tetapi melonjak hingga 3 meter lebih pada akhir 2020 dan 2022, terutama saat musim hujan dengan angin muson barat. Grafik panjang gelombang ([Gambar 1c](#)) menampilkan kisaran dominan 20–50 meter, dengan lonjakan ekstrem di atas 100 meter pada pertengahan 2022 dan awal 2023. Sementara itu, grafik periode gelombang ([Gambar 1d](#)) memperlihatkan fluktuasi 3–5 detik, dengan kenaikan di atas 8 detik pada pertengahan dan akhir 2022.


Selain itu, dua variabel penting lainnya—tinggi maksimum gelombang dan kecepatan angin periode selanjutnya—ditunjukkan pada [Gambar 2](#).




(a) Grafik Kecepatan Angin dalam Knot



(b) Grafik Tinggi Rata-rata Gelombang dalam Meter




(c) Grafik Panjang Gelombang dalam Meter




(d) Grafik Periode Gelombang dalam Detik

Gambar 1: Visualisasi data kecepatan angin dan parameter gelombang laut di jalur Gresik–Bawean periode 2020–2023.



(a) Grafik Tinggi Maksimum Gelombang dalam Meter



(b) Grafik Kecepatan Angin Periode Selanjutnya dalam Knot

Gambar 2: Visualisasi tinggi maksimum gelombang dan kecepatan angin periode selanjutnya pada jalur Gresik–Bawean.

Grafik tinggi maksimum gelombang ([Gambar 2a](#)) memperlihatkan puncak ekstrem lebih dari 4 meter pada akhir 2020 dan awal 2023. Kondisi ini konsisten dengan periode musim hujan dan dominasi angin baratan. Sebaliknya, grafik kecepatan angin periode selanjutnya ([Gambar 2b](#)) menunjukkan pola fluktuatif dengan kisaran hampir 0 hingga 25 knot, dengan peningkatan pada Januari–Maret dan November–Desember, serta penurunan pada Mei–September saat angin timur mendominasi.

3.2 Penentuan Data dan Arsitektur Jaringan

Data penelitian dibagi menjadi dua bagian, yaitu data pelatihan untuk membangun model dan data pengujian untuk mengevaluasi performa model. Pembagian dilakukan secara proporsional dengan porsi data pelatihan lebih besar daripada data pengujian. Model JST yang digunakan berbasis algoritma *backpropagation* dengan arsitektur multilayer. Pemilihan arsitektur terbaik dilakukan melalui pendekatan *trial and error* dengan membandingkan nilai MAPE dan MSE dari beberapa konfigurasi.

Hasil pada [Tabel 4](#) menunjukkan bahwa konfigurasi terbaik adalah arsitektur (5–3–2–1), yaitu jaringan dengan lima neuron pada *input layer*, dua *hidden layer* masing-masing terdiri dari tiga dan dua neuron, serta satu neuron pada *output layer*. Arsitektur ini menghasilkan nilai MSE dan MAPE terkecil dibandingkan konfigurasi lainnya.

Tabel 4: Proporsi Pembagian Data dengan Berbagai Arsitektur


Data Splitting	Input Layer	Hidden Layer	Output Layer	MSE	MAPE
93% : 7%	5	3-2	1	5.805604	16.21559
	5	4-2	1	14.20996	24.02597
	5	4-3	1	13.40459	24.32448

3.3 Normalisasi Data


Agar proses pelatihan lebih stabil dan cepat konvergen, seluruh variabel dinormalisasi ke dalam rentang 0–1 sesuai dengan karakteristik fungsi aktivasi sigmoid biner yang digunakan. Normalisasi dilakukan pada data latih sebanyak 1.018 baris menggunakan Pers. 1. Sebagai contoh, hasil normalisasi untuk variabel X_1 adalah sebagai berikut:

$$x'_{11} = \frac{5.46 - 1.15}{25.35 - 1.15} = 0.178099174.$$

Visualisasi hasil normalisasi data ditampilkan pada Gambar 3. Grafik kiri memperlihatkan hasil normalisasi pada variabel independen, sedangkan grafik kanan menunjukkan hasil normalisasi kecepatan angin sebagai variabel dependen.



