

**PREDIKSI KECEPATAN ANGIN DI JALUR
PENYEBERANGAN KAPAL GRESIK-BAWEAN
MENGUNAKAN METODE JARINGAN SARAF TIRUAN**

SKRIPSI

**OLEH:
MUHAMMAD IMAMUL KHOIRI
NIM. 210601110044**



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2025**

**PREDIKSI KECEPATAN ANGIN DI JALUR
PENYEBERANGAN KAPAL GRESIK-BAWEAN
MENGUNAKAN METODE JARINGAN SARAF TIRUAN**

SKRIPSI

**Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh
MUHAMMAD IMAMUL KHOIRI
NIM. 210601110044**

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2025**

**PREDIKSI KECEPATAN ANGIN DI JALUR
PENYEBERANGAN KAPAL GRESIK-BAWEAN
MENGUNAKAN METODE JARINGAN SARAF TIRUAN**

SKRIPSI

**Oleh
Muhammad Imamul Khoiri
NIM. 210601110044**

Telah Disetujui Untuk Diuji


Malang, 3 Juni 2025

Dosen Pembimbing I


**Prof. Dr. Hj. Sri Harini, M.Si.
NIP. 19731014 200112 2 002**

Dosen Pembimbing II


**Achmad Nashichuddin, M.A.
NIP. 19730705 200003 1 002**


**Mengetahui,
Ketua Program Studi Matematika**

**Dr. Ely Susanti, M.Sc
NIP. 19741129 200012 2 005**

**PREDIKSI KECEPATAN ANGIN DI JALUR
PENYEBERANGAN KAPAL GRESIK-BAWEAN
MENGUNAKAN METODE JARINGAN SARAF TIRUAN**

SKRIPSI

Oleh
Muhammad Imamul Kholil
NIM. 210601110044

Telah Dipertahankan di Depan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat)

Tanggal, 19 Juni 2025

Ketua Penguji : Hisyam Fahmi, M.Kom.

Anggota Penguji 1 : Ria Dhea Layla Nur Karisma, M.Si.

Anggota Penguji 2 : Prof. Dr. Hj. Sri Harini, M.Si.

Anggota Penguji 3 : Achmad Nashichuddin, M.A.


.....


.....

.....

.....

Mengetahui,
Ketua Program Studi Matematika

Dr. Lily Susanti, M.Sc
NIP. 19741129 200012 2 005



PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Muhammad Imamul Khoiri
NIM : 210601110044
Program Studi : Matematika
Fakultas : Sains dan Teknologi
Judul Skripsi : Prediksi Kecepatan Angin di Jalur Penyeberangan Kapal
Gresik-Bawean Menggunakan Metode Jaringan Saraf
Tiruan

Menyatakan dengan sebenarnya bahwa skripsi yang saya tulis benar-benar merupakan hasil karya sendiri, bukan merupakan pengambilan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan dan pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka. Apabila di kemudian hari terbukti atau dapat dibuktikan skripsi ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 19 Juni 2025

Yang membuat pernyataan,



Muhammad Imamul Khoiri
NIM. 210601110044

MOTO

“*Allahumma* paksa, kalau tidak dipaksa, tidak bakal bisa.”

- K.H. Ainul Yaqin

PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT, skripsi ini saya persembahkan kepada:

Pertama Bapak dan Ibu tercinta Abdul Hadi dan Badriyah yang telah menjadi sumber inspirasi, kekuatan, dan doa tiada henti. Terima kasih atas cinta, pengorbanan, dan dukungan tanpa batas yang telah kalian berikan selama ini. Segala usaha dan perjuangan ini adalah untuk membalas sebagian kecil dari kasih sayang yang tidak ternilai dari kalian.

Kedua Adik Luthfiyatur Rohmah, semoga karya ini dapat menjadi pengingat bahwa mimpi dapat diraih dengan usaha dan doa. Jangan pernah berhenti bermimpi, karena setiap langkah kecil yang kau ambil akan membawamu lebih dekat ke cita-cita. Teruslah berjuang dan yakinkanlah bahwa masa depan yang indah menantimu.

KATA PENGANTAR

Assalamualaikum warahmatullahi wabarakatuh.

Alhamdulillah robbil ‘alamin, puji syukur ke hadirat Allah SWT yang senantiasa memberikan Rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi ini dengan judul “Prediksi Kecepatan Angin di Jalur Penyeberangan Kapal Gresik-Bawean Menggunakan Metode Jaringan Saraf Tiruan”. Skripsi ini disusun sebagai salah satu syarat kelulusan dari Universitas Islam Negeri Maulana Malik Ibrahim Malang.

Selama pelaksanaan skripsi ini, penulis mendapatkan banyak pengetahuan, pengalaman, bimbingan, dukungan, juga arahan dan saran dari berbagai pihak yang telah membantu dalam penyelesaian skripsi ini. Untuk itu penulis ingin menyampaikan ucapan terima kasih kepada:

1. Penulis ingin mengucapkan rasa terima kasih yang mendalam kepada Bapak dan Ibu tercinta, Abdul Hadi dan Badriyah, terima kasih atas segala doa, dukungan, dan kasih sayang yang tiada henti, yang selalu menjadi kekuatan dan motivasi terbesar saya dalam menuntut ilmu dan menghadapi berbagai tantangan.
2. Penulis ingin menyampaikan rasa terima kasih yang mendalam kepada adik Luthfiyatur Rohmah, terima kasih atas semangat yang selalu terpancar dalam setiap langkahmu untuk menggapai cita-cita.
3. Prof. Dr. H. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim.
4. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim dan dosen pembimbing I yang telah memberikan berbagai pengetahuan, pengalaman, arahan, nasihat, serta motivasi kepada penulis.
5. Dr. Elly Susanti, S.Pd., M.Sc., selaku ketua Program Studi Matematika Universitas Islam Negeri Maulana Malik Ibrahim.
6. Dr. Fachrur Rozi, M. Si., selaku dosen wali yang telah memberikan berbagai arahan, nasihat, solusi, serta motivasi kepada penulis.

7. Achmad Nashichuddin, M.A., selaku dosen pembimbing II yang telah memberikan ilmu, nasihat, bimbingan, pengalaman, serta motivasi kepada penulis.
8. Hisyam Fahmi, M.Kom., selaku ketua penguji dalam ujian skripsi yang telah memberikan saran yang bermanfaat bagi penulis.
9. Ria Dhea Layla Nur Karisma, M.Si., selaku dosen penguji 1 dalam ujian skripsi yang telah memberikan saran yang bermanfaat bagi penulis.
10. Seluruh dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim, *Masyayikh* dan ustadz serta ustadzah Pondok Pesantren Tebuireng Jombang, dan Pondok Pesantren Hamalatul Qur'an Jombang yang telah memberikan pembelajaran kepada kami semua dengan niat yang ikhlas. Semoga amal baik tersebut menjadi bagian dari ibadah untuk mendapatkan ridha Allah SWT. dan menjadi berkah terhadap peneliti.
11. Sahabat-sahabat dan seluruh teman penulis, khususnya 'Rumah Suami Idaman', GAMMA (Angkatan 5 SMA Trensains Tebuireng), dan Teorema 21 yang telah memberikan dukungan moral, semangat, motivasi, dan kerjasama yang tak tergantikan. Kebersamaan dalam perjalanan selama masa kuliah telah memberikan keceriaan dan kekuatan dalam menghadapi setiap hambatan.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna, namun dengan ikhlas, penulis mempersembahkan sebagai bentuk apresiasi dan penghormatan kepada semua pihak yang telah memberikan kontribusi, dukungan, dan inspirasi kepadapenulis. Semoga skripsi ini bermanfaat bagi pembaca dan dapat menjadi pijakan untuk perjalanan ilmiah yang lebih luas.

Wassalamu'alaikum warahmatullahi wabarakatuh.

Malang, 19 Juni 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTO	vi
PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
DAFTAR SIMBOL	xiv
DAFTAR LAMPIRAN	xv
ABSTRAK	xvi
ABSTRACT	xvii
مستخلص البحث	xviii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	7
1.5 Batasan Masalah	7
1.6 Definisi Istilah	8
BAB II KAJIAN TEORI	11
2.1 Teori Pendukung	11
2.1.1 Normalisasi Data	11
2.1.2 Metode Pelatihan	11
2.1.3 Jaringan Saraf Tiruan	12
2.1.4 Arsitektur Jaringan	15
2.1.5 Fungsi Aktivasi	17
2.1.6 <i>Backpropagation</i>	18
2.1.7 Keakuratan Model Prediksi	20
2.1.8 Angin	22
2.1.9 Gelombang Laut	24
2.2 Fenomena Angin dalam Al-Qur'an	25
2.3 Kajian Topik Dengan Teori Pendukung	28
BAB III METODE PENELITIAN	32
3.1 Jenis Penelitian	32
3.2 Data dan Sumber Data	32
3.3 Teknik Analisis Data	33
3.4 Diagram Alir Penelitian	36
BAB IV HASIL DAN PEMBAHASAN	38
4.1 Analisis Data	38
4.2 Penentuan Data dan Arsitektur Jaringan	43

4.3 Normalisasi Data	45
4.4 <i>Backpropagation</i>	47
4.4.1 Inisialisasi Bobot dan Bias Awal	47
4.4.2 Propagasi Maju	50
4.4.3 Propagasi Mundur	54
4.4.4 Perubahan Bobot dan Bias	59
4.5 Model Jaringan Saraf Tiruan	61
4.6 Tingkat Keakuratan Model.....	65
4.7 Prediksi	66
4.8 Pengelompokan Gelombang Laut	70
4.9 Prediksi Kecepatan Angin Menggunakan Metode JST dalam Pandangan Islam.....	72
BAB V PENUTUP	74
5.1 Kesimpulan.....	74
5.2 Saran	75
DAFTAR PUSTAKA	76
LAMPIRAN.....	80
RIWAYAT HIDUP	100

DAFTAR TABEL

Tabel 2.1	Kategori Nilai MAPE	21
Tabel 2.2	Skala Beaufort.....	23
Tabel 4.1	Deskripsi Data.....	38
Tabel 4.2	Kombinasi Pembagian Data dan Arsitektur Jaringan Terbaik.....	44
Tabel 4.3	Bobot awal dan Bias <i>Input Layer</i> ke <i>Hidden Layer</i> Pertama.....	48
Tabel 4.4	Bobot Awal dan Bias <i>Hidden Layer</i> Pertama ke <i>Hidden Layer</i> Kedua	49
Tabel 4.5	Bobot Awal dan Bias <i>Hidden Layer</i> Kedua ke <i>Output Layer</i>	49
Tabel 4.6	Sinyal <i>Input</i> dari <i>Input Layer</i> ke <i>Hidden Layer</i> Pertama	51
Tabel 4.7	Sinyal <i>Output</i> di <i>Hidden Layer</i> Pertama	51
Tabel 4.8	Sinyal <i>Input</i> dari <i>Hidden Layer</i> Pertama ke <i>Hidden Layer</i> Kedua	52
Tabel 4.9	Sinyal <i>Output</i> di <i>Hidden Layer</i> Kedua.....	53
Tabel 4.10	Sinyal <i>Input</i> dari <i>Hidden Layer</i> Kedua ke <i>Output Layer</i>	53
Tabel 4.11	Sinyal <i>Output</i> pada <i>Output layer</i>	53
Tabel 4.12	Koreksi Bobot dan Bias <i>Hidden Layer</i> Kedua ke <i>Output Layer</i>	54
Tabel 4.13	Nilai <i>Error</i> pada <i>Hidden Layer</i> Kedua	55
Tabel 4.14	Koreksi Bobot dan Bias <i>Hidden Layer</i> Pertama ke <i>Hidden Layer</i> Kedua	56
Tabel 4.15	Nilai <i>Error</i> pada <i>Hidden Layer</i> Pertama.....	57
Tabel 4.16	Koreksi Bobot dan Bias <i>Input Layer</i> ke <i>Hidden Layer</i> Pertama.....	58
Tabel 4.17	Bobot dan Bias Baru <i>Hidden Layer</i> Kedua ke <i>Output Layer</i>	59
Tabel 4.18	Bobot dan Bias Baru <i>Hidden Layer</i> Pertama ke <i>Hidden Layer</i> Kedua	60
Tabel 4.19	Bobot dan Bias Baru <i>Input Layer</i> ke <i>Hidden Layer</i> Pertama	61
Tabel 4.20	Bobot dan Bias Akhir <i>Hidden Layer</i> Pertama	62
Tabel 4.21	Bobot dan Bias Akhir <i>Hidden Layer</i> Kedua	62
Tabel 4.22	Bobot dan Bias Akhir <i>Output Layer</i>	63
Tabel 4.23	Pengelompokan Gelombang Laut.....	70

DAFTAR GAMBAR

Gambar 2.1	Model JST	13
Gambar 2.2	Jaringan Lapisan Tunggal	15
Gambar 2.3	Jaringan Lapisan Banyak	16
Gambar 2.4	Jaringan <i>Recurrent</i>	16
Gambar 3.1	Diagram Alir Penelitian	37
Gambar 4.1	Grafik Kecepatan Angin dalam Knot.....	39
Gambar 4.2	Grafik Tinggi Rata-rata Gelombang dalam Meter	39
Gambar 4.3	Grafik Panjang Gelombang dalam Meter.....	40
Gambar 4.4	Grafik Periode Gelombang dalam Detik.....	41
Gambar 4.5	Grafik Tinggi Maksimum Gelombang dalam Meter.....	42
Gambar 4.6	Grafik Kecepatan Angin Periode Selanjutnya dalam Knot.....	43
Gambar 4.7	Grafik Hasil Normalisasi pada Variabel Independen.....	46
Gambar 4.8	Grafik Hasil Normalisasi Kecepatan Angin Periode Selanjutnya...	47
Gambar 4.9	Model Optimal JST	64
Gambar 4.10	Grafik Data Aktual dan Prediksi Kecepatan Angin	69

DAFTAR SIMBOL

X_1	: Kecepatan angin (knot)
X_2	: Tinggi gelombang rata-rata (meter)
X_3	: Panjang gelombang (meter)
X_4	: Periode gelombang (detik)
X_5	: Tinggi gelombang maksimum (meter)
Y	: Kecepatan angin periode selanjutnya (knot)
x_k	: Data aktual ke- k
x'_k	: Data normalisasi ke- k
x_{min}	: Nilai minimum data x
x_{max}	: Nilai maksimum data x
o_j	: <i>Output</i> dari unit tersembunyi ke- j
o_m	: <i>Output</i> dari unit tersembunyi ke- m
y_i	: <i>Output</i> dari unit keluaran ke- i
w_{kj}	: Bobot yang menghubungkan unit masukan ke- k ke unit tersembunyi pertama ke- j
w_{jm}	: Bobot yang menghubungkan unit tersembunyi ke- j ke unit tersembunyi kedua ke- m
u_{mi}	: Bobot yang menghubungkan unit tersembunyi ke- m ke unit keluaran ke- i
β_j	: Bias unit tersembunyi pertama ke- j
θ_m	: Bias unit tersembunyi kedua ke- j
γ_i	: Bias unit keluaran ke- i
K	: Banyak unit masukan
J	: Banyak unit tersembunyi pertama
M	: Banyak unit tersembunyi kedua
α	: <i>Learning rate</i>
δ_j	: Nilai <i>error</i> pada unit tersembunyi ke- j
δ_m	: Nilai <i>error</i> pada unit tersembunyi ke- m
δ_i	: Nilai <i>error</i> pada unit keluaran ke- i

DAFTAR LAMPIRAN

Lampiran 1. Data Penelitian.....	80
Lampiran 2. Hasil <i>Trial and Error</i> Penentuan Data dan Arsitektur Jaringan.....	85
Lampiran 3. Data Latih Normalisasi.....	87
Lampiran 4. Data Uji Normalisasi	88
Lampiran 5. <i>Script Rstudio</i>	89
Lampiran 6. Perhitungan MAPE.....	91
Lampiran 7. Perhitungan MSE.....	92
Lampiran 8. Data Input Prediksi 1-30 Desember 2023	93
Lampiran 9. Hasil Prediksi 1 Desember 2023 – 31 Januari 2024.....	95
Lampiran 10. Pengelompokan Gelombang Laut	96

ABSTRAK

Khoiri, Muhammad Imamul. 2025. **Prediksi Kecepatan Angin di Jalur Penyeberangan Kapal Gresik-Bawean Menggunakan Metode Jaringan Saraf Tiruan**. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Hj. Sri Harini, M.Si. (II) Achmad Nashichuddin, M.A.

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

Indonesia sebagai negara maritim sering mengalami perubahan cuaca ekstrem, salah satunya adalah kecepatan angin yang fluktuatif. Perubahan ini berdampak signifikan terhadap aktivitas pelayaran, khususnya pada jalur penyeberangan kapal Gresik–Bawean yang rawan terhadap gelombang tinggi dan angin kencang. Untuk mengantisipasi risiko tersebut, diperlukan prediksi kecepatan angin yang akurat. Penelitian ini bertujuan untuk memprediksi kecepatan angin di jalur penyeberangan kapal Gresik–Bawean menggunakan metode Jaringan Saraf Tiruan (JST) dengan algoritma backpropagation. Data yang digunakan adalah data kecepatan angin dan gelombang laut yang meliputi tinggi gelombang rata-rata, panjang gelombang, periode gelombang, dan tinggi maksimum gelombang, serta data kecepatan angin periode selanjutnya sebagai *output* periode 1 Desember 2020 hingga 30 November 2023 dari BMKG. Model JST dibangun melalui beberapa tahap, yaitu pembagian data dan penentuan arsitektur jaringan, normalisasi data, pelatihan model, dan evaluasi menggunakan *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa model JST terbaik diperoleh pada konfigurasi 1 *input layer* dengan 5 neuron, dua *hidden layer* dengan jumlah neuron masing-masing 3 dan 2, serta 1 *output layer*. Model ini menghasilkan nilai MSE sebesar 5.8056 dan MAPE sebesar 16.22%, yang mengindikasikan kemampuan prediksi yang akurat. Selain itu, analisis gelombang laut selama Desember 2023 dan Januari 2024 menunjukkan kondisi yang cenderung stabil dengan gelombang halus hingga sedang dan tidak ditemukan gelombang tinggi ekstrem. Hasil ini menunjukkan bahwa model JST dapat digunakan sebagai alat bantu prediksi dalam mitigasi risiko pelayaran dan mendukung keselamatan laut di wilayah jalur penyeberangan Gresik–Bawean.

ABSTRACT

Khoiri, Muhammad Imamul. 2025. **Wind Speed Prediction on the Gresik–Bawean Ferry Route Using Artificial Neural Network Method**. Thesis. Mathematics Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisors: (I) Prof. Dr. Hj. Sri Harini, M.Si. (II) Achmad Nashichuddin, M.A.

Kata Kunci: Prediction, Wind Speed, Artificial Neural Network, Backpropagation.

Indonesia, as a maritime country, frequently experiences extreme weather changes, one of which is fluctuating wind speed. These changes significantly affect shipping activities, especially on the Gresik–Bawean ferry route, which is prone to high waves and strong winds. To anticipate such risks, accurate wind speed prediction is essential. This study aims to predict wind speed on the Gresik–Bawean ferry route using the Artificial Neural Network (ANN) method with the backpropagation algorithm. The data used includes wind speed and ocean wave characteristics such as average wave height, wave length, wave period, and maximum wave height, along with future wind speed data as the output, sourced from BMKG for the period of December 1, 2020 to November 30, 2023. The ANN model was built through several stages: data partitioning and network architecture determination, data normalization, model training, and evaluation using Mean Squared Error (MSE) and Mean Absolute Percentage Error (MAPE). The results show that the best ANN model configuration consists of one input layer with five neurons, two hidden layers with three and two neurons respectively, and one output layer. This model produced an MSE value of 5.8056 and a MAPE value of 16.22%, indicating accurate predictive capability. Moreover, wave analysis during December 2023 and January 2024 revealed generally stable conditions with mild to moderate waves and no occurrence of extreme wave heights. These findings suggest that the ANN model can be utilized as a predictive tool to support maritime safety and risk mitigation in the Gresik–Bawean crossing route.

مستخلص البحث

الخير، محمد إمام. ٢٠٢٥. التنبؤ بسرعة الرياح على معبر سفينة جريسك-باويان باستخدام طريقة الشبكة العصبية الاصطناعية. البحث العلمي. قسم الرياضيات ، كلية العلوم والتكنولوجيا ، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف: (١). أ. د، سري هاريني، الماجستير في العلوم، الحاج (٢) أحمد ناصح الدين ، الماجستير في تعليم اللغة العربية.

الكلمات المفتاحية: التنبؤ ، سرعة الرياح ، الشبكة العصبية الاصطناعية ، الانتشار الخلفي.

غالبًا ما تشهد إندونيسيا كدولة بحرية تغيرات مناخية شديدة ، أحدها تقلب سرعات الرياح. هذا التغيير له تأثير كبير على أنشطة الشحن ، خاصة على خط عبور السفن جريسك-باويان المعرض للأمواج العالية والرياح القوية. لتوقع هذه المخاطر ، هناك حاجة إلى تنبؤ دقيق بسرعة الرياح. هدفت هذه الدراسة إلى التنبؤ بسرعة الرياح على طريق عبور السفن جريسك-باويان باستخدام طريقة الشبكة العصبية الاصطناعية (*JST*) مع خوارزمية الانتشار العكسي. البيانات المستخدمة هي بيانات سرعة الرياح وموجات البحر والتي تشمل متوسط ارتفاع الأمواج وطول الموجة وفترة الموجة وأقصى ارتفاع للموجة ، بالإضافة إلى بيانات سرعة الرياح للفترة القادمة كناتج للفترة من ١ ديسمبر ٢٠٢٠ إلى ٣٠ نوفمبر ٢٠٢٣ من *BMKG*. تم بناء نموذج *JST* من خلال عدة مراحل ، وهي مشاركة البيانات وتحديد بنية الشبكة ، وتطبيع البيانات ، وتدريب النموذج ، والتقييم باستخدام متوسط الخطأ التربيعي (*MSE*) ومتوسط النسبة المئوية المطلقة للخطأ (*MAPE*). أظهرت النتائج أنه تم الحصول على أفضل نموذج *JST* في تكوين طبقة إدخال واحدة مع ٥ خلايا عصبية ، وطبقتين مخفيتين بعدد الخلايا العصبية ٣ و ٢ على التوالي ، و ١ طبقة إخراج. ينتج عن هذا النموذج قيمة *MSE* تبلغ ٥,٨٠٥٦ و *MAPE* بنسبة ١٦,٢٢ ٪ ، مما يشير إلى قدرات تنبؤية دقيقة. بالإضافة إلى ذلك ، أظهر تحليل أمواج البحر خلال ديسمبر ٢٠٢٣ ويناير ٢٠٢٤ ظروفًا تميل إلى الاستقرار مع موجات دقيقة إلى معتدلة ولم يتم العثور على موجات عالية للغاية. ظهرت هذه النتائج أنه يمكن استخدام نموذج *JST* كأداة تنبؤ في التخفيف من مخاطر الشحن ودعم السلامة البحرية في منطقة طريق عبور جريسك-باويان.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia adalah negara maritim dengan dua pertiga wilayahnya berupa perairan teritorial. Sebagai negara kepulauan dengan 18.306 pulau, luas daratan sekitar 1,92 juta km², dan panjang garis pantai mencapai 81.000 km, Indonesia memiliki potensi maritim yang signifikan (Brotosusilo dkk., 2016). Potensi ini mencakup berbagai bidang seperti bioteknologi, pariwisata laut, eksplorasi perairan dalam, mineral laut, serta industri perkapalan dan pertahanan maritim. Potensi besar ini memerlukan dukungan transportasi laut sebagai fasilitas penghubung antarpulau yang memberikan dampak positif bagi masyarakat dan daerah yang memiliki pelabuhan (Purwendah, 2020).

