

**PREDIKSI KECEPATAN DAN ARAH ANGIN DI PERAIRAN
KEPULAUAN RIAU MENGGUNAKAN METODE INFORMER
DAN BiLSTM**

TUGAS AKHIR



Danyi Aprizal

NIM. 2201020027

**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK ELEKTRO DAN INFORMATIKA
FAKULTAS TEKNIK DAN TEKNOLOGI KEMARITIMAN
UNIVERSITAS MARITIM RAJA ALI HAJI
TANJUNGPINANG
2026**

PREDIKSI KECEPATAN DAN ARAH ANGIN DI PERAIRAN KEPULAUAN RIAU MENGGUNAKAN METODE INFORMER DAN BiLSTM

Tugas Akhir

Skema Skripsi

Tugas Akhir diajukan sebagai salah satu persyaratan memperoleh gelar Sarjana

Teknik pada Program Studi Teknik Informatika



Danyi Aprizal

NIM. 2201020027

**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK ELEKTRO DAN INFORMATIKA
FAKULTAS TEKNIK DAN TEKNOLOGI KEMARITIMAN
UNIVERSITAS MARITIM RAJA ALI HAJI
TANJUNGPINANG
2026**

PERNYATAAN MENGENAI TUGAS AKHIR DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa tugas akhir berjudul “Prediksi Kecepatan dan Arah Angin di Perairan Kepulauan Riau Menggunakan Metode Informer dan BiLSTM” adalah benar karya saya dengan arahan dari komisi pembimbing dan belum diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka di bagian akhir skripsi ini.

Apabila di kemudian hari terbukti pernyataan saya tidak benar dan melanggar peraturan yang berlaku dalam karya tulis dan hak intelektual, maka saya bersedia ijazah yang telah saya terima untuk ditarik kembali oleh Universitas Maritim Raja Ali Haji dan menerima sanksi lainnya sesuai dengan peraturan yang berlaku. Dengan ini saya melimpahkan hak cipta dari karya tulis saya kepada Universitas Maritim Raja Ali Haji.

Tanjungpinang, 6 Mei 2026



Danyi Aprizal
NIM 2201020027



© Hak Cipta Milik Universitas Maritim Raja Ali Haji, Tahun 2026

Hak Cipta Dilindungi Undang- Undang

Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan atau menyebutkan sumbernya. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik, atau tinjauan suatu masalah; dan pengutipan tersebut tidak merugikan kepentingan Universitas Maritim Raja Ali Haji.

Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin Universitas Maritim Raja Ali Haji.

HALAMAN PERSETUJUAN

Judul : Prediksi Kecepatan dan Arah Angin di Perairan Kepulauan
Riau Menggunakan Metode Informer dan BiLSTM
Nama : Danyi Aprizal
NIM : 2201020027
Program Studi : Teknik Informatika
Tanggal Persetujuan : 6 Mei 2026

Disetujui oleh,
Komisi Pembimbing


Tekad Matulatan, S.Sos., S.Kom.,
M.Inf.Tech.
(Ketua)



Nolan Efranda, M.Kom
(Anggota)

HALAMAN PENGESAHAN

Judul : Prediksi Kecepatan dan Arah Angin di Perairan
Kepulauan Riau Menggunakan Metode Informer dan
BiLSTM
Nama : Danyi Aprizal
NIM : 2201020027

Telah berhasil dipertahankan di hadapan Komisi Penguji sebagai bagian persyaratan yang diperlukan dalam memperoleh gelar Sarjana Teknik pada Program Studi Teknik Informatika, Jurusan Teknik Elektro dan Informatika, Fakultas Teknik dan Teknologi Kemaritiman, Universitas Maritim Raja Ali Haji.

KOMISI PENGUJI

Ketua	: Martaleli Bettiza, S.Si., M.Sc.	()
Anggota I	: Novrizal Fattah Fahmitra, S.Kom., M.Kom.	()
Anggota II	: Fortia Magfira, M.Kom.	()
Anggota III	: Tekad Matulatan, S.Sos., S.Kom., M.Inf.Tech.	()
Anggota IV	: Nolan Efranda, M.Kom.	()

Mengetahui,

Ketua Jurusan Teknik Elektro dan Informatika



Hollanda Arie Kusuma, S.IK., M.Si

NIP. 198904012019031016

Tanggal Ujian: 25 Juni 2026

Tanggal Lulus: 25 Juni 2026

ABSTRAK

DANYI APRIZAL. Prediksi Kecepatan dan Arah Angin di Perairan Kepulauan Riau Menggunakan Metode Informer dan BiLSTM. Dibimbing oleh TEKAD MATULATAN dan NOLAN EFRANDA.

Perairan Kepulauan Riau merupakan jalur pelayaran strategis yang mengalami variabilitas angin tinggi akibat pengaruh sistem monsun, sehingga prediksi kecepatan dan arah angin yang akurat sangat dibutuhkan untuk keselamatan navigasi maritim. Penelitian ini membandingkan performa dua model *deep learning* berbasis pendekatan *data-driven*, yaitu Informer yang menggunakan mekanisme *ProbSparse self-attention* dengan kompleksitas $O(L \log L)$, dan Bidirectional Long Short-Term Memory (BiLSTM) yang memproses sekuens dari dua arah. Data observasi kecepatan dan arah angin interval 6 jam periode Januari 2023 hingga Desember 2025 diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Tanjungpinang pada empat titik pengamatan di perairan Kepulauan Riau. Data dibagi secara kronologis dengan rasio 70:10:20 untuk pelatihan, validasi, dan pengujian. Evaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) pada data pengujian periode Mei hingga Desember 2025. Hasil penelitian menunjukkan bahwa Informer unggul dalam prediksi kecepatan angin dengan RMSE rata-rata 4,9862 knot dan MAE 3,7747 knot, lebih rendah 3,5% dan 11,6% dibandingkan BiLSTM. Sebaliknya, BiLSTM unggul dalam prediksi arah angin dengan RMSE rata-rata $66,5686^\circ$ dan MAE $51,7779^\circ$, lebih rendah 17,4% dan 25,1% dibandingkan Informer. Temuan ini konsisten pada skala asli maupun skala ternormalisasi, mengindikasikan bahwa tidak ada satu model yang mutlak superior untuk seluruh parameter angin. Implementasi aplikasi web *WindSight* berbasis Streamlit dikembangkan untuk memvisualisasikan hasil prediksi secara interaktif.

Kata kunci: *deep learning*, Informer, Bidirectional LSTM, prediksi angin, prakiraan cuaca maritim.

ABSTRACT

DANYI APRIZAL. Wind Speed and Direction Prediction in the Riau Islands Waters Using the Informer and BiLSTM Methods. Supervised by TEKAD MATULATAN and NOLAN EFRANDA.

The Riau Islands waters constitute a strategic shipping lane characterized by high wind variability driven by the monsoon system, making accurate predictions of wind speed and direction essential for maritime navigation safety. This study compares the performance of two data-driven deep learning models: Informer, which employs a ProbSparse self-attention mechanism with $O(L \log L)$ complexity, and Bidirectional Long Short-Term Memory (BiLSTM), which processes sequences in both temporal directions. Wind speed and direction observations at 6-hour intervals from January 2023 to December 2025 were obtained from the Meteorology, Climatology, and Geophysics Agency (BMKG) at Tanjungpinang, covering four monitoring points in the Riau Islands waters. Data were split chronologically at a 70:10:20 ratio for training, validation, and testing. Model performance was evaluated using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE) on test data spanning May through December 2025. Results show that Informer outperforms BiLSTM in wind speed prediction, achieving an average RMSE of 4.9862 knots and MAE of 3.7747 knots, reductions of 3.5% and 11.6%, respectively. Conversely, BiLSTM outperforms Informer in wind direction prediction with an average RMSE of 66.5686° and MAE of 51.7779° , which are 17.4% and 25.1% lower than Informer, respectively. These findings are consistent across both original and normalized scales, indicating that no single model is universally superior for all maritime wind parameters. A Streamlit-based web application named WindSight was developed to interactively visualize the prediction results.

Keywords: bidirectional LSTM, deep learning, Informer, maritime weather forecasting, wind prediction.

HALAMAN PERSEMBAHAN

Puji syukur penulis panjatkan ke hadirat Allah SWT atas rahmat, hidayah, serta karunia-Nya yang senantiasa menyertai penulis dalam setiap langkah penyusunan skripsi ini. Hanya atas izin dan kemudahan dari Allah SWT, penulis dapat melewati setiap proses, tantangan, dan rasa lelah, hingga akhirnya mampu menyelesaikan skripsi ini dengan baik. Penulis menyadari bahwa perjalanan ini tidak lepas dari ujian dan kesulitan, namun setiap langkah yang dilalui menjadi bukti bahwa Allah SWT senantiasa memberikan jalan keluar bagi hamba-Nya yang berusaha dan bersabar.

Penulis menyadari bahwa pencapaian ini tidak dapat diraih seorang diri. Skripsi ini bukan sekadar hasil dari empat tahun perkuliahan, melainkan juga buah dari doa, pengorbanan, dan dukungan banyak orang yang hadir sepanjang perjalanan ini. Dengan penuh rasa syukur dan kerendahan hati, penulis mempersembahkan karya sederhana ini kepada:

1. **Ibu tercinta, Dewi**, sosok yang menjadi alasan terbesar penulis untuk terus berjuang hingga sejauh ini. Dahulu, sebelum penulis melangkah ke bangku perkuliahan, tidak sedikit yang meragukan dan bahkan berkata bahwa penulis tidak akan menjadi apa-apa. Namun di tengah semua keraguan itu, hanya Ibu yang tetap percaya, tetap mendukung, dan tetap berjuang tanpa kenal lelah demi masa depan penulis. Berkat tekad, doa yang tak pernah putus, keringat, dan pengorbanan Ibu, penulis akhirnya mampu membuktikan bahwa semua keraguan itu keliru. Gelar dan pencapaian ini bukan semata milik penulis, melainkan juga milik Ibu - sebab tanpa Ibu, tidak akan ada penulis yang berdiri di titik ini hari ini. Tidak ada untaian kata yang cukup untuk membalas semua pengorbanan itu, tetapi izinkan skripsi ini menjadi salah satu bukti kecil bahwa perjuangan Ibu tidak sia-sia. Selamat, Ibu, telah membuktikan bahwa bersama Ibu, penulis bisa kuliah dan menyelesaikan pendidikan tinggi ini. Karya ini penulis persembahkan sepenuhnya untuk Ibu.
2. **Bapak Feri Irawan, M.Kom**, selaku Koordinator Program Studi Teknik Informatika yang telah memberikan arahan dan dukungan selama masa studi penulis.

3. **Bapak Tekad Matulatan, S.Sos., S.Kom., M.Inf.Tech.** selaku Dosen Pembimbing I dan **Bapak Nolan Efranda, M.Kom.** selaku Dosen Pembimbing II, yang dengan penuh kesabaran, ketelitian, dan dedikasi telah membimbing penulis dari awal penyusunan hingga penyelesaian skripsi ini. Terima kasih atas setiap waktu yang diluangkan di tengah kesibukan, ilmu yang dibagikan dengan tulus, serta setiap kritik dan saran yang membangun. Bimbingan Bapak berdua tidak hanya membentuk skripsi ini menjadi lebih baik, tetapi juga mengajarkan penulis untuk lebih teliti, sabar, dan bertanggung jawab dalam berpikir maupun bekerja. Semoga segala ilmu dan bimbingan yang telah diberikan menjadi ladang pahala yang tidak pernah putus.
4. **Dwi Apprela Angraini**, yang telah menemani penulis sejak semester 3 hingga detik ini. Terima kasih telah menjadi tempat berkeluh kesah di saat lelah, menjadi penyemangat di saat semangat mulai memudar, dan tetap bertahan mendampingi penulis yang tidak jarang keras kepala dan kurang peka. Kesabaran dan pengertian yang diberikan selama ini tidak pernah luput dari perhatian penulis, meskipun jarang terucap secara langsung. Terima kasih telah menjadi bagian dari perjalanan ini, baik dalam suka maupun duka, dan telah menjadi salah satu alasan penulis untuk terus bertahan hingga sejauh ini.
5. **Seluruh teman-teman Teknik Informatika angkatan 2022**, atas kebersamaan, bantuan, dan perjuangan bersama selama masa perkuliahan yang penuh dinamika ini.
6. Semua pihak yang tidak dapat penulis sebutkan satu per satu, yang telah membantu dan mendukung, baik secara langsung maupun tidak langsung, hingga skripsi ini dapat terselesaikan dengan baik.

Akhir kata, penulis berharap semoga skripsi ini dapat memberikan manfaat dan menjadi kontribusi kecil bagi perkembangan ilmu pengetahuan, serta menjadi awal dari perjalanan baru yang penuh keberkahan bagi penulis dan bagi semua pihak yang telah turut serta di dalamnya.

HALAMAN MOTTO

"Sesungguhnya bersama kesulitan ada kemudahan."

(QS. Al-Insyirah: 6)

"Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya."

(QS. Al-Baqarah: 286)

"Asa Kawa Pasti Pacak"

Selama ada kemauan, pasti ada jalan untuk bisa.

Dengarkan kata hati, bukan sekadar kata orang,
sebab pada akhirnya diri sendirilah yang menjalani setiap langkah.