(a) Grafik Hasil Normalisasi pada Variabel Independen



(b) Grafik Hasil Normalisasi Kecepatan Angin Periode Selanjutnya

Gambar 3: Visualisasi hasil normalisasi data: variabel independen (kiri) dan variabel dependen (kanan).

3.4 Backpropagation

Bagian ini menguraikan secara rinci tahapan komputasi pada JST dengan algoritma *backpropagation*, dimulai dari inisialisasi bobot–bias, propagasi maju, perhitungan galat dan propagasi mundur, hingga pembaruan parameter. Untuk memperjelas alur, setiap tahap disertai tabel ringkasan nilai yang relevan.

1. Inisialisasi Bobot dan Bias Awal

Tabel 5 menyajikan bobot awal w_{kj} dari *input layer* ke *hidden layer* pertama (3 neuron) beserta bias β_j . Baris ke- k merepresentasikan variabel independen dan bias, sementara kolom ke- j adalah indeks neuron pada lapisan tersembunyi pertama.

Tabel 5: Bobot Awal dan Bias *Input Layer* ke *Hidden Layer* Pertama

Bobot/Bias	w_{k1}	w_{k2}	w_{k3}
Bias (β_j)	-0.08658011	0.6775081	-1.53428157
w_{1j}	1.32252443	1.1177719	-1.8170016
w_{2j}	0.63970204	1.3840475	0.35563308
w_{3j}	1.17478657	1.2839409	0.86390468
w_{4j}	0.11629031	-0.9764798	-0.08051261
w_{5j}	-2.93084636	0.9908363	-0.96248032

Selanjutnya, Tabel 6 memuat bobot w_{jm} dan bias θ_m dari *hidden layer* pertama (3 neuron) ke *hidden layer* kedua (2 neuron). Baris menunjukkan neuron pada *hidden layer* pertama (beserta bias), sedangkan kolom mengacu pada dua neuron di *hidden layer* kedua.

Tabel 6: Bobot Awal dan Bias *Hidden Layer* Pertama ke *Hidden Layer* Kedua

Bobot / Bias	w_{j1}	w_{j2}
Bias (θ_m)	0.112311	-0.71862122
w_1 (w_{1m})	-0.2576519	-0.54787228
w_2 (w_{2m})	1.4834263	1.52752066
w_3 (w_{3m})	0.6776003	-0.03994143

Terakhir untuk inisialisasi, [Tabel 7](#) merangkum bobot u_{mi} dan bias γ_i dari *hidden layer* kedua (2 neuron) ke *output layer* (1 neuron).

Tabel 7: Bobot Awal dan Bias *Hidden Layer* Kedua ke *Output Layer*

Bobot / Bias	u_{m1}
Bias (γ_i)	0.3840873
u_1 (u_{1i})	2.2391646
u_2 (u_{2i})	1.7539743

2. Propagasi Maju

Pada tahap ini dihitung sinyal *input* dan *output* di setiap lapisan. Berdasarkan [Pers. 3](#), *input* ke *hidden layer* pertama (o_{net_j}) merupakan kombinasi linier bobot dan *input* ternormalisasi ditambah bias. Hasilnya ditampilkan pada [Tabel 8](#).

Tabel 8: Sinyal *Input* dari *Input Layer* ke *Hidden Layer* Pertama

o_{net_j}	Nilai
o_{net_1}	0.248597985
o_{net_2}	1.008685391
o_{net_3}	-1.754388111

Selanjutnya, *output* o_j pada *hidden layer* pertama diperoleh melalui fungsi aktivasi sigmoid sesuai [Pers. 4](#); ringkasannya pada [Tabel 9](#).

Tabel 9: Sinyal *Output* di *Hidden Layer* Pertama

o_j	Nilai
o_1	0.561831387
o_2	0.732762799
o_3	0.147494583

Menggunakan [Pers. 3](#) kembali, *input* ke *hidden layer* kedua (o_{net_m}) dihitung dari o_j , w_{jm} , dan θ_m ; hasilnya pada [Tabel 10](#).