Pelabuhan adalah tempat pemberhentian kapal setelah berlayar (Rodrigue dan Notteboom, 2012). Pelabuhan Bawean terletak di Sangkapura, sedangkan Pelabuhan Gresik terletak di Gresik. Kedua pelabuhan ini menjadi pintu masuk bagi kapal transportasi maupun nelayan. Namun, lalu lintas laut tidak lepas dari risiko kecelakaan. Dilansir oleh Arfah dan Kurniati (2024), sebuah kapal tenggelam saat hendak berlabuh di pulau Bawean. Kecelakaan ini diduga disebabkan oleh cuaca buruk, gelombang tinggi, dan kelebihan.

Variabilitas iklim seperti curah hujan, gelombang tinggi, dan angin kencang sangat memengaruhi aktivitas nelayan, termasuk dalam operasi penangkapan ikan (Samah dkk., 2019). Angin, yang merupakan aliran udara besar akibat rotasi bumi dan perbedaan tekanan udara (Fengbo dkk., 2017), dipengaruhi oleh kecepatan

angin (Stathopoulos dkk., 2014). Musim Barat terjadi pada bulan Desember, Januari, dan Februari, sementara Musim Timur terjadi pada bulan Juni, Juli, dan Agustus. Angin yang bertiup di Indonesia dipengaruhi oleh musim, sehingga disebut angin Muson atau Monsoon (Nababan dkk., 2016). Pergerakan angin ini mempengaruhi karakteristik massa air di laut, termasuk perubahan arah arus permukaan dan pencampuran massa air di lapisan atas yang menghasilkan distribusi suhu yang homogen (Stanev dkk., 2019). Kecepatan angin laut dan kekuatan gelombang laut memiliki hubungan yang sangat erat karena kekuatan gelombang dipengaruhi oleh kecepatan angin (Young dan Ribal, 2019). Al-qur'an juga menjelaskan tentang fenomena angin dan gelombang laut, sebagaimana disebutkan dalam surat Yunus ayat 22:

هُوَ الَّذِي يُسَيِّرُكُمْ فِي الْبَرِّ وَالْبَحْرِ ۚ حَتَّىٰ إِذَا كُنْتُمْ فِي الْفُلِكِ وَجَرَيْنَ بِهِم بِرِيحٍ طَيِّبَةٍ وَفَرِحُوا بِهَا جَاءَتْهَا رِيحٌ عَاصِفٌ وَجَاءَهُمُ الْمَوْجُ مِنْ كُلِّ مَكَانٍ وَظَنُوا أَمْهَمَ أَحْاطَ بِهِمْ ۖ دَعَوُا اللَّهَ مُخْلِصِينَ لَهُ الدِّينَ لَئِنْ أَجَبْنَاهُمْ مِنْ هَٰذِهِ لَنَكُونَنَّ مِنَ الشَّاكِرِينَ

Artinya: “Dialah (Allah) yang menjadikan kamu dapat berjalan di daratan (dan berlayar) di lautan sehingga ketika kamu berada di dalam kapal, lalu meluncurlah (kapal) itu membawa mereka dengan tiupan angin yang baik dan mereka bergembira karenanya. Kemudian, datanglah badai dan gelombang menyimpannya dari segenap penjuru dan mereka pun mengira telah terkepung (bahaya). Maka, mereka berdoa dengan mengikhlaskan ketaatan kepada-Nya (seraya berkata), ‘Sekiranya Engkau menyelamatkan kami dari (bahaya) ini, pasti kami termasuk orang-orang yang bersyukur.’”(Q.S. Yunus [10] : 22) (Kementerian Agama RI, 2019).

Pada ayat tersebut, dijelaskan bahwasanya Allah telah memberikan kepada umat manusia kemampuan untuk berjalan di daratan, baik dengan berjalan kaki maupun berkendara, serta untuk berlayar di lautan menggunakan kapal yang bergerak di atas air dengan bantuan angin yang telah disediakan. Kapal-kapal ini dapat sampai ke tujuan dengan selamat. Namun, ketika umat manusia merasa

tenang dan bahagia, tiba-tiba datanglah badai yang membawa gelombang dari berbagai arah (Shihab, 2013). Berdasarkan hal tersebut, dapat diketahui bahwa angin memengaruhi gelombang. Tinggi gelombang dipengaruhi oleh musim angin, di mana angin kencang cenderung menghasilkan gelombang yang lebih besar (Marino dkk., 2017).

Prediksi merupakan elemen penting dalam berbagai bidang, termasuk lingkungan, yang biasanya diklasifikasikan menjadi prediksi jangka pendek, menengah, dan panjang. Dalam konteks lingkungan, khususnya pada jalur penyeberangan kapal, prediksi kecepatan angin sangat krusial karena angin berpengaruh langsung terhadap gelombang laut, yang pada gilirannya mempengaruhi keselamatan dan efisiensi operasional. Untuk menghasilkan prediksi yang akurat, metode statistik sering digunakan karena kemampuannya dalam memodelkan pola historis secara efektif (Montgomery dkk., 2016). Salah satu metode prediksi yang sering diterapkan adalah prediksi deret waktu (*time series*), di mana data masa lalu dianalisis untuk membangun model yang dapat menggambarkan pola hubungan antarvariabel. Model ini kemudian digunakan untuk memprediksi data di masa depan, terutama dalam kondisi di mana pengetahuan tentang bagaimana data dihasilkan masih terbatas. Metode ini sangat bermanfaat ketika tidak ada model lain yang dapat menjelaskan hubungan antara variabel yang diprediksi dan variabel lainnya secara lebih mendalam. Seiring waktu, berbagai penelitian telah dilakukan untuk mengembangkan model yang lebih efisien guna meningkatkan akurasi prediksi. Salah satu metode yang muncul dalam literatur adalah Jaringan Saraf Tiruan (JST), yang terbukti efektif dalam

menangkap pola kompleks dari data historis dan meningkatkan ketepatan prediksi (Adhikari dan Agrawal, 2013).

Satu diantara model deret waktu yang paling penting dan banyak digunakan adalah model JST. JST, atau dikenal sebagai *Artificial Neural Network* (ANN), adalah sebuah model yang meniru cara kerja otak manusia untuk menyelesaikan masalah. Model ini bekerja dengan melakukan pembelajaran melalui penyesuaian bobot-bobot yang diberikan. Satu di antara keunggulan utama JST adalah kemampuannya untuk mengenali dan mempelajari pola hubungan antara data *input* dan target *output* yang diinginkan, berdasarkan data historis yang tersedia (Abhishek dkk., 2012). JST menganalisis data historis untuk mempelajari pola, kemudian menggunakan pengetahuan tersebut untuk membuat keputusan atau prediksi pada data baru yang belum pernah dilihat sebelumnya (Kusumadewi, 2003). JST juga mampu memodelkan data dengan volatilitas tinggi dan varians yang tidak konstan (Chhajer dkk., 2022). Algoritma *backpropagation* merupakan salah satu algoritma JST yang banyak digunakan untuk menyelesaikan masalah kompleks, terutama dalam bidang peramalan, identifikasi, dan pengenalan pola (Anwar, 2011). Dalam algoritma ini, jika *output* yang dihasilkan tidak sesuai dengan target yang diinginkan, bobot akan diperbarui selama proses pembelajaran. Proses ini berlanjut hingga kesalahan mencapai nilai minimum yang diharapkan atau hingga *output* mendekati target (Muis dan Setiyadi, 2020).

Beberapa sumber penelitian telah mengkaji terkait JST. Diantaranya penelitian oleh Khasanah dan Ulinnuha (2019) yang memprediksi biaya konsumsi bahan bakar gas menggunakan algoritma *backpropagation* memperoleh kesimpulan nilai MAPE yang dihasilkan termasuk dalam kategori baik dalam

kemampuan memprediksi dan memiliki akurasi yang cukup akurat. Sijabat dkk. (2020) juga menggunakan algoritma *backpropagation* untuk memprediksi harga komoditi pemetaan karakteristik konsumen pada produk kopi lokal nasional menghasilkan tingkat akurasi tinggi dengan *error* yang cukup kecil. Selain itu, Ariannor dan Razatillah (2022) yang memprediksi Nilai Tukar Petani (NTP). Penelitian tersebut menghasilkan kesimpulan tingkat keakuratan model jaringan saraf tiruan algoritma *backpropagation* dalam memprediksi NTP menghasilkan nilai MAPE yang rendah hingga masuk kategori sangat baik. Penelitian lain oleh 'Alim dan Murni (2023) memprediksi hasil pertandingan sepak bola Liga Premier Inggris memperoleh kesimpulan bahwa model JST mampu meminimalkan kesalahan prediksi dengan nilai *Mean Squared Error* (MSE) yang kecil dengan tingkat keakuratan prediksi pada data pelatihan cukup akurat. Terdapat pula penelitian oleh Rodia dan Ridla (2024) memprediksi nilai impor susu segar memperoleh kesimpulan *error* terkecil ditemukan pada lapisan 9 dan lapisan tersembunyi 7.

Berdasarkan uraian tersebut, penulis berusaha menerapkan metode JST untuk memprediksi kecepatan angin dalam mendeteksi gelombang air laut berdasarkan skala *Beaufort* yang tentunya akan sangat bermanfaat bagi masyarakat, terutama bagi nelayan dan nahkoda yang melewati jalur penyeberangan kapal Gresik-Bawean serta bagi otoritas pelabuhan dan Badan Meteorologi Klimatologi dan Geofisika (BMKG) yang memiliki wewenang untuk memberikan peringatan jika terjadi angin kencang dan gelombang tinggi. Oleh karena itu, penulis mengangkat judul “Prediksi Kecepatan Angin di Jalur Penyeberangan Kapal Gresik-Bawean Menggunakan Metode Jaringan Saraf Tiruan”.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana model jaringan saraf tiruan algoritma *backpropagation* dalam memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean?
2. Bagaimana pengelompokan gelombang air laut berdasarkan prediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean berdasarkan kategori skala *Beaufort*?
3. Bagaimana tingkat akurasi model JST algoritma *backpropagation* dalam memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah, tujuan yang ingin dicapai pada penelitian ini adalah:

1. Mendapatkan model jaringan saraf tiruan algoritma *backpropagation* dalam memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean.
2. Menganalisis hasil pengelompokan gelombang air laut berdasarkan prediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean berdasarkan kategori skala *Beaufort*.
3. Menganalisis tingkat akurasi model jaringan saraf tiruan algoritma *backpropagation* dalam memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean.

1.4 Manfaat Penelitian

Manfaat penelitian pada penelitian ini antara lain:

1. Bagi Penulis

Dapat memperluas wawasan dan memperdalam pemahaman mengenai jaringan saraf tiruan, khususnya dalam penerapan algoritma *backpropagation*.

2. Bagi Pembaca

Dapat menambah informasi dan referensi bacaan bagi peneliti selanjutnya terkait metode untuk memprediksi data.

3. Bagi Instansi

- a. Program Studi Matematika

Dapat menjadi referensi bagi mahasiswa dan dosen di program studi matematika yang melakukan penelitian serupa.

- b. BMKG

Dapat menjadi bahan evaluasi dalam memprediksi kecepatan angin dan gambaran gelombang air laut.

- c. Otoritas Pelabuhan

Dapat membantu otoritas pelabuhan dalam pengambilan keputusan terkait kebijakan pelayaran.

1.5 Batasan Masalah

Batasan masalah pada penelitian ini antara lain:

1. Variabel yang digunakan dalam penelitian ini saling berkaitan.

2. Penelitian ini tidak menggunakan validasi silang untuk memeriksa *overfitting*.
3. Penelitian ini menggunakan fungsi aktivasi sigmoid biner.
4. Model optimal ketika *error* < 0.001 .
5. Perancangan model prediksi menggunakan JST algoritma *backpropagation*.
6. Proses evaluasi model prediksi akan menggunakan MAPE dan MSE.
7. Untuk keperluan klasifikasi gelombang laut, hasil prediksi kecepatan angin dibulatkan dengan ketentuan: nilai desimal < 0.5 dibulatkan ke bawah, dan ≥ 0.5 dibulatkan ke atas.

1.6 Definisi Istilah

Dalam penelitian ini, beberapa istilah yang digunakan antara lain:

Backpropagation : Algoritma yang digunakan untuk melatih jaringan saraf tiruan dengan menghitung *error* antara keluaran prediksi jaringan dan keluaran yang diharapkan kemudian memperbarui bobot-bobot jaringan saraf secara iteratif untuk meminimalkan *error* tersebut.

Time series : Serangkaian data yang dikumpulkan dan direkam dalam urutan kronologis berdasarkan waktu.

<i>Neuron</i>	: Unit dasar yang meniru cara kerja neuron biologis di otak manusia.
<i>Layer</i>	: Kumpulan neuron yang bekerja secara bersamaan untuk memproses informasi.
<i>Multilayer</i>	: Arsitektur jaringan yang terdiri dari lebih dari satu lapisan neuron.
<i>Feed forward</i>	: Proses aliran data dari lapisan <i>input</i> ke lapisan <i>output</i> melalui lapisan tersembunyi secara linear tanpa adanya umpan balik.
<i>Data Training</i>	: Kumpulan data yang digunakan untuk melatih model pembelajaran mesin dalam proses klasifikasi.
<i>Data Testing</i>	: Kumpulan data yang digunakan untuk menguji performa model yang telah dilatih sebelumnya.
<i>Bobot</i>	: Nilai numerik yang digunakan untuk mengukur kekuatan koneksi antara neuron di satu lapisan dengan neuron di lapisan berikutnya.
<i>Bias</i>	: Nilai tambahan yang digunakan dalam setiap neuron untuk menggeser fungsi aktivasi.

Skala *Beaufort* : Sistem klasifikasi standar untuk mengukur dan mendeskripsikan kecepatan angin berdasarkan pengamatan visual terhadap dampak angin pada lingkungan sekitar.

BAB II

KAJIAN TEORI

2.1 Teori Pendukung

2.1.1 Normalisasi Data

Normalisasi data dilakukan dengan menyesuaikan data ke bentuk skala umum menggunakan *range* fungsi aktivasi *sigmoid biner* yaitu dengan interval $[0,1]$. Rumus untuk menghitung normalisasi adalah:

$$x'_k = \frac{x_k - x_{min}}{x_{max} - x_{min}} \quad (2.1)$$

dimana:

x'_k : Data normalisasi ke- k

x_k : Data aktual ke- k

x_{min} : Nilai minimum data x

x_{max} : Nilai maksimum data x

2.1.2 Metode Pelatihan

Secara umum, proses pelatihan jaringan saraf tiruan dibagi menjadi dua metode utama. Metode-metode ini mengatur bagaimana jaringan mempelajari dan menyesuaikan bobot berdasarkan data yang diberikan selama proses pelatihan (Walczak dan Cerpa, 2003).

1. *Supervised Training*

Metode pelatihan disebut *supervised* jika *output* yang diharapkan sudah diketahui sebelumnya. Dalam proses ini, setiap pola *input* diberikan ke *neuron* pada lapisan *input* dan kemudian diteruskan hingga mencapai

neuron di lapisan *output*. Pola *output* yang dihasilkan kemudian dibandingkan dengan pola *output* target. Jika terdapat perbedaan antara keduanya, maka akan terjadi kesalahan (*error*). Jika nilai kesalahan masih besar, pelatihan akan dilanjutkan hingga kesalahan tersebut berkurang.

2. *Unsupervised Training*

Selama proses pelatihan dengan metode ini, hasil yang diinginkan tidak dapat ditentukan, sehingga target *output* tidak diperlukan. Dalam pelatihan, nilai bobot diatur dalam rentang tertentu berdasarkan nilai *input* yang diberikan. Tujuan dari pelatihan ini adalah untuk mengklasifikasikan data ke dalam kategori-kategori tertentu untuk unit-unit yang memiliki kesamaan yang hampir serupa.

2.1.3 Jaringan Saraf Tiruan

Jaringan Syaraf Tiruan (JST) adalah model buatan yang meniru cara kerja otak manusia untuk mereplikasi proses pemikiran dan pengolahan informasi (Matondang, 2013). JST dikembangkan sebagai model matematis berdasarkan pemahaman manusia tentang cara kerja otak. Menurut (Herdianto, 2013) terdapat 3 lapis pada jaringan saraf tiruan, diantaranya:

1. Lapisan Masukan (*Input Layer*)

Pada tahap ini dilakukan proses *input* data berdasarkan informasi historis dan data terkini. Node-node yang terlibat dalam proses ini umumnya dikenal sebagai unit masukan, yang merepresentasikan variabel-variabel independen dalam suatu sistem atau model matematis.


2. Lapisan Tersembunyi (*Hidden Layer*)

Node-node pada lapisan ini dikenal sebagai *hidden units*, yang berada di antara lapisan masukan (*input layer*) dan lapisan keluaran (*output layer*). Satu lapisan tersembunyi umumnya cukup untuk memodelkan fungsi nonlinier. Sementara penambahan lapisan dapat meningkatkan kompleksitas dan membebani proses komputasi, namun dapat meningkatkan akurasi pada prediksi.

3. Lapisan Keluaran (*Output Layer*)

Lapisan ini menghasilkan *output* sebagai respons terhadap data yang diberikan pada lapisan masukan. Node-node pada lapisan ini dikenal sebagai unit keluaran, yang merepresentasikan nilai-nilai dari variabel dependen dalam model atau sistem yang dianalisis.

Berikut ilustrasi dari model JST (Putra, 2020):



Gambar 2.1 Model JST

Model pada JST ini terdiri dari *neuron* sebagai elemen dasar yang memproses informasi, dengan koneksi antar *neuron* yang membawa sinyal, di mana setiap koneksi memiliki bobot yang memengaruhi pemrosesan sinyal.

Fungsi aktivasi pada setiap *neuron* mengolah *input* dan menentukan *output* sinyal (Wati, 2011). Kualitas model JST secara matematis ditentukan oleh arsitektur jaringan yang mengatur pola hubungan antar *neuron*, metode pembelajaran yang menyesuaikan bobot, dan fungsi aktivasi yang mempengaruhi pemrosesan *input* dan *output* (Sutojo dkk., 2011). Berikut model matematis JST (Putra, 2020).

$$o_j = f \left(\sum_{k=1}^K x'_k \cdot w_{kj} + \beta_j \right) \quad (2.2)$$

$$o_m = f \left(\sum_{j=1}^J o_j \cdot w_{jm} + \theta_m \right) \quad (2.3)$$

$$\begin{aligned} y_i &= f \left(\sum_{m=1}^M o_m \cdot u_{mi} + \gamma_i \right) \\ &= f \left(\sum_{m=1}^M \left[f \left(\sum_{j=1}^J \left[f \left(\sum_{k=1}^K x'_k \cdot w_{kj} + \beta_j \right) \right] \cdot w_{jm} + \theta_m \right) \right] \cdot u_{mi} + \gamma_i \right) \end{aligned} \quad (2.4)$$

dimana:

o_j : *Output* dari unit tersembunyi ke- j

o_m : *Output* dari unit tersembunyi ke- m

y_i : *Output* dari unit keluaran ke- i

f : Fungsi aktivasi

x'_k : *Input* normalisasi ke- k

w_{kj} : Bobot yang menghubungkan unit masukan ke- k ke unit tersembunyi pertama ke- j

w_{jm} : Bobot yang menghubungkan unit tersembunyi ke- j ke unit tersembunyi kedua ke- m

u_{mi} : Bobot yang menghubungkan unit tersembunyi ke- m ke unit keluaran ke- i

β_j : Bias unit tersembunyi pertama ke- j

θ_m : Bias unit tersembunyi kedua ke- j

γ_i : Bias unit keluaran ke- i

K : Banyak unit masukan


J : Banyak unit tersembunyi pertama

M : Banyak unit tersembunyi kedua

2.1.4 Arsitektur Jaringan

Kualitas suatu model JST ditentukan oleh hubungan antara *neuron-neuron* di dalamnya, yang dikenal sebagai arsitektur jaringan. Setiap jaringan saraf tiruan (neural network) memiliki struktur dasar yang bersifat umum. Secara umum, jaringan ini selalu mengikuti satu di antara beberapa jenis arsitektur yang telah ditetapkan (Herdianto, 2013):


1. Jaringan Lapisan Tunggal (*Single Layer Net*)



Gambar 2.2 Jaringan Lapisan Tunggal

Pada jenis arsitektur ini, jaringan hanya terdiri dari unit masukan dan unit keluaran yang saling terhubung melalui bobot (*weight*). Nilai bobot tersebut mencerminkan kekuatan atau derajat pengaruh hubungan antara unit masukan dan keluaran.


2. Jaringan Lapisan Banyak (*Multilayer Net*)



Gambar 2.3 Jaringan Lapisan Banyak

Arsitektur jaringan ini terdiri dari lebih dari satu lapisan, dan setiap lapisan memiliki nilai bobot masing-masing. Jaringan ini memiliki unit masukan, unit tersembunyi, dan unit keluaran, yang semuanya saling terhubung melalui bobot. Jenis jaringan ini mampu menyelesaikan masalah yang lebih kompleks, tetapi proses pembelajarannya juga lebih sulit.

3. Jaringan Recurrent



Gambar 2.4 Jaringan Recurrent

Jaringan ini mirip dengan jaringan satu lapis maupun berlapis banyak, tetapi memiliki perbedaan yaitu adanya unit keluaran yang mengirimkan sinyal kembali ke unit masukan (disebut umpan balik atau *feedback*). Ciri khas jaringan ini adalah strukturnya yang sederhana karena hanya memiliki satu jalur umpan balik.

2.1.5 Fungsi Aktivasi

Fungsi aktivasi merupakan komponen dasar dalam JST yang berfungsi untuk menentukan *output* suatu unit sebelum diteruskan ke unit berikutnya, dengan cara mengubah sinyal *input* menjadi sinyal *output*. Setiap unit dalam satu *layer* pada JST umumnya menggunakan fungsi aktivasi yang sama. Agar dapat digunakan dalam pelatihan jaringan, fungsi aktivasi harus memenuhi syarat yaitu bersifat kontinu, mudah didiferensialkan, dan tidak mengalami penurunan nilai. Menurut Sutojo dkk. (2011) fungsi sigmoid biner merupakan salah satu fungsi aktivasi yang umum digunakan dalam JST, terutama dalam pelatihan menggunakan algoritma *backpropagation*. Fungsi ini memiliki rentang *output* antara 0 hingga 1, sehingga sesuai dengan kebutuhan JST yang mengharuskan nilai *output* berada dalam kisaran tersebut untuk mendukung proses propagasi kesalahan dan pembaruan bobot secara efektif. Berikut fungsi *sigmoid biner* (Fausett, 1994).