Berusahalah menjadi manusia yang bermanfaat,
peduli pada sesama dan lingkungan sekitar,
serta tidak menjadikan materi sebagai satu-satunya tujuan hidup.

Dan saat penat mendera, jangan lupa jaga diri
makan dan minum yang cukup, sebab tubuh yang terjaga
adalah bekal untuk terus melangkah.

PRAKATA

Puji dan syukur dipanjatkan kepada Allah *subhanahu wa ta'ala* atas segala karunia-Nya sehingga tugas akhir ini berhasil diselesaikan. Tema yang dipilih dalam tugas akhir ini ialah prediksi angin, dengan judul **“Prediksi Kecepatan dan Arah Angin di Perairan Kepulauan Riau Menggunakan Metode Informer Dan BiLSTM”**.

Terima kasih penulis ucapkan kepada Bapak Tekad Matulatan, S.Sos., S.Kom., M.Inf.Tech. dan Nolan Efranda, M.Kom. yang telah banyak memberi saran. Ungkapan terima kasih juga disampaikan kepada ayah, ibu, serta seluruh keluarga, atas segala doa dan kasih sayangnya.

Semoga laporan tugas akhir ini bermanfaat.

Tanjungpinang, 6 Mei 2026



Danyi Aprizal

DAFTAR ISI

HALAMAN PERSETUJUAN.....	iv
HALAMAN PENGESAHAN.....	v
ABSTRAK	vi
ABSTRACT.....	vii
HALAMAN PERSEMBAHAN.....	viii
HALAMAN MOTTO	x
PRAKATA.....	xi
DAFTAR ISI.....	xii
DAFTAR TABEL.....	xv
DAFTAR GAMBAR	xvii
BAB I PENDAHULUAN	1
A. Latar Belakang	1
B. Perumusan Masalah	4
C. Batasan Penelitian	4
D. Tujuan Penelitian	5
E. Manfaat Penelitian	6
1. Manfaat Akademis	6
2. Manfaat Praktis	6
BAB II KAJIAN LITERATUR	7
A. Tinjauan Pustaka	7
B. Landasan Teori.....	11
1. Data Deret Waktu (Time Series).....	11
2. Angin.....	13
3. Sistem Monsun di Perairan Kepulauan Riau	15

4. Prediksi Cuaca Berbasis Data (Data-Driven Weather Forecasting/DDWF).....	16
5. Deep Learning.....	20
6. Long Short-Term Memory (LSTM).....	21
7. Bidirectional LSTM (BiLSTM).....	25
8. Transformer.....	27
9. Informer.....	30
10. Normalisasi Data.....	33
11. Transformasi Data.....	34
12. Penanganan Missing Values	35
13. Metrik Evaluasi	35
BAB III METODE PENELITIAN.....	38
A. Waktu dan Tempat Penelitian	38
B. Prosedur Pelaksanaan Penelitian.....	40
C. Perancangan Sistem	42
1. Perancangan Metode Informer.....	42
2. Perancangan Metode BiLSTM.....	44
D. Analisis Data.....	46
1. Preprocessing Data.....	48
2. Parameter dan Bobot Awal Model.....	49
3. Perhitungan Manual BiLSTM.....	51
4. Perhitungan Manual Informer.....	53
5. Evaluasi Model.....	54
6. Analisis Perbandingan Model	59
BAB IV HASIL DAN PEMBAHASAN	61
A. Hasil Implementasi	61

1. Lingkungan Pengembangan	61
2. Konfigurasi Hyperparameter Model	61
3. Proses Pelatihan Model	65
4. Implementasi Antarmuka Aplikasi Web	67
B. Hasil Prediksi Kecepatan dan Arah Angin	73
1. Hasil Prediksi Kecepatan dan Arah Angin Model BiLSTM.....	74
2. Hasil Prediksi Kecepatan dan Arah Angin Model Informer	77
C. Analisis Hasil Prediksi Arah Angin	80
1. Analisis Prediksi Arah Angin Model BiLSTM.....	80
2. Analisis Prediksi Arah Angin Model Informer	82
D. Perbandingan Model Informer dan BiLSTM	84
1. Perbandingan pada Skala Asli.....	84
2. Perbandingan pada Skala Normalized	85
E. Pembahasan.....	86
1. Interpretasi Akurasi Prediksi.....	86
2. Keunggulan Informer pada Prediksi Kecepatan Angin	86
3. Keunggulan BiLSTM pada Prediksi Arah Angin	87
4. Implikasi Pemilihan Model.....	88
5. Variasi yang Memengaruhi Angin dan Keterbatasan Model.....	88
BAB V SIMPULAN DAN SARAN	90
A. Simpulan	90
B. Saran	91
DAFTAR PUSTAKA	93

DAFTAR TABEL

Tabel 1. Perbandingan Penelitian Terdahulu	10
Tabel 2. Klasifikasi Kecepatan Angin Berdasarkan Skala Beaufort.....	14
Tabel 3. Konversi Arah Angin dalam Derajat ke Arah Mata Angin	14
Tabel 4. Perbandingan Kompleksitas Informer dan BiLSTM	33
Tabel 5. Interpretasi Nilai MAPE	37
Tabel 6. Hasil Korelasi Arah Angin Antar Titik Pengamatan	39
Tabel 7. Data Training (5 sampel pertama dari 154 sampel).....	47
Tabel 8. Data Testing (10 sampel pertama dari 38 sampel).....	47
Tabel 9. Hasil Normalisasi Data Training (5 sampel pertama).....	49
Tabel 10. Hasil Normalisasi Data Testing (10 sampel pertama)	49
Tabel 11. Bobot BiLSTM (Forward LSTM).....	50
Tabel 12. Bobot Input BiLSTM.....	50
Tabel 13. Bobot BiLSTM (Backward LSTM).....	50
Tabel 14. Parameter Informer	50
Tabel 15. Prediksi 5 Sampel Pertama Data Testing (Ternormalisasi)	55
Tabel 16. Perbandingan Metrik Evaluasi: 5 Sampel Pertama terhadap 38 Sampel Penuh	58
Tabel 17. Perbandingan Kinerja Model BiLSTM dan Informer (38 Sampel Testing)	59
Tabel 18. Spesifikasi Lingkungan Pengembangan	61
Tabel 19. Konfigurasi Hyperparameter Model BiLSTM.....	62
Tabel 20. Konfigurasi Hyperparameter Model Informer.....	62
Tabel 21. Hasil Eksperimen Learning Rate BiLSTM (Titik T1).....	64
Tabel 22. Hasil Eksperimen Learning Rate Informer (Titik T1, LR Konstan)....	64
Tabel 23. Detail Proses Pelatihan Model BiLSTM per Titik dan Iterasi	66
Tabel 24. Detail Proses Pelatihan Model Informer per Titik dan Iterasi	67
Tabel 25. Fitur Utama Antarmuka Aplikasi Web WindSight.....	69
Tabel 26. Hasil Evaluasi Model BiLSTM per Titik dan Iterasi - Skala Asli (knot dan °)	74
Tabel 27. Hasil Evaluasi Model BiLSTM per Titik - Skala Normalized.....	75

Tabel 28. Hasil Evaluasi Model Informer per Titik dan Iterasi - Skala Asli (knot dan °)	77
Tabel 29. Hasil Evaluasi Model Informer per Titik - Skala Normalized.....	78
Tabel 30. Rekap Hasil Evaluasi Seluruh Titik Pengamatan - Skala Asli.....	84
Tabel 31. Perbandingan Langsung Rata-rata Informer dan BiLSTM - Skala Asli	85
Tabel 32. Perbandingan Langsung Rata-rata Informer dan BiLSTM - Skala Normalized	85
Tabel 33. Interpretasi Kategori Akurasi Berdasarkan Nilai MAPE.....	86



DAFTAR GAMBAR

Gambar 1. Komponen Data Deret Waktu	13
Gambar 2. Arsitektur Dasar Deep Learning	21
Gambar 3. Arsitektur LSTM dengan Mekanisme Gating.....	21
Gambar 4. Arsitektur Bidirectional LSTM (BiLSTM)	25
Gambar 5. Arsitektur Transformer	27
Gambar 6. Arsitektur Informer	30
Gambar 7. Tahapan Penelitian	40
Gambar 8. Metode Informer	43
Gambar 9. Metode BiLSTM	45
Gambar 10. Grafik kurva Training Loss dan Validation Loss per epoch per kandidat LR - Model BiLSTM	64
Gambar 11. Grafik kurva Training Loss dan Validation Loss per epoch per kandidat LR - Model Informer.....	65
Gambar 12. Tampilan Antarmuka Utama Aplikasi WindSight - Tab Peta.....	68
Gambar 13. Tab Peta - Heatmap IDW dan Panah Angin Prediksi terhadap Aktual BMKG.....	70
Gambar 14. Tab Prediksi - Grafik Plotly dan Kompas SVG per Titik Pengamatan	71
Gambar 15. Tab Komparasi Aktual - Prediksi terhadap Data Aktual BMKG.....	72
Gambar 16. Tab Metrik - Perbandingan Metrik Evaluasi BiLSTM dan Informer	73
Gambar 17. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T1 (Mei-Des 2025).....	76
Gambar 18. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T2 (Mei-Des 2025).....	76
Gambar 19. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T3 (Mei-Des 2025).....	76
Gambar 20. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T4 (Mei-Des 2025).....	77
Gambar 21. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T1 (Jun-Des 2025).....	79

Gambar 22. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T2 (Jun-Des 2025).....	79
Gambar 23. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T3 (Jun-Des 2025).....	79
Gambar 24. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T4 (Jun-Des 2025).....	80
Gambar 25. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T1 (Mei-Des 2025).....	81
Gambar 26. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T2 (Mei-Des 2025).....	81
Gambar 27. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T3 (Mei-Des 2025)	81
Gambar 28. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T4 (Mei-Des 2025).....	82
Gambar 29. Grafik prediksi terhadap aktual arah angin model Informer - Titik T1 (Jun-Des 2025).....	82
Gambar 30. Grafik prediksi terhadap aktual arah angin model Informer - Titik T2 (Jun-Des 2025).....	83
Gambar 31. Grafik prediksi terhadap aktual arah angin model Informer - Titik T3 (Jun-Des 2025).....	83
Gambar 32. Grafik prediksi terhadap aktual arah angin model Informer - Titik T4 (Jun-Des 2025).....	83

BAB I

PENDAHULUAN

A. Latar Belakang

Indonesia merupakan negara kepulauan terbesar di dunia dengan wilayah perairan yang mencapai sekitar 70% dari total luas wilayahnya. Kondisi geografis ini menjadikan sektor kelautan sebagai tulang punggung ekonomi nasional, khususnya dalam bidang pelayaran, perikanan, dan perdagangan maritim. Aktivitas maritim di perairan Indonesia sangat dipengaruhi oleh kondisi cuaca dan laut, terutama kecepatan dan arah angin yang secara langsung mempengaruhi tinggi gelombang, arus laut, dan keselamatan navigasi [1]. Kecepatan angin merupakan parameter meteorologi kritis yang menjadi fokus utama dalam prakiraan cuaca maritim karena dampaknya terhadap keselamatan pelayaran dan efisiensi operasional pelabuhan. Peramalan kecepatan angin yang akurat terbukti penting untuk menghindari pemborosan energi dan kerugian operasional pada pembangkit listrik tenaga bayu [2].

Provinsi Kepulauan Riau, khususnya perairan di sekitar Batam, Bintan, dan Karimun, merupakan salah satu jalur pelayaran tersibuk di Indonesia yang menghubungkan Selat Malaka dengan Laut Cina Selatan. Perairan ini mengalami variabilitas angin yang tinggi dengan pola semi-periodik yang dipengaruhi oleh pergantian musim monsun. Pada musim barat (Desember-Februari), kecepatan angin dapat mencapai 15-25 knots dengan arah dominan dari barat laut, sedangkan pada musim timur (Juni-Agustus) angin bertiup dari tenggara dengan kecepatan 10-20 knots [1]. Karakteristik angin yang tidak sepenuhnya periodik ini, dengan sekitar 60% pola teratur akibat pengaruh monsun dan 40% pola irregular akibat cuaca lokal, menjadi tantangan tersendiri dalam upaya prediksi yang akurat [3]. Ketidakmampuan memprediksi perubahan angin secara tepat dapat berdampak serius, mulai dari keterlambatan operasional pelabuhan, risiko kecelakaan maritim, hingga kerugian ekonomi pada sektor perikanan dan transportasi laut.

Dalam beberapa tahun terakhir, metode *deep learning* telah menunjukkan kemajuan signifikan dalam prediksi parameter cuaca berbasis data deret waktu. Perbandingan antara model *point-wise machine learning* konvensional dengan

model *deep learning* berbasis korelasi temporal menunjukkan bahwa BiLSTM menghasilkan akurasi tertinggi dibandingkan model konvensional seperti ARIMA, SVM, dan *Decision Tree* dalam prediksi kecepatan angin horizontal, membuktikan keunggulan arsitektur *bidirectional* dalam menangkap dependensi temporal dua arah [4]. Pendekatan lain mengintegrasikan *Automatic Weather Observing System* (AWOS) dan model regresi linear untuk memprediksi kecepatan angin 12 jam ke depan, dengan RMSE 0,63 hingga 3,07 untuk berbagai parameter kecepatan angin [5]. Salah satu varian LSTM yang semakin populer adalah Bidirectional LSTM (BiLSTM), yang mampu menangkap dependensi temporal dari dua arah (masa lalu dan masa depan) sehingga meningkatkan akurasi prediksi pada data deret waktu [6][7]. Namun, RNN dan variannya termasuk BiLSTM memiliki keterbatasan dalam menangani data dengan panjang sekuens yang sangat panjang dan kompleksitas komputasi yang tinggi dengan *time complexity* $O(Ld^2)$ dimana L adalah panjang sekuens dan d adalah dimensi *hidden state* [8].