Tabel 10: Sinyal *Input* dari *Hidden Layer* Pertama ke *Hidden Layer* Kedua

o_{net_m}	Nilai
o_{net_1}	1.154496057
o_{net_2}	0.086986107

Output o_m pada *hidden layer* kedua kemudian diperoleh melalui fungsi aktivasi sesuai [Pers. 4](#); ringkasannya pada [Tabel 11](#).

Tabel 11: Sinyal *Output* di *Hidden Layer* Kedua

o_m	Nilai
o_1	0.760331182
o_2	0.521732825

Berdasarkan [Pers. 5](#), *input* ke *output layer* (y_{net_i}) dihitung dari o_m , u_{mi} , dan γ_i (lihat [Tabel 12](#)); kemudian *output* y'_i diperoleh melalui [Pers. 6](#) (lihat [Tabel 13](#)).

Tabel 12: Sinyal *Input* dari *Hidden Layer* Kedua ke *Output Layer*

y_{net_i}	Nilai
y_{net_1}	3.001699933

Tabel 13: Sinyal *Output* pada *Output Layer*

y_i	Nilai
y_1	0.952650865

3. Propagasi Mundur

Tahap ini menghitung faktor galat dan koreksi parameter secara berurutan dari lapisan keluaran ke lapisan sebelumnya. Berdasarkan [Tabel 13](#), selisih antara *output* jaringan dan target dihitung melalui [Pers. 7](#) untuk memperoleh δ_i ([Tabel 14](#)).

Tabel 14: Nilai *Error* pada *Output Layer*

δ_i	Nilai
δ_1	-0.034937854

Dengan *learning rate* $\alpha = 0.001$, koreksi bobot (Δu_{mi}) dan bias ($\Delta \gamma_i$) dari *hidden layer* kedua ke *output layer* dihitung via [Pers. 8–Pers. 9](#); ringkasannya terdapat pada [Tabel 15](#).

Tabel 15: Koreksi Bobot dan Bias *Hidden Layer* Kedua ke *Output Layer*

Bobot/Bias	Nilai
$\Delta \gamma_1$	-3.49379×10^{-5}
Δu_{1i}	-2.65643×10^{-5}
Δu_{2i}	-1.82282×10^{-5}

Selanjutnya, *delta input* ke *hidden layer* kedua (δ_{net_m}) dan faktor galat δ_m dihitung via [Pers. 10](#) dan turunan aktivasi; hasilnya pada [Tabel 16](#).

Tabel 16: Nilai *Error* pada *Hidden Layer* Kedua

m	δ_{net_m}	δ_m
1	-0.078231605	-0.014255964
2	-0.061280097	-0.015291081

Berdasarkan δ_m tersebut, koreksi bobot dan bias penghubung *hidden layer* pertama ke *hidden layer* kedua (Δw_{jm} dan $\Delta \theta_m$) dihitung via [Pers. 12–Pers. 13](#); ringkasannya pada [Tabel 17](#).

Tabel 17: Koreksi Bobot dan Bias *Hidden Layer* Pertama ke *Hidden Layer* Kedua

Bobot/Bias	Δw_{j1}	Δw_{j2}
$\Delta \theta_m$	-1.4256×10^{-5}	-1.52911×10^{-5}
Δw_{1m}	-8.00945×10^{-6}	-8.59101×10^{-6}
Δw_{2m}	-1.04462×10^{-5}	-1.12047×10^{-5}
Δw_{3m}	-2.10268×10^{-6}	-2.25535×10^{-6}

Proses yang sama diteruskan ke *hidden layer* pertama. Nilai δ_{net_j} dan δ_j dihitung via [Pers. 10](#) dan [Pers. 11](#); hasilnya pada [Tabel 18](#).

Tabel 18: Nilai *Error* pada *Hidden Layer* Pertama

j	δ_{net_j}	δ_j
1	0.012050635	0.002966588
2	-0.044505113	-0.008715057
3	-0.009049098	-0.001137833

Dengan δ_j di atas, koreksi bobot dan bias dari *input layer* ke *hidden layer* pertama (Δw_{kj} dan $\Delta \beta_j$) dihitung via Pers. 12–Pers. 13; ringkasan pada Tabel 19.