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (2.5)$$

dengan turunan

$$f'(x) = (f(x)(1 - f(x))) \quad (2.6)$$

dimana:

- $f(x)$: Fungsi aktivasi
 $f'(x)$: Turunan fungsi aktivasi
 x : Jumlah bobot sinyal *input*

2.1.6 *Backpropagation*

Metode pelatihan *backpropagation*, atau dikenal sebagai *generalized delta rule*, adalah teknik pelatihan terawasi yang bertujuan untuk meminimalkan kesalahan (*error*) pada *output* jaringan (Tambun dkk., 2018). Metode ini diterapkan pada jaringan dengan arsitektur *multilayer*, di mana sinyal mengalir maju (*feed forward*) melalui lapisan-lapisan dan pelatihan dilakukan menggunakan algoritma *backpropagation*. Seperti pada jaringan saraf tiruan umumnya, tujuan pelatihan dengan *backpropagation* adalah untuk mencapai keseimbangan antara kemampuan jaringan dalam menghafal data (*memorization*) dan kemampuannya untuk menggeneralisasi pola dari data yindang belum pernah dilihat (*generalization*) (Jumarwanto dkk., 2009). Terdapat tiga fase dalam melakukan pelatihan jaringan, diantaranya yaitu propagasi maju, propagasi balik, dan perubahan bobot dan bias. Berikut langkah-langkah dalam algoritma *backpropagation* menurut Jumarwanto dkk.:

1. Inisialisasi bobot dan bias awal.
2. Masuk ke tahap propagasi maju, setiap unit *input* ($x_k, k = 1, 2, \dots, K$) menerima sinyal *input* dan menyalurkan ke semua unit lapisan tersembunyi.
3. Setiap unit tersembunyi ($o_j, j = 1, 2, \dots, J$) memproses sinyal-sinyal *input* yang berbobot,

$$o_{net_j} = \sum_{k=1}^K x'_k w_{kj} + \beta_j \quad (2.7)$$

Untuk menghitung sinyal *output*-nya menggunakan fungsi aktivasi

$$o_j = f(o_{net_j}) = \frac{1}{1 + e^{-o_{net_j}}} \quad (2.8)$$

Kemudian hasilnya akan dikirimkan ke semua unit pada lapisan *output*.

4. Setiap unit keluaran ($y_i, i = 1, 2, \dots, I$) memproses sinyal *output* yang berbobot,

$$y_{net_i} = \sum_{j=1}^J o_j u_{ji} + \gamma_i \quad (2.9)$$

Untuk menghitung sinyal *output*-nya menggunakan fungsi aktivasi

$$y'_i = f(y_{net_i}) = \frac{1}{1 + e^{-y_{net_i}}} \quad (2.10)$$

5. Masuk ke tahap propagasi mundur, setiap unit keluaran (y_i) menerima target sesuai dengan sinyal *input* pelatihan, kemudian menghitung *error*

$$\delta_i = (y_i - y'_i) \cdot f'(y'_i) \quad (2.11)$$

dimana y_i adalah target *output* ke- i . Untuk memperbaiki nilai u_{ji} , maka hitung koreksi bobotnya

$$\Delta u_{ji} = \alpha \delta_i o_j \quad (2.12)$$

dimana α adalah learning rate. Untuk memperbaiki nilai γ_i maka hitung koreksi biasnya

$$\Delta \gamma_i = \alpha \delta_i \quad (2.13)$$

dan sekaligus mengirimkan δ_k ke lapisan sebelumnya.

6. Setiap unit dari lapisan tersembunyi (o_j) memproses semua sinyal *input* dari lapisan *output*

$$\delta_{net_j} = \sum_{i=1}^I \delta_i u_{ji} \quad (2.14)$$

untuk menghitung *error* maka kalikan dengan fungsi aktivasi yang sudah diturunkan

$$\delta_j = f'(o_{net_j}) \delta_{net_j} = o_j(1 - o_j) \sum_{i=1}^I \delta_i u_{ji} \quad (2.15)$$

kemudian menghitung koreksi bobot untuk memperbaiki nilai w_{kj}

$$\Delta w_{kj} = \alpha \delta_j x_k \quad (2.16)$$

menghitung koreksi bias untuk memperbaiki nilai β_j

$$\Delta \beta_j = \alpha \delta_j \quad (2.17)$$

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

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (2.18)$$

setiap unit keluaran dilakukan perubahan bobot

$$u_{ji}(\text{baru}) = u_{ji}(\text{lama}) + \Delta u_{ji} \quad (2.19)$$

8. Perubahan tiap bias di lapisan tersembunyi

$$\beta_j(\text{baru}) = \beta_j(\text{lama}) + \Delta \beta_j \quad (2.20)$$

perubahan tiap bias di lapisan keluaran

$$\gamma_i(\text{baru}) = \gamma_i(\text{lama}) + \Delta \gamma_i \quad (2.21)$$

9. Apabila *error* sudah sesuai maka tes kondisi berhenti.

2.1.7 Keakuratan Model Prediksi

Beberapa metode dapat digunakan untuk mengukur tingkat akurasi prediksi model JST. Satu diantara metode yang umum digunakan adalah *Mean*

Absolute Percentage Error (MAPE). MAPE dihitung dengan membagi kesalahan absolut pada setiap periode dengan nilai aktual dari periode tersebut, kemudian menghitung rata-rata persentase kesalahan absolut. MAPE memberikan gambaran tentang seberapa besar kesalahan prediksi dibandingkan dengan nilai aktual. Rumus MAPE yaitu (Herjanto, 2009):

$$MAPE = \frac{1}{I} \sum_{i=1}^I \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (2.22)$$

dimana:

y_i : Nilai aktual pada keluaran i

y'_i : Nilai prediksi keluaran i

I : Banyaknya unit di lapisan keluaran

Nilai MAPE yang lebih rendah menunjukkan bahwa hasil peramalan semakin akurat. Kategori penilaian terhadap nilai MAPE dapat dilihat pada tabel berikut (Lewis, 1982).

Tabel 2. 1 Kategori Nilai MAPE

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

Adapun cara lain untuk mengukur tingkat akurasi prediksi model JST yaitu dengan menggunakan *Mean Squared Error* (MSE). Semakin kecil nilai MSE, mendekati nol, semakin baik performa model tersebut dalam memprediksi data dengan akurasi tinggi. Berikut rumus MSE (Herjanto, 2009):

$$MSE = \frac{1}{I} \sum_{i=1}^I (y_i - y'_i)^2 \quad (2.23)$$

dimana:

y_i : Nilai aktual keluaran ke- i

y'_i : Nilai prediksi keluaran ke- i

I : Banyaknya unit di lapisan keluaran

2.1.8 Angin

Angin merupakan udara yang bergerak akibat tekanan udara sekitar dan perputaran bumi. Angin bergerak dari daerah bertekanan tinggi ke daerah bertekanan rendah. Karena adanya perbedaan suhu maka akan terjadi angin pula. Angin yang bertemu dengan energi panas memuai, menjadi lebih ringan, dan mengalami penurunan tekanan udara karena berkurangnya udara. Oleh karena itu, angin berkaitan dengan sinar matahari. Karena tekanan udara lebih rendah, panas matahari menimbulkan angin. Hembusan angin mempengaruhi tinggi gelombang, kecepatan dan panjang gelombang (Hidayat, 2005).

Tinggi dan periode gelombang dipengaruhi oleh kecepatan, durasi, dan arah angin, meskipun data yang dapat diukur umumnya hanya kecepatan angin. Kecepatan angin mengacu pada aliran udara yang bergerak dengan kecepatan tertentu, di mana semakin besar massa yang tergerak, semakin tinggi kecepatan angin. Kecepatan angin diukur sebagai aliran udara dari tekanan tinggi ke rendah, menggunakan anemometer atau berdasarkan skala Beaufort. Kecepatan angin dianggap konstan jika perubahan tidak melebihi 5 knot (2.5 m/s) dari kecepatan rata-rata. Berikut deskripsi kecepatan angin berdasarkan skala Beaufort

(Wirjohamidjojo dan Sugarin, 2008) (*National Meteorological Library and Archive*, 2023).

Tabel 2. 2 Skala Beaufort

Skala Beaufort	Kecepatan Angin (knot)	Deskripsi Keadaan Angin	Estimasi Tinggi Gelombang (m)	Deskripsi Keadaan 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 bergelombang hingga bergelombang 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	Bergelombang kasar hingga sangat kasar

Lanjutan Tabel 2.2 Skala Beaufort

Skala Beaufort	Kecepatan Angin (knot)	Deskripsi Keadaan Angin	Estimasi Tinggi Gelombang (m)	Deskripsi Keadaan Laut
8	34 – 40	Angin kencang (<i>gale</i>)	5.5	Bergelombang sangat kasar hingga tinggi
9	41 – 47	Badai lemah (<i>strong gale</i>)	7	Bergelombang tinggi
10	48 – 55	Badai sedang (<i>storm</i>)	9	Bergelombang sangat tinggi
11	56 – 63	Badai kuat (<i>violent storm</i>)	11.5	Bergelombang sangat tinggi
12	> 64	Badai topan (<i>hurricane</i>)	> 14	Gelombang fenomenal

2.1.9 Gelombang Laut

Gelombang laut adalah gerakan naik-turun massa air yang membentuk kurva sinusoidal (Wakkary dkk., 2017). Gelombang ini menyebabkan ayunan air yang terus-menerus di permukaan laut, dengan pergerakan yang tidak teratur dan tidak stabil. Ketidakaturan ini disebabkan oleh variasi arah perambatan gelombang dan bentuk gelombang yang tidak beraturan, terutama saat dipengaruhi oleh angin (Loupatty, 2013). Gelombang angin adalah jenis gelombang paling dominan di permukaan laut, baik dari segi frekuensi maupun energi (Kurniawan dkk., 2012). Angin yang bertiup memindahkan energinya ke air, menciptakan ketegangan di permukaan dan mengganggu air yang tenang, menghasilkan riak kecil. Semakin cepat kecepatan angin, semakin besar riak yang

terbentuk, dan jika angin terus bertiup, gelombang akan terbentuk. Semakin lama dan kuat angin bertiup, semakin besar gelombang laut yang dihasilkan (Hidayat, 2005).

Tinggi gelombang rata-rata, panjang gelombang, periode gelombang, dan tinggi gelombang maksimum saling berkaitan erat dengan kecepatan angin, sehingga sering digunakan dalam prediksi kecepatan angin. Panjang gelombang adalah jarak mendatar yang memisahkan dua puncak atau dua lembah berturut-turut, dengan satuan meter (Riadi, 2021), sementara periode gelombang adalah durasi waktu yang diperlukan untuk gelombang bergerak antara dua puncak atau dua lembah yang berurutan pada posisi tetap, diukur dalam satuan detik (Riadi, 2021). Tinggi gelombang rata-rata meningkat seiring dengan kecepatan angin yang lebih tinggi, karena angin yang lebih cepat memberikan lebih banyak energi ke permukaan air. Hubungan ini memungkinkan parameter-parameter gelombang laut digunakan dalam model prediksi untuk mengestimasi kecepatan angin, terutama di wilayah perairan terbuka.

2.2 Fenomena Angin dalam Al-Qur'an

Angin dan gelombang air laut bukan sekadar unsur alam, tetapi juga memiliki peran dalam kehidupan manusia, khususnya dalam bidang pelayaran. Kemampuan manusia untuk mengamati, menganalisis, dan memprediksi perubahan alam adalah bagian dari anugerah ilmu yang diberikan oleh Allah. Namun, ilmu ini harus digunakan dengan penuh kesadaran akan kebesaran-Nya dan sebagai bentuk syukur atas nikmat yang telah diberikan. Dengan memahami pola angin dan gelombang air laut, manusia dapat mengambil langkah preventif untuk menjaga keselamatan

perjalanan laut, sebagaimana yang ingin dicapai dalam penelitian ini terkait prediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean.

Allah Swt. telah menggambarkan fenomena angin dalam al-qur'an. Satu diantaranya dalam surat Asy-Syuraa ayat 33:

إِنْ يَشَأْ يُسْكِنِ الرِّيحَ فَيَظْلِلْنَ رَوَاكِدَ عَلَى ظَهْرِهِ ۚ إِنَّ فِي ذَلِكَ لَآيَاتٍ لِّكُلِّ صَبَّارٍ شَكُورٍ (٣٣)

Artinya: *"Jika Dia menghendaki, Dia akan menenangkan angin, maka jadilah kapal-kapal itu terhenti di permukaan laut. Sesungguhnya pada yang demikian itu terdapat tanda-tanda (kekuasaannya) bagi setiap orang yang banyak bersabar dan banyak bersyukur."* (Q.S. Asy-Syuraa [42] : 33) (Kementerian Agama RI, 2019).

Dalam tafsir Al-Wajiz, pakar fiqih dan tafsir Suriah, Prof. Dr. Wahbah Az-Zuhaili menjelaskan bahwa apabila Allah menghendaki, Dia dapat menghentikan hembusan angin yang menggerakkan kapal-kapal layar, sehingga kapal-kapal tersebut tetap diam di permukaan laut. Sesungguhnya, pergerakan dan pemberhentian kapal di atas air merupakan bukti kebesaran dan keagungan kekuasaan Allah. Hal ini menjadi pelajaran berharga bagi orang-orang beriman yang senantiasa bersabar dan bersyukur atas nikmat yang dianugerahkan oleh-Nya (Az-Zuhaili, 2015).

Dalam tafsir Ibnu Katsir, Allah Swt. menegaskan dalam surat Asy-Syura ayat 33 bahwa jika Dia menghendaki, Dia dapat menenangkan angin yang bertiup di laut, sehingga kapal-kapal yang berlayar tidak dapat bergerak, baik maju maupun mundur, dan hanya diam mengapung di tengah lautan. Fenomena ini menjadi bukti nyata dari kekuasaan-Nya, yang mengatur alam semesta sesuai dengan kehendak-Nya. Dalam ayat tersebut, Allah juga menyampaikan bahwa tanda-tanda kebesaran-Nya dapat dikenali oleh orang-orang yang memiliki kesabaran dan rasa syukur. Kesabaran yang dimaksud merujuk pada ketabahan dalam menghadapi kesulitan, penderitaan, serta cobaan, sedangkan rasa syukur mengacu pada penghargaan

terhadap nikmat yang diberikan Allah dalam kondisi kemakmuran dan kebahagiaan. Laut yang tunduk pada ketetapan Allah dan angin yang bertiup sesuai kebutuhan pelayaran merupakan manifestasi dari nikmat-Nya bagi makhluk-Nya. Oleh karena itu, ayat ini mengajarkan pentingnya kesadaran manusia terhadap kebesaran Allah melalui fenomena alam serta menanamkan sikap sabar dan syukur dalam menjalani kehidupan (Katsir, 2004).

Sejalan dengan penjelasan tersebut, tafsir Jalalain oleh As-Suyuthi dan Al-Mahally juga mengungkapkan bahwa jika Allah Swt. menghendaki, Dia dapat menenangkan angin, sehingga kapal-kapal yang berlayar di lautan menjadi terhenti dan tidak dapat bergerak. Peristiwa ini merupakan bukti nyata dari kekuasaan Allah yang mengatur alam sesuai dengan kehendak-Nya. Dalam kejadian tersebut, terdapat tanda-tanda kebesaran-Nya yang dapat dipahami oleh orang-orang beriman, yaitu mereka yang memiliki kesabaran dalam menghadapi musibah serta bersyukur ketika berada dalam keadaan senang dan sejahtera. Dengan demikian, ayat ini mengajarkan bahwa setiap aspek kehidupan, baik dalam kesulitan maupun kemudahan, harus disikapi dengan kesadaran akan keagungan Allah melalui sikap sabar dan syukur (As-Suyuthi dan Al-Mahally, 2015).

Satu di antara ayat lainnya yang menggambarkan fenomena angin yaitu surat Yunus ayat 2:

هُوَ الَّذِي يُسَيِّرُكُمْ فِي الْبَرِّ وَالْبَحْرِ حَتَّىٰ إِذَا كُنْتُمْ فِي الْفُلِّ وَجَرْتُمْ بِهِمْ بِرِيحٍ طَيِّبَةٍ وَفَرِحُوا بِهَا جَاءَتْهَا رِيحٌ عَاصِفٌ وَجَاءَهُمُ الْمَوْجُ مِنْ كُلِّ مَكَانٍ وَظَنُّوا أَنَّهُمْ أُحِيطَ بِهِمْ دَعَوُا اللَّهَ مُخْلِصِينَ لَهُ الدِّينَ ۚ لَئِنْ أَجَبْنَاهُمْ مِنْ هَٰذِهِ ۖ لَنُكَوِّنَنَّ مِنَ الشَّكِرِينَ ﴿٢٢﴾

Artinya: “Dialah (Allah) yang menjadikan kamu dapat berjalan di daratan (dan berlayar) di lautan sehingga ketika kamu berada di dalam kapal, lalu meluncurlah (kapal) itu membawa mereka dengan tiupan angin yang baik dan mereka bergembira karenanya. Kemudian, datanglah badai dan gelombang menimpanya dari segenap penjuru dan mereka pun mengira telah terkepung (bahaya). Maka,

mereka berdoa dengan mengikhlaskan ketaatan kepada-Nya (seraya berkata), 'Sekiranya Engkau menyelamatkan kami dari (bahaya) ini, pasti kami termasuk orang-orang yang bersyukur.' (Q.S. Yunus [10] : 22) (Kementerian Agama RI, 2019)

Dalam tafsir *al-Mishbah*, M. Quraish Shihab menjelaskan bahwa ayat ini mengingatkan manusia akan kekuasaan Allah SWT yang mutlak atas alam semesta, termasuk darat, laut, dan angin. Allah adalah pengendali perjalanan manusia, baik di darat maupun di laut. Ketika manusia merasa aman dengan kondisi alam seperti angin yang bertiup sepoi-sepoi untuk melancarkan pelayaran mereka seringkali larut dalam kesenangan dan melupakan Allah. Namun, ketika angin badai datang secara tiba-tiba, menciptakan gelombang besar yang mengancam keselamatan, manusia menjadi sadar betapa kecil dan lemahnya mereka.

Dalam situasi tersebut, menurut Quraish Shihab, manusia akan beralih kepada Allah, memohon pertolongan dengan tulus dan sepenuh hati. Fenomena ini menunjukkan fitrah manusia yang sebenarnya, yaitu kembali kepada Allah ketika berada dalam kondisi genting. Ayat ini juga mengandung pelajaran bahwa segala hal yang tampak indah atau mendukung perjalanan hidup dapat berubah menjadi bencana dalam sekejap jika tidak dikelola dengan baik atau jika manusia melupakan Allah (Shihab, 2013).

2.3 Kajian Topik Dengan Teori Pendukung

Berdasarkan landasan teori yang mendukung, penelitian ini dapat dirancang melalui beberapa tahapan. Tahapan penelitian kecepatan angin di jalur penyeberangan kapal Gresik-Bawean dimulai dengan pengumpulan data kecepatan angin dari jalur tersebut pada 1 Desember 2020 hingga 30 November 2023

sebanyak 1095 baris data dari arsip yang tersimpan di BMKG Maritim Tanjung Perak Surabaya. Setelah data terkumpul, dilakukan proses *trial and error* pembagian data. Data pelatihan sebanyak 50%, 60%, 70%, 80%, 90%, 91%, 92%, 93%, 94%, 95%, 96%, 97%, 98%, dan 99% sementara sisanya digunakan sebagai data pengujian. Kemudian penentuan arsitektur JST, untuk lapisan masukannya 5 unit, lalu pada lapisan tersembunyi dilakukan *trial and error* [3,2], [4,2], dan [4,3], dan lapisan keluarannya 1 unit. Setelah diperoleh proporsi data dan arsitektur jaringan terbaik, dilakukan normalisasi pada data latih menggunakan Persamaan 2.1 untuk memastikan semua data berada dalam rentang 0 hingga 1 sehingga sesuai untuk digunakan dalam model prediksi.

Algoritma backpropagation dimulai dengan penginisialisasian bobot dan bias awal yang ditentukan secara acak. Kemudian masuk ke tahap propagasi maju, setiap unit *input* ($x'_k, k = 1, 2, \dots, K$) menerima sinyal *input* dan menyalurkan ke semua unit lapisan tersembunyi. Setiap unit tersembunyi pertama ($o_j, j = 1, 2, \dots, J$) memproses sinyal-sinyal *input* dengan bobot yang dihitung dengan Persamaan 2.7 dan untuk menghitung sinyal *output*-nya menggunakan fungsi aktivasi pada Persamaan 2.8, berlaku selanjutnya ke unit tersembunyi kedua ($o_m, m = 1, 2, \dots, M$). Kemudian setiap unit keluaran ($y_i, i = 1, 2, \dots, I$) memproses sinyal *output* dengan bobot yang dihitung dengan Persamaan 2.9 dan untuk menghitung sinyal *output*-nya menggunakan fungsi aktivasi pada Persamaan 2.10. Jika *error output* telah terpenuhi, pada penelitian ini target *error*-nya yaitu 0.001, maka pelatihan berhenti. Namun jika *error* tidak mencapai target, maka masuk ke tahap selanjutnya yaitu propagasi mundur, setiap unit keluaran (y_i) menerima target sesuai dengan sinyal *input* pelatihan, kemudian menghitung *error* menggunakan

Persamaan 2.11 dan untuk memperbaiki nilai u_{ji} , maka hitung koreksi bobotnya menggunakan Persamaan 2.12 serta untuk memperbaiki nilai γ_i maka hitung koreksi biasnya menggunakan Persamaan 2.13. Selanjutnya setiap unit dari lapisan tersembunyi pertama (o_j) memproses semua sinyal *input* dari lapisan *output* menggunakan persamaan 2.14, untuk menghitung *error* maka kalikan dengan fungsi aktivasi sigmoid biner, seperti pada Persamaan 2.15, berlaku selanjutnya untuk lapisan tersembunyi kedua (o_m). Kemudian menghitung koreksi bobot untuk memperbaiki nilai w_{kj} dan w_{jm} menggunakan Persamaan 2.16 dan koreksi bias untuk memperbaiki nilai β_j dan θ_m menggunakan Persamaan 2.17. Tahap selanjutnya yaitu perubahan bobot dan bias, setiap unit tersembunyi (o_j maupun o_m) dilakukan perubahan bobot menggunakan Persamaan 2.18 dan setiap unit keluaran dilakukan perubahan bobot menggunakan Persamaan 2.19. Perubahan bias setiap unit tersembunyi dan unit keluaran dilakukan menggunakan Persamaan 2.20 dan 2.21. Jika setelah dilakukan perubahan bobot dan bias baru target *error* telah terpenuhi, maka pelatihan berhenti. Namun, jika target *error* belum terpenuhi maka kembali lagi dilakukan proses propagasi mundur dan seterusnya hingga target *error* terpenuhi. Model terbaik yang diperoleh selama tahap pelatihan digunakan dalam tahap pengujian. Tujuan dari pengujian ini adalah untuk mengevaluasi tingkat kesalahan (*error*) dari model yang telah dilatih. Apabila nilai kesalahan yang dihasilkan rendah, maka model tersebut layak digunakan untuk prediksi.