Sebagai solusi atas keterbatasan tersebut, arsitektur berbasis *Transformer* telah dikembangkan untuk prediksi deret waktu jangka panjang. Salah satu inovasi terkini adalah *Informer*, yang diperkenalkan oleh Zhou et al. pada tahun 2021 dan memenangkan penghargaan *Best Paper Award* di konferensi AAAI 2021. *Informer* dirancang khusus untuk *Long-term Time Series Forecasting* (LTSF) dengan mekanisme *ProbSparse self-attention* yang mengurangi kompleksitas komputasi menjadi $O(L \log L)$, sehingga lebih efisien untuk dataset besar dan sekuens panjang [9]. Model berbasis *patch* terbukti dapat meningkatkan performa *Informer* hingga 21% dalam prediksi deret waktu dibandingkan model *Transformer* konvensional [10]. *Informer* juga telah diterapkan untuk prediksi temperatur menggunakan data *Automatic Weather Station* (AWS) dan *Local Data Assimilation and Prediction System* (LDAPS), dengan reduksi RMSE sebesar 0,25 °C dan MAE sebesar 0,203 °C dibandingkan model CNN-BLSTM untuk prediksi 6 hingga 336 jam ke depan, membuktikan kemampuan *Informer* menangkap pola temporal kompleks dalam variabel meteorologi [11].

Meskipun demikian, efektivitas *Transformer* untuk prediksi deret waktu masih menjadi perdebatan. Studi analitis menunjukkan bahwa pada beberapa kasus, model linear sederhana dapat mengalahkan *Transformer* akibat sifat

permutation-invariant dari mekanisme *self-attention* yang dapat menghilangkan informasi urutan temporal [12]. Hal ini mengindikasikan bahwa pemilihan model harus disesuaikan dengan karakteristik data yang digunakan. Di sisi lain, dengan arsitektur yang tepat, LSTM masih mampu bersaing dengan Transformer untuk tugas prediksi deret waktu tertentu [8]. Penelitian-penelitian sebelumnya di Indonesia lebih banyak berfokus pada aplikasi LSTM untuk prediksi harga saham, harga bahan pokok, beban listrik, atau parameter cuaca di wilayah daratan [13][14][15] namun belum ada yang secara khusus membandingkan Informer dengan BiLSTM untuk prediksi angin.

Salah satu sistem prakiraan cuaca numerik (*Numerical Weather Prediction/NWP*) konvensional yang paling banyak digunakan secara global adalah *Global Forecast System* (GFS), yang dikembangkan oleh *National Oceanic and Atmospheric Administration* (NOAA) melalui *National Centers for Environmental Prediction* (NCEP). GFS bekerja dengan menyelesaikan persamaan-persamaan fisika atmosfer secara numerik pada grid global dengan resolusi horizontal hingga 13 km dan menghasilkan prakiraan hingga 16 hari ke depan dengan pembaruan empat kali sehari [16]. Meskipun akurat pada skala global, sistem NWP seperti GFS membutuhkan infrastruktur komputasi yang sangat besar dan belum tentu merepresentasikan karakteristik angin lokal secara optimal, khususnya di wilayah perairan dengan variabilitas tinggi seperti Kepulauan Riau [17].

Pendekatan berbasis *data-driven* seperti Informer dan BiLSTM hadir sebagai alternatif terhadap sistem NWP konvensional. Alih-alih memodelkan dinamika atmosfer secara eksplisit melalui persamaan fisika, model *deep learning* mempelajari pola langsung dari data historis observasi sehingga lebih adaptif terhadap karakteristik lokal dan tidak bergantung pada infrastruktur komputasi berskala besar [17][16]. Penelitian terkini menunjukkan bahwa pendekatan *data-driven* mampu meningkatkan akurasi prediksi kecepatan dan arah angin hingga lebih dari 50% dibandingkan keluaran model GFS langsung pada wilayah maritim tertentu [18].

Hingga saat ini belum ada penelitian yang secara khusus membandingkan performa Informer dan BiLSTM untuk prediksi kecepatan dan arah angin di perairan Indonesia, khususnya Kepulauan Riau. Data angin memiliki karakteristik unik berupa *sparse sampling* (interval 6 jam), dataset yang dikumpulkan dari peta angin BMKG, dan pola semi-periodik yang mencerminkan kondisi meteorologi maritim tropis. Penelitian ini hadir untuk mengisi *gap* tersebut dengan memanfaatkan data observasi BMKG periode 2023-2025, memberikan kontribusi ilmiah dalam pemilihan model *deep learning* yang optimal untuk prediksi angin di Indonesia, sekaligus memberikan rekomendasi praktis bagi BMKG dan *stakeholder* maritim dalam pengambilan keputusan operasional.

B. Perumusan Masalah

Berdasarkan latar belakang di atas, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana performa model Informer dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau?
2. Bagaimana performa model BiLSTM dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau?
3. Model mana yang memberikan akurasi prediksi lebih baik antara Informer dan BiLSTM untuk kasus prediksi angin dengan data *sparse* dan semi-periodik?

C. Batasan Penelitian

Agar penelitian ini lebih fokus dan terarah, batasan penelitian ditetapkan sebagai berikut:

1. Data yang digunakan bersumber dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kota Tanjungpinang, mencakup periode 1 Januari 2023 hingga 31 Desember 2025.
2. Variabel yang diprediksi adalah kecepatan angin (dalam satuan knots) dan arah angin (dalam derajat) dengan interval observasi setiap 6 jam (4 kali per hari).

3. Metode yang dibandingkan terbatas pada Informer dan BiLSTM, tanpa melibatkan arsitektur lain.
4. Evaluasi model menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).
5. Penelitian ini tidak mencakup analisis dampak prediksi angin terhadap tinggi gelombang atau parameter oseanografi lainnya.
6. Data observasi diekstraksi dari 4 titik pengamatan tetap pada peta angin BMKG di perairan Kepulauan Riau, dengan koordinat T1 (5,9722°N, 106,9621°E), T2 (5,9491°N, 107,1699°E), T3 (5,7870°N, 106,9621°E), T4 (5,7755°N, 107,1699°E). Data yang diekstraksi berupa vektor angin yang terdiri dari komponen kecepatan angin (dalam satuan knots) dan arah angin (dalam derajat), sesuai dengan format peta angin BMKG.

D. Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Menganalisis performa model Informer dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau menggunakan data BMKG periode 2023-2025.
2. Menganalisis performa model BiLSTM dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau menggunakan data BMKG periode 2023-2025.
3. Membandingkan akurasi prediksi antara model Informer dan BiLSTM berdasarkan metrik evaluasi MAE, RMSE, dan MAPE untuk menentukan model yang paling optimal dalam memprediksi kecepatan dan arah angin.

E. Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

1. Manfaat Akademis

- a. Memberikan kontribusi ilmiah dalam bidang meteorologi maritim dan *deep learning* dengan membandingkan arsitektur *Transformer* (Informer) dan RNN (BiLSTM) pada data angin laut Indonesia.
- b. Menjadi referensi bagi penelitian selanjutnya yang berkaitan dengan prediksi variabel meteorologi maritim menggunakan metode *time series forecasting*.

2. Manfaat Praktis

- a. Memberikan rekomendasi model prediksi angin yang optimal untuk BMKG dalam meningkatkan akurasi prakiraan cuaca maritim di wilayah Kepulauan Riau.
- b. Mendukung pengambilan keputusan operasional bagi pelaku industri maritim seperti pelayaran, perikanan, dan manajemen pelabuhan dalam mengantisipasi kondisi cuaca yang dapat mempengaruhi keselamatan dan efisiensi operasional.
- c. Menyediakan dasar ilmiah untuk pengembangan sistem prediksi angin yang lebih akurat bagi masyarakat pesisir dan nelayan di wilayah Kepulauan Riau.

BAB II KAJIAN LITERATUR

A. Tinjauan Pustaka

Penelitian ini merujuk pada beberapa penelitian terdahulu yang relevan dengan topik prediksi data deret waktu menggunakan metode *deep learning*, khususnya arsitektur *Long Short-Term Memory (LSTM)*, *Bidirectional LSTM (BiLSTM)*, dan *Transformer*. Tinjauan pustaka ini dikelompokkan berdasarkan metode yang digunakan, yaitu penelitian berbasis *Informer* dan *Transformer* untuk prediksi deret waktu, penelitian berbasis *LSTM* dan *BiLSTM*, serta aplikasi prediksi cuaca dan parameter meteorologi di Indonesia.

Informer merupakan arsitektur *Transformer* yang dioptimasi untuk *Long Sequence Time-Series Forecasting*, dipublikasikan pada konferensi AAAI 2021 dan meraih penghargaan *Best Paper Award*. Arsitektur ini dirancang untuk mengatasi tiga kelemahan utama *Transformer* standar: (1) kompleksitas kuadratik $O(L^2)$ pada mekanisme *self-attention*, (2) penggunaan memori yang tinggi pada *stacking layers*, dan (3) kecepatan inferensi yang lambat. Solusi yang diajukan mencakup mekanisme *ProbSparse self-attention* dengan kompleksitas $O(L \log L)$, operasi *self-attention distilling*, serta *generative style decoder* yang mampu memprediksi sekuens panjang dalam satu *forward operation*. Eksperimen pada empat dataset berskala besar (ETT, ECL, Weather) menunjukkan penurunan MSE rata-rata 26,8% pada horizon 168 langkah dan 60,1% pada horizon 720 langkah dibandingkan *LSTM* [9].

Informer juga telah diterapkan untuk prediksi temperatur dengan mengombinasikan data observasi dari *Automatic Weather Station (AWS)* dan *Local Data Assimilation and Prediction System (LDAPS)* dari Korea Meteorological Administration. Dataset mencakup variabel suhu udara, komponen angin, presipitasi, dan kelembaban relatif. Model *Informer* dengan fusi data terbukti mampu mereduksi RMSE sebesar $0,25^{\circ}\text{C}$ dan MAE sebesar $0,203^{\circ}\text{C}$ dibandingkan model *CNN-BLSTM* untuk horizon prediksi 6 hingga 336 jam, membuktikan kemampuan *Informer* dalam menangkap pola temporal kompleks pada variabel meteorologi [11].

Analisis kritis terhadap efektivitas arsitektur Transformer untuk prediksi deret waktu menunjukkan bahwa pada beberapa kasus, model linear sederhana (DLinear) dapat mengungguli model Transformer yang kompleks pada berbagai *benchmark*. Hal ini disebabkan oleh sifat *permutation-invariant* dari mekanisme *self-attention* yang dapat menghilangkan informasi urutan temporal. Namun, untuk data dengan pola non-linear yang kompleks seperti data meteorologi dengan pengaruh musiman, model berbasis *attention* tetap menunjukkan keunggulan. Temuan ini memberikan perspektif penting bahwa pemilihan arsitektur model harus disesuaikan dengan karakteristik data yang digunakan [12].

Arsitektur LSTM yang dioptimasi dengan tepat terbukti masih memiliki potensi besar untuk prediksi deret waktu jangka panjang. Dengan penambahan *layer normalization* dan teknik *residual connection*, model LSTM yang diperbaiki (sLSTM) mampu bersaing dengan model *Transformer* modern pada berbagai *benchmark*. Hal ini menunjukkan bahwa arsitektur RNN tidak sepenuhnya kalah dengan *Transformer* dan tetap relevan untuk kasus tertentu, terutama pada dataset dengan ukuran terbatas dan karakteristik temporal yang kuat [8].

Konsep *patching* pada arsitektur *Transformer* untuk prediksi deret waktu diperkenalkan melalui pendekatan *subseries-level patches* yang berfungsi sebagai *input tokens*. Pendekatan ini terbukti meningkatkan kemampuan *Transformer* dalam menangkap semantik lokal dan mengurangi kompleksitas komputasi. Hasil eksperimen menunjukkan bahwa PatchTST meningkatkan performa Informer hingga 21% pada berbagai dataset prediksi deret waktu [10].

Perbandingan antara model *point-wise machine learning* konvensional (ARIMA, SVM, *Decision Tree*) dengan model *deep learning* berbasis korelasi temporal (LSTM dan BiLSTM) untuk prediksi kecepatan angin horizontal dilakukan menggunakan berbagai indikator kualitas meteorologi. Hasil eksperimen menunjukkan bahwa model berbasis *deep learning* menghasilkan akurasi prediksi lebih tinggi dibandingkan model *point-wise*, dan secara khusus BiLSTM menghasilkan akurasi tertinggi dibandingkan model konvensional seperti ARIMA, SVM, dan *Decision Tree* yang diuji. Penelitian yang dipublikasikan di jurnal *Sensors* (MDPI, Scopus Q2) tahun 2024 ini menjadi referensi penting karena

membuktikan keunggulan BiLSTM dalam menangkap dependensi temporal dua arah untuk prediksi kecepatan angin [4].