Tabel 19: Koreksi Bobot dan Bias *Input Layer* ke *Hidden Layer* Pertama

Bobot/Bias	Δw_{k1}	Δw_{k2}	Δw_{k3}
$\Delta \beta_j$	2.96659×10^{-6}	-8.71506×10^{-6}	-1.13783×10^{-6}
Δw_{1j}	3.92338×10^{-6}	-9.74145×10^{-6}	2.06744×10^{-6}
Δw_{2j}	1.89773×10^{-6}	-1.20621×10^{-5}	-4.04651×10^{-7}
Δw_{3j}	3.48511×10^{-6}	-1.11896×10^{-5}	-9.82979×10^{-7}
Δw_{4j}	3.44985×10^{-7}	8.51008×10^{-6}	9.16099×10^{-8}
Δw_{5j}	-8.69461×10^{-6}	-8.63519×10^{-6}	1.09514×10^{-6}

4. Perubahan Bobot dan Bias

Tahap akhir adalah pembaruan parameter dengan menjumlahkan bobot/bias lama dan nilai koreksi sesuai Pers. 14–Pers. 17. Tabel 20 menampilkan hasil pembaruan parameter dari *hidden layer* kedua ke *output layer*; Tabel 21 dari *hidden layer* pertama ke kedua; dan Tabel 22 dari *input layer* ke *hidden layer* pertama. Nilai-nilai inilah yang kemudian digunakan pada iterasi data berikutnya.

Tabel 20: Bobot dan Bias Baru *Hidden Layer* Kedua ke *Output Layer*

Bobot/Bias	Nilai (baru)
γ_1 (baru)	2.239138036
u_{1i} (baru)	1.753956072
u_{2i} (baru)	0.384052362

Tabel 21: Bobot dan Bias Baru *Hidden Layer* Pertama ke *Hidden Layer* Kedua

Bobot/Bias	w_{j1} (baru)	w_{j2} (baru)
θ_m (baru)	0.112296744	-0.718636511
w_{1m} (baru)	-0.257659909	-0.547880871
w_{2m} (baru)	1.483415854	1.527509455
w_{3m} (baru)	0.677598197	-0.039943685

Tabel 22: Bobot dan Bias Baru *Input Layer* ke *Hidden Layer* Pertama

Bobot/Bias	w_{k1} (baru)	w_{k2} (baru)	w_{k3} (baru)
β_j (baru)	-0.086577143	0.677499385	-1.534282708
w_{1j} (baru)	1.322528353	1.117762159	-1.816999533
w_{2j} (baru)	0.639703938	1.384035438	0.355632675
w_{3j} (baru)	1.174790055	1.283929710	0.863903697
w_{4j} (baru)	0.116290655	-0.976471290	-0.080512518
w_{5j} (baru)	-2.930855055	0.990827665	-0.962479225

3.5 Model Jaringan Saraf Tiruan

Setelah tahap *backpropagation* berjalan iteratif, pada data kedua dan seterusnya pelatihan selalu diawali dengan bobot dan bias hasil pembaruan dari langkah sebelumnya, lalu dilanjutkan berurutan hingga seluruh data diproses. Proses dihentikan ketika nilai galat mencapai tolok henti (target error) sebesar 0.001. Setelah pelatihan selesai, diperoleh bobot dan bias akhir untuk setiap lapisan, sebagaimana disajikan pada Tabel 23 hingga Tabel 25. Secara umum, tanda bobot mengindikasikan arah kontribusi terhadap aktivasi neuron (positif: searah; negatif: berlawanan), sedangkan bias menggeser ambang aktivasi.