Selanjutnya, tingkat akurasi model diperiksa untuk memastikan hasil prediksi yang dihasilkan cukup akurat. Keakuratan model prediksi dapat diketahui berdasarkan nilai MAPE dan MSE. Perhitungan nilai MAPE menggunakan Persamaan 2.22 dan MSE menggunakan Persamaan 2.23. Semakin kecil nilai

MAPE dan MSE maka semakin baik model tersebut, sehingga prediksi semakin akurat. Selanjutnya dilakukan prediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean dan terakhir pengelompokan berdasarkan skala Beaufort. Setiap tahapan ini dirancang untuk memastikan model yang dihasilkan dapat memberikan prediksi yang andal dan relevan untuk mendukung keselamatan pelayaran.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif karena analisisnya berfokus pada data numerik yang diproses dengan metode statistik. Pendekatan kuantitatif melibatkan analisis yang sistematis dan objektif terhadap data, sehingga menghasilkan kesimpulan yang dapat diukur dan diuji. Selain itu, penelitian ini memanfaatkan berbagai sumber, seperti jurnal ilmiah dan buku, sebagai referensi dalam kajian literturnya.

3.2 Data dan Sumber Data

Data yang digunakan dalam penelitian ini bersifat sekunder, yaitu data kecepatan angin di wilayah penyeberangan kapal Gresik-Bawean pada 1 Desember 2020 hingga 30 November 2023 sebanyak 1095 baris data. Data diambil dari arsip pada 31 Juli 2024 di BMKG Maritim Tanjung Perak Surabaya. Data tersebut berupa data deret waktu harian.

Penelitian ini menggunakan aplikasi RStudio untuk mengolah data dengan variabel-variabel yang digunakan sebagai berikut:

$Y_{(t+1)}$: Kecepatan angin periode selanjutnya (knot)

$X_{1(t)}$: Kecepatan angin (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 gelombang maksimum (meter)

Dalam penelitian ini, seluruh variabel independen yang terdiri dari kecepatan angin dalam satuan knot (X_1), tinggi gelombang rata-rata dalam satuan meter (X_2), panjang gelombang dalam satuan meter (X_3), periode gelombang dalam satuan detik (X_4), dan tinggi maksimum gelombang dalam satuan meter (X_5) merupakan data yang diambil pada waktu t , yaitu waktu sekarang atau hari ini. Sedangkan variabel dependen yang berupa kecepatan angin periode selanjutnya (Y) merupakan data kecepatan angin pada waktu $t + 1$, yaitu satu periode sehari setelahnya.

3.3 Teknik Analisis Data

Adapun tahapan yang dilakukan dalam penelitian 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 kelompok, yaitu data pelatihan dan pengujian, guna melatih serta mengevaluasi model yang dikembangkan. Proporsi data pelatihan yang divariasikan sebesar 50%, 60%, 70%, 80%, 90%, 91%, 92%, 93%, 94%, 95%, 96%, 97%, 98%, dan 99%, sementara sisanya digunakan sebagai data pengujian. Arsitektur jaringan terdiri dari 5 neuron pada *input layer*, 1 neuron pada *output layer*, serta kombinasi *hidden layer*

[3,2], [4,2], dan [4,3] yang ditentukan melalui *trial and error* untuk memperoleh performa terbaik.

3. Normalisasi data.

Setelah proporsi data ditentukan, dilakukan proses normalisasi pada data latih menggunakan Persamaan 2.1 untuk memastikan semua data berada dalam rentang 0 hingga 1 sehingga sesuai untuk digunakan dalam model prediksi.

4. Penginisialisasian bobot awal.

Penginisialisasian bobot dan bias awal dilakukan dengan acak.

5. Pelatihan jaringan.

Pada tahap propagasi maju, setiap unit masukan menerima sinyal *input* dan menyalurkan ke semua unit lapisan tersembunyi. Unit lapisan tersembunyi pertama memproses sinyal menggunakan bobot (Persamaan 2.7) dan menghasilkan *output* melalui fungsi aktivasi sigmoid biner (Persamaan 2.8), dilanjutkan dengan unit lapisan tersembunyi kedua menggunakan persamaan yang sama. *Output* ini diteruskan ke unit keluaran, yang menghitung sinyal menggunakan bobot (Persamaan 2.9) dan fungsi aktivasi sigmoid biner (Persamaan 2.10). Jika *error output* mencapai target 0.001, pelatihan dihentikan. Jika belum, dilanjutkan ke propagasi mundur, unit keluaran menghitung *error* (Persamaan 2.11), memperbaiki bobot u_{ji} (Persamaan 2.12), dan bias γ_i (Persamaan 2.13). Unit tersembunyi memproses sinyal dari *output* (Persamaan 2.14), menghitung *error* (Persamaan 2.15), koreksi bobot w_{kj} (Persamaan 2.16), dan koreksi bias β_j (Persamaan 2.17). Bobot dan bias diperbarui menggunakan Persamaan 2.18 hingga 2.21. Proses diulang sampai target *error* tercapai.

6. Pengujian model.

Model terbaik yang diperoleh selama tahap pelatihan digunakan dalam tahap pengujian. Tujuan dari pengujian ini adalah untuk mengevaluasi tingkat kesalahan (*error*) dari model yang telah dilatih. Apabila nilai kesalahan yang dihasilkan rendah, maka model tersebut layak digunakan untuk prediksi.

7. Pengujian tingkat akurasi model.

Pengujian tingkat akurasi model dilakukan menggunakan nilai MAPE dan MSE. Perhitungan nilai MAPE menggunakan Persamaan 2.21 dan MSE menggunakan Persamaan 2.22.

8. Prediksi.

Model terbaik yang didapatkan digunakan untuk memprediksi kecepatan angin.


9. Pengelompokan gelombang air laut.


Prediksi kecepatan angin yang telah diperoleh dibulatkan dengan ketentuan: nilai desimal < 0.5 dibulatkan ke bawah, dan ≥ 0.5 dibulatkan ke atas. Berdasarkan prediksi tersebut, gelombang air laut dapat dikelompokkan sesuai kategori skala Beaufort.

3.4 Diagram Alir Penelitian

Langkah-langkah dalam proses prediksi menggunakan metode Jaringan Saraf

Tiruan algoritma *backpropagation* adalah sebagai berikut:





Gambar 3.1 Diagram Alir Penelitian

BAB IV


HASIL DAN PEMBAHASAN

4.1 Analisis Data

Penelitian ini menggunakan data kecepatan angin di wilayah penyeberangan kapal Gresik-Bawean yang diperoleh dari arsip BMKG dalam format Excel. Data tersebut diambil dari periode 1 Desember 2020 hingga 30 November 2023 sebanyak 1095 baris data, terlampir pada Lampiran 1. Variabel pada data tersebut yaitu kecepatan angin dalam satuan knot (X_1), tinggi gelombang rata-rata dalam satuan meter (X_2), panjang gelombang dalam satuan meter (X_3), periode gelombang dalam satuan detik (X_4), dan tinggi maksimum gelombang dalam satuan meter (X_5) sebagai variabel independen, serta kecepatan angin periode selanjutnya dalam satuan knot sebagai variabel dependen. Berikut deskripsi dan plot datanya.


Tabel 4.1 Deskripsi 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




Gambar 4.1 Grafik Kecepatan Angin dalam Knot

Grafik pada Gambar 4.1 menampilkan variasi kecepatan angin (dalam satuan knot) dari 1 Desember 2020 hingga 30 November 2023. Secara umum, kecepatan angin menunjukkan fluktuasi yang cukup tinggi dengan rentang antara 5 hingga 20 knot, dan beberapa puncak signifikan mencapai lebih dari 25 knot, seperti yang terlihat pada akhir tahun 2022. Berdasarkan pola musiman, terdapat kecenderungan peningkatan kecepatan angin pada awal tahun (Januari–Maret) dan akhir tahun (sekitar Oktober–Desember), yang kemungkinan dipengaruhi oleh peralihan musim hujan dan angin muson barat. Sementara itu, penurunan kecepatan angin cenderung terjadi pada pertengahan tahun, terutama sekitar Mei hingga Agustus, yang bertepatan dengan periode musim kemarau dan dominasi angin timur yang umumnya lebih stabil. Pola ini menunjukkan adanya siklus musiman yang perlu diperhatikan dalam analisis dan prediksi kecepatan angin, terutama untuk kepentingan pelayaran dan aktivitas laut lainnya.



Gambar 4.2 Grafik Tinggi Rata-rata Gelombang dalam Meter


Grafik pada Gambar 4.2 menunjukkan variasi tinggi rata-rata gelombang laut (dalam meter) dari 1 Desember 2020 hingga 30 November 2023. Terlihat bahwa tinggi gelombang mengalami fluktuasi signifikan, dengan puncak ekstrem yang mencapai lebih dari 3 meter, khususnya pada akhir tahun 2020 dan akhir 2022. Secara umum, tinggi gelombang berada di bawah 2 meter, namun meningkat tajam pada periode tertentu. Berdasarkan pola musiman, peningkatan tinggi gelombang umumnya terjadi pada bulan Desember hingga Maret, bertepatan dengan musim hujan dan pengaruh angin muson barat yang cenderung membawa gelombang lebih besar. Sebaliknya, penurunan tinggi gelombang cenderung terjadi antara Mei hingga September, yaitu saat musim kemarau dan pengaruh angin timur yang lebih stabil. Pola musiman ini penting untuk diperhatikan dalam konteks keselamatan pelayaran dan aktivitas kelautan lainnya, karena menunjukkan waktu-waktu yang berisiko tinggi terhadap gelombang besar.



Gambar 4.3 Grafik Panjang Gelombang dalam Meter

Grafik pada Gambar 4.3 menunjukkan variasi panjang gelombang laut (dalam meter) dari 1 Desember 2020 hingga 30 November 2023. Secara umum, panjang gelombang berkisar antara 20 hingga 50 meter, dengan beberapa lonjakan ekstrem yang melebihi 100 meter, khususnya pada pertengahan tahun 2022 dan awal 2023. Pola musiman terlihat cukup jelas, di mana peningkatan panjang gelombang


umumnya terjadi pada bulan Desember hingga Maret, seiring dengan musim hujan dan meningkatnya aktivitas angin muson barat yang cenderung memperbesar karakteristik gelombang. Sebaliknya, penurunan panjang gelombang cenderung terjadi pada bulan Mei hingga Oktober, saat musim kemarau berlangsung dan kondisi laut lebih tenang. Variasi ini penting untuk dipahami dalam konteks perencanaan aktivitas kelautan dan keselamatan pelayaran, karena panjang gelombang yang besar berpotensi meningkatkan risiko gangguan terhadap stabilitas kapal dan aktivitas laut lainnya.



Gambar 4.4 Grafik Periode Gelombang dalam Detik


Grafik pada Gambar 4.4 menunjukkan variasi periode gelombang laut (dalam detik) dari 1 Desember 2020 hingga 30 November 2023. Umumnya, periode gelombang berada dalam kisaran 3 hingga 5 detik dan menunjukkan kestabilan dari waktu ke waktu. Namun, terdapat lonjakan signifikan pada pertengahan dan akhir tahun 2022, dengan nilai periode melebihi 8 detik. Pola musiman dapat diamati, di mana periode gelombang cenderung meningkat pada bulan Desember hingga Maret, yang bertepatan dengan musim hujan dan intensitas angin yang lebih tinggi. Sebaliknya, penurunan periode gelombang umumnya terjadi pada bulan Mei hingga Oktober saat musim kemarau, ketika angin dan aktivitas gelombang cenderung melemah. Periode gelombang yang lebih panjang biasanya berkaitan dengan

gelombang yang lebih kuat dan berenergi besar, sehingga pemantauan terhadap pola ini penting untuk keselamatan dan perencanaan pelayaran.



Gambar 4.5 Grafik Tinggi Maksimum Gelombang dalam Meter

Grafik pada Gambar 4.5 menunjukkan variasi tinggi maksimum gelombang laut (dalam meter) dari 1 Desember 2020 hingga 30 November 2023. Terlihat bahwa tinggi maksimum gelombang mengalami fluktuasi yang cukup signifikan sepanjang periode tersebut, dengan beberapa puncak ekstrem yang mencapai lebih dari 4 meter. Lonjakan tertinggi tercatat terjadi pada akhir tahun 2020 dan awal tahun 2023. Jika diamati lebih lanjut, terdapat pola musiman yang cukup konsisten, di mana peningkatan tinggi maksimum gelombang umumnya terjadi pada bulan Desember hingga Maret. Periode ini bertepatan dengan musim hujan dan dominasi angin baratan, yang menyebabkan kondisi laut menjadi lebih bergelombang. Sebaliknya, penurunan tinggi maksimum gelombang biasanya terjadi pada bulan Mei hingga Oktober, yang merupakan musim kemarau dengan karakteristik laut yang lebih tenang. Pola ini mencerminkan pengaruh musim angin tahunan terhadap dinamika gelombang laut di wilayah perairan Indonesia, khususnya di jalur penyeberangan laut Gresik–Bawean.



Gambar 4.6 Grafik Kecepatan Angin Periode Selanjutnya dalam Knot

Grafik pada Gambar 4.6 menunjukkan variasi kecepatan angin pada periode selanjutnya (dalam knot) dari 1 Desember 2020 hingga 30 November 2023. Secara umum, grafik memperlihatkan fluktuasi kecepatan angin yang cukup signifikan dari hari ke hari, dengan kisaran nilai antara hampir 0 hingga lebih dari 25 knot. Terlihat bahwa puncak-puncak kecepatan angin yang tinggi terjadi terutama pada awal tahun, yakni sekitar Januari hingga Maret, yang berkaitan erat dengan musim angin barat atau angin muson barat yang membawa udara lembap dan kencang dari Samudra Hindia. Peningkatan lainnya juga terlihat pada akhir tahun, sekitar November hingga Desember, yang menjadi fase transisi menjelang musim hujan. Sebaliknya, penurunan kecepatan angin umumnya terjadi pada pertengahan tahun, sekitar Mei hingga September, seiring dengan dominasi angin timur yang cenderung lebih kering dan tenang, mencerminkan musim kemarau di wilayah Indonesia. Pola musiman ini mencerminkan siklus angin tahunan yang dipengaruhi oleh pergerakan matahari dan distribusi tekanan udara di wilayah tropis.

4.2 Penentuan Data dan Arsitektur Jaringan

Dalam penelitian ini, data dibagi menjadi dua bagian, yaitu data pelatihan (*training*) dan data pengujian (*testing*). Data pelatihan digunakan untuk melatih jaringan selama proses pembelajaran, sedangkan data pengujian dimanfaatkan

untuk mengevaluasi hasil pelatihan dengan membandingkan tingkat kesalahan terhadap nilai aktual. Pembagian dilakukan dengan proporsi di mana jumlah data pelatihan lebih besar dibandingkan data pengujian. Berikut merupakan rincian pembagian data yang digunakan. JST yang digunakan dalam penelitian ini menerapkan algoritma *backpropagation* dengan arsitektur *multilayer*, yaitu jaringan yang terdiri atas *input layer*, *hidden layer*, dan *output layer*, di mana setiap lapisan memiliki sejumlah neuron. Pemilihan arsitektur jaringan yang optimal dilakukan melalui pendekatan *trial and error*, dengan hasil lengkap pada Lampiran 2. Berikut ini merupakan proporsi pembagian data latih dan uji yang digunakan, karena menghasilkan nilai MAPE dan MSE terkecil.

Tabel 4.2 Proporsi Pembagian Data

Data Pelatihan : Pengujian	<i>Input Layer</i>	<i>Hidden Layer</i>	<i>Output Layer</i>	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

Pada Tabel 4.2 menunjukkan bahwa arsitektur jaringan dengan performa terbaik, ditinjau dari nilai MAPE dan MSE terkecil, yaitu arsitektur satu *input layer* dengan lima neuron, dua *hidden layer* masing-masing dengan tiga neuron pada lapisan pertama dan dua neuron pada lapisan kedua, serta satu *output layer* dengan satu neuron. Oleh karena itu, arsitektur (5-3-2-1) dipilih sebagai rancangan JST dalam penelitian ini.

4.3 Normalisasi Data

Proses pelatihan jaringan dapat dipercepat apabila data terlebih dahulu dinormalisasi ke dalam rentang nilai yang sesuai dengan fungsi aktivasi yang digunakan. Mengingat penelitian ini menggunakan fungsi aktivasi sigmoid biner, maka data dinormalisasi ke dalam rentang 0 hingga 1 agar selaras dengan karakteristik fungsi tersebut. Data yang dinormalisasi yaitu data latih sebanyak 1018 baris data. Secara matematis, perhitungan normalisasi menggunakan Persamaan (2.1). Berikut contoh perhitungannya.

1. Hasil normalisasi data variabel X_1

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

$$x'_{12} = \frac{3.595-1.15}{25.35-1.15} = 0.101033058$$

$$x'_{13} = \frac{10.63-1.15}{25.35-1.15} = 0.391735537$$

2. Hasil normalisasi data variabel X_2

$$x'_{21} = \frac{0.255-0.005}{3.24-0.005} = 0.077279753$$

$$x'_{22} = \frac{0.15-0.005}{3.24-0.005} = 0.044822257$$

$$x'_{23} = \frac{0.215-0.005}{3.24-0.005} = 0.064914992$$

3. Hasil normalisasi data variabel X_3

$$x'_{31} = \frac{34.885-9.385}{134.155-9.385} = 0.204376052$$

$$x'_{32} = \frac{31.81-9.385}{134.155-9.385} = 0.179730704$$

$$x'_{33} = \frac{18.16-9.385}{134.155-9.385} = 0.070329406$$

4. Hasil normalisasi data variabel X_4

$$x'_{41} = \frac{4.685-2.34}{9.63-2.34} = 0.321673525$$

$$x'_{42} = \frac{4.48-2.34}{9.63-2.34} = 0.293552812$$

$$x'_{43} = \frac{3.2-2.34}{9.63-2.34} = 0.117969822$$

5. Hasil normalisasi data variabel X_5

$$x'_{51} = \frac{0.34-0.01}{4.265-0.01} = 0.077555817$$

$$x'_{52} = \frac{0.195-0.01}{4.265-0.01} = 0.043478261$$

$$x'_{53} = \frac{0.285-0.01}{4.265-0.01} = 0.064629847$$

6. Hasil normalisasi data variabel Y


$$y'_1 = \frac{3.595-1.15}{25.35-1.15} = 0.101033058$$

$$y'_2 = \frac{10.63-1.15}{25.35-1.15} = 0.391735537$$

$$y'_3 = \frac{11.28-1.15}{25.35-1.15} = 0.418595041$$

Data normalisasi data latih dan uji dapat dilihat pada Lampiran 3 dan 4.


Berikut ini disajikan grafik dari data variabel dependen dan independen yang telah melalui proses normalisasi.



Gambar 4.7 Grafik Hasil Normalisasi pada Variabel Independen

Grafik pada Gambar 4.7 menunjukkan lima variabel independen yang telah dinormalisasi, yaitu kecepatan angin (kuning), tinggi rata-rata gelombang (oranye), panjang gelombang (hijau), periode gelombang (merah), dan tinggi maksimum gelombang (ungu).

gelombang (ungu), pada lintasan penyeberangan Gresik–Bawean pada periode 1 Desember 2020 hingga 30 November 2023. Normalisasi dilakukan untuk memastikan bahwa seluruh variabel berada pada skala yang sebanding, sehingga meminimalkan bias dalam proses pelatihan model.



Gambar 4.8 Grafik Hasil Normalisasi Kecepatan Angin Periode Selanjutnya

Grafik pada Gambar 4.8 menampilkan data kecepatan angin periode selanjutnya yang telah melalui proses normalisasi, terhitung dari tanggal 1 Desember 2020 hingga 30 November 2023. Berdasarkan grafik, terlihat bahwa nilai kecepatan angin mengalami fluktuasi yang cukup tinggi sepanjang periode pengamatan dan tidak menunjukkan pola yang stasioner. Terdapat pola musiman dan beberapa lonjakan ekstrem, terutama pada akhir tahun 2022 hingga awal 2023. Pola ini mengindikasikan bahwa data kecepatan angin bersifat nonlinier dan sangat dipengaruhi oleh waktu, sehingga penggunaan metode JST menjadi relevan karena mampu menangani kompleksitas data seperti ini.

4.4 *Backpropagation*

4.4.1 Inisialisasi Bobot dan Bias Awal

Kombinasi arsitektur jaringan terbaik yang digunakan yaitu satu *input layer* dengan lima neuron, dua *hidden layer* yang masing-masing terdiri dari tiga neuron pada *hidden layer* pertama dan dua neuron pada *hidden layer* kedua, serta

satu *output layer* dengan satu neuron. Setiap lapisan diberikan inisialisasi bobot untuk menghubungkan antar neuron. Bobot ini mencerminkan tingkat kepentingan hubungan antar neuron. Semakin besar nilainya, semakin signifikan kontribusinya terhadap proses jaringan. Inisialisasi bobot awal memiliki peran penting dalam kemampuan jaringan untuk melakukan generalisasi terhadap data pelatihan. Pada penelitian ini, proses inisialisasi bobot dan bias dilakukan secara acak menggunakan perangkat lunak RStudio. Meskipun dilakukan secara acak, proses ini tidak memengaruhi kemampuan jaringan untuk mencapai konvergensi terhadap nilai akhir yang stabil.

Berikut pada Tabel 4.3 disajikan hasil yang dinotasikan dengan w_{kj} , di mana baris ke- k menyatakan variabel independen beserta nilai biasnya, sedangkan kolom ke- j merepresentasikan neuron pada *hidden layer* pertama yang terdiri dari tiga unit.

Tabel 4.3 Bobot awal dan Bias *Input Layer* ke *Hidden Layer* Pertama

Variabel	$w[k,]$	$w[, j]$		
		w_{k1}	w_{k2}	w_{k3}
Bias	β_j	-0.08658011	0.6775081	-1.53428157
x_1	w_{1j}	1.32252443	1.1177719	-1.8170016
x_2	w_{2j}	0.63970204	1.3840475	0.35563308
x_3	w_{3j}	1.17478657	1.2839409	0.86390468
x_4	w_{4j}	0.11629031	-0.9764798	-0.08051261
x_5	w_{5j}	-2.93084636	0.9908363	-0.96248032

Bobot awal dan bias yang menghubungkan neuron pada *hidden layer* pertama ke *hidden layer* kedua disajikan pada Tabel 4.4. Notasi w_{jm} digunakan untuk merepresentasikan hubungan tersebut, di mana baris ke- j menunjukkan

neuron pada *hidden layer* pertama beserta biasnya, sedangkan kolom ke- m mengacu pada neuron pada *hidden layer* kedua yang terdiri dari dua unit.