Penerapan kombinasi optimasi Tuna Swarm (TSO), dekomposisi Variational Mode Decomposition (VMD), dan jaringan BiLSTM untuk prediksi kecepatan angin jangka pendek dilakukan pada data kecepatan angin, arah angin, tekanan, dan suhu dari sebuah ladang angin. VMD digunakan untuk mendekomposisi data kecepatan angin menjadi beberapa sub-deret dengan frekuensi berbeda, sedangkan algoritma TSO digunakan untuk mengoptimalkan parameter model. Hasil penelitian menunjukkan bahwa model TSO-VMD-BiLSTM menghasilkan akurasi tertinggi dibandingkan model LSTM, VMD-LSTM, dan TSO-VMD-LSTM, dengan RMSE serendah 0,81 dan MAPE serendah 6,89%. Penggunaan BiLSTM terbukti meningkatkan kemampuan model dalam menangkap parameter mikrometeorologi melalui pemrosesan data secara dua arah. Penelitian ini relevan karena secara langsung membuktikan keunggulan BiLSTM untuk prediksi kecepatan angin [6].

Studi komparatif antara LSTM, GRU, dan BiLSTM dalam memprediksi harga *cryptocurrency* menggunakan variabel harga pembukaan, harga tertinggi, harga terendah, dan volume perdagangan menunjukkan bahwa BiLSTM memberikan performa lebih baik dengan nilai MAPE yang lebih rendah dibandingkan LSTM unidirectional. Peningkatan akurasi ini disebabkan oleh kemampuan BiLSTM dalam memproses informasi sekuensial dari dua arah sehingga mampu menangkap konteks temporal yang lebih lengkap [7].

Penerapan LSTM untuk prediksi kecepatan angin pada Pembangkit Listrik Tenaga Bayu (PLTB) Jeneponto, Sulawesi Selatan, dilakukan menggunakan data dari *Copernicus Climate Data Store* dengan periode multi-tahun. Penelitian ini menunjukkan pentingnya peramalan kecepatan angin yang akurat untuk efisiensi operasional dan menghindari pemborosan energi pada pembangkit listrik tenaga bayu. Model LSTM terbukti mampu menangkap pola temporal kecepatan angin dengan akurasi yang baik [2].

Implementasi LSTM untuk prediksi harga bahan pokok nasional di Indonesia menggunakan dataset harga komoditas dengan periode multi-tahun menunjukkan performa yang baik. Model LSTM dikonfigurasi dengan optimasi *hyperparameter* untuk mencapai akurasi terbaik. Hasil penelitian menunjukkan bahwa LSTM efektif dalam menangkap pola fluktuasi harga komoditas yang dipengaruhi oleh faktor musiman dan ekonomi [14].

Perbandingan performa LSTM dan RNN dasar dalam memprediksi konsumsi listrik menunjukkan bahwa LSTM secara konsisten mengungguli RNN dasar karena kemampuannya dalam mengatasi masalah *vanishing gradient* melalui mekanisme *gating*. Penelitian ini memberikan bukti empiris bahwa arsitektur LSTM lebih cocok untuk data deret waktu dengan dependensi jangka panjang [15].

Berdasarkan tinjauan pustaka di atas, dapat disimpulkan bahwa baik arsitektur berbasis Transformer (Informer) maupun berbasis RNN (BiLSTM) memiliki keunggulan masing-masing dalam prediksi deret waktu. Informer unggul dalam menangani sekuens panjang dengan kompleksitas komputasi yang lebih rendah $O(L \log L)$, sedangkan BiLSTM unggul dalam menangkap konteks temporal dari dua arah. Namun, belum ada penelitian yang secara khusus membandingkan kedua arsitektur ini untuk prediksi kecepatan dan arah angin di Indonesia dengan karakteristik data *sparse sampling* (interval 6 jam), dataset yang dikumpulkan dari peta angin BMKG, dan pola semi-periodik. Penelitian ini hadir untuk mengisi *gap* tersebut dengan membandingkan Informer dan BiLSTM pada data angin Kepulauan Riau.

Tabel 1. Perbandingan Penelitian Terdahulu

No	Peneliti (Tahun)	Metode	Dataset	Hasil Utama
1	Zhou et al. (2021)	Informer	ETT, ECL, <i>Weather</i> (multi-tahun)	MSE turun 60,1% dibandingkan LSTM pada horizon 720
2	Jun & Kim (2023)	Informer + CNN-BLSTM	AWS Korea (temperatur)	RMSE turun 0,25°C dibandingkan CNN-BLSTM
3	Zeng et al. (2023)	DLinear, <i>Transformer</i>	Multiple <i>benchmarks</i>	Model linear bisa unggul <i>Transformer</i> pada kasus tertentu
4	Kong et al. (2025)	sLSTM	Multiple <i>benchmarks</i>	LSTM optimasi bersaing dengan <i>Transformer</i>

No	Peneliti (Tahun)	Metode	Dataset	Hasil Utama
5	Nie et al. (2023)	PatchTST	Multiple <i>benchmarks</i>	Performa naik 21% dibandingkan Informer
6	Li et al. (2024)	LSTM, BiLSTM, ARIMA, SVM, Decision Tree	Data meteorologi multi-indikator (kecepatan angin horizontal)	BiLSTM menghasilkan akurasi tertinggi dibandingkan model konvensional yang diuji.
7	Wang & Zhang (2024)	TSO-VMD-BiLSTM	Kecepatan angin ladang angin (2022)	RMSE turun hingga 0,81 dan MAPE 6,89%, BiLSTM tingkatkan akurasi tangkap parameter mikrometeorologi
8	Priadinata et al. (2025)	LSTM, BiLSTM	GRU, <i>Cryptocurrency prices</i>	BiLSTM MAPE terendah
9	Rachma et al. (2025)	LSTM	Copernicus (angin PLTB)	LSTM efektif untuk prediksi angin
10	Cahyani et al. (2023)	LSTM	Harga bahan pokok	LSTM tangkap pola musiman harga
11	Selle et al. (2022)	LSTM dan RNN	Konsumsi listrik	LSTM unggul dibandingkan RNN dasar
12	Penelitian ini (2026)	Informer dan BiLSTM	BMKG Kepulauan Riau (angin, 6 jam interval)	Perbandingan Transformer dan RNN pada data <i>sparse</i> semi-periodik

Sumber: Diolah dari berbagai referensi (2021-2025)

Tabel 1 menunjukkan perbandingan penelitian terdahulu yang relevan dengan penelitian ini. Dapat dilihat bahwa penelitian-penelitian sebelumnya telah mengaplikasikan berbagai arsitektur *deep learning* untuk prediksi deret waktu dengan hasil yang bervariasi tergantung pada karakteristik data dan domain aplikasi. Posisi penelitian ini (baris 12) adalah membandingkan secara langsung arsitektur *Transformer-based* (Informer) dengan arsitektur *RNN-based* (BiLSTM) untuk prediksi kecepatan dan arah angindi perairan Kepulauan Riau dengan karakteristik data yang unik: *sparse sampling* (interval 6 jam), *small dataset* yang dikumpulkan dari peta anginBMKG, dan pola semi-periodik yang dipengaruhi sistem monsun.

B. Landasan Teori

1. Data Deret Waktu (Time Series)

Data deret waktu (*time series*) merupakan serangkaian data yang dikumpulkan, dicatat, atau diobservasi berdasarkan urutan waktu secara berurutan dengan interval yang tetap [19]. Analisis deret waktu merupakan suatu metode

yang digunakan untuk mengevaluasi data dengan mempertimbangkan unsur waktu sebagai variabel independen. Data yang dianalisis dikumpulkan secara berkala dalam urutan waktu tertentu, seperti per jam, harian, mingguan, bulanan, triwulan, maupun tahunan [20].

Peramalan deret waktu (*time series forecasting*) merupakan suatu proses penerapan matematis atau statistik yang digunakan untuk memperkirakan nilai variabel waktu yang akan datang, dengan berdasarkan pada pola dan informasi historis yang telah terjadi sebelumnya [19]. Tujuan utama dari peramalan adalah untuk meminimalkan kesalahan antara nilai prediksi dengan nilai aktual yang akan terjadi.

Data deret waktu memiliki empat komponen gerak atau variasi utama [20]:

a. Gerak Jangka Panjang (Trend)

Trend menggambarkan pola pergerakan data deret waktu dalam kurun waktu yang cukup panjang. Gerakan ini menunjukkan arah perubahan umum yang bersifat berkelanjutan, baik naik (*upward trend*) maupun turun (*downward trend*). *Trend* bermanfaat untuk melakukan peramalan jangka panjang dan perencanaan strategis.

b. Gerak Siklis (Cyclical)

Gerak siklis merupakan variasi jangka panjang yang terjadi di sekitar garis *trend*, meskipun memiliki rentang waktu yang lebih pendek dibanding *trend*. Pergerakan ini bersifat berulang namun tidak selalu periodik, artinya dapat terjadi kembali setelah jangka waktu tertentu yang tidak tetap. Gerak siklis menggambarkan empat fase utama dalam suatu periode ekonomi, yaitu kemajuan, kemunduran, depresi, dan pemulihan.


c. Gerak Musiman (Seasonal)

Gerak musiman terjadi dengan lebih teratur dibandingkan gerak siklis dan berlangsung secara lengkap dalam satu tahun kalender. Gerak ini memiliki pola tetap dari waktu ke waktu dengan periode yang sama setiap

tahunnya. Pada data angin, pola musiman sangat dipengaruhi oleh sistem monsun yang berganti setiap enam bulan, yaitu monsun barat (Desember-Februari) dan monsun timur (Juni-Agustus) [1].

d. Gerak Tak Teratur (Irregular)

Gerak *irregular* memiliki sifat yang tidak teratur dan tidak dapat diprediksi. Faktor-faktor seperti bencana alam, cuaca ekstrem, dan kejadian tak terduga lainnya dapat menyebabkan gerak ini. Pada data angin di Kepulauan Riau, sekitar 40% variasi disebabkan oleh cuaca lokal yang bersifat *irregular* [8].



Gambar 1. Komponen Data Deret Waktu
(Sumber: [21])

2. Angin

Angin adalah udara yang bergerak dari daerah bertekanan tinggi ke daerah bertekanan rendah. Pergerakan ini disebabkan oleh perbedaan pemanasan permukaan bumi oleh radiasi matahari yang mengakibatkan perbedaan tekanan udara [22]. Angin merupakan salah satu parameter meteorologi yang sangat penting dalam prakiraan cuaca maritim karena dampaknya terhadap keselamatan pelayaran, tinggi gelombang, dan efisiensi operasional pelabuhan [9].

a. Kecepatan Angin

Kecepatan angin adalah besaran yang menunjukkan seberapa cepat udara bergerak dari satu tempat ke tempat lain. Dalam konteks meteorologi maritim, kecepatan angin umumnya dinyatakan dalam satuan *knots* ($1 \text{ knot} = 1,852 \text{ km/jam} = 0,514 \text{ m/s}$). Pengukuran kecepatan angin dilakukan menggunakan anemometer yang dipasang pada ketinggian standar 10 meter di atas permukaan [14].

Klasifikasi kecepatan angin secara internasional menggunakan Skala Beaufort yang dikembangkan oleh Admiral Francis Beaufort pada tahun 1805 [23]. Skala ini menggunakan angka 0 hingga 12 untuk menggambarkan kondisi angin dan dampaknya terhadap permukaan laut. Tabel 2 menunjukkan klasifikasi kecepatan angin berdasarkan Skala Beaufort yang digunakan oleh BMKG.

Tabel 2. Klasifikasi Kecepatan Angin Berdasarkan Skala Beaufort

Skala	Klasifikasi	Knots	m/s	Kondisi Laut
0	<i>Calm</i> (Tenang)	< 1	< 0,5	Laut seperti cermin
1-3	<i>Light</i> (Ringan)	1-10	0,5-5,4	Riak kecil mulai terbentuk
4-5	<i>Moderate</i> (Sedang)	11-21	5,5-10,7	Gelombang kecil, puncak putih
6-7	<i>Strong</i> (Kuat)	22-33	10,8-17,1	Gelombang besar, buih putih
8-9	<i>Gale</i> (Badai)	34-47	17,2-24,4	Gelombang tinggi, semburan
10-12	<i>Storm</i> (Topan)	> 48	> 24,5	Kondisi laut sangat berbahaya

(Sumber: [23])

b. Arah Angin

Arah angin adalah arah dari mana angin bertiup, yang dinyatakan dalam derajat (0° – 360°) menggunakan sistem kompas meteorologi. Nilai 0° atau 360° menunjukkan angin dari arah Utara, sedangkan nilai meningkat searah jarum jam. Dalam prakiraan cuaca maritim, arah angin sangat penting karena menentukan pola gelombang dan arus laut [22].