Tabel 23: Bobot dan Bias Akhir *Hidden Layer* Pertama

Bobot/Bias	w_{k1}	w_{k2}	w_{k3}
β_j	0.1724351	-0.2621448	-1.492778
w_{1j}	2.3158652	4.1186395	-5.46295
w_{2j}	-5.7153875	-11.00102	-4.005915
w_{3j}	1.9295123	4.7790261	5.705943
w_{4j}	6.1583703	2.3529065	2.216537
w_{5j}	0.5113034	7.0111137	-7.921608


Tabel 24: Bobot dan Bias Akhir *Hidden Layer* Kedua

Bobot/Bias	w_{j1}	w_{j2}
θ_m	-0.04544929	-3.601966
w_{1m}	-5.40720304	-3.329012
w_{2m}	3.30755847	6.53562
w_{3m}	1.01687276	-3.559361

Tabel 25: Bobot dan Bias Akhir *Output Layer*

Bobot/Bias	u_{m1}
γ_i	-2.728483
u_{1i}	5.26523
u_{2i}	4.996003

Struktur jaringan terbaik terdiri atas satu *input layer*, dua *hidden layer*, dan satu *output layer* seperti pada Gambar 4. Visualisasi dibuat menggunakan RStudio; setiap neuron terhubung ke neuron pada lapisan berikutnya. Garis berwarna hitam menunjukkan bobot antar-neuron, sedangkan anotasi berwarna biru merepresentasikan nilai bias tiap lapisan.

**Gambar 4:** Model Optimal JST

Berdasarkan struktur pada Gambar 4, model jaringan saraf tiruan dapat diformulasikan sebagai:

$$o_j = f\left(\sum_{k=1}^5 x_k \cdot w_{kj} + \beta_j\right), \quad (20)$$

$$o_m = f\left(\sum_{j=1}^3 o_j \cdot w_{jm} + \theta_m\right), \quad (21)$$

$$y_i = f\left(\sum_{m=1}^2 o_m \cdot u_{mi} + \gamma_i\right). \quad (22)$$

Model keseluruhan secara komprehensif dirumuskan sebagai:

$$y_i = f\left(\sum_{m=1}^2 \left[f\left(\sum_{j=1}^3 \left[f\left(\sum_{k=1}^5 x_k \cdot w_{kj} + \beta_j\right)\right] \cdot w_{jm} + \theta_m\right)\right] \cdot u_{mi} + \gamma_i\right). \quad (23)$$

Model inilah yang digunakan untuk memprediksi kecepatan angin pada jalur penyeberangan kapal Gresik–Bawean.

3.6 Tingkat Keakuratan Model

Akurasi model dievaluasi menggunakan MAPE dan MSE sesuai Pers. 18 dan Pers. 19. Perhitungan ringkasnya sebagai berikut:


$$\begin{aligned} \text{MAPE} &= \frac{1}{77} \left(\left| \frac{17.445 - 11.1341}{17.445} \right| + \left| \frac{15.865 - 11.1778}{15.865} \right| + \left| \frac{11.25 - 11.1503}{11.25} \right| + \dots + \left| \frac{6.095 - 11.0130}{6.095} \right| \right) \times 100\% \\ &= 16.22\%, \end{aligned}$$

$$\begin{aligned} \text{MSE} &= \frac{1}{77} [(17.445 - 11.1341)^2 + (15.865 - 11.1778)^2 + (11.25 - 11.1503)^2 + \dots + (6.095 - 11.0130)^2] \\ &= 5.8056. \end{aligned}$$

Hasil ini menunjukkan bahwa model memiliki tingkat galat yang rendah dan mampu memprediksi kecepatan angin secara akurat menurut kategori MAPE yang digunakan.

3.7 Prediksi

Dengan menggunakan Pers. 20–Pers. 22, model JST kemudian diterapkan untuk memprediksi kecepatan angin periode Desember 2023 dan Januari 2024. *Output* prediksi 62 hari ke depan ditunjukkan pada Gambar 5.



Gambar 5: Grafik Data Aktual dan Prediksi Kecepatan Angin

Grafik pada Gambar 5 membandingkan data aktual (biru) dan hasil prediksi (oranye) pada 1–30 Desember 2023, serta prediksi lanjutan hingga 31 Januari 2024 (merah). Secara umum,

prediksi akurat pada kondisi relatif stabil, namun kurang presisi dalam menangkap lonjakan ekstrem di awal periode. Hal ini sejalan dengan karakter fluktuatif musim Desember–Januari, sehingga JST cenderung kesulitan mengeneralisasi perubahan tajam meskipun dilatih dengan data tiga tahun terakhir.