Tabel 4.4 Bobot Awal dan Bias *Hidden Layer* Pertama ke *Hidden Layer* Kedua

$w[j,]$	$w[, m]$	
	w_{j1}	w_{j2}
θ_m	0.112311	-0.71862122
w_{1m}	-0.2576519	-0.54787228
w_{2m}	1.4834263	1.52752066
w_{3m}	0.6776003	-0.03994143

Setelah penetapan bobot awal dan bias dari *hidden layer* pertama ke *hidden layer* kedua, langkah selanjutnya adalah menentukan bobot awal dan bias yang menghubungkan neuron pada *hidden layer* kedua ke *output layer*. Notasi u_{mi} digunakan untuk menyatakan hubungan ini, di mana baris ke- m merepresentasikan neuron pada *hidden layer* kedua beserta biasnya, sedangkan kolom ke- i mengacu pada *output layer* yang terdiri dari satu neuron. Berikut pada Tabel 4.5 disajikan bobot awal dan bias pada *hidden layer* kedua ke *output layer*.

Tabel 4.5 Bobot Awal dan Bias *Hidden Layer* Kedua ke *Output Layer*

$u[m,]$	$u[, i]$
	u_{m1}
γ_i	0.3840873
u_{1i}	2.2391646
u_{2i}	1.7539743

Setelah setiap lapisan jaringan memiliki bobot awal dan bias yang telah ditetapkan, proses pelatihan JST dapat mulai dilaksanakan.

4.4.2 Propagasi Maju

Tahap *forward propagation* (propagasi maju) dilakukan untuk menghitung nilai *output* pada *hidden layer* maupun *output layer*. Melalui Persamaan (2.7), sinyal *input* yang diteruskan dari *input layer* ke *hidden layer* pertama diperoleh dengan menghitung kontribusi bias serta seluruh *input* yang telah dikalikan dengan bobot pada masing-masing neuron di *hidden layer* pertama, sebagaimana ditunjukkan berikut ini.

$$\begin{aligned}
 o_{net_1} &= [(0.178099174 \times 1.32252443) + (0.077279753 \times \\
 &\quad 0.63970204) + (0.204376052 \times 1.17478657) + \\
 &\quad (0.321673525 \times 0.11629031) + (0.077555817 \times \\
 &\quad (-2.93084636))] + (-0.08658011) \\
 &= 0.248597985
 \end{aligned}$$

$$\begin{aligned}
 o_{net_2} &= [(0.178099174 \times 1.1177719) + (0.077279753 \times \\
 &\quad 1.3840475) + (0.204376052 \times 1.2839409) + \\
 &\quad (0.321673525 \times (-0.9764798)) + (0.077555817 \times \\
 &\quad 0.9908363)] + 0.6775081 \\
 &= 1.008685391
 \end{aligned}$$

$$\begin{aligned}
 o_{net_3} &= [(0.178099174 \times (-1.8170016)) + (0.077279753 \times \\
 &\quad 0.35563308) + (0.204376052 \times 0.86390468) + \\
 &\quad (0.321673525 \times (-0.08051261)) + (0.077555817 \times \\
 &\quad (-0.96248032))] + (-1.53428157) \\
 &= -1.754388111
 \end{aligned}$$

Tabel 4.6 Sinyal *Input* dari *Input Layer* ke *Hidden Layer* Pertama

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

Pada Tabel 4.6, sinyal *input* yang mengalir dari *input layer* menuju *hidden layer* pertama dinotasikan dengan o_{net_j} , di mana indeks j menunjukkan jumlah neuron yang terdapat pada *hidden layer* pertama.

Setelah setiap neuron pada *hidden layer* pertama menerima bias serta seluruh *input* yang telah dikalikan dengan bobotnya, langkah selanjutnya adalah menghitung sinyal *output* pada *hidden layer* pertama (o_j) menggunakan fungsi aktivasi sesuai dengan Persamaan (2.8). Hasil perhitungan disajikan pada Tabel 4.7 dan berikut perhitungan matematisnya:

$$\begin{aligned}
 o_1 &= f(o_{net_1}) = \frac{1}{1 + e^{-o_{net_1}}} = \frac{1}{1 + e^{-0.248597985}} = 0.561831387 \\
 o_2 &= f(o_{net_2}) = \frac{1}{1 + e^{-o_{net_2}}} = \frac{1}{1 + e^{-1.008685391}} = 0.732762799 \\
 o_3 &= f(o_{net_3}) = \frac{1}{1 + e^{-o_{net_3}}} = \frac{1}{1 + e^{-(-1.754388111)}} = 0.147494583
 \end{aligned}$$

Tabel 4.7 Sinyal *Output* di *Hidden Layer* Pertama

o_j	
o_1	0.561831387
o_2	0.732762799
o_3	0.147494583

Selanjutnya, dengan menggunakan metode perhitungan yang sama berdasarkan Persamaan (2.7), diperoleh sinyal *input* yang diteruskan dari *hidden layer* pertama ke *hidden layer* kedua. Perhitungan sinyal *input* pada *hidden layer*

kedua dilakukan dengan memanfaatkan nilai *output* dari *hidden layer* pertama yang tercantum pada Tabel 4.7. Karena *hidden layer* kedua terdiri dari dua neuron, maka dihasilkan dua nilai o_{net_m} pada Tabel 4.8. Berikut perhitungan matematisnya.

$$\begin{aligned} o_{net_1} &= [(0.561831387 \times (-0.2576519)) + (0.732762799 \times \\ &\quad 1.4834263) + (0.147494583 \times 0.6776003)] + 0.112311 \\ &= 1.154496057 \end{aligned}$$

$$\begin{aligned} o_{net_2} &= [(0.561831387 \times (-0.54787228)) + (0.732762799 \times \\ &\quad 1.52752066) + (0.147494583 \times (-0.03994143))] + \\ &\quad (-0.71862122) \\ &= 0.086986107 \end{aligned}$$

Tabel 4.8 Sinyal *Input* dari *Hidden Layer* Pertama ke *Hidden Layer* Kedua

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

Sinyal *input* yang mengalir dari *hidden layer* pertama menuju *hidden layer* kedua dinotasikan dengan o_{net_m} , di mana indeks m menunjukkan jumlah neuron yang terdapat pada *hidden layer* kedua.

Selanjutnya untuk mengaktifkan sinyal *output* pada *hidden layer* kedua (o_m) dengan menghitung menggunakan fungsi aktivasi sesuai dengan Persamaan (2.8), dengan perhitungan sebagai berikut.

$$o_1 = f(o_{net_1}) = \frac{1}{1 + e^{-o_{net_1}}} = \frac{1}{1 + e^{-1.154496057}} = 0.760331182$$

$$o_2 = f(o_{net_2}) = \frac{1}{1 + e^{-o_{net_2}}} = \frac{1}{1 + e^{-0.086986107}} = 0.521732825$$

Tabel 4.9 Sinyal *Output* di *Hidden Layer* Kedua

o_m	
o_1	0.760331182
o_2	0.521732825

Hasil pada Tabel 4.9 selanjutnya digunakan untuk menghitung sinyal *input* yang mengalir dari *hidden layer* kedua ke *output layer* (y_{net_i}) dengan menerapkan Persamaan (2.9). Hasil perhitungan ditampilkan pada Tabel 4.10 dengan perhitungan matematis sebagai berikut.

$$\begin{aligned}
 y_{net_1} &= [(0.760331182 \times 2.2391646) + (0.521732825 \times \\
 &\quad 1.7539743)] + 0.3840873 \\
 &= 3.001699933
 \end{aligned}$$

Tabel 4.10 Sinyal *Input* dari *Hidden Layer* Kedua ke *Output Layer*

y_{net_i}	
y_{net_1}	3.001699933

Kemudian dihitung *output*-nya menggunakan fungsi aktivasi pada Persamaan (2.10). Hasil perhitungan ditampilkan pada Tabel 4.11 dengan perhitungan matematis sebagai berikut.

$$y_1 = f(y_{net_1}) = \frac{1}{1 + e^{-y_{net_1}}} = \frac{1}{1 + e^{-3.001699933}} = 0.952650865$$

Tabel 4.11 Sinyal *Output* pada *Output layer*

y_i	
y_1	0.952650865

Dimana y_i merupakan sinyal *output* pada *output layer* dengan indeks i menunjukkan banyaknya neuron pada *output layer*.

4.4.3 Propagasi Mundur

Tahap *backpropagation* dilakukan untuk menghitung koreksi terhadap bobot dan bias secara berurutan dari belakang ke depan. Berdasarkan hasil pada tahap sebelumnya, nilai *output* dari *output layer* dapat dilihat pada Tabel 4.11. Selanjutnya, Persamaan (2.11) digunakan untuk menghitung selisih antara *output* yang dihasilkan oleh jaringan dan target yang diharapkan, sehingga diperoleh nilai *error* sebagai berikut.

$$\begin{aligned}\delta_1 &= (0.178099174 - 0.952650865)0.952650865(1 - 0.952650865) \\ &= -0.034937854\end{aligned}$$

Untuk melakukan pembaruan bobot (u_{mi}) dan bias (γ_i) pada lapisan sebelumnya, yaitu *hidden layer* kedua, digunakan nilai faktor kesalahan yang telah diperoleh, dengan *learning rate* (α) sebesar 0,001 sesuai dengan Persamaan (2.12) dan (2.13). Hasil koreksi bobot dan bias dari *hidden layer* kedua terhadap *output layer* dinotasikan dengan Δu_{mi} , di mana baris ke- m merepresentasikan neuron pada *hidden layer* kedua beserta biasnya, sedangkan kolom ke- i mengacu pada neuron pada *output layer* yang berjumlah satu disajikan pada Tabel 4.12.

$$\Delta u_{11} = 0.001(-0.034937854)0.760331182 = -2.65643 \times 10^{-5}$$

$$\Delta u_{21} = 0.001(-0.034937854)0.521732825 = -1.82282 \times 10^{-5}$$

$$\Delta \gamma_1 = 0.001(-0.034937854) = -3.49379 \times 10^{-5}$$

Tabel 4.12 Koreksi Bobot dan Bias *Hidden Layer* Kedua ke *Output Layer*

$\Delta u[m,]$	$\Delta u[, i]$
	Δu_{m1}
$\Delta \gamma_1$	-3.49379×10^{-5}
Δu_{1i}	-2.65643×10^{-5}
Δu_{2i}	-1.82282×10^{-5}

Setiap *hidden layer* menerima koreksi bobot dan bias dalam bentuk *input* delta dari lapisan di atasnya, yaitu *output layer*. Informasi ini kemudian digunakan untuk menghitung faktor kesalahan δ_{net_m} pada masing-masing neuron di *hidden layer*, sesuai dengan Persamaan (2.14). Adapun hasil perhitungan *error* pada *hidden layer* kedua disajikan sebagai berikut.

$$\delta_{net_1} = -0.034937854(2.2391646) = -0.078231605$$

$$\delta_{net_2} = -0.034937854(1.7539743) = -0.061280097$$

Selanjutnya, aktivasi dilakukan dengan menggunakan Persamaan (2.15), dan hasil perhitungannya disajikan sebagai berikut.

$$\begin{aligned}\delta_1 &= -0.078231605 \times 0.760331182(1 - 0.760331182) \\ &= -0.014255964\end{aligned}$$

$$\begin{aligned}\delta_2 &= -0.061280097 \times 0.521732825(1 - 0.521732825) \\ &= -0.015291081\end{aligned}$$

Tabel 4.13 Nilai *Error* pada *Hidden Layer* Kedua

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

Setelah diperoleh nilai *error* pada *hidden layer* kedua yang telah melalui fungsi aktivasi (δ_m) pada Tabel 4.13, nilai ini digunakan untuk memperbarui bobot dan bias yang menghubungkan *hidden layer* pertama ke *hidden layer* kedua menggunakan Persamaan (2.16) dan (2.17). Notasi Δw_{jm} digunakan untuk menunjukkan perubahan bobot, di mana baris ke- j mewakili neuron pada *hidden layer* pertama beserta biasnya, dan kolom ke- m mengacu pada neuron-neuron di *hidden layer* kedua yang berjumlah dua. Perhitungan lengkap ditunjukkan sebagai berikut dan hasilnya pada Tabel 4.14.

$$\Delta w_{11} = 0.001(-0.014255964)0.561831387 = -8.00945 \times 10^{-6}$$

$$\Delta w_{21} = 0.001(-0.014255964)0.732762799 = -1.04462 \times 10^{-5}$$

$$\Delta w_{31} = 0.001(-0.014255964)0.147494583 = -2.10268 \times 10^{-6}$$

$$\Delta w_{12} = 0.001(-0.015291081)0.561831387 = -8.59101 \times 10^{-6}$$

$$\Delta w_{22} = 0.001(-0.015291081)0.732762799 = -1.12047 \times 10^{-5}$$

$$\Delta w_{32} = 0.001(-0.015291081)0.147494583 = -2.25535 \times 10^{-6}$$

$$\Delta \theta_1 = 0.001(-0.014255964) = -1.4256 \times 10^{-5}$$

$$\Delta \theta_2 = 0.001(-0.015291081) = -1.52911 \times 10^{-5}$$

Tabel 4.14 Koreksi Bobot dan Bias *Hidden Layer* Pertama ke *Hidden Layer* Kedua

$\Delta w[j,]$	$\Delta w[, m]$	
	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 perhitungan yang sama dilakukan untuk memperoleh nilai δ_{net_j} dan δ_j dengan menggunakan Persamaan (2.14) dan (2.15). Hasil perhitungan pada Tabel 4.15 dan perhitungan matematisnya sebagai berikut.

$$\begin{aligned} \delta_{net_1} &= -0.014255964(-0.2576519) + \\ &\quad (-0.015291081)(-0.54787228) \\ &= 0.012050635 \end{aligned}$$

$$\begin{aligned} \delta_{net_2} &= -0.014255964(1.4834263) + (-0.015291081)(1.52752066) \\ &= -0.044505113 \end{aligned}$$

$$\begin{aligned}
\delta_{net_3} &= -0.014255964(0.6776003) + \\
&\quad (-0.015291081)(-0.03994143) \\
&= -0.009049098 \\
\delta_1 &= 0.012050635 \times 0.561831387(1 - 0.561831387) \\
&= 0.002966588 \\
\delta_2 &= -0.044505113 \times 0.732762799(1 - 0.732762799) \\
&= -0.008715057 \\
\delta_3 &= -0.009049098 \times 0.147494583(1 - 0.147494583) \\
&= -0.001137833
\end{aligned}$$

Tabel 4.15 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

Koreksi terhadap bobot dan bias antara *input layer* ke *hidden layer* pertama dilakukan menggunakan Persamaan (2.16) dan (2.17). Perubahan bobot dinotasikan sebagai Δw_{kj} , di mana baris ke- k merepresentasikan variabel independen beserta biasnya, dan kolom ke- j mengacu pada neuron-neuron di *hidden layer* pertama yang berjumlah tiga. Hasil perhitungan disajikan pada Tabel 4.16 dan berikut perhitungan matematisnya.

$$\begin{aligned}
\Delta w_{11} &= 0.001(0.002966588)1.32252443 = 3.92338 \times 10^{-6} \\
\Delta w_{21} &= 0.001(0.002966588)0.63970204 = 1.89773 \times 10^{-6} \\
\Delta w_{31} &= 0.001(0.002966588)1.17478657 = 3.48511 \times 10^{-6} \\
\Delta w_{41} &= 0.001(0.002966588)0.11629031 = 3.44985 \times 10^{-7}
\end{aligned}$$

$$\begin{aligned}
\Delta w_{51} &= 0.001(0.002966588)(-2.93084636) = -8.69461 \times 10^{-6} \\
\Delta w_{12} &= 0.001(-0.008715057)1.1177719 = -9.74145 \times 10^{-6} \\
\Delta w_{22} &= 0.001(-0.008715057)1.3840475 = -1.20621 \times 10^{-5} \\
\Delta w_{32} &= 0.001(-0.008715057)1.2839409 = -1.11896 \times 10^{-5} \\
\Delta w_{42} &= 0.001(-0.008715057)(-0.9764798) = 8.51008 \times 10^{-6} \\
\Delta w_{52} &= 0.001(-0.008715057)0.9908363 = -8.63519 \times 10^{-6} \\
\Delta w_{13} &= 0.001(-0.001137833)(-1.8170016) = 2.06744 \times 10^{-6} \\
\Delta w_{23} &= 0.001(-0.001137833)0.35563308 = -4.04651 \times 10^{-7} \\
\Delta w_{33} &= 0.001(-0.001137833)0.86390468 = -9.82979 \times 10^{-7} \\
\Delta w_{43} &= 0.001(-0.001137833)(-0.08051261) = 9.16099 \times 10^{-8} \\
\Delta w_{53} &= 0.001(-0.001137833)(-0.96248032) = 1.09514 \times 10^{-6} \\
\Delta \beta_1 &= 0.001(0.002966588) = 2.96659 \times 10^{-6} \\
\Delta \beta_2 &= 0.001(-0.008715057) = -8.71506 \times 10^{-6} \\
\Delta \beta_3 &= 0.001(-0.001137833) = -1.13783 \times 10^{-6}
\end{aligned}$$

Tabel 4.16 Koreksi Bobot dan Bias *Input Layer* ke *Hidden Layer* Pertama

$\Delta w[k,]$	$\Delta w[, j]$		
	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}

4.4.4 Perubahan Bobot dan Bias

Pada tahap ini, digunakan Persamaan (2.19) dan (2.21) untuk menghitung perubahan bobot dan bias pada setiap lapisan. Perubahan tersebut dilakukan dengan menambahkan bobot dan bias awal dari *hidden layer* kedua ke *output layer* dengan nilai koreksi bobot dan bias yang telah diperoleh. Hasil perhitungan disajikan pada Tabel 4.17 dan berikut perhitungan matematisnya.

$$u_{11}(\text{baru}) = 2.2391646 + (-2.65643 \times 10^{-5}) = 2.239138036$$

$$u_{21}(\text{baru}) = 1.7539743 + (-1.82282 \times 10^{-5}) = 1.753956072$$

$$\gamma_1(\text{baru}) = 0.3840873 + (-3.49379 \times 10^{-5}) = 0.384052362$$

Tabel 4.17 Bobot dan Bias Baru *Hidden Layer* Kedua ke *Output Layer*

$u[m,]$	$u[, i]$
	$u_{m1}(\text{baru})$
$\gamma_1(\text{baru})$	2.239138036
$u_{1i}(\text{baru})$	1.753956072
$u_{2i}(\text{baru})$	0.384052362

Selanjutnya, perubahan bobot dan bias dari *hidden layer* pertama ke *hidden layer* kedua dihitung dengan menjumlahkan bobot dan bias awal antara *hidden layer* pertama dan kedua dengan nilai koreksi bobot dan biasnya, menggunakan Persamaan (2.18) dan (2.20). Hasil perhitungan disajikan pada Tabel 4.18 dan berikut perhitungan matematisnya.

$$w_{11}(\text{baru}) = -0.2576519 + (-8.00945 \times 10^{-6}) = -0.257659909$$

$$w_{21}(\text{baru}) = 1.4834263 + (-1.04462 \times 10^{-5}) = 1.483415854$$

$$w_{31}(\text{baru}) = 0.6776003 + (-2.10268 \times 10^{-6}) = 0.677598197$$

$$w_{12}(\text{baru}) = -0.54787228 + (-8.59101 \times 10^{-6}) = -0.547880871$$

$$w_{22}(\text{baru}) = 1.52752066 + (-1.12047 \times 10^{-5}) = 1.527509455$$

$$w_{32}(\text{baru}) = -0.03994143 + (-2.25535 \times 10^{-6}) = -0.039943685$$

$$\theta_1(\text{baru}) = 0.112311 + (-1.4256 \times 10^{-5}) = 0.112296744$$

$$\theta_2(\text{baru}) = -0.71862122 + (-1.52911 \times 10^{-5}) = -0.718636511$$

Tabel 4.18 Bobot dan Bias Baru *Hidden Layer* Pertama ke *Hidden Layer* Kedua

$w[j,]$	$w[, m]$	
	$w_{j1}(\text{baru})$	$w_{j2}(\text{baru})$
$\theta_m(\text{baru})$	0.112296744	-0.718636511
$w_{1m}(\text{baru})$	-0.257659909	-0.547880871
$w_{2m}(\text{baru})$	1.483415854	1.527509455
$w_{3m}(\text{baru})$	0.677598197	-0.039943685

Perhitungan serupa dilakukan menggunakan Persamaan (2.18) dan (2.20) untuk memperoleh perubahan bobot dan bias baru dari *input layer* ke *hidden layer* pertama, yaitu dengan menambahkan bobot dan bias awal dengan nilai koreksi yang telah dihitung sebelumnya. Hasil perhitungan disajikan pada Tabel 4.19 dan berikut perhitungan matematisnya.

$$w_{11}(\text{baru}) = 1.32252443 + (3.92338 \times 10^{-6}) = 1.322528353$$

$$w_{21}(\text{baru}) = 0.63970204 + (1.89773 \times 10^{-6}) = 0.639703938$$

$$w_{31}(\text{baru}) = 1.17478657 + (3.48511 \times 10^{-6}) = 1.174790055$$

$$w_{41}(\text{baru}) = 0.11629031 + (3.44985 \times 10^{-7}) = 0.116290655$$

$$w_{51}(\text{baru}) = -2.93084636 + (-8.69461 \times 10^{-6}) = -2.930855055$$

$$w_{12}(\text{baru}) = 1.1177719 + (-9.74145 \times 10^{-6}) = 1.117762159$$

$$w_{22}(\text{baru}) = 1.3840475 + (-1.20621 \times 10^{-5}) = 1.384035438$$

$$w_{32}(\text{baru}) = 1.2839409 + (-1.11896 \times 10^{-5}) = 1.28392971$$

$$w_{42}(\text{baru}) = -0.9764798 + (8.51008 \times 10^{-6}) = -0.97647129$$

$$w_{52}(\text{baru}) = 0.9908363 + (-8.63519 \times 10^{-6}) = 0.990827665$$

$$\begin{aligned}
w_{13}(\text{baru}) &= -1.8170016 + 2.06744 \times 10^{-6} = -1.816999533 \\
w_{23}(\text{baru}) &= 0.35563308 + (-4.04651 \times 10^{-7}) = 0.355632675 \\
w_{33}(\text{baru}) &= 0.86390468 + (-9.82979 \times 10^{-7}) = 0.863903697 \\
w_{43}(\text{baru}) &= -0.08051261 + 9.16099 \times 10^{-8} = -0.080512518 \\
w_{53}(\text{baru}) &= -0.96248032 + 1.09514 \times 10^{-6} = -0.962479225 \\
\beta_1(\text{baru}) &= -0.08658011 + (2.96659 \times 10^{-6}) = -0.086577143 \\
\beta_2(\text{baru}) &= 0.6775081 + (-8.71506 \times 10^{-6}) = 0.677499385 \\
\beta_3(\text{baru}) &= -1.53428157 + (-1.13783 \times 10^{-6}) = -1.534282708
\end{aligned}$$

Tabel 4.19 Bobot dan Bias Baru *Input Layer* ke *Hidden Layer* Pertama

$w[k,]$	$w[, j]$		
	$w_{k1}(\text{baru})$	$w_{k2}(\text{baru})$	$w_{k3}(\text{baru})$
$\beta_j(\text{baru})$	-0.086577143	0.677499385	-1.534282708
$w_{1j}(\text{baru})$	1.322528353	1.117762159	-1.816999533
$w_{2j}(\text{baru})$	0.639703938	1.384035438	0.355632675
$w_{3j}(\text{baru})$	1.174790055	1.28392971	0.863903697
$w_{4j}(\text{baru})$	0.116290655	-0.97647129	-0.080512518
$w_{5j}(\text{baru})$	-2.930855055	0.990827665	-0.962479225

Bobot dan bias baru yang diperoleh dari proses pada data pertama akan digunakan sebagai dasar untuk menghitung data kedua, dengan menerapkan langkah-langkah yang sama seperti pada data sebelumnya.