Tabel 3. Konversi Arah Angin dalam Derajat ke Arah Mata Angin

No	Arah Mata Angin	Rentang Derajat ($^{\circ}$)	Keterangan
1	Utara (N)	0° - 44° / 316° - 360°	Angin bertiup dari arah Utara
2	Timur Laut (NE)	45° - 89°	Angin bertiup dari arah Timur Laut
3	Timur (E)	90° - 134°	Angin bertiup dari arah Timur

No	Arah Mata Angin	Rentang Derajat (°)	Keterangan
4	Tenggara (SE)	135° - 179°	Angin bertiup dari arah Tenggara
5	Selatan (S)	180° - 224°	Angin bertiup dari arah Selatan
6	Barat Daya (SW)	225° - 269°	Angin bertiup dari arah Barat Daya
7	Barat (W)	270° - 314°	Angin bertiup dari arah Barat
8	Barat Laut (NW)	315° - 359°	Angin bertiup dari arah Barat Laut

(Sumber: [23])

3. Sistem Monsun di Perairan Kepulauan Riau

Indonesia, termasuk perairan Kepulauan Riau, sangat dipengaruhi oleh sistem monsun yang berganti setiap enam bulan [1][3]. Monsun adalah pola angin musiman yang disebabkan oleh perbedaan pemanasan antara daratan Asia dan lautan di sekitarnya. Terdapat dua periode monsun utama:

a. Monsun Barat (Desember - Februari)

Pada periode ini, angin bertiup dari arah barat laut menuju tenggara dengan kecepatan rata-rata 15-25 knots. Monsun barat membawa udara lembab dari Samudera Pasifik dan Laut Cina Selatan, mengakibatkan curah hujan tinggi dan kondisi laut yang relatif bergelombang di perairan Kepulauan Riau [1].

b. Monsun Timur (Juni - Agustus)

Pada periode ini, angin bertiup dari arah tenggara menuju barat laut dengan kecepatan rata-rata 10-20 knots. Monsun timur membawa udara kering dari benua Australia, mengakibatkan musim kemarau dan kondisi laut yang relatif lebih tenang [1].

c. Masa Peralihan (Maret-Mei dan September-November)

Periode transisi antara kedua monsun ditandai dengan arah angin yang tidak menentu dan kecepatan yang bervariasi. Pada masa ini, sekitar 40% variasi angin disebabkan oleh cuaca lokal yang bersifat *irregular* [3].

Dalam konteks penelitian ini, prediksi kecepatan dan arah angin dilakukan menggunakan pendekatan *data-driven*, yaitu model hanya belajar dari pola numerik historis tanpa mempertimbangkan faktor fisik penyebab angin seperti perbedaan tekanan, suhu, atau kelembapan secara eksplisit. Pendekatan ini berbeda dengan metode fisik yang membutuhkan persamaan dinamika atmosfer yang kompleks. Model *data-driven* cukup dengan menggunakan nilai kecepatan dan arah angin pada waktu-waktu sebelumnya sebagai input untuk menghasilkan prediksi ke depan. Efek kombinasi antar variabel seperti pengaruh suhu terhadap arah angin tidak dimodelkan secara eksplisit, melainkan secara implisit terabstraksi dalam pola deret waktu yang dipelajari model. Dengan demikian, model hanya berfokus pada angka input tanpa memandang latar belakang fisis penyebabnya.

4. Prediksi Cuaca Berbasis Data (Data-Driven Weather Forecasting/DDWF)

Data-Driven Weather Forecasting (DDWF) adalah paradigma prediksi cuaca yang menggantikan atau melengkapi model fisik numerik dengan model *deep learning* yang dilatih pada dataset observasi dan reanalisis atmosfer skala besar [17]. Berbeda dengan *Numerical Weather Prediction* (NWP) yang memecahkan persamaan diferensial parsial dinamika atmosfer secara numerik, model DDWF mempelajari pola statistik dari data historis untuk menghasilkan prediksi secara *inductive inference* -menyimpulkan dari pola masa lalu tanpa menyelesaikan persamaan fisika secara eksplisit [16].

a. Penerimaan DDWF di Komunitas Geoscience

Penerimaan DDWF di kalangan *geoscience* didorong oleh tiga faktor utama yang terbukti secara empiris. Pertama, ketersediaan dataset reanalisis berkualitas tinggi seperti ERA5 (ECMWF Reanalysis v5) yang menyediakan data atmosfer global dari tahun 1940 hingga kini pada resolusi spasial $0,25^\circ$ dan 137 lapisan vertikal, sehingga menjadi fondasi pelatihan model *deep learning* yang konsisten dan tervalidasi [17]. Data ERA5 yang merupakan rekonstruksi terbaik kondisi atmosfer hasil asimilasi jutaan observasi historis ini menjadi alasan utama mengapa komunitas *geoscience*

dapat menerima *output* DDWF -karena fondasi datanya adalah produk saintifik yang sudah mapan.

Kedua, kemampuan kompetitif DDWF dibandingkan sistem NWP operasional. Evaluasi pertama secara *operational-like* oleh Ben Bouallègue et al. (2024) di jurnal *Bulletin of the American Meteorological Society* (BAMS) menunjukkan bahwa model DDWF seperti PanguWeather menghasilkan RMSE yang sebanding dengan sistem IFS ECMWF untuk variabel geopotensial 500 hPa (Z500) dan temperatur 850 hPa (T850) pada *lead time* lebih dari 3 hari. Lebih signifikan lagi, PanguWeather menunjukkan kemampuan diskriminasi yang lebih baik dari IFS untuk kejadian suhu ekstrem musim panas berdasarkan metrik *Area Under ROC Curve* (AUC). Hal ini membuktikan bahwa DDWF bukan sekadar alternatif komputasi yang murah, tetapi secara saintifik kompetitif dalam parameter yang relevan bagi komunitas meteorologi [16].

Ketiga, efisiensi komputasi yang transformatif. Model DDWF menghasilkan prediksi 10 hari dalam waktu 1–2 detik pada satu GPU, dibandingkan IFS yang membutuhkan sekitar 1.000 *node-hours* untuk asimilasi data dan prediksi saja [24]. Pengurangan biaya komputasi hingga beberapa orde besaran ini membuka kemungkinan bagi lembaga meteorologi yang tidak memiliki superkomputer -termasuk BMKG -untuk mengoperasikan sistem prediksi cuaca yang kompetitif. Wu dan Xue pada tahun 2024 mencatat bahwa model seperti *GraphCast* (Google DeepMind) dan FuXi mengungguli IFS ECMWF pada 90% dari 1.380 target validasi untuk *forecast* 10 hari, dengan waktu *inference* kurang dari 1 menit pada satu TPU.

b. Landasan Ilmiah DDWF untuk Prediksi Angin

Relevansi DDWF untuk prediksi variabel meteorologi spesifik seperti kecepatan dan arah angin telah terbukti di beberapa aspek. Wu dan Xue pada tahun 2024 dalam tinjauan komprehensif mereka di jurnal *Atmosphere* (MDPI) mencatat bahwa model DDWF yang dilatih pada reanalisis ERA5 mampu menghasilkan prediksi variabel atmosfer dengan

Anomaly Correlation Coefficient (ACC) lebih besar dari 0,6 hingga 15 hari ke depan pada resolusi spasial $0,25^\circ$, termasuk untuk komponen angin pada berbagai level tekanan. Komponen angin permukaan 10 meter (U10, V10) yang secara fisik terkait langsung dengan kecepatan dan arah angin merupakan salah satu variabel yang divalidasi secara konsisten dalam evaluasi DDWF.

Penelitian *Aardvark Weather* yang dipublikasikan di jurnal *Nature* memperkuat argumen ini dengan menunjukkan bahwa model *end-to-end data-driven* mampu memprediksi kecepatan angin permukaan 10 meter (U10 dan V10) dengan *Mean Absolute Error* (MAE) yang kompetitif terhadap sistem IFS ECMWF hingga 10 hari ke depan. Secara khusus, untuk wilayah dengan sumber daya rendah seperti Afrika Barat dan Pasifik -yang karakteristik ketersediaan datanya lebih mendekati kondisi Indonesia -*Aardvark* bahkan mengungguli IFS yang telah dikoreksi secara statistik per stasiun. Temuan ini memberikan dasar ilmiah bahwa pendekatan *data-driven* relevan dan dapat diandalkan untuk prediksi angin di wilayah tropis dengan karakteristik cuaca yang dipengaruhi monsun [24].

c. Limitasi DDWF dan Konteks Penelitian Ini

Meskipun DDWF telah menunjukkan kemajuan pesat, [16] mengidentifikasi beberapa keterbatasan yang relevan. Model DDWF cenderung menghasilkan prediksi yang terlalu *smooth* pada skala kecil, mengalami *bias drift* yang meningkat seiring *lead time*, dan masih lemah dalam memprediksi intensitas siklon tropis. Selain itu, Wu dan Xue pada tahun 2024 menekankan bahwa model DDWF masih menghadapi tantangan dalam kuantifikasi ketidakpastian, interpretabilitas fisik, dan prediksi kondisi ekstrem yang tidak terwakili cukup dalam data pelatihan.

Dalam konteks penelitian ini, pendekatan *data-driven* dengan model Informer dan BiLSTM mengikuti paradigma DDWF dengan skala yang lebih terfokus: bukan prediksi global, melainkan prediksi lokal di 4 titik pengamatan perairan Kepulauan Riau menggunakan data BMKG interval 6 jam. Justifikasi penggunaan pendekatan *data-driven* didasarkan pada: (1)

keterbatasan akses terhadap model NWP operasional resolusi tinggi untuk wilayah spesifik, (2) tersedianya data historis BMKG yang memadai sebagai fondasi pelatihan, dan (3) dukungan literatur yang kuat bahwa model *deep learning* berbasis deret waktu mampu mengekstraksi pola temporal angin yang dipengaruhi siklus monsun secara efektif, sebagaimana ditunjukkan oleh perkembangan DDWF global [16] [17]

d. Global Forecast System (GFS) sebagai Representasi NWP Konvensional

Global Forecast System (GFS) adalah model prakiraan cuaca numerik (*Numerical Weather Prediction/NWP*) yang dikembangkan dan dioperasikan oleh *National Centers for Environmental Prediction* (NCEP) di bawah *National Oceanic and Atmospheric Administration* (NOAA), Amerika Serikat. GFS menggunakan persamaan-persamaan fisika atmosfer - mencakup dinamika fluida, termodinamika, dan transfer radiasi - yang diselesaikan secara numerik pada grid global dengan resolusi horizontal hingga 13 km [16]. Model ini dijalankan empat kali sehari pada pukul 00, 06, 12, dan 18 UTC dan menghasilkan prakiraan hingga 16 hari ke depan untuk berbagai parameter meteorologi, termasuk kecepatan dan arah angin, suhu, tekanan udara, serta curah hujan.

Sebagai representasi pendekatan NWP konvensional, GFS menjadi acuan perbandingan konseptual dalam penelitian berbasis *data-driven*. Berbeda dengan GFS yang memerlukan pemodelan fisika atmosfer secara eksplisit dan infrastruktur komputasi berskala besar, pendekatan *data-driven* seperti Informer dan BiLSTM mempelajari pola langsung dari data historis observasi tanpa perlu merumuskan persamaan fisika secara eksplisit [17][16]. Studi terkini pada wilayah maritim menunjukkan bahwa pendekatan *deep learning* mampu mengurangi *mean absolute error* prediksi kecepatan angin hingga lebih dari 50% dibandingkan keluaran GFS secara langsung, sekaligus meningkatkan akurasi prediksi arah angin dari 64,46% menjadi 82,85% dalam toleransi 20° [18]. Temuan ini memperkuat posisi


pendekatan *data-driven* sebagai alternatif yang menjanjikan untuk prakiraan angin skala lokal dan regional.

5. Deep Learning

Deep learning merupakan bagian dari *machine learning* yang menggunakan jaringan saraf tiruan (*artificial neural network*) dengan banyak lapisan tersembunyi (*hidden layers*) untuk mempelajari representasi data secara hierarkis [7]. dalam publikasi di jurnal *Nature* mendefinisikan *deep learning* sebagai metode representasi pembelajaran yang memungkinkan model komputasi dengan banyak lapisan pemrosesan untuk mempelajari representasi data dengan berbagai tingkat abstraksi.

Arsitektur *deep learning* terdiri dari lapisan masukan (*input layer*), satu atau lebih lapisan tersembunyi (*hidden layers*), dan lapisan keluaran (*output layer*). Setiap lapisan terdiri dari unit-unit pemrosesan (neuron) yang terhubung dengan lapisan sebelum dan sesudahnya melalui bobot (*weights*) yang dapat dipelajari [7]. Proses pembelajaran dilakukan dengan menyesuaikan bobot-bobot tersebut menggunakan algoritma *backpropagation* untuk meminimalkan fungsi kerugian (*loss function*).

Untuk data sekuensial seperti deret waktu, arsitektur *Recurrent Neural Network* (RNN) dan variannya seperti *Long Short-Term Memory* (LSTM) telah terbukti efektif karena kemampuannya dalam menangkap dependensi temporal dalam data [7]. Selain itu, arsitektur berbasis *Transformer* yang menggunakan mekanisme *self-attention* juga telah menunjukkan performa yang sangat baik untuk prediksi deret waktu jangka panjang [9].




Gambar 2. Arsitektur Dasar Deep Learning

(Sumber: [7])

6. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan arsitektur *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Schuster dan Paliwal pada tahun 1997 [25]. LSTM dirancang untuk mengatasi masalah *vanishing gradient* yang sering terjadi pada RNN standar ketika mempelajari dependensi jangka panjang dalam data sekuensial. Masalah ini menyebabkan RNN kesulitan untuk mengingat informasi yang relevan dari langkah waktu yang jauh di masa lalu.