3.8 Pengelompokan Gelombang Laut

Sebagai ilustrasi pemanfaatan hasil prediksi, pengelompokan kondisi laut berdasarkan Skala Beaufort untuk tanggal 1–7 Desember 2023 disajikan pada Tabel 26.

Tabel 26: Pengelompokan Gelombang Laut Berdasarkan Skala Beaufort (1–7 Desember 2023)

Tanggal	Kecepatan Angin (knot)	Skala Beaufort	Tinggi Gelombang (m)	Gelombang Laut
01/12/2023	11	4	1.0	Sedikit bergelombang hingga bergelombang sedang
02/12/2023	7	3	0.6	Sedikit bergelombang (<i>slight</i>)
03/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
04/12/2023	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
05/12/2023	10	3	0.6	Sedikit bergelombang (<i>slight</i>)
06/12/2023	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
07/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)

4 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah diuraikan, dapat ditarik beberapa kesimpulan penting. Pertama, model jaringan saraf tiruan (JST) dengan algoritma *backpropagation* yang optimal untuk memprediksi kecepatan angin di jalur penyeberangan kapal Gresik–Bawean memiliki arsitektur (5–3–2–1), yaitu satu *input layer* dengan lima neuron, dua *hidden layer* masing-masing tiga dan dua neuron, serta satu *output layer* dengan satu neuron.

Kedua, hasil pengelompokan gelombang laut pada periode Desember 2023 hingga Januari 2024 menunjukkan kondisi relatif stabil, dengan kategori gelombang halus hingga bergelombang sedang. Tidak ditemukan kejadian gelombang ekstrem yang mengindikasikan potensi cuaca buruk. Fluktuasi ringan pola angin harian masih dalam batas aman, tercermin dari pergantian antara kategori gelombang halus, sedikit bergelombang, dan bergelombang sedang.

Ketiga, tingkat akurasi model JST cukup baik. Nilai MSE sebesar 5.8056 dan MAPE sebesar 16.22% pada data latih menunjukkan model mampu mempelajari pola data historis dengan cukup akurat. Sementara itu, nilai MSE sebesar 6.7379 dan MAPE sebesar 33.95% pada data prediksi memperlihatkan bahwa model tetap memberikan hasil yang cukup memadai, meskipun akurasinya menurun ketika dihadapkan pada data di luar sampel pelatihan, khususnya saat menghadapi fluktuasi musiman yang tajam.

Dengan demikian, model JST yang dikembangkan dapat digunakan sebagai dasar prediksi kecepatan angin untuk mendukung keselamatan pelayaran di jalur Gresik–Bawean, meskipun pengembangan lebih lanjut masih diperlukan agar lebih adaptif terhadap kondisi ekstrem.

Pernyataan Kontribusi Penulis (CRediT)

Muhammad Imamul Khoiri: Konseptualisasi, Metodologi, Penulisan–Draf Awal. **Sri Harini:** Supervisi, Administrasi Proyek, Penulisan–Telaah dan Penyuntingan. **Achmad Nashichuddin:** Kurasi Data, Analisis Formal, Perangkat Lunak, Visualisasi.

Deklarasi Penggunaan AI atau Teknologi Berbasis AI

Model ChatGPT versi 4 digunakan untuk membantu penyusunan draf awal dan koreksi struktur kalimat.

Deklarasi Konflik Kepentingan

Penulis menyatakan tidak ada konflik kepentingan.

Pendanaan dan Ucapan Terima Kasih

Penelitian ini tidak menerima pendanaan eksternal.

Penulis mengucapkan terima kasih kepada BMKG Maritim Tanjung Perak Surabaya atas ketersediaan data kecepatan angin dan gelombang laut yang menjadi dasar penelitian ini. Apresiasi juga diberikan kepada Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang yang telah menyediakan fasilitas laboratorium komputasi.

Ketersediaan Data

Dataset yang dianalisis dalam studi ini tersedia atas permintaan wajar kepada penulis korespondensi, dan penggunaannya tunduk pada perjanjian kerahasiaan dari BMKG selaku pemilik data.