4.5 Model Jaringan Saraf Tiruan

Pada data kedua, proses perhitungan dilakukan dengan cara yang sama seperti pada data pertama, namun nilai bobot dan bias awal yang digunakan berasal dari hasil pembaruan pada data pertama. Proses serupa diterapkan secara berurutan hingga seluruh data selesai dihitung. Pelatihan akan terus berlangsung hingga

kondisi penghentian terpenuhi, yaitu ketika nilai *error* telah mencapai tingkat yang dianggap optimal yaitu 0.001. Setelah itu, diperoleh bobot dan bias akhir untuk masing-masing lapisan seperti ditunjukkan berikut ini.

Tabel 4.20 Bobot dan Bias Akhir *Hidden Layer* Pertama

Variabel	$w[k,]$	$w[, j]$		
		w_{k1}	w_{k2}	w_{k3}
Bias	β_j	0.1724351	-0.2621448	-1.492778
x_1	w_{1j}	2.3158652	4.1186395	-5.46295
x_2	w_{2j}	-5.7153875	-11.00102	-4.005915
x_3	w_{3j}	1.9295123	4.7790261	5.705943
x_4	w_{4j}	6.1583703	2.3529065	2.216537
x_5	w_{5j}	0.5113034	7.0111137	-7.921608

Pada Tabel 4.20, digunakan notasi w_{kj} , di mana baris ke- k merepresentasikan variabel independen beserta biasnya, sedangkan kolom ke- j menunjukkan neuron pada *hidden layer* pertama yang berjumlah tiga. Selain itu, diperoleh juga bobot dan bias akhir pada *hidden layer* kedua yang dinotasikan dengan w_{jm} pada Tabel 4.21, di mana baris ke- j menunjukkan neuron pada *hidden layer* pertama beserta biasnya, dan kolom ke- m merujuk pada dua neuron yang terdapat pada *hidden layer* kedua. Hasil selengkapnya disajikan berikut ini.

Tabel 4.21 Bobot dan Bias Akhir *Hidden Layer* Kedua

$w[j,]$	$w[, m]$	
	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


Selanjutnya, bobot dan bias akhir pada *output layer* dinotasikan dengan u_{mi} pada Tabel 4.22, di mana baris ke- m merepresentasikan neuron pada *hidden layer* kedua beserta biasnya, sedangkan kolom ke- i mengacu pada neuron di *output layer*, yang dalam hal ini hanya terdiri dari satu neuron.

Tabel 4.22 Bobot dan Bias Akhir *Output Layer*

$u[m,]$	$u[, i]$
	u_{m1}
γ_i	-2.728483
u_{1i}	5.26523
u_{2i}	4.996003

Nilai-nilai pada tabel ini merupakan hasil pelatihan JST hingga mencapai *error* minimum sebesar 0.001, yang menggambarkan kontribusi masing-masing variabel terhadap aktivasi setiap neuron. Bobot yang bernilai positif menunjukkan bahwa variabel input tersebut memiliki pengaruh searah terhadap aktivasi neuron, artinya semakin besar nilai *input*, maka semakin besar pula kontribusinya dalam meningkatkan *output* neuron. Sebaliknya, bobot yang bernilai negatif mengindikasikan adanya pengaruh berlawanan arah, yaitu ketika nilai *input* meningkat, maka *output* neuron cenderung menurun. Bias berfungsi sebagai parameter penyesuaian tambahan yang membantu menggeser fungsi aktivasi. Bias positif dapat mendorong neuron lebih mudah aktif, sedangkan bias negatif dapat menurunkan kecenderungan aktivasi neuron. Jika suatu variabel input memiliki bobot negatif, hal tersebut menunjukkan bahwa model belajar bahwa kenaikan nilai variabel tersebut cenderung diikuti oleh penurunan kecepatan angin pada periode berikutnya. Sebaliknya, bobot positif menunjukkan bahwa kenaikan nilai input tersebut berkontribusi pada peningkatan kecepatan angin selanjutnya.

Struktur hubungan antar neuron yang membentuk jaringan terdiri dari *input layer*, *hidden layer* pertama, *hidden layer* kedua, hingga *output layer*—yang merepresentasikan model terbaik dalam penelitian ini—ditampilkan pada Gambar 4.9 menggunakan RStudio. Setiap neuron terhubung ke neuron-neuron di lapisan berikutnya, dan dari hubungan tersebut diperoleh nilai bobot dan bias antar lapisan. Plot tersebut menggunakan dua warna, yaitu hitam untuk menunjukkan bobot akhir setiap neuron di masing-masing lapisan, dan biru untuk merepresentasikan nilai bias pada tiap lapisan.



Gambar 4.9 Model Optimal JST

Berdasarkan Gambar 4.9, dapat disusun sebuah model yang menggambarkan hasil perhitungan yang telah dilakukan sebelumnya. Model tersebut disajikan sebagai berikut.

$$o_j = f\left(\sum_{k=1}^5 x_k \cdot w_{kj} + \beta_j\right) \quad (4.1)$$

o_j merupakan *output* dari *hidden layer* pertama yang telah melalui proses aktivasi menggunakan fungsi aktivasi. Sementara itu, w_{kj} dan β_j masing-masing menunjukkan bobot dan bias akhir pada *hidden layer* pertama. Pendekatan serupa

digunakan untuk menghitung *output* pada *hidden layer* kedua, dengan input berupa nilai dari o_j . Adapun modelnya adalah sebagai berikut.

$$o_m = f \left(\sum_{j=1}^3 o_j \cdot w_{jm} + \theta_m \right) \quad (4.2)$$

o_m merupakan *output* dari *hidden layer* kedua yang telah diproses melalui fungsi aktivasi. Adapun w_{jm} dan θ_m masing-masing merepresentasikan bobot dan bias akhir yang menghubungkan *hidden layer* pertama ke *hidden layer* kedua. Selanjutnya, *output* pada *output layer* dihitung dengan menggunakan o_m sebagai *input*. Adapun modelnya adalah sebagai berikut.

$$y_i = f \left(\sum_{m=1}^2 o_m \cdot u_{m,i} + \gamma_i \right) \quad (4.3)$$

y_i merupakan *output* dari *output layer* yang telah melalui fungsi aktivasi. Sementara itu, u_{mi} dan γ_i masing-masing menunjukkan bobot dan bias akhir yang menghubungkan *hidden layer* kedua dengan *output layer*. Model-model yang telah dibentuk ini selanjutnya akan digunakan untuk memprediksi kecepatan angin pada jalur penyeberangan kapal Gresik–Bawean. Adapun keseluruhan modelnya sebagai berikut.

$$y_i = f \left(\sum_{m=1}^2 \left[f \left(\sum_{j=1}^3 \left[f \left(\sum_{k=1}^5 x_k \cdot w_{k,j} + \beta_j \right) \right] \cdot w_{j,m} + \theta_m \right) \right] \cdot u_{m,i} + \gamma_i \right) \quad (4.4)$$

4.6 Tingkat Keakuratan Model

Data uji digunakan untuk mengevaluasi tingkat akurasi model yang telah dihasilkan dari proses pelatihan, berdasarkan pembagian data sebelumnya. Satu di antara metode untuk mengukur akurasi model adalah dengan menggunakan MAPE.

Pada Lampiran 6 perhitungan lengkap MAPE. Berikut perhitungan matematis MAPE menggunakan Persamaan (2.22).

$$\begin{aligned}
 MAPE &= \frac{1}{77} \left(\left| \frac{17.445 - 11.13409536}{17.445} \right| + \left| \frac{15.865 - 11.17783554}{15.865} \right| + \right. \\
 &\quad \left. \left| \frac{11.25 - 11.15033366}{11.25} \right| + \dots + \left| \frac{6.095 - 11.01302988}{6.095} \right| \right) \times 100\% \\
 &= 16.22\%
 \end{aligned}$$

Selain itu, akurasi model juga dapat dievaluasi menggunakan *Mean Squared Error* (MSE). Pada Lampiran 7 disajikan perhitungan lengkap MSE. Berikut perhitungan matematis MSE menggunakan Persamaan (2.23).

$$\begin{aligned}
 MSE &= \frac{1}{77} [(17.445 - 11.13409536)^2 + (15.865 - 11.17783554)^2 + \\
 &\quad (11.25 - 11.15033366)^2 + \dots + (6.095 - 11.01302988)^2] \\
 &= 5.805603854
 \end{aligned}$$

Berdasarkan hasil perhitungan MAPE dan MSE, diperoleh nilai MAPE 16.22% dan MSE 5.805603854. Nilai ini menunjukkan bahwa tingkat kesalahan yang dihasilkan relatif rendah dan model mampu memprediksi kecepatan angin dengan akurat.

4.7 Prediksi

Berdasarkan Persamaan (4.1), (4.2), dan (4.3), model tersebut dapat digunakan untuk memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean pada periode selanjutnya, yaitu pada 1 hingga 30 Desember 2023. Nilai *input* tiap variabel independen telah terlampir dalam Lampiran 8. Berikut perhitungan matematis prediksi periode 1 Desember 2023 dengan memasukkan

nilai x_1, x_2, x_3, x_4 , dan x_5 periode 30 November 2023 ke dalam Persamaan (4.1), diperoleh hasil perhitungan (o_j) sebagai berikut:

$$\begin{aligned}
 o_1 &= f([(2.3158652 \times 0.6690231) + (-5.7153875 \times 0.6463415) + \\
 &\quad (1.9295123 \times 0) + (6.1583703 \times 0.009302326) + \\
 &\quad (0.5113034 \times 0.6532258)] + 0.1724351) \\
 &= f(-1.581005974) = \frac{1}{1 + e^{-(-1.581005974)}} = 0.170653059 \\
 o_2 &= f([(4.1186395 \times 0.6690231) + (-11.00102 \times 0.6463415) + \\
 &\quad (4.7790261 \times 0) + (2.3529065 \times 0.009302326) + \\
 &\quad (7.0111137 \times 0.6532258)] + (-0.2621448)) \\
 &= f(-0.015367743) = \frac{1}{1 + e^{-(-0.015367743)}} = 0.49615814 \\
 o_3 &= f([(-5.46295 \times 0.6690231) + (-4.005915 \times 0.6463415) + \\
 &\quad (5.705943 \times 0) + (2.216537 \times 0.009302326) + \\
 &\quad (-7.921608 \times 0.6532258)] + (-1.492778)) \\
 &= f(-12.89078663) = \frac{1}{1 + e^{-(-12.89078663)}} = 2.52117 \times 10^{-6}
 \end{aligned}$$

Setelah diperoleh nilai *output* dari *input layer* menuju *hidden layer* pertama, nilai tersebut selanjutnya digunakan sebagai *input* untuk menghitung *output* dari *hidden layer* pertama ke *hidden layer* kedua. Proses perhitungan (o_m) dilakukan dengan menggunakan Persamaan (4.2) sebagai berikut.

$$\begin{aligned}
 o_1 &= f([(-5.40720304 \times 0.170653059) + (3.30755847 \times \\
 &\quad 0.49615814) + (1.01687276 \times 2.52117 \times 10^{-6})] + \\
 &\quad (-0.04544929))
 \end{aligned}$$

$$\begin{aligned}
&= f(0.672869593) = \frac{1}{1 + e^{-(0.672869593)}} = 0.662145411 \\
o_2 &= f([(-3.329012 \times 0.170653059) + (6.53562 \times 0.49615814) + \\
&\quad (-3.559361 \times 2.52117 \times 10^{-6})] + (-3.601966)) \\
&= f(-0.927379993) = \frac{1}{1 + e^{-(0.927379993)}} = 0.283456559
\end{aligned}$$


Output yang dihasilkan dari *hidden layer* pertama menuju *hidden layer* kedua kemudian dimanfaatkan untuk menghitung nilai *output* prediksi. Perhitungan (y_i) dilakukan menggunakan Persamaan (4.3) dengan hasil sebagai berikut.

$$\begin{aligned}
y'_1 &= f([(5.26523 \times 0.662145411) + (4.996003 \times \\
&\quad 0.283456559)] + (-2.728483)) \\
&= f(2.174014703) = \frac{1}{1 + e^{-(2.174014703)}} = 0.897891632
\end{aligned}$$

Karena nilai y_i yang diperoleh masih dalam bentuk data yang telah dinormalisasi, maka diperlukan proses pengembalian ke skala aslinya. Adapun perhitungannya ditunjukkan sebagai berikut.

$$\begin{aligned}
\text{Nilai prediksi skala asli} &= 0.897891632(11.96 - 4.18) + 4.18 \\
&= 11.1655969
\end{aligned}$$

Pada 1 Desember 2023, nilai aktual kecepatan angin yang tercatat adalah 5.545, sedangkan nilai hasil prediksi sebesar 11.1655969. Proses perhitungan ini juga akan diterapkan untuk periode-periode selanjutnya. Diperoleh MSE 6.737982733 dan MAPE 33.95% yang menunjukkan hasil prediksi cukup akurat. *Output* dari prediksi selama 62 hari kedepan terdapat pada Lampiran 9. Grafik data aktual dan prediksi ditampilkan sebagai berikut.



Gambar 4.10 Grafik Data Aktual dan Prediksi Kecepatan Angin

Grafik pada Gambar 4.10 menunjukkan perbandingan antara data aktual kecepatan angin dari tanggal 1 hingga 30 Desember 2023 (biru), hasil prediksi pada periode yang sama (oranye), serta prediksi lanjutan dari 31 Desember 2023 hingga 31 Januari 2024 (merah). Terlihat bahwa hasil prediksi pada bulan Desember 2023 menunjukkan tingkat akurasi yang cukup akurat, meskipun masih terdapat fluktuasi dan selisih pada beberapa titik. Model JST sudah mulai mampu menangkap pola umum kecepatan angin dalam jangka pendek, terutama pada kondisi yang relatif stabil. Namun demikian, pada awal periode Desember, hasil prediksi belum sepenuhnya mengikuti pola data aktual, khususnya dalam menangkap lonjakan atau penurunan tajam kecepatan angin yang terjadi secara tiba-tiba. Hal ini menunjukkan bahwa pada awal periode prediksi, model JST belum mampu mengenali dengan baik perubahan ekstrem dalam data. Salah satu penyebabnya adalah karena pola kecepatan angin pada bulan Desember hingga Januari secara historis cenderung fluktuatif, dengan naik turun tajam dari hari ke hari. Pola musiman ini juga terlihat pada data tahun-tahun sebelumnya, di mana terdapat variabilitas tinggi akibat pergantian musim dari angin timur ke angin barat. Meskipun data pelatihan mencakup tiga tahun, karakteristik musiman yang berubah-ubah dan tidak

sepenuhnya berulang secara identik setiap tahun menyebabkan model JST kesulitan mengeneralisasi lonjakan atau penurunan ekstrem, sehingga prediksi cenderung lebih akurat saat pola data lebih stabil dan kurang tepat saat menghadapi perubahan mendadak.

4.8 Pengelompokan Gelombang Laut

Pengelompokan gelombang laut dalam penelitian ini dilakukan dengan mengacu pada hasil prediksi kecepatan angin yang telah diperoleh dari model JST periode 1 Desember 2023 hingga 31 Januari 2024. Kecepatan angin yang diprediksi selanjutnya dibulatkan kemudian diklasifikasikan ke dalam skala Beaufort untuk menentukan kondisi angin dan potensi tinggi gelombang laut yang mungkin terjadi.

Berdasarkan klasifikasi tersebut, kecepatan angin yang diprediksi dikelompokkan ke dalam 13 kategori, mulai dari skala 0 (tenang) hingga skala 12 (badai topan). Setiap kategori memiliki rentang kecepatan angin tertentu, serta deskripsi karakteristik angin dan estimasi tinggi gelombang yang mungkin terjadi di laut. Pengelompokan gelombang air laut berdasarkan hasil prediksi kecepatan angin pada 1 Desember 2023 hingga 31 Januari 2024 terlampir pada Lampiran 10, berikut pengelompokan pada 1 hingga 7 Desember 2023.

Tabel 4.23 Pengelompokan Gelombang Laut

Tanggal	Kecepatan Angin (knot)	Skala Beaufort	Estimasi Tinggi Gelombang (meter)	Gelombang Laut
01/12/2023	11	4	1	Sedikit bergelombang hingga bergelombang sedang

Lanjutan Tabel 4.23 Pengelompokan Gelombang Laut

Tanggal	Kecepatan Angin (knot)	Skala Beaufort	Estimasi Tinggi Gelombang (meter)	Gelombang Laut
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>)

Secara keseluruhan, prediksi kondisi laut selama Desember 2023 dan Januari 2024 menunjukkan variasi gelombang yang relatif ringan hingga sedang. Tidak terdapat kejadian gelombang tinggi ekstrem yang menandakan cuaca buruk. Pergantian antara gelombang halus, sedikit bergelombang, hingga bergelombang sedang juga menunjukkan adanya fluktuasi ringan dalam pola angin harian, namun dalam rentang yang masih tergolong aman. Dengan pendekatan ini, hasil prediksi kecepatan angin tidak hanya memberikan informasi tentang besarnya angin, tetapi juga berkontribusi pada analisis kondisi kelautan di jalur penyeberangan kapal

Gresik-Bawean pada periode tersebut, khususnya dalam mengidentifikasi potensi gelombang laut.

4.9 Prediksi Kecepatan Angin Menggunakan Metode JST dalam Pandangan Islam

Penelitian ini memiliki keterkaitan erat dengan konsep ketentuan Allah dalam mengatur alam semesta, khususnya dalam hal pergerakan angin yang menjadi faktor utama dalam pelayaran. Melalui metode JST, manusia berupaya menganalisis dan memprediksi kecepatan angin demi meningkatkan keselamatan serta efisiensi transportasi laut. Meskipun kemajuan teknologi memungkinkan manusia untuk memahami dan mengantisipasi perubahan angin, hakikatnya seluruh fenomena alam tetap berada dalam kekuasaan Allah. Oleh karena itu, penelitian ini tidak hanya berkontribusi dalam bidang ilmu pengetahuan dan teknologi, tetapi juga menjadi pengingat akan kebesaran-Nya dalam mengatur keseimbangan alam. Kesadaran ini menuntun manusia untuk terus berikhtiar dalam mengembangkan ilmu sambil tetap berserah diri kepada ketentuan-Nya.

Penelitian ini secara khusus mengambil lokasi di jalur penyeberangan laut Gresik–Bawean, sebuah lintasan transportasi laut yang memiliki intensitas pelayaran cukup tinggi dan rentan terhadap perubahan kondisi cuaca, khususnya angin. Dalam konteks ini, metode JST dengan algoritma *backpropagation* diterapkan untuk memprediksi kecepatan angin guna meningkatkan keselamatan dan efisiensi pelayaran. Upaya ini tidak hanya mencerminkan penggunaan teknologi modern dalam menghadapi tantangan alam, tetapi juga merupakan bentuk konkret ikhtiar manusia dalam memahami *sunnatullah* (hukum Allah di alam

semesta). Dengan memahami pola kecepatan angin, khususnya di jalur penyeberangan laut Gresik-Bawean, manusia dapat mengantisipasi bahaya dan mengurangi risiko kecelakaan. Langkah ini tidak hanya mendukung keselamatan transportasi, tetapi juga mencerminkan wujud rasa syukur atas ilmu pengetahuan yang telah dianugerahkan Allah Swt. Sebagai makhluk yang diberi akal, manusia dituntut untuk memanfaatkan ilmu dengan sebaik-baiknya dalam rangka menjaga keseimbangan dan kemaslahatan bersama.

Selain itu, penelitian ini sejalan dengan pesan dalam al-qur'an yang mengajak manusia untuk merenungkan tanda-tanda kebesaran Allah dalam alam semesta. Mempelajari angin dan laut, sebagaimana disebutkan dalam ayat-ayat al-qur'an, merupakan salah satu bentuk ibadah yang meneguhkan pengakuan bahwa Allah adalah Sang Pengatur segala sesuatu. Ilmu pengetahuan yang diperoleh dari penelitian ini, jika digunakan dengan benar, tidak hanya bermanfaat secara ilmiah, tetapi juga dapat membawa manusia lebih dekat kepada Allah dan meningkatkan rasa syukur terhadap kebesaran-Nya. Dengan demikian, integrasi antara ilmu pengetahuan dan spiritualitas dapat menjadi landasan dalam menjalankan kehidupan yang lebih harmonis dan bertanggung jawab.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan uraian hasil dan pembahasan pada bab sebelumnya, diperoleh kesimpulan sebagai berikut:

1. Model jaringan syaraf tiruan dengan algoritma *backpropagation* yang memberikan hasil terbaik dalam memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean adalah dengan konfigurasi 1 *input layer* yang terdiri dari 5 neuron, 2 *hidden layer* dimana *hidden layer* pertama memiliki 3 neuron dan *hidden layer* kedua terdiri dari 2 neuron, serta 1 *output layer* dengan 1 neuron.
2. Secara keseluruhan, pengelompokan gelombang laut selama Desember 2023 dan Januari 2024 menunjukkan gelombang halus hingga bergelombang sedang. Tidak terdapat kejadian gelombang tinggi ekstrem yang menandakan cuaca buruk. Pergantian antara gelombang halus, sedikit bergelombang, dan bergelombang sedang juga menunjukkan adanya fluktuasi ringan dalam pola angin harian, namun dalam rentang yang masih tergolong aman.
3. Akurasi model JST dengan algoritma *backpropagation* dalam memprediksi kecepatan angin di jalur penyeberangan kapal Gresik-Bawean ditunjukkan oleh nilai MSE 5.805603854 dan MAPE 16.22%. Nilai tersebut mengindikasikan bahwa model memiliki kemampuan prediksi yang akurat. Sedangkan nilai MSE dan MAPE pada prediksi yaitu 6.737982733 dan 33.95% yang menunjukkan hasil prediksi cukup akurat.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, penulis menyampaikan beberapa saran yang dapat menjadi bahan pertimbangan, di antaranya sebagai berikut:

1. Disarankan menambahkan variabel *input* lain yang berpengaruh terhadap kecepatan angin, seperti suhu, tekanan udara, kelembapan, dan variabel oceanografi lainnya, agar model dapat menangkap lebih banyak faktor yang mempengaruhi kecepatan angin.
2. Disarankan memprediksi kecepatan angin dalam jangka waktu yang pendek.
3. Disarankan mengkombinasikan jaringan syaraf tiruan dengan metode optimasi seperti *Genetic Algorithm* (GA) atau *Particle Swarm Optimization* (PSO) guna mendapatkan bobot dan bias yang lebih optimal.