Perbedaan utama antara LSTM dan RNN konvensional terletak pada arsitektur selnya. LSTM memiliki struktur yang lebih kompleks dengan tiga mekanisme *gating* yang mengatur aliran informasi: *forget gate*, *input gate*, dan *output gate*. Selain itu, LSTM memiliki *cell state* yang berfungsi sebagai jalur informasi jangka panjang yang dapat menyimpan atau menghapus informasi secara selektif [4][13].



Gambar 3. Arsitektur LSTM dengan Mekanisme Gating

(Sumber:[13])

Berikut adalah penjelasan setiap komponen dalam arsitektur LSTM [13]:

a. Forget Gate

Forget gate berfungsi untuk menentukan informasi mana dari *cell state* sebelumnya yang harus dilupakan atau dibuang. *Gate* ini menggunakan fungsi aktivasi *sigmoid* yang menghasilkan nilai antara 0 dan 1, di mana nilai mendekati 0 berarti informasi akan dilupakan dan nilai mendekati 1 berarti informasi akan dipertahankan. Persamaan *forget gate* adalah:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Keterangan:

f_t = nilai forget gate pada waktu t

σ = fungsi aktivasi sigmoid

W_f = matriks bobot forget gate

h_{t-1} = hidden state pada waktu $t-1$

x_t = input pada waktu t

b_f = bias forget gate

Fungsi aktivasi *sigmoid* didefinisikan sebagai:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Keterangan:

$\sigma(x)$ = output fungsi sigmoid

x = nilai input

e = bilangan Euler (≈ 2.718)

b. Input Gate

Input gate berfungsi untuk menentukan informasi baru mana yang akan disimpan ke dalam *cell state*. Proses ini melibatkan dua tahap: pertama, fungsi *sigmoid* menentukan nilai mana yang akan diperbarui; kedua, fungsi *tanh* membuat vektor kandidat nilai baru. Persamaan *input gate* adalah:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

Keterangan:

i_t = nilai input gate pada waktu t

σ = fungsi aktivasi sigmoid

W_i = matriks bobot input gate

h_{t-1} = hidden state pada waktu $t-1$

x_t = input pada waktu t

b_i = bias input gate

Candidate cell state dihitung menggunakan fungsi *tanh*:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

Keterangan:

$\tilde{C}_t$ = kandidat cell state pada waktu t

$\tanh$ = fungsi aktivasi hyperbolic tangent

W_c = matriks bobot cell state

h_{t-1} = hidden state pada waktu $t-1$

x_t = input pada waktu t

b_c = bias cell state

Fungsi aktivasi *tanh* didefinisikan sebagai:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

Keterangan:

$\tanh(x)$ = output fungsi hyperbolic tangent (rentang -1 sampai 1)

x = nilai input

e = bilangan Euler (= 2.718)

e^x = eksponensial positif

e^{-x} = eksponensial negatif

c. Memory Update (Cell State Update)

Pada tahap ini, *cell state* yang lama (C_{t-1}) diperbarui menjadi *cell state* yang baru (C_t). Proses ini menggabungkan informasi yang dilupakan dari *forget gate* dengan informasi baru dari *input gate*:

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (6)$$

Keterangan:

C_t = *cell state* pada waktu t

f_t = nilai *forget gate* pada waktu t

C_t^{-1} = *cell state* pada waktu $t - 1$

i_t = nilai *input gate* pada waktu t

$\tilde{C}_t$ = kandidat *cell state* pada waktu t

d. Output Gate

Output gate berfungsi untuk menentukan bagian mana dari *cell state* yang akan menjadi keluaran. Pertama, fungsi *sigmoid* menentukan bagian mana yang akan dikeluarkan, kemudian *cell state* dilewatkan melalui fungsi *tanh* dan dikalikan dengan keluaran *sigmoid*:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

Keterangan:

o_t = nilai *output gate* pada waktu t

σ = fungsi aktivasi *sigmoid*

W_o = matriks bobot *output gate*

h_t^{-1} = *hidden state* pada waktu $t - 1$

x_t = *input* pada waktu t

b_o = bias *output gate*

$$h_t = o_t \times \tanh(C_t) \quad (8)$$

Keterangan:

h_t = *hidden state pada waktu t*

o_t = *nilai output gate pada waktu t*


$\tanh$ = fungsi aktivasi hyperbolic tangent

C_t = *cell state pada waktu t*

7. Bidirectional LSTM (BiLSTM)

Bidirectional Long Short-Term Memory (BiLSTM) merupakan pengembangan dari arsitektur LSTM yang diperkenalkan oleh Schuster dan Paliwal pada tahun 1997 [25]. Berbeda dengan LSTM standar yang hanya memproses sekuens dalam satu arah (dari masa lalu ke masa depan), BiLSTM memproses sekuens dalam dua arah secara bersamaan: arah maju (*forward*) dan arah mundur (*backward*). Pendekatan ini memungkinkan model untuk menangkap konteks dari kedua sisi setiap titik waktu dalam sekuens [4][6].

Arsitektur BiLSTM terdiri dari dua lapisan LSTM yang independen: satu lapisan memproses input dari waktu $t=1$ hingga $t=T$ (*forward LSTM*), dan lapisan lainnya memproses input dari waktu $t=T$ hingga $t=1$ (*backward LSTM*). Keluaran dari kedua lapisan kemudian digabungkan (biasanya melalui konkatensi) untuk menghasilkan representasi akhir [7].



Gambar 4. Arsitektur Bidirectional LSTM (BiLSTM)

(Sumber: [7])

Persamaan untuk *forward LSTM* adalah:

$$h_t^{\rightarrow} = \text{LSTM}(x_t, h_{t-1}^{\rightarrow}) \quad (9)$$

Keterangan:

$h_t^{\rightarrow} = \text{hiddenstateforwardpadawaktut}$

$x_t = \text{input pada waktu } t$

$h_{t-1}^{\rightarrow} = \text{hiddenstateforwardpadawaktut} - 1$

Persamaan untuk *backward LSTM* adalah:

$$h_t^{\leftarrow} = \text{LSTM}(x_t, h_{t+1}^{\leftarrow}) \quad (10)$$

Keterangan:

$h_t^{\leftarrow} = \text{hiddenstatebackwardpadawaktut}$

$x_t = \text{input pada waktu } t$

$h_{t+1}^{\leftarrow} = \text{hiddenstatebackwardpadawaktut} + 1$

Output akhir BiLSTM diperoleh dengan menggabungkan kedua *hidden state*:

$$h_t = [h_t^{\rightarrow}; h_t^{\leftarrow}] \quad (11)$$

Keterangan:

$h_t^{\rightarrow} = \text{hiddenstateforwardpadawaktut}$

$h_t^{\leftarrow} = \text{hiddenstatebackwardpadawaktut}$

$[;] = \text{operasi konkatensi}$

Keunggulan BiLSTM dibandingkan LSTM unidirectional antara lain [4][6][7]:


1. Mampu menangkap konteks dari kedua arah temporal, sehingga informasi dari masa depan (dalam konteks sekuens input) juga dapat dimanfaatkan untuk prediksi.
2. Lebih efektif dalam menangkap pola periodik dan semi-periodik seperti yang terdapat pada data angin yang dipengaruhi sistem monsun.
3. Penelitian empiris menunjukkan bahwa BiLSTM menghasilkan nilai MAPE dan RMSE yang lebih rendah dibandingkan LSTM unidirectional pada berbagai tugas prediksi deret waktu [6][7].

Namun, BiLSTM memiliki kompleksitas komputasi yang lebih tinggi, yaitu $O(Ld^2)$ di mana L adalah panjang sekuens dan d adalah dimensi *hidden state*, karena memproses data dalam dua arah. Hal ini perlu dipertimbangkan terutama untuk dataset dengan sekuens yang sangat panjang [7].

8. Transformer

Transformer merupakan arsitektur *deep learning* yang diperkenalkan oleh Vaswani *et al.* pada tahun 2017 melalui publikasi berjudul "*Attention is All You Need*" [26]. Berbeda dengan arsitektur RNN yang memproses sekuens secara berurutan, *Transformer* menggunakan mekanisme *self-attention* yang memungkinkan pemrosesan paralel seluruh elemen sekuens secara bersamaan. Hal ini menghasilkan pelatihan yang lebih cepat dan kemampuan untuk menangkap dependensi jangka panjang dengan lebih baik [9][26].

Arsitektur *Transformer* terdiri dari dua komponen utama: *encoder* dan *decoder*. *Encoder* bertugas untuk mengekstrak representasi dari sekuens input, sedangkan *decoder* bertugas untuk menghasilkan sekuens output berdasarkan representasi dari *encoder* dan output sebelumnya [26].



Gambar 5. Arsitektur Transformer

(Sumber: [26])

a. Mekanisme Self-Attention

Self-attention (atau *intra-attention*) adalah mekanisme yang menghitung hubungan antara setiap posisi dalam sekuens dengan semua posisi lainnya. Mekanisme ini menggunakan tiga komponen: *Query (Q)*, *Key (K)*, dan *Value (V)*, yang diperoleh dari transformasi linear input [26]. *Scaled Dot-Product Attention* dihitung dengan persamaan:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (12)$$

Keterangan:

Q = matriks Query dengan dimensi $(L \times d_k)$

K = matriks Key dengan dimensi $(L \times d_k)$

V = matriks Value dengan dimensi $(L \times d_v)$

d_k = dimensi Key (faktor penskalaan)

L = panjang sekuens

b. Multi-Head Attention

Multi-Head Attention memungkinkan model untuk secara bersamaan memperhatikan informasi dari subspace representasi yang berbeda pada posisi yang berbeda. Mekanisme ini menjalankan beberapa operasi *attention* secara paralel (disebut *heads*), kemudian menggabungkan hasilnya [26]:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}^1, \dots, \text{head}_h)W^O \quad (13)$$

Keterangan:

MultiHead = output multi – head attention

Concat = operasi konkatenasi

head_i = output attention head ke – i

h = jumlah attention head

W^O = matriks bobot output

di mana setiap *head* dihitung sebagai:

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (14)$$

Keterangan:

head_i = *output attention head ke - i*

Q, K, V = matriks Query, Key, dan Value

W_i^Q = *matriks bobot Query untuk head ke - i*

W_i^K = *matriks bobot Key untuk head ke - i*

W_i^V = *matriks bobot Value untuk head ke - i*

c. Positional Encoding

Karena *Transformer* tidak memiliki struktur rekuren atau konvolusional, informasi posisi dalam sekuens perlu ditambahkan secara eksplisit melalui *positional encoding*. Vaswani *et al.* menggunakan fungsi sinusoidal untuk menghasilkan *positional encoding* [26]:

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (15)$$

Keterangan:

PE = *positional encoding*

pos = *posisi token dalam sekuens*

i = *indeks dimensi*

d_{model} = *dimensi model*

$\sin$ = *fungsi sinus*

$$PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (16)$$

Keterangan:

PE = *positional encoding*

pos = *posisi token dalam sekuens*

i = *indeks dimensi*

d_{model} = *dimensi model*


$\cos$ = *fungsi cosinus*

Kompleksitas komputasi *Transformer* standar adalah $O(L^2)$ karena setiap posisi harus menghitung *attention* terhadap semua posisi lainnya. Hal ini menjadi hambatan utama ketika memproses sekuens yang sangat panjang [26][12].

9. Informer

Informer merupakan arsitektur *Transformer* yang dioptimasi untuk *Long Sequence Time-Series Forecasting* (LSTF), diperkenalkan oleh Zhou *et al.* pada tahun 2021 dan memenangkan *Best Paper Award* di konferensi AAAI 2021 [9]. Informer dirancang untuk mengatasi tiga kelemahan utama *Transformer* standar dalam prediksi deret waktu:

1. Kompleksitas kuadratik $O(L^2)$ pada mekanisme *self-attention* yang menyebabkan waktu komputasi dan penggunaan memori yang tinggi.
2. *Bottleneck* memori pada *stacking layers* yang membatasi skalabilitas model untuk input sekuens panjang.
3. Kecepatan inferensi yang lambat pada prediksi output panjang karena *dynamic decoding* yang bersifat *step-by-step*.



Gambar 6. Arsitektur Informer

(Sumber: [9])

a. ProbSparse Self-Attention

Inovasi utama Informer adalah mekanisme *ProbSparse self-attention* yang mengurangi kompleksitas dari $O(L^2)$ menjadi $O(L \log L)$. Mekanisme ini didasarkan pada observasi bahwa distribusi *attention score* dalam *self-attention* bersifat *sparse* (jarang), di mana hanya sebagian kecil pasangan *query-key* yang berkontribusi signifikan terhadap nilai *attention* [9].

Untuk mengidentifikasi *query* yang dominan, Informer mendefinisikan *Query Sparsity Measurement*:

$$M(q_i, K) = \max_j \left\{ \frac{q_i k_j^T}{\sqrt{d}} \right\} - \frac{1}{L_K} \sum_j \left(\frac{q_i k_j^T}{\sqrt{d}} \right) \quad (17)$$

Keterangan:

M = *sparsity measurement*

q_i = *query ke - i*

K = *matriks Key*

k_j = *key ke - j*

d = *dimensi*

L_k = *panjang Key*

$\max_j$ = *nilai maksimum terhadap j*

Σ_j = *penjumlahan terhadap j*

Pengukuran ini menghitung perbedaan antara nilai maksimum dan rata-rata dari dot-product antara setiap *query* dengan semua *key*. *Query* dengan nilai M yang lebih tinggi dianggap lebih penting dan dipilih untuk perhitungan *attention* [9].