Daftar Pustaka

- [1] A. Brotosusilo, I. W. A. Apriana, A. A. Satria, and T. Jokopitoyo, "Littoral and Coastal Management in Supporting Maritime Security for Realizing Indonesia as World Maritime Axis," *IOP Publishing*, vol. 30, 2016. DOI: [10.1088/1755-1315/30/1/012016](https://doi.org/10.1088/1755-1315/30/1/012016). Available online.
- [2] H. Arfah and P. Kurniati, *Perahu yang Tenggelam dan Tewaskan 1 Orang di Bawean Gresik Diduga Kelebihan Muatan*, 2024. Available online (visited on 09/25/2024).
- [3] I. R. Young and A. Ribal, "Multiplatform Evaluation of Global Trends in Wind Speed and Wave Height," vol. 364, no. 6440, pp. 548–552, 2019. DOI: <https://doi.org/10.1126/science.aav9527>.
- [4] A. A. Samah, H. Azril, M. Shaffril, A. Hamzah, and B. A. Samah, "Factors Affecting Small-Scale Fishermen 's Adaptation Toward the Impacts of Climate Change : Reflections From Malaysian Fishers," *Sage Open*, vol. 9, no. 3, 2019. DOI: <https://doi.org/10.1177/2158244019864204>. Available online.
- [5] C. D. Lewis, *Industrial and Business Forecasting Methods : A Practical Guide to Exponential Smoothing and Curve Fitting*. London: Butterworth Scientific, 1982, p. 40.
- [6] M. Jamhuri, M. I. Irawan, I. Mukhlash, M. Iqbal, and N. N. T. Puspaningsih, "Neural networks optimization via gauss-newton based qr factorization on sars-cov-2 variant classification," *Systems and Soft Computing*, vol. 7, p. 200 195, 2025. DOI: [10.1016/j.sasc.2025.200195](https://doi.org/10.1016/j.sasc.2025.200195).
- [7] A. T. W. Almais, R. A. Fajrin, A. Naba, M. Sarosa, J. Juhari, and A. Susilo, "Assessment of post-disaster building damage levels using back-propagation neural network prediction techniques," *JOIV: International Journal on Informatics Visualization*, 2024.

- [8] M. Jamhuri and T. Utomo, “Penggunaan particle swarm optimization pada jaringan syaraf tiruan untuk klasifikasi radar,” *MAp (Mathematics and Applications) Journal*, vol. 6, no. 2, pp. 191–201, 2024.
- [9] U. Khasanah and N. Ulinnuha, “Prediksi Biaya Konsumsi Bahan Bakar Gas Menggunakan Metode Backpropagation Neural Network (Studi Kasus: PLTU PT. Pembangkit Jawa Bali Unit Pembangkitan Gresik),” *Jurnal Sains Matematika dan Statistika*, vol. 5, no. 2, pp. 9–17, 2019. DOI: <http://dx.doi.org/10.24014/jsms.v5i2.7630>. Available online.
- [10] P. I. Sijabat, Y. Yuhandri, G. W. Nurcahyo, and A. Sindar, “Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional,” *Digital Zone: Jurnal Teknologi Informasi dan Komunikasi*, vol. 11, no. 1, 2020. DOI: [10.31849/digitalzone.v11i1.3880](https://doi.org/10.31849/digitalzone.v11i1.3880).
- [11] W. Ariannor and M. F. Razatillah, “Penerapan Jaringan Saraf Tiruan Backpropagation Dalam Memprediksi Nilai Tukar Petani,” *Jurnal Ilmiah Komputer*, vol. 18, no. 1, pp. 127–140, 2022. DOI: <https://dx.doi.org/10.35889/progresif.v18i1.798>.
- [12] S. A. Rodia and M. A. Ridla, “Prediksi Nilai Impor Susu Segar Menggunakan Algoritma Backpropagation,” *Jurnal Ahsana*, vol. 2, no. 1, pp. 27–32, 2024. DOI: <https://doi.org/10.59395/ahsana.v1i1.352>. Available online.
- [13] E. Herjanto, *Sains Manajemen*, Jakarta, 2009.
- [14] S. Wirjohamidjojo and Sugarin, *Praktek Meteorologi Kelautan*. Badan Meteorologi dan Geofisika, 2008, pp. 40–41.