DAFTAR PUSTAKA

- 'Alim, K., & Murni, D. (2023). Prediksi Hasil Pertandingan Sepak Bola Liga Premier Inggris Dengan Artificial Neural Network. *Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, 4, 1523–1531. <https://doi.org/https://dx.doi.org/10.46306/lb.v4i3.425>
- Abhishek, K., Khairwa, A., Pratap, T., & Prakash, S. (2012). A Stock Market Prediction Model using Artificial Neural Network. *IEEE*, 1–5. <https://doi.org/https://doi.org/10.1109/ICCCNT.2012.6396089>
- Adhikari, R., & Agrawal, R. K. (2013). *An Introductory Study on Time Series Modeling and Forecasting* (D. Magu (ed.)). LAP Lambert Academic Publishing. <https://doi.org/http://dx.doi.org/10.13140/2.1.2771.8084>
- Anwar, B. (2011). Penerapan Algoritma Jaringan Syaraf Tiruan Back Propagation dalam Memprediksi Tingkat Suku Bunga Bank. *Jurnal Saintikom*, 10(2).
- Arfah, H., & Kurniati, P. (2024). *Perahu yang Tenggelam dan Tewaskan 1 Orang di Bawean Gresik Diduga Kelebihan Muatan*. Kompas.com. <https://surabaya.kompas.com/read/2024/04/30/113720678/perahu-yang-tenggelam-dan-tewaskan-1-orang-di-bawean-gresik-diduga>
- Ariannor, W., & Razatillah, M. F. (2022). Penerapan Jaringan Saraf Tiruan Backpropagation Dalam Memprediksi Nilai Tukar Petani. *Jurnal Ilmiah Komputer*, 18(1), 127–140. <https://doi.org/https://dx.doi.org/10.35889/progresif.v18i1.798>
- As-Suyuthi, J., & Al-Mahally, J. M. I. A. (2015). Tafsir Al-Jalalain. *Tafsir jalalain (terjemah)*.
- Az-Zuhaili, W. (2015). *Tafsir Al wajiz*. Lajnah Pentashihan Mushaf Al-Qur'an.
- BrotoSusilo, A., Apriana, I. W. A., Satria, A. A., & Jokopitoyo, T. (2016). Littoral and Coastal Management in Supporting Maritime Security for Realizing Indonesia as World Maritime Axis. *IOP Publishing*, 30. <https://doi.org/10.1088/1755-1315/30/1/012016>
- Chhajer, P., Shah, M., & Kshirsagar, A. (2022). The Applications of Artificial Neural Networks, Support Vector Machines, and Long–Short Term Memory for Stock Market Prediction. *Decision Analytics Journal*, 2. <https://doi.org/10.1016/j.dajour.2021.100015>
- Fausett, L. (1994). *Fundamentals of Neural Network: Architectures, Algorithms, and Applications*. Prentice-Hall.
- Fengbo, Y., Xinyu, X., Ling, Z., & Zhu, S. (2017). Numerical Simulation and Experimental Verification on Downwash Air Flow of Six-Rotor Agricultural

- Unmanned Aerial Vehicle in Hover. *International Journal of Agricultural and Biological Engineering*, 10(4), 41–53.
<https://doi.org/10.25165/j.ijabe.20171004.3077>
- Herdianto. (2013). Prediksi Kerusakan Motor Induksi Menggunakan Tesis Oleh Herdianto Fakultas Teknik. *Fakultas Teknik, Universitas Sumatera Utara, Medan*.
- Herjanto, E. (2009). *Sains Manajemen*. Grasindo.
- Hidayat, N. (2005). Kajian Hidro-Oseanografi untuk Deteksi Proses Fisik di Pantai. *Jurnal Smartek*, 3(2), 73–85.
- Jumarwanto, A., Hartanto, R., & Prastiyanto, D. (2009). Aplikasi Jaringan Saraf Tiruan Backpropagation untuk Memprediksi Penyakit THT di Rumah Sakit Mardi Rahayu Kudus. *Jurnal Teknik Elektro*, 1(1), 11–21.
<https://doi.org/https://doi.org/10.15294/jte.v1i1.1601>
- Katsir, I. I. (2004). لباب التفسير من ابن كثير (Tafsir Ibnu Katsir). In *Tafsir Ibnu Katsir* (Vol. 26).
- Kementerian Agama RI. (2019). *Al-Qur'an dan Terjemahannya*. Lajnah Pentashihan Mushaf Al-Qur'an.
- Khasanah, U., & Ulinnuha, N. (2019). 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*, 5(2), 9–17.
<https://doi.org/http://dx.doi.org/10.24014/jsms.v5i2.7630>
- Kurniawan, R., Habibie, M. N., & Permana, D. S. (2012). Kajian Daerah Rawan Gelombang Tinggi Di Perairan Indonesia. *Jurnal Meteorologi dan Geofisika*, 13(3), 201–212. <https://doi.org/10.31172/jmg.v13i3.135>
- Kusumadewi, S. (2003). Artificial Intelligence (Teknik dan Aplikasinya). In *Graha Ilmu* (1 ed.).
- Lewis, C. D. (1982). *Industrial and Business Forecasting Methods : A Practical Guide to Exponential Smoothing and Curve Fitting*. Butterworth Scientific.
- Loupatty, G. (2013). Karakteristik Energi Gelombang dan Arus Perairan di Provinsi Maluku. *Jurnal Barekeng*, 7(1), 19–22.
<https://doi.org/https://dx.doi.org/10.30598/barekengvol7iss1pp19-22>
- Marino, E., Giusti, A., & Manuel, L. (2017). Offshore Wind Turbine Fatigue Loads: The Influence of Alternative Wave Modeling for Different Turbulent and Mean Winds. *Renewable Energy*, 102, 157–169.
<https://doi.org/10.1016/j.renene.2016.10.023>
- Matondang, Z. A. (2013). Jaringan Syaraf Tiruan Dengan Algoritma

- Backpropagation Untuk Penentuan Kelulusan Sidang Skripsi. *Pelita Informatika Budi Darma*, 4(1), 84–93.
- Muis, S., & Setiyadi, D. (2020). Model Statistik Arima dalam Meramal Pergerakan Harga Saham. *Information System for Educators and Professionals*, 4(2), 154–167.
- Nababan, B., Rosyadi, N., Manurung, D., Natih, N. M., & Hakim, R. (2016). The Seasonal Variability of Sea Surface Temperature and Chlorophyll-a Concentration in the South of Makassar Strait. *Procedia Environmental Sciences*, 33, 583–599. <https://doi.org/https://dx.doi.org/10.1016/j.proenv.2016.03.112>
- National Meteorological Library and Archive. (2023). *Factsheet 6 – The Beaufort Scale*.
- Purwendah, E. K. (2020). Sea Protection From Oil Pollution by Ship Tanker. *Ganesha Law Review*, 2(1), 77–88. <https://dx.doi.org/10.23887/blr.v2i1.122>
- Putra, J. W. G. (2020). *Pengenalan Pembelajaran Mesin dan Deep Learning* (1.4). <https://wiragotama.github.io/resources/ebook/intro-to-ml-secured.pdf>
- Riadi, M. (2021). *Teori Gelombang Laut*. Kajianpustaka.com. <https://www.kajianpustaka.com/2016/01/teori-gelombang-laut.html>
- Rodia, S. A., & Ridla, M. A. (2024). Prediksi Nilai Impor Susu Segar Menggunakan Algoritma Backpropagation. *Jurnal Ahsana*, 2(1), 27–32. <https://doi.org/https://doi.org/10.59395/ahsana.v1i1.352>
- Rodrigue, J., & Notteboom, T. (2012). The Geography Of Cruise Shipping : Caribbean and Mediterranean Itineraries , Capacity Deployment, and Ports Of Call. In *Atti Della IAME 2012 Conference, Taipei, Taiwan*, 1–20.
- Samah, A. A., Azril, H., Shaffril, M., Hamzah, A., & Samah, B. A. (2019). Factors Affecting Small-Scale Fishermen ' s Adaptation Toward the Impacts of Climate Change : Reflections From Malaysian Fishers. *Sage Open*, 9(3). <https://doi.org/https://doi.org/10.1177/2158244019864204>
- Shihab, M. Q. (2013). *Tafsir Al-Mishbah, Pesan, Kesan dan Keserasian Al-Qur'an Vol.6* (Vol. 6). Lentera Hati.
- Sijabat, P. I., Yuhandri, Y., Nurcahyo, G. W., & Sindar, A. (2020). Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional. *Digital Zone: Jurnal Teknologi Informasi dan Komunikasi*, 11(1). <https://doi.org/10.31849/digitalzone.v11i1.3880>
- Stanev, E. V., Peneva, E., & Chtirkova, B. (2019). Climate Change and Regional Ocean Water Mass Disappearance : Case of the Black Sea. *Journal of Geophysical Research: Oceans*, 1–17. <https://doi.org/10.1029/2019JC015076>

- Stathopoulos, T., Zisis, I., & Xypnitou, E. (2014). Local and Overall Wind Pressure and Force Coefficients for Solar Panels. *Journal of Wind Engineering and Industrial Aerodynamics*, 125, 195–206.
<https://doi.org/https://dx.doi.org/10.1016/j.jweia.2013.12.007>
- Sutojo, T., Mulyanto, E., & Suhartono, V. (2011). *Kecerdasan Buatan* (1 ed.). Andi.
<https://inlislite.uin-suska.ac.id/opac/detail-opac?id=15366>
- Tambun, M. S., Furqon, M. T., & Widodo, A. W. (2018). Penerapan Algoritme Jaringan Syaraf Tiruan Backpropagation pada Pengklasifikasian Status Gizi Balita. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 2(9), 3074–3080.
- Wakkary, A. C., Jasin, M. I., & Dundu, A. K. T. (2017). Studi Karakteristik Gelombang pada Daerah Pantai Desa Kalinaung Kab. Minahasa Utara. *Jurnal Sipil Statik*, 5(3), 167–174.
- Walczak, S., & Cerpa, N. (2003). Artificial Neural Networks. In *Encyclopedia of Physical Science and Technology* (3 ed., hal. 631–645). Academic Press.
<https://doi.org/https://doi.org/10.1016/B0-12-227410-5/00837-1>
- Wati, D. A. R. (2011). *Sitem Kendali Cerdas*. Graha Ilmu.
- Wirjohamidjojo, S., & Sugarin. (2008). *Praktek Meteorologi Kelautan*. Badan Meteorologi dan Geofisika.
- Young, I. R., & Ribal, A. (2019). *Multiplatform Evaluation of Global Trends in Wind Speed and Wave Height*. 364(6440), 548–552.
<https://doi.org/https://doi.org/10.1126/science.aav9527>

LAMPIRAN

Lampiran 1. Data Penelitian

Tanggal	Kecepatan Angin (knot)	Tinggi Rata-rata Gelombang (meter)	Panjang Gelombang (meter)	Periode Gelombang (detik)	Tinggi Maksimum Gelombang (meter)	Target (knot)
01/12/2020	5.46	0.255	34.885	4.685	0.34	3.595
02/12/2020	3.595	0.15	31.81	4.48	0.195	10.63
03/12/2020	10.63	0.215	18.16	3.2	0.285	11.28
04/12/2020	11.28	0.61	17.475	3.255	0.8	17.11
05/12/2020	17.11	1.03	24.065	3.805	1.36	15.665
06/12/2020	15.665	1.73	38.44	4.79	2.27	20.295
07/12/2020	20.295	2.135	46.485	5.285	2.805	19.14
08/12/2020	19.14	2.555	51.14	5.57	3.36	20.335
09/12/2020	20.335	3.105	58.87	5.995	4.08	17.31
10/12/2020	17.31	2.43	51.215	5.565	3.2	14.27
11/12/2020	14.27	1.705	39.25	4.845	2.24	11.8
12/12/2020	11.8	1.06	33.12	4.445	1.39	12.85
13/12/2020	12.85	0.885	26.745	4	1.17	8.9
14/12/2020	8.9	0.625	20.49	3.475	0.82	3.665
15/12/2020	3.665	0.3	25.15	3.855	0.395	9.995
16/12/2020	9.995	0.355	24.595	3.75	0.47	17.175
17/12/2020	17.175	1.66	39.21	4.775	2.19	14.69
18/12/2020	14.69	1.345	39.17	4.825	1.765	11.42

19/12/2020	11.42	1.16	34.865	4.53	1.525	13.025
20/12/2020	13.025	1.62	45.965	5.225	2.13	11.795
21/12/2020	11.795	1.095	39.21	4.82	1.44	9.45
22/12/2020	9.45	0.925	35.935	4.645	1.215	8.975
23/12/2020	8.975	0.78	30.59	4.31	1.035	8.045
24/12/2020	8.045	0.385	25.42	3.93	0.505	5.74
25/12/2020	5.74	0.12	33.05	4.525	0.16	4.69
26/12/2020	4.69	0.27	39.32	4.97	0.36	7.37
27/12/2020	7.37	0.25	25.48	3.935	0.33	12.275
28/12/2020	12.275	0.53	17.795	3.24	0.695	13.12
29/12/2020	13.12	0.645	19.48	3.425	0.85	9.5
30/12/2020	9.5	1.055	33.37	4.46	1.385	13.12
31/12/2020	13.12	0.76	31.82	4.38	1	9.165
01/01/2021	9.165	0.8	31.325	4.335	1.055	9.04
02/01/2021	9.04	0.75	25.545	3.865	0.98	8.78
03/01/2021	8.78	0.765	30.09	4.205	1.005	8.94
04/01/2021	8.94	0.405	29.32	4.215	0.535	9.06
05/01/2021	9.06	1.11	29.495	4.195	1.46	9.25
06/01/2021	9.25	0.725	24.28	3.795	0.95	13.37
07/01/2021	13.37	1.3	29.595	4.155	1.7	8.695
08/01/2021	8.695	0.89	25.785	3.915	1.165	9.355
09/01/2021	9.355	0.56	31.075	4.335	0.735	9.315
10/01/2021	9.315	1.045	27.54	4.02	1.375	10.51
11/01/2021	10.51	0.895	32.76	4.42	1.175	12.5

12/01/2021	12.5	1.54	34.71	4.55	2.025	17.275
13/01/2021	17.275	2.12	47.5	5.335	2.795	16.41
14/01/2021	16.41	1.705	43.285	5.065	2.24	13.69
15/01/2021	13.69	1.74	40.335	4.905	2.285	12.115
16/01/2021	12.115	0.895	27.825	4.035	1.185	11.385
17/01/2021	11.385	1.115	28.815	4.165	1.47	17.685
18/01/2021	17.685	1.935	38.43	4.8	2.55	15.06
19/01/2021	15.06	2.24	50.145	5.485	2.945	13.72
20/01/2021	13.72	1.43	36.125	4.62	1.88	15.125
21/01/2021	15.125	1.585	31.955	4.385	2.09	15.815
22/01/2021	15.815	1.51	31.935	4.375	1.99	9.71
23/01/2021	9.71	0.915	27.915	4.045	1.21	10.84
24/01/2021	10.84	0.69	18.505	3.335	0.91	6.195
25/01/2021	6.195	0.775	26.07	3.965	1.025	8.59
26/01/2021	8.59	0.305	19.66	3.365	0.4	12.81
27/01/2021	12.81	1.285	27.615	4.02	1.685	17.915
28/01/2021	17.915	2.4	46.405	5.29	3.155	20.7
29/01/2021	20.7	2.81	54.74	5.775	3.7	18.195
30/01/2021	18.195	2.67	53.54	5.695	3.515	15.665
31/01/2021	15.665	1.79	37.675	4.76	2.355	16.76
01/02/2021	16.76	1.88	40.045	4.905	2.47	15.42
02/02/2021	15.42	1.985	39.835	4.9	2.61	18.405
03/02/2021	18.405	2.35	46.885	5.305	3.095	19.425
04/02/2021	19.425	2.43	47.89	5.39	3.19	16.38

05/02/2021	16.38	2.595	50.35	5.53	3.425	15.48
06/02/2021	15.48	1.88	41.17	4.97	2.48	13.815
07/02/2021	13.815	1.805	40.14	4.9	2.375	13.285
08/02/2021	13.285	1.825	40.46	4.92	2.405	13.865
09/02/2021	13.865	1.67	38.49	4.805	2.195	12.03
10/02/2021	12.03	1.29	30.765	4.28	1.7	10.595
11/02/2021	10.595	0.87	25.645	3.9	1.14	12.485
12/02/2021	12.485	0.92	25.935	3.925	1.215	14.445
13/02/2021	14.445	1.345	30.72	4.28	1.77	11.15
14/02/2021	11.15	0.99	28.095	4.085	1.305	10.315
15/02/2021	10.315	0.985	28.89	4.14	1.3	11.22
16/02/2021	11.22	1.17	30.235	4.25	1.54	15.115
17/02/2021	15.115	1.41	30.67	4.285	1.855	13.875
18/02/2021	13.875	1.525	36.45	4.675	2.005	13.445
19/02/2021	13.445	2.075	43.73	5.12	2.73	14.345
20/02/2021	14.345	1.65	39.39	4.835	2.165	14.995
21/02/2021	14.995	1.52	33.81	4.485	2	13.745
22/02/2021	13.745	1.57	33.48	4.475	2.07	17.045
23/02/2021	17.045	1.775	36.055	4.65	2.335	19.25
24/02/2021	19.25	2.635	51.52	5.595	3.465	12.71
25/02/2021	12.71	2.14	49.105	5.43	2.805	12.535
26/02/2021	12.535	1.365	40.895	4.93	1.8	10.71
27/02/2021	10.71	1.025	30.145	4.22	1.35	5.655
28/02/2021	5.655	0.37	31.46	4.435	0.485	4.115

01/03/2021	4.115	0.1	26.52	4.09	0.135	8.12
02/03/2021	8.12	0.115	18.26	3.15	0.15	7.755
03/03/2021	7.755	0.46	16.4	3.17	0.605	8.9
04/03/2021	8.9	0.605	17.5	3.26	0.795	5.86
05/03/2021	5.86	0.375	20.11	3.5	0.495	5.575
06/03/2021	5.575	0.105	24.295	3.9	0.14	10.08
07/03/2021	10.08	0.52	13.77	2.825	0.68	15.41
08/03/2021	15.41	1.4	29.12	4.17	1.835	14.05
09/03/2021	14.05	1.74	36.56	4.68	2.29	9.245
10/03/2021	9.245	0.975	27.07	4.015	1.28	9.67
⋮	⋮	⋮	⋮	⋮	⋮	⋮
18/11/2023	5.4	0.08	21.57	3.495	0.115	9.98
19/11/2023	9.98	0.15	20.06	3.375	0.225	8.475
20/11/2023	8.475	0.08	23.4	3.67	0.11	11.855
21/11/2023	11.855	0.665	22.07	3.64	1.015	14.525
22/11/2023	14.525	1.05	28.345	4.11	1.59	13.155
23/11/2023	13.155	0.995	36.875	4.675	1.51	8.625
24/11/2023	8.625	0.615	34.85	4.52	0.93	8.465
25/11/2023	8.465	0.28	25.655	3.92	0.42	7
26/11/2023	7	0.15	23.74	3.755	0.225	7.09
27/11/2023	7.09	0.07	30.77	4.335	0.11	8.58
28/11/2023	8.58	0.125	28.33	4.195	0.19	7.885
29/11/2023	7.885	0.05	26.57	3.965	0.085	9.385
30/11/2023	9.385	0.28	13.815	2.835	0.425	6.095

Lampiran 2. Hasil *Trial and Error* Penentuan Data dan Arsitektur Jaringan

Data Pelatihan : Pengujian	<i>Input Layer</i>	<i>Hidden Layer</i>	<i>Output Layer</i>	MSE	MAPE
50%: 50%	5	3-2	1	6.843213	27.68105
	5	4-2	1	7.310206	27.91434
	5	4-3	1	6.922828	27.81844
60%: 40%	5	3-2	1	6.736337	29.14364
	5	4-2	1	7.237086	29.28974
	5	4-3	1	7.639054	30.27806
70%: 30%	5	3-2	1	9.732862	24.14033
	5	4-2	1	8.305958	23.73836
	5	4-3	1	12.38499	26.37208
80%: 20%	5	3-2	1	18.34024	28.38946
	5	4-2	1	16.26867	27.94538
	5	4-3	1	12.87348	24.36385
90%: 10%	5	3-2	1	8.46402	17.88766
	5	4-2	1	10.73636	19.63843
	5	4-3	1	8.979418	18.34728
91%: 9%	5	3-2	1	6.468138	16.59104
	5	4-2	1	8.862822	20.97694
	5	4-3	1	9.580678	19.64356
92%: 8%	5	3-2	1	6.856482	17.2927
	5	4-2	1	9.587706	21.80497
	5	4-3	1	10.40556	20.20012
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
94%: 6%	5	3-2	1	5.999165	16.98972
	5	4-2	1	13.98141	24.05363
	5	4-3	1	6.174841	17.8799
	5	3-2	1	6.080392	18.52819

95%: 5%	5	4-2	1	12.393	26.19795
	5	4-3	1	5.124215	17.52998
96%: 4%	5	3-2	1	4.723918	17.72457
	5	4-2	1	7.526359	22.68635
	5	4-3	1	4.556589	18.12819
97%: 3%	5	3-2	1	4.482973	19.2587
	5	4-2	1	5.683673	23.23819
	5	4-3	1	4.317007	20.13576
98%: 2%	5	3-2	1	4.866748	20.94252
	5	4-2	1	5.807005	24.72524
	5	4-3	1	4.653581	22.68173
99%: 1%	5	3-2	1	5.970256	21.08155
	5	4-2	1	5.830576	22.2071
	5	4-3	1	8.100841	26.79503

Lampiran 3. Data Latih Normalisasi

Tanggal	Tinggi Rata-rata Gelombang	Panjang Gelombang	Periode Gelombang	Tinggi Maksimum Gelombang	Kecepatan Angin	Target
01/12/2020	0.178099174	0.077279753	0.204376052	0.321673525	0.077555817	0.101033058
02/12/2020	0.101033058	0.044822257	0.179730704	0.293552812	0.043478261	0.391735537
03/12/2020	0.391735537	0.064914992	0.070329406	0.117969822	0.064629847	0.418595041
04/12/2020	0.418595041	0.187017002	0.064839304	0.125514403	0.185663925	0.659504132
05/12/2020	0.659504132	0.316846986	0.117656488	0.200960219	0.317273796	0.599793388
06/12/2020	0.599793388	0.533230294	0.232868478	0.336076818	0.531139835	0.791115702
07/12/2020	0.791115702	0.658423493	0.297347119	0.403978052	0.656874266	0.74338843
08/12/2020	0.74338843	0.788253478	0.334655767	0.443072702	0.787309048	0.792768595
09/12/2020	0.792768595	0.958268934	0.396609762	0.501371742	0.956521739	0.667768595
10/12/2020	0.667768595	0.749613601	0.335256873	0.442386831	0.749706228	0.54214876
11/12/2020	0.54214876	0.525502318	0.239360423	0.343621399	0.524089307	0.440082645
12/12/2020	0.440082645	0.326120556	0.190230023	0.288751715	0.324324324	0.483471074
13/12/2020	0.483471074	0.27202473	0.13913601	0.227709191	0.272620447	0.320247934
14/12/2020	0.320247934	0.191653787	0.089003767	0.15569273	0.190364277	0.10392562
⋮	⋮	⋮	⋮	⋮	⋮	⋮
10/09/2023	0.559710744	0.313755796	0.150677246	0.241426612	0.363102233	0.386157025
11/09/2023	0.386157025	0.304482226	0.199246614	0.299039781	0.351351351	0.440495868
12/09/2023	0.440495868	0.27202473	0.196481526	0.290809328	0.311398355	0.581198347
13/09/2023	0.581198347	0.377125193	0.193075258	0.290123457	0.434782609	0.696900826
14/09/2023	0.696900826	0.454404946	0.211749619	0.315500686	0.524089307	0.591528926