ProbSparse self-attention kemudian hanya menghitung *attention* untuk top- u *query* yang dominan:

$$A(Q, K, V) = \text{softmax} \left(\frac{\bar{Q} K^T}{\sqrt{d}} \right) V \quad (18)$$

Keterangan:

A = output ProbSparse attention

Q = Query yang telah diseleksi (sparse)

K = matriks Key

V = matriks Value

d = dimensi

di mana $\bar{Q}$ adalah matriks *sparse* yang hanya berisi top- u query dengan $u = c \times \ln(L)$, dan c adalah konstanta *sampling factor* [9].

b. Self-Attention Distilling

Untuk mengurangi penggunaan memori pada *stacking layers*, Informer menggunakan operasi *distilling* yang secara progresif mengurangi dimensi temporal input. Operasi ini menggunakan konvolusi 1D dan *max-pooling* [9]:

$$X^{(j+1)} = \text{MaxPool} \left(\text{ELU} \left(\text{Conv1d}(X_{AB}^j) \right) \right) \quad (19)$$

Keterangan:

$X^{(j+1)}$ = output layer ke $-(j + 1)$

MaxPool = operasi max pooling

ELU = fungsi aktivasi Exponential Linear Unit

Conv1d = operasi konvolusi 1 dimensi

X_{AB} = input dari attention block layer ke $-j$

di mana X^j_{AB} adalah output dari *attention block* pada layer ke- j . Dengan *stride* = 2 pada *max-pooling*, dimensi input berkurang setengahnya setiap layer, sehingga total penggunaan memori menjadi $O((2 - \varepsilon)L \log L)$ [9].

c. Generative Style Decoder

Berbeda dengan *Transformer* standar yang menggunakan *dynamic decoding* (prediksi *step-by-step*), Informer menggunakan *generative style*

decoder yang dapat memprediksi seluruh sekuens output dalam satu *forward pass*. *Decoder* menerima input berupa:

$$X_{de} = \text{Concat}(X_{token}, X_0) \quad (20)$$

Keterangan:

X_{de} = *input decoder*

Concat = *operasi konkatenasi*

X_{token} = *token start*

X_0 = *embedding awal*

di mana X_{token} adalah *start token* (segmen dari sekuens input sebelum target) dan X_0 adalah *placeholder* untuk sekuens target yang diisi dengan nilai nol. Pendekatan ini secara drastis meningkatkan kecepatan inferensi untuk prediksi sekuens panjang [9].

Tabel 4. Perbandingan Kompleksitas Informer dan BiLSTM

Aspek	Informer	BiLSTM
Basis Arsitektur	<i>Transformer</i>	<i>RNN (Recurrent)</i>
Kompleksitas Waktu	$O(L \log L)$	$O(Ld^2)$
Pemrosesan	Paralel	Sekuensial (2 arah)
Mekanisme Utama	<i>ProbSparse Attention</i>	<i>Self- Gating (Forget, Input, Output)</i>
Keunggulan	Efisien untuk Konteks <i>bidirectional</i> sekuens panjang	
Kelemahan	Perlu data besar Lambat untuk sekuens untuk optimal panjang	

(Sumber: [9] [25])

10. Normalisasi Data

Normalisasi data merupakan tahap *preprocessing* yang penting dalam *deep learning* untuk mentransformasi nilai fitur ke dalam rentang yang seragam. Proses ini membantu mempercepat konvergensi algoritma optimasi dan mencegah fitur dengan skala besar mendominasi proses pembelajaran [8]. Pada penelitian ini,

digunakan teknik *Min-Max Normalization* yang mentransformasi data ke rentang [0, 1].

Persamaan normalisasi *Min-Max Normalization* adalah [8]:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (21)$$

Keterangan:

x' = nilai hasil normalisasi

x = nilai asli yang akan dinormalisasi

x_{min} = nilai minimum dalam dataset

x_{max} = nilai maksimum dalam dataset

Setelah proses prediksi selesai, hasil prediksi perlu dikembalikan ke skala aslinya melalui proses denormalisasi:

$$x = x' \times (x_{max} - x_{min}) + x_{min} \quad (22)$$

Keterangan:

x' = nilai hasil normalisasi

x = nilai asli yang akan dinormalisasi

x_{min} = nilai minimum dalam dataset

x_{max} = nilai maksimum dalam dataset

11. Transformasi Data

Data angin yang diperoleh dari BMKG pada tahap awal penelitian ini berupa citra peta angin dalam format gambar digital. Setiap citra merepresentasikan kondisi kecepatan dan arah angin pada suatu waktu tertentu di wilayah Kepulauan Riau, di mana nilai parameter angin dikodekan secara visual melalui warna dan simbol pada koordinat geografis tertentu. Untuk dapat digunakan sebagai masukan model *deep learning*, data dalam format citra tersebut harus dikonversi terlebih dahulu menjadi data numerik terstruktur melalui proses pembacaan nilai piksel pada koordinat yang bersesuaian [22].

Proses transformasi dilakukan dengan mengidentifikasi posisi piksel yang bersesuaian dengan koordinat geografis empat titik pengamatan (T1–T4),

kemudian mengonversinya ke nilai numerik berupa kecepatan angin dalam satuan knot dan arah angin dalam satuan derajat (0° – 360°). Hasil konversi ini selanjutnya disusun menjadi data deret waktu (*time series*) berinterval 6 jam yang siap diproses pada tahap prapemrosesan data. Transformasi data citra ke numerik merupakan langkah krusial yang memastikan kesesuaian format data masukan dengan arsitektur model yang digunakan.

12. Penanganan Missing Values

Data deret waktu seringkali memiliki nilai yang hilang (*missing values*) akibat kesalahan sensor, gangguan transmisi, atau masalah teknis lainnya. Penanganan nilai yang hilang merupakan tahap penting dalam *preprocessing* karena sebagian besar model *deep learning* tidak dapat menangani nilai kosong secara langsung [8].

Salah satu metode yang umum digunakan untuk mengisi nilai yang hilang pada data deret waktu adalah interpolasi linear. Metode ini mengasumsikan hubungan linear antara titik data yang diketahui dan menghitung nilai yang hilang berdasarkan garis lurus yang menghubungkan kedua titik tersebut:

$$f(x) = f(x_0) + \frac{f(x_1) - f(x_0)}{x_1 - x_0} \times (x - x_0) \quad (23)$$

Keterangan:

$f(x)$ = nilai taksiran pada titik x

x_0, x_1 = dua titik waktu yang diketahui

$f(x_0), f(x_1)$ = nilai pada titik x_0 dan x_1

13. Metrik Evaluasi

Evaluasi performa model prediksi dilakukan menggunakan metrik yang mengukur perbedaan antara nilai prediksi dengan nilai aktual. Pada penelitian ini, digunakan tiga metrik evaluasi yang umum digunakan dalam prediksi kecepatan angin [27]:

a. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) mengukur rata-rata nilai absolut dari selisih antara nilai prediksi dan nilai aktual. MAE memberikan gambaran langsung tentang besarnya kesalahan prediksi dalam satuan yang sama dengan data asli:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (24)$$

Keterangan:

n = jumlah total data

y_i = nilai aktual ke - i

$\hat{y}_i$ = nilai prediksi ke - i

b. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) mengukur akar kuadrat dari rata-rata kuadrat kesalahan. RMSE memberikan penalti yang lebih besar untuk kesalahan yang besar, sehingga sensitif terhadap outlier:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (25)$$

Keterangan :

RMSE = *Root Mean Square Error*

n = jumlah total data

y_i = nilai aktual ke- i

$\hat{y}_i$ = nilai prediksi ke- i

$(y_i - \hat{y}_i)^2$ = kuadrat selisih antara nilai aktual dan prediksi

c. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) mengukur rata-rata persentase kesalahan absolut. MAPE berguna untuk membandingkan akurasi prediksi antar variabel dengan skala yang berbeda karena hasilnya dalam bentuk persentase [28]:

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (26)$$

Keterangan:

MAPE = *Mean Absolute Percentage Error*

100% = faktor konversi ke persentase

n = jumlah total data

y_i = nilai aktual ke- i

$\hat{y}_i$ = nilai prediksi ke- i

$\frac{y_i - \hat{y}_i}{y_i}$ = nilai absolut persentase kesalahan

Tabel 5. Interpretasi Nilai MAPE

Nilai MAPE	Interpretasi
< 10%	Sangat Akurat (<i>Highly Accurate Forecasting</i>)
10% - 20%	Baik (<i>Good Forecasting</i>)
20% - 50%	Cukup (<i>Reasonable Forecasting</i>)
> 50%	Tidak Akurat (<i>Inaccurate Forecasting</i>)

(Sumber:[28])

Ketiga metrik evaluasi ini akan digunakan untuk membandingkan performa model Informer dan BiLSTM dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau. Model dengan nilai MAE, RMSE, dan MAPE yang lebih rendah dianggap memiliki performa prediksi yang lebih baik.

BAB III

METODE PENELITIAN

A. Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan dalam beberapa tahapan utama yang meliputi studi literatur, pengumpulan data, *preprocessing* data, analisis dan pemodelan menggunakan metode Informer dan BiLSTM, serta evaluasi hasil prediksi. Keseluruhan proses penelitian dilakukan secara sistematis untuk memastikan validitas dan reliabilitas hasil yang diperoleh.

Data yang digunakan dalam penelitian ini merupakan data observasi meteorologi dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Stasiun Meteorologi Tanjungpinang, Kepulauan Riau, mencakup parameter kecepatan angin (knots) dan arah angin (derajat) yang diekstraksi dari 4 titik pengamatan tetap T1 (5,9722°N, 106,9621°E), T2 (5,9491°N, 107,1699°E), T3 (5,7870°N, 106,9621°E), T4 (5,7755°N, 107,1699°E) dengan interval pengukuran 6 jam, yaitu pukul 00:00, 06:00, 12:00, dan 18:00 UTC (*Universal Time Coordinated*).

Jarak antar titik pengamatan dihitung menggunakan formula Haversine berdasarkan koordinat lintang dan bujur masing-masing titik. Jarak T1-T2 sejauh 23,12 km, T1-T3 sejauh 20,59 km, T1-T4 sejauh 31,73 km, T2-T3 sejauh 29,21 km, T2-T4 sejauh 19,30 km, dan T3-T4 sejauh 23,02 km. Dengan demikian, jarak terdekat antar titik pengamatan adalah T2-T4 (19,30 km) dan jarak terjauh adalah T1-T4 (31,73 km), sehingga keempat titik tersebar dalam radius sekitar 20-32 km yang merepresentasikan variasi spasial kondisi angin di perairan Kepulauan Riau.

Keterkaitan spasial arah angin antar titik pengamatan dianalisis menggunakan korelasi komponen sinus dan kosinus, mengingat sifat data arah angin yang sirkular. Analisis dilakukan terhadap 3.927 observasi yang bertepatan waktu pada keempat titik pengamatan. Hasilnya menunjukkan korelasi sedang hingga kuat pada seluruh pasangan titik, berkisar antara 0,692 (T2-T4) hingga 0,814 (T1-T3), dengan 70-82% observasi berada pada oktan kompas yang sama antar pasangan titik. Nilai korelasi ini tidak sepenuhnya berbanding lurus dengan jarak antar titik pasangan T2-T4 yang berjarak terdekat (19,30 km) justru memiliki korelasi terendah, sedangkan T1-T3 yang berjarak lebih jauh (20,59 km) memiliki korelasi tertinggi mengindikasikan variasi lokal turut memengaruhi arah angin

selain jarak spasial semata. Secara umum, temuan ini mengonfirmasi bahwa arah angin di keempat titik tidak bersifat independen, melainkan dipengaruhi oleh sistem angin skala regional (monsun) yang sama.

Rincian hasil perhitungan korelasi pada setiap pasangan titik pengamatan disajikan pada Tabel 6.

Tabel 6. Hasil Korelasi Arah Angin Antar Titik Pengamatan


Pasangan Titik	r_sin	r_cos	Korelasi Arah (rata-rata)	Rata-rata Selisih Sudut (°)	% Oktan Sama	Jarak Titik (km)
T1-T2	0,789	0,785	0,787	22,57	79,1	23,12
T1-T3	0,793	0,836	0,814	20,09	81,8	20,59
T1-T4	0,736	0,717	0,727	28,35	72,9	31,73
T2-T3	0,816	0,780	0,798	22,05	77,5	29,21
T2-T4	0,735	0,648	0,692	30,78	70,0	19,30
T3-T4	0,737	0,697	0,717	28,44	74,2	23,02

Analisis dominasi arah per musim menunjukkan pola pergantian yang jelas: pada monsun barat (Desember-Februari), arah angin didominasi sektor Selatan dan Barat Daya (gabungan 83,1%), sedangkan pada monsun timur (Juni-Agustus) didominasi sektor Utara dan Timur Laut (gabungan 83,8%). Pada masa peralihan, dominasi arah jauh lebih tersebar (SW 33,6%; NE 18,3%; N 15,8%), mengonfirmasi tingginya variasi *irregular* pada periode ini. Sumbu dominasi yang teramati (Selatan-Barat Daya ↔ Utara-Timur Laut) berbeda dari deskripsi umum arah monsun regional Indonesia pada BAB II (Barat Laut-Tenggara), yang kemungkinan disebabkan oleh karakteristik geografis lokal di sekitar titik pengamatan.