Lampiran 4. Data Uji Normalisasi

Tanggal	Tinggi Rata-rata Gelombang	Panjang Gelombang	Periode Gelombang	Tinggi Maksimum Gelombang	Kecepatan Angin	Target
15/09/2023	0.814979757	0.964052288	1	1	0.965517241	0.975303644
16/09/2023	0.975303644	1	0.928470255	0.944827586	1	0.847368421
17/09/2023	0.847368421	0.931372549	0.940155807	0.949425287	0.931034483	0.473684211
18/09/2023	0.473684211	0.620915033	0.936968839	0.933333333	0.618534483	0.325506073
19/09/2023	0.325506073	0.516339869	0.655984419	0.698850575	0.515086207	0.578137652
20/09/2023	0.578137652	0.506535948	0.485481586	0.551724138	0.50862069	0.665182186
21/09/2023	0.665182186	0.666666667	0.566395184	0.632183908	0.665948276	0.526315789
22/09/2023	0.526315789	0.535947712	0.674929178	0.72183908	0.534482759	0.493117409
23/09/2023	0.493117409	0.431372549	0.572415014	0.620689655	0.42887931	0.494331984
24/09/2023	0.494331984	0.483660131	0.452372521	0.514942529	0.482758621	0.618623482
25/09/2023	0.618623482	0.509803922	0.542669972	0.604597701	0.510775862	0.565182186
26/09/2023	0.565182186	0.696078431	0.672450425	0.728735632	0.693965517	0.909716599
27/09/2023	0.909716599	0.784313725	0.673512748	0.728735632	0.784482759	0.918623482
28/09/2023	0.918623482	0.970588235	0.876947592	0.903448276	0.974137931	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮
26/11/2023	0.129554656	0.075163399	0.351451841	0.422988506	0.073275862	0.136842105
27/11/2023	0.136842105	0.022875817	0.600389518	0.689655172	0.023706897	0.257489879
28/11/2023	0.257489879	0.058823529	0.513987252	0.625287356	0.058189655	0.201214575
29/11/2023	0.201214575	0.009803922	0.451664306	0.51954023	0.012931034	0.322672065
30/11/2023	0.322672065	0.160130719	0	0	0.159482759	0.056275304

Lampiran 5. Script Rstudio

```
# --- Load library ---
library(readxl)
library(neuralnet)
library(Metrics)
library(zoo)
library(caret)

#Data latih
data <- read_excel("C:/Users/Hp/Documents/kuliah/SEMESTER
7/SKRIPSI/FIX/data.xlsx", sheet = "latih93")
data <- data[,-1]

#Data uji
datauji <- read_excel("C:/Users/Hp/Documents/kuliah/SEMESTER
7/SKRIPSI/FIX/data.xlsx", sheet = "uji7")
datauji <- datauji[,-1]

# Normalisasi data latih
max_val <- apply(data, 2, max)
min_val <- apply(data, 2, min)
data.norm <- as.data.frame(scale(data, center = min_val, scale = max_val - min_val))

#Normalisasi data uji
max_val_uji <- apply(datauji, 2, max)
min_val_uji <- apply(datauji, 2, min)
datauji.norm <- as.data.frame(scale(datauji, center = min_val_uji, scale = max_val_uji -
min_val_uji))

#Pembagian data 93%:7%
train_norm <- data.frame(data.norm[1:1018,])
test_norm <- data.frame(datauji.norm[1:77,])

#Training Model
set.seed(1111)
model_final <- neuralnet(Target ~ Kecepatan.Angin + Tinggi.Rata.rata.Gelombang +
Panjang.Gelombang + Periode.Gelombang + Tinggi.Maksimum.Gelombang,
data = train_norm,
hidden = c(3,2), # <- pilih terbaik
linear.output = FALSE,
algorithm = 'backprop',
learningrate = 0.001,
threshold = 0.001,
stepmax = 1e8)

#Menampilkan model
plot(model_final)

#Bobot dan bias awal
model_final$startweights

#Bobot dan bias akhir
model_final$weights
```

```

#Prediksi pada data uji
temp_test <- subset(test_norm, select = c(
  "Kecepatan.Angin", "Tinggi.Rata.rata.Gelombang", "Panjang.Gelombang",
  "Periode.Gelombang", "Tinggi.Maksimum.Gelombang"))
model_final.results <- neuralnet::compute(model_final, temp_test)
results <- data.frame(actual = test_norm$Target, prediction =
  model_final.results$net.result)

#Denormalisasi hasil ke skala asli
results_denorm <- results * (17.75 - 5.4) + 5.4
print(results_denorm)

#MAPE dan MSE
MSE_test <- sum((results_denorm$actual - results_denorm$prediction)^2) /
  nrow(results_denorm)
MAPE_test <- (sum(abs(results_denorm$actual - results_denorm$prediction) /
  results_denorm$actual) * 100) / nrow(results_denorm)
cat("MSE pada data uji:", MSE_test, "\n")
cat("MAPE pada data uji:", MAPE_test, "\n")

#Input prediksi periode selanjutnya
input <- read_excel("C:/Users/Hp/Documents/kuliah/SEMESTER
7/SKRIPSI/FIX/forecast.xlsx", sheet = "forecast")
input <- input[,-1]
max_val_input <- apply(input, 2, max)
min_val_input <- apply(input, 2, min)
input.norm <- as.data.frame(scale(input, center = min_val_input, scale = max_val_input -
  min_val_input))

#Ambil input untuk prediksi
input_model_norm <- input.norm[, c("Kecepatan.Angin",
  "Tinggi.Rata.rata.Gelombang",
  "Panjang.Gelombang",
  "Periode.Gelombang",
  "Tinggi.Maksimum.Gelombang")]

#Prediksi menggunakan model terbaik
prediksi_baru <- neuralnet::compute(model_final, input_model_norm)

#Hasil prediksi dalam bentuk normalisasi
hasil_norm <- prediksi_baru$net.result

#Denormalisasi hasil ke skala asli
hasil_prediksi <- hasil_norm * (11.96 - 4.18) + 4.18
print(hasil_prediksi)
hasil_akhir <- data.frame(Tanggal = input.norm$Tanggal,
  Prediksi_Kecepatan_Angin = hasil_prediksi)

```

Lampiran 6. Perhitungan MAPE

Data ke-	Aktual (y_i)	Prediksi (y'_i)	$y_i - y'_i$	$\left \frac{y_i - y'_i}{y_i} \right $
1019	17.445	11.13409536	6.310904643	0.361760083
1020	15.865	11.17783554	4.687164456	0.295440558
1021	11.25	11.15033366	0.099666342	0.00885923
1022	9.42	10.86205279	-1.442052792	0.153084161
1023	12.54	10.69111799	1.848882008	0.147438757
1024	13.615	11.17223816	2.442761837	0.179416955
1025	11.9	11.33385084	0.566149159	0.04757556
1026	11.49	11.00075336	0.48924664	0.042580212
1027	11.505	10.91063584	0.594364158	0.051661378
1028	13.04	11.0587135	1.9812865	0.151939149
1029	12.38	11.13372468	1.24627532	0.100668443
1030	16.635	11.1538028	5.481197202	0.329497878
1031	16.745	11.29503366	5.449966336	0.325468279
1032	17.75	11.21549746	6.534502543	0.368140988
⋮	⋮	⋮	⋮	⋮
1085	11.855	7.931692821	3.923307179	0.330941137
1086	14.525	11.25215513	3.272844874	0.225324948
1087	13.155	11.4811749	1.673825104	0.1272387
1088	8.625	11.05327344	-2.42827344	0.28153895
1089	8.465	9.151803042	-0.686803042	0.081134441
1090	7	8.642359736	-1.642359736	0.234622819
1091	7.09	7.652960174	-0.562960174	0.079401999
1092	8.58	7.818668237	0.761331763	0.088733306
1093	7.885	7.706989768	0.178010232	0.022575806
1094	9.385	7.685812518	1.699187482	0.181053541
1095	6.095	11.01302988	-4.918029879	0.806895796
$\sum_{i=1}^{77} \left \frac{y_i - y'_i}{y_i} \right $				12.48600717
$\sum_{i=1}^{77} \left \frac{y_i - y'_i}{y_i} \right \times 100\%$				1248.600717
$\frac{1}{77} \sum_{i=1}^{77} \left \frac{y_i - y'_i}{y_i} \right \times 100\%$				16.22%

Lampiran 7. Perhitungan MSE

Data ke-	Aktual (y_i)	Prediksi (y'_i)	$y_i - y'_i$	$(y_i - y'_i)^2$
1019	17.445	11.13409536	6.310904643	39.82751741
1020	15.865	11.17783554	4.687164456	21.96951063
1021	11.25	11.15033366	0.099666342	0.00993338
1022	9.42	10.86205279	-1.442052792	2.079516255
1023	12.54	10.69111799	1.848882008	3.418364678
1024	13.615	11.17223816	2.442761837	5.967085392
1025	11.9	11.33385084	0.566149159	0.32052487
1026	11.49	11.00075336	0.48924664	0.239362275
1027	11.505	10.91063584	0.594364158	0.353268753
1028	13.04	11.0587135	1.9812865	3.925496197
1029	12.38	11.13372468	1.24627532	1.553202174
1030	16.635	11.1538028	5.481197202	30.04352276
1031	16.745	11.29503366	5.449966336	29.70213307
1032	17.75	11.21549746	6.534502543	42.69972348
⋮	⋮	⋮	⋮	⋮
1085	11.855	7.931692821	3.923307179	15.39233922
1086	14.525	11.25215513	3.272844874	10.71151357
1087	13.155	11.4811749	1.673825104	2.801690479
1088	8.625	11.05327344	-2.42827344	5.896511899
1089	8.465	9.151803042	-0.686803042	0.471698419
1090	7	8.642359736	-1.642359736	2.697345503
1091	7.09	7.652960174	-0.562960174	0.316924158
1092	8.58	7.818668237	0.761331763	0.579626054
1093	7.885	7.706989768	0.178010232	0.031687643
1094	9.385	7.685812518	1.699187482	2.887238099
1095	6.095	11.01302988	-4.918029879	24.18701789
$\sum_{i=1}^{77} (y_i - y'_i)^2$				447.0314968
$\frac{1}{77} \sum_{i=1}^{77} (y_i - y'_i)^2$				5.805603854

Lampiran 8. Data Input Prediksi 1-30 Desember 2023

Tanggal	Kecepatan Angin	Tinggi Rata-rata Gelombang	Panjang Gelombang	Periode Gelombang	Tinggi Maksimum Gelombang
30/11/2023	9.385	0.28	13.815	2.835	0.425
01/12/2023	6.095	0.19	21.205	3.635	0.285
02/12/2023	5.545	0.095	20.44	3.465	0.15
03/12/2023	7.78	0.205	18.83	3.375	0.31
04/12/2023	7.22	0.425	22.29	3.665	0.64
05/12/2023	6.655	0.38	22.795	3.755	0.58
06/12/2023	5.415	0.08	26.99	4.11	0.115
07/12/2023	11.96	0.025	26.745	3.925	0.035
08/12/2023	5.08	0.015	40.175	4.215	0.02
09/12/2023	5.275	0.115	21.63	3.51	0.175
10/12/2023	8.325	0.22	19.875	3.48	0.335
11/12/2023	7.295	0.06	14.3	2.815	0.095
12/12/2023	6.69	0.12	16.91	3.13	0.18
13/12/2023	5.3	0.04	18.98	3.315	0.055
14/12/2023	4.835	0.055	28.94	4.205	0.08
15/12/2023	6.22	0.1	19.935	3.46	0.15
16/12/2023	9.88	0.04	21.655	3.58	0.065
17/12/2023	7.545	0.385	18.74	3.41	0.59
18/12/2023	8.07	0.105	18.3	3.26	0.16
19/12/2023	6.2	0.255	16.75	3.12	0.385
20/12/2023	8.75	0.27	22.56	3.64	0.415
21/12/2023	4.18	0.09	32.885	4.53	0.125

22/12/2023	6.05	0.055	29.675	4.305	0.085
23/12/2023	8.315	0.04	25.045	3.88	0.055
24/12/2023	5.19	0.035	36.38	4.59	0.055
25/12/2023	5.08	0.08	30.475	4.135	0.115
26/12/2023	5.475	0.12	27.6	4.09	0.18
27/12/2023	5.425	0.035	39.655	4.965	0.05
28/12/2023	5.785	0.025	31.23	4.28	0.045
29/12/2023	8.48	0.305	15.445	3.045	0.46
30/12/2023	4.725	0.15	19.93	3.485	0.235

Lampiran 9. Hasil Prediksi 1 Desember 2023 – 31 Januari 2024

Tanggal	Prediksi Kecepatan Angin	Tanggal	Prediksi Kecepatan Angin
01/12/2023	11.165597	01/01/2024	5.892107406
02/12/2023	6.603103	02/01/2024	3.970305
03/12/2023	6.462238	03/01/2024	3.90441
04/12/2023	8.398322	04/01/2024	4.386201
05/12/2023	9.787674	05/01/2024	3.873817
06/12/2023	8.930811	06/01/2024	4.701528
07/12/2023	5.670665	07/01/2024	4.817678
08/12/2023	7.502266	08/01/2024	4.053574
09/12/2023	5.784579	09/01/2024	9.141859
10/12/2023	6.385038	10/01/2024	11.425075
11/12/2023	8.576485	11/01/2024	7.90717
12/12/2023	8.463968	12/01/2024	10.952506
13/12/2023	7.383888	13/01/2024	5.509231
14/12/2023	5.75449	14/01/2024	4.686754
15/12/2023	5.635972	15/01/2024	8.258932
16/12/2023	6.702585	16/01/2024	8.214225
17/12/2023	7.622696	17/01/2024	4.36434
18/12/2023	9.909266	18/01/2024	6.520011
19/12/2023	7.925432	19/01/2024	6.438866
20/12/2023	8.480689	20/01/2024	6.99117
21/12/2023	9.067062	21/01/2024	8.820239
22/12/2023	5.680375	22/01/2024	7.7149
23/12/2023	5.641106	23/01/2024	8.426525
24/12/2023	6.637544	24/01/2024	11.758867
25/12/2023	5.764977	25/01/2024	9.414057
26/12/2023	5.629624	26/01/2024	10.856097
27/12/2023	6.178586	27/01/2024	7.786186
28/12/2023	5.776997	28/01/2024	9.770284
29/12/2023	5.71005	29/01/2024	9.106181
30/12/2023	10.43916	30/01/2024	5.403952
31/12/2023	5.923478031	31/01/2024	9.945408

Lampiran 10. Pengelompokan Gelombang Laut

Tanggal	Kecepatan Angin (knot)	Skala Beaufort	Estimasi Tinggi Gelombang (meter)	Gelombang Laut
01/12/2023	11	4	1	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>)
08/12/2023	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
09/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
10/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
11/12/2023	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
12/12/2023	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
13/12/2023	7	3	0.6	Sedikit bergelombang (<i>slight</i>)
14/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
15/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
16/12/2023	7	3	0.6	Sedikit bergelombang (<i>slight</i>)

17/12/2023	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
18/12/2023	10	3	0.6	Sedikit bergelombang (<i>slight</i>)
19/12/2023	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
20/12/2023	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
21/12/2023	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
22/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
23/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
24/12/2023	7	3	0.6	Sedikit bergelombang (<i>slight</i>)
25/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
26/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
27/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
28/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
29/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
30/12/2023	10	3	0.6	Sedikit bergelombang (<i>slight</i>)
31/12/2023	6	2	0.2	Gelombang halus (<i>wavelets</i>)
01/01/2024	6	2	0.2	Gelombang halus (<i>wavelets</i>)
02/01/2024	4	2	0.2	Gelombang halus (<i>wavelets</i>)
03/01/2024	4	2	0.2	Gelombang halus (<i>wavelets</i>)
04/01/2024	4	2	0.2	Gelombang halus (<i>wavelets</i>)
05/01/2024	4	2	0.2	Gelombang halus (<i>wavelets</i>)

06/01/2024	5	2	0.2	Gelombang halus (<i>wavelets</i>)
07/01/2024	5	2	0.2	Gelombang halus (<i>wavelets</i>)
08/01/2024	4	2	0.2	Gelombang halus (<i>wavelets</i>)
09/01/2024	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
10/01/2024	11	4	1	Sedikit bergelombang hingga bergelombang sedang
11/01/2024	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
12/01/2024	11	4	1	Sedikit bergelombang hingga bergelombang sedang
13/01/2024	6	2	0.2	Gelombang halus (<i>wavelets</i>)
14/01/2024	5	2	0.2	Gelombang halus (<i>wavelets</i>)
15/01/2024	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
16/01/2024	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
17/01/2024	4	2	0.2	Gelombang halus (<i>wavelets</i>)
18/01/2024	7	3	0.6	Sedikit bergelombang (<i>slight</i>)
19/01/2024	6	2	0.2	Gelombang halus (<i>wavelets</i>)
20/01/2024	7	3	0.6	Sedikit bergelombang (<i>slight</i>)
21/01/2024	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
22/01/2024	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
23/01/2024	8	3	0.6	Sedikit bergelombang (<i>slight</i>)

24/01/2024	12	4	1	Sedikit bergelombang hingga bergelombang sedang
25/01/2024	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
26/01/2024	11	4	1	Sedikit bergelombang hingga bergelombang sedang
27/01/2024	8	3	0.6	Sedikit bergelombang (<i>slight</i>)
28/01/2024	10	3	0.6	Sedikit bergelombang (<i>slight</i>)
29/01/2024	9	3	0.6	Sedikit bergelombang (<i>slight</i>)
30/01/2024	5	2	0.2	Gelombang halus (<i>wavelets</i>)
31/01/2024	10	3	0.6	Sedikit bergelombang (<i>slight</i>)

RIWAYAT HIDUP



Muhammad Imamul Khoiri, lahir di Kabupaten Cirebon pada 9 Desember 2002, biasa dipanggil Imam. Bertempat tinggal di Blok Asinan, RT.05 RW.03 Desa Tegalsari Kecamatan Plered, Kabupaten Cirebon, Jawa Barat. Penulis merupakan anak pertama dari pasangan Bapak Abdul Hadi dan Ibu Badriyah. Penulis memulai pendidikan pertama di TK Kemala Bhayangkari 29 pada tahun 2008 dan lulus pada tahun 2009. Penulis melanjutkan pendidikan ke jenjang sekolah dasar di SD Negeri 1 Weru Kidul dan lulus pada tahun 2015. Setelah lulus sekolah dasar, penulis melanjutkan ke pendidikan jenjang menengah pertama di MTs Salafiyah Syafi'iyah Bandung dan lulus pada tahun 2018. Setelah itu, penulis melanjutkan pendidikan jenjang menengah atas di SMA Trensains Tebuireng dan dinyatakan lulus pada tahun 2021. Setelah lulus SMA di tahun 2021, penulis melanjutkan pendidikan di salah satu Perguruan Tinggi yang ada di Kota Malang, Jawa Timur yaitu di Universitas Islam Negeri Maulana Malik Ibrahim Malang (UIN Malang). Penulis mengambil Program Studi Matematika, Fakultas Sains dan Teknologi di UIN Malang melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN). Satu diantara mata kuliah wajib yang pernah diikuti oleh penulis adalah Praktik Kerja Lapangan (PKL) di Badan Meteorologi Klimatologi dan Geofisika (BMKG) Maritim Tanjung Perak Surabaya. Penulis dapat dihubungi melalui email berikut: imamulkhoiri9@gmail.com.



KE MENTERIAN AGAMA RI
UN VERSITAS ISLAM NEGERI
MA ULANA MALIK IBRAHIM MALANG
FA KULTAS SAINS DAN TEKNOLOGI
Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

BUKTI KONSULTASI SKRIPSI

Nama : Muhammad Imamul Khoiri
NIM : 210601110044
Fakultas/Jurusan : Sains dan Teknologi/Matematika
Judul Skripsi : Prediksi Kecepatan Angin di Penyeberangan Kapal
Gresik-Bawean Menggunakan Metode Jaringan Saraf
Tiruan
Pembimbing I : Prof. Dr. Hj. Sri Harini, M.Si.
Pembimbing II : Achmad Nashichuddin, M.A.

No.	Tanggal	Hal	Tanda Tangan
1.	27 Agustus 2024	Konsultasi Topik dan Data	1.
2.	21 Oktober 2024	Konsultasi Topik dan Data	2.
3.	24 Oktober 2024	Konsultasi Topik dan Data	3.
4.	10 Januari 2025	Konsultasi Bab I, II, dan III	4.
5.	17 Januari 2025	Konsultasi Bab I, II, dan III	5.
6.	22 Januari 2025	ACC Bab I, II, dan III	6.
7.	04 Februari 2025	Konsultasi Kajian Agama Bab I dan II	7.
8.	10 Februari 2025	ACC Kajian Agama Bab I dan II	8.
9.	12 Februari 2025	ACC Seminar Proposal	9.
10.	29 April 2025	Konsultasi Revisi Seminar Proposal	10.
11.	08 Mei 2025	Konsultasi Bab IV dan V	11.
12.	09 Mei 2025	Konsultasi Kajian Agama Bab I dan II	12.
13.	14 Mei 2025	ACC Kajian Agama Bab IV	13.
14.	03 Juni 2025	ACC Seminar Hasil	14.



KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Gajayana No.50 Dinoyo Malang Telp / Fax. (0341)558933

No.	Tanggal	Hal	Tanda Tangan
15.	05 Juni 2025	Konsultasi Revisi Seminar Hasil	15.
16.	10 Juni 2025	Konsultasi Revisi Seminar Hasil	16.
17.	10 Juni 2025	Konsultasi Kajian Agama Bab I, II, dan IV	17.
18.	10 Juni 2025	ACC Kajian Agama Bab I, II, dan IV	18.
19.	11 Juni 2025	ACC Revisi Seminar Hasil	19.
20.	12 Juni 2025	ACC Sidang Skripsi	20.
21.	19 Juni 2025	ACC Akhir Keseluruhan	21.

Malang, 19 Juni 2025

Mengetahui,

Ketua Program Studi Matematika

Dr. Elly Susanti, M.Sc.
NIP. 19741129 200012 2 005