Periode data yang digunakan adalah 1 Januari 2023 hingga 31 Desember 2025, dengan rata-rata sekitar 4.000 sampel per titik pengamatan setelah proses deduplikasi dan penghapusan data yang rusak. Pemilihan periode tiga tahun ini bertujuan untuk menangkap pola musiman dan variabilitas angin di perairan Kepulauan Riau secara komprehensif. Data dengan interval 6 jam dipilih karena merupakan standar observasi sinoptik internasional yang umum digunakan dalam analisis meteorologi maritim[23].

B. Prosedur Pelaksanaan Penelitian

Prosedur pelaksanaan penelitian ini terdiri dari beberapa tahapan yang saling berkaitan dan dilakukan secara berurutan. Tahapan-tahapan tersebut dapat dilihat pada Gambar 7 yang menunjukkan tahapan penelitian secara keseluruhan.



Gambar 7. Tahapan Penelitian

Berikut adalah penjelasan detail dari setiap tahapan penelitian:

1. Studi Literatur

Tahap studi literatur dilakukan untuk mengumpulkan informasi dan referensi yang relevan dengan topik penelitian. Studi literatur meliputi pemahaman mengenai karakteristik angin di perairan Kepulauan Riau, konsep dasar *time series forecasting*, arsitektur model Informer dengan mekanisme *ProbSparse Self-Att* [9], serta arsitektur Bidirectional Long Short-Term Memory (BiLSTM) yang mampu menangkap dependensi temporal dari dua arah [6]. Selain itu, studi literatur juga mencakup teknik

preprocessing data meteorologi dan metrik evaluasi yang umum digunakan dalam prediksi time series.

2. Pengumpulan Data

Data diperoleh dari BMKG Stasiun Meteorologi Tanjungpinang yang merupakan stasiun pengamatan utama untuk wilayah Kepulauan Riau. Data yang dikumpulkan mencakup dua variabel utama pada 4 titik pengamatan, yaitu kecepatan angin (X_1) dalam satuan knots dan arah angin (X_2) dalam satuan derajat dengan rentang nilai 0–360°. Pengambilan data dilakukan dengan interval waktu 6 jam sesuai dengan standar observasi sinoptik *World Meteorological Organization* (WMO). Proses ini merupakan tahap transformasi data, yaitu mengonversi data citra peta angin BMKG menjadi data numerik berupa nilai kecepatan (knot) dan arah angin (derajat) pada koordinat titik pengamatan yang telah ditentukan [22].

3. Preprocessing Data

Tahap *preprocessing* merupakan tahapan penting untuk mempersiapkan data sebelum dimasukkan ke dalam model. *Preprocessing* meliputi penanganan *missing values*, *pengecekan outliers*, dan normalisasi data. Normalisasi data dilakukan menggunakan metode *Min-Max Normalization* untuk mentransformasi nilai data ke dalam rentang [0, 1] sehingga mempercepat proses konvergensi selama pelatihan model. Data dibagi secara kronologis dengan rasio 70% untuk data pelatihan, 10% untuk data validasi, dan 20% untuk data pengujian.

4. Analisis dan Pemodelan Metode Informer dan BiLSTM

Pada tahap ini, dua model *deep learning* diimplementasikan dan dianalisis, yaitu Informer dan BiLSTM. Model Informer memanfaatkan mekanisme *ProbSparse Self-Attention* yang efisien untuk menangkap pola temporal jangka panjang dalam data *time series* dengan kompleksitas komputasi $O(L \log L)$. Sementara itu, BiLSTM menggabungkan informasi dari arah *forward* dan *backward* untuk menangkap konteks temporal yang

lebih komprehensif. Kedua model dilatih menggunakan data pelatihan dan dievaluasi menggunakan data pengujian.

5. Perhitungan Manual

Perhitungan manual dilakukan untuk memvalidasi pemahaman terhadap algoritma yang digunakan. Perhitungan ini mencakup proses normalisasi data, forward dan backward propagation pada BiLSTM, perhitungan *Query-Key-Value* dan *ProbSparse Attention* pada *Informer*, serta perhitungan metrik evaluasi. Perhitungan manual menggunakan subset data yang representatif untuk mengilustrasikan alur komputasi secara detail.

6. Evaluasi Hasil

Tahap evaluasi dilakukan untuk mengukur kinerja kedua model dalam memprediksi kecepatan dan arah angin. Metrik evaluasi yang digunakan meliputi *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Hasil evaluasi dari kedua model kemudian dibandingkan untuk menentukan model mana yang lebih unggul dalam memprediksi parameter angin di perairan Kepulauan Riau [7].

C. Perancangan Sistem


Perancangan sistem prediksi kecepatan dan arah angin dalam penelitian ini melibatkan dua metode *deep learning*, yaitu *Informer* dan *BiLSTM*. Masing-masing metode memiliki arsitektur dan alur proses yang berbeda, namun keduanya dirancang untuk menangani masalah prediksi *time series* multivariat.

1. Perancangan Metode Informer

Informer merupakan arsitektur *transformer* yang dioptimalkan untuk prediksi *time series* jangka panjang. Arsitektur *Informer* memiliki tiga komponen inovatif utama: *ProbSparse Self-Attention* yang mengurangi kompleksitas dari $O(L^2)$ menjadi $O(L \log L)$, *Self-Attention Distilling* yang

secara progresif mengurangi dimensi fitur, dan *Generative Style Decoder* yang menghasilkan prediksi secara langsung dalam satu *forward pass* [9].

Diagram aliran metode Informer dapat dilihat pada Gambar 8 berikut:



Gambar 8. Metode Informer

Diagram alir data (DFD) metode Informer terdiri atas 9 proses utama dan 5 penyimpanan data. Proses 1.0 (Normalisasi) menerima data mentah dari Sumber Data dan parameter model dari Pengguna/Peneliti, lalu menyimpannya di D1 (Data Mentah). Proses 2.0 (*Positional Embedding*) menambahkan informasi urutan temporal pada data ternormalisasi yang disimpan di D2, menghasilkan vektor *embedding*. Proses 3.0 (*Encoder Layer 1*) mengubah vektor *embedding* menjadi *Query*, *Key*, dan *Value* yang diproses oleh 4.0 (*ProbSparse Self-Attention*) menghasilkan peta atensi tersaring (*sparse attention map*). Hasil ini diteruskan ke 5.0 (*Self-Attention Distilling*) yang mereduksi dimensi fitur menjadi fitur terdistilasi, disimpan di D3 (*Data Embedding*), dan diiterasi kembali ke *Encoder Layer 1* sebanyak jumlah *layer encoder* ($e_layers=2$) sebelum diteruskan sebagai representasi konteks ke D4 (*Representasi Encoder*). Proses 7.0 (*Generative Style Decoder*) menggunakan konteks *encoder* untuk menghasilkan *output* yang


disimpan di D5 (*Output Decoder*), lalu di-denormalisasi pada proses 8.0 sebelum dievaluasi pada proses 9.0 menggunakan metrik MAE, RMSE, dan MAPE, menghasilkan Hasil Prediksi Akhir dan laporan evaluasi bagi Peneliti.

Proses pada metode Informer dimulai dengan input data *time series* berupa kecepatan dan arah angin. Data kemudian dinormalisasi menggunakan *Min-Max Normalization* dan ditambahkan dengan positional embedding untuk mempertahankan informasi urutan temporal. Pada tahap encoder, mekanisme *ProbSparse Self-Attention* diterapkan untuk mengekstrak fitur-fitur penting dengan kompleksitas komputasi yang efisien. *Self-Attention* Distilling kemudian mengurangi dimensi secara bertahap untuk meningkatkan efisiensi memori. *Decoder* dengan gaya generatif menghasilkan prediksi untuk beberapa *timestep* ke depan secara langsung. *Output* prediksi kemudian di-denormalisasi untuk mendapatkan nilai aktual kecepatan dan arah angin.

2. Perancangan Metode BiLSTM

Bidirectional Long Short-Term Memory (BiLSTM) merupakan pengembangan dari arsitektur LSTM konvensional yang memproses *sequence* dari dua arah: *forward* (dari *timestep* pertama ke terakhir) dan *backward* (dari *timestep* terakhir ke pertama). Dengan menggabungkan informasi dari kedua arah, BiLSTM mampu menangkap konteks temporal yang lebih lengkap dan meningkatkan akurasi prediksi [6].

Diagram metode BiLSTM dapat dilihat pada Gambar 9 berikut:



Gambar 9. Metode BiLSTM

Diagram alir data metode BiLSTM terdiri atas 9 proses utama dan 7 penyimpanan data. Proses 1.0 (Normalisasi) menerima data mentah dan parameter model, menyimpannya di D1, kemudian diteruskan ke 2.0 (*Positional Embedding*) yang menghasilkan vektor *embedding* tersimpan di D2 dan D3. Vektor *embedding* ini diproses secara paralel oleh dua jalur: 3.0 (*LSTM Forward*) yang memproses *sequence* dari arah kiri ke kanan menghasilkan *hidden state* maju tersimpan di D4, dan 4.0 (*LSTM Backward*) yang memproses dari arah kanan ke kiri menghasilkan *hidden state* mundur tersimpan di D5. Kedua *hidden state* ini digabungkan pada proses 5.0 (*Concatenate Hidden State*) membentuk fitur gabungan $[H_f; H_b]$ yang disimpan di D6, lalu diproses oleh 6.0 (*Fully Connected Layer*) menghasilkan nilai prediksi pada proses 7.0 (*Output*), yang disimpan di D7. *Output* ini di-denormalisasi pada proses 8.0 untuk mendapatkan nilai pada skala asli, kemudian dievaluasi pada proses 9.0 menggunakan metrik MAE, RMSE, dan MAPE, menghasilkan Hasil Prediksi Akhir dan laporan evaluasi bagi Peneliti.

Proses pada metode BiLSTM dimulai dengan input data *time series* yang telah dinormalisasi. Data kemudian diproses secara paralel oleh dua layer LSTM: *Forward LSTM* yang memproses *sequence* dari $t = 1$ hingga $t=n$, dan *Backward LSTM* yang memproses *sequence* dari $t=n$ hingga $t=1$. Setiap LSTM cell memiliki komponen *forget gate*, *input gate*, *cell state*, dan *output gate* yang bekerja sama untuk mengatur aliran informasi dan mengatasi masalah *vanishing gradient*. Output dari kedua LSTM di-*concatenate* untuk membentuk representasi gabungan yang kemudian diproses oleh *Dense Layer* untuk menghasilkan prediksi. Hasil prediksi di-denormalisasi untuk mendapatkan nilai aktual.

D. Analisis Data

Data yang digunakan dalam penelitian ini merupakan data *time series* multivariat yang terdiri dari dua variabel, yaitu kecepatan angin (knots) dan arah angin (derajat). Data diperoleh dari BMKG Stasiun Meteorologi Tanjungpinang dengan interval pencatatan setiap 6 jam untuk periode 1 Januari 2023 hingga 31 Desember 2025, dengan rata-rata sekitar 4.000 sampel per titik pengamatan setelah proses pembersihan data.

Data dibagi secara kronologis menjadi tiga bagian 70% untuk data *training* (pelatihan), 10% untuk data validasi, dan 20% untuk data *testing* (pengujian). Pembagian kronologis berarti data yang lebih lama digunakan untuk pelatihan, dan data yang lebih baru digunakan untuk pengujian - tidak dilakukan pengacakan agar tidak terjadi kebocoran data (*data leakage*). Secara kronologis, data training mencakup 1 Januari 2023 hingga 4 Februari 2025, data validasi mencakup 5 Februari 2025 hingga 25 Mei 2025, dan data testing mencakup 26 Mei 2025 hingga 31 Desember 2025.

Titik potong pembagian data berlaku sama untuk kedua model. Pada implementasinya, setiap prediksi menggunakan sekuens historis yang seluruhnya mendahului titik prediksi - tidak ada data masa depan yang digunakan sebagai input, sehingga tidak terjadi kebocoran data. Perbedaan panjang sekuens input menyebabkan jumlah sampel efektif yang dapat dibentuk sedikit berbeda BiLSTM menghasilkan 2.929 sampel training, 418 sampel validasi, dan 838 sampel testing, sedangkan Informer menghasilkan 3.066 sampel training, 438 sampel validasi, dan 876 sampel testing, dengan rasio 70:10:20 yang tetap konsisten pada keduanya.

Untuk keperluan ilustrasi perhitungan manual, digunakan 192 sampel data yang terdiri dari 154 sampel untuk *training* (80.2%) dan 38 sampel untuk *testing* (19.8%), sesuai dengan proporsi pembagian data yang telah ditetapkan. Perhitungan manual ini bertujuan untuk memberikan pemahaman mendalam terhadap mekanisme kerja model BiLSTM dan Informer secara matematis.

Tabel 7. Data Training (5 sampel pertama dari 154 sampel)

No	Tanggal	Jam	Kecepatan (knots)	Arah (°)
1	2023-01-01	00:00	25	192.9
2	2023-01-01	06:00	20	191.4
3	2023-01-01	12:00	20	200.4
4	2023-01-01	18:00	20	194.4
5	2023-01-02	00:00	15	193
... (total 154 sampel)				

Tabel 8. Data Testing (10 sampel pertama dari 38 sampel)

No	Tanggal	Jam	Kecepatan (knots)	Arah (°)
1	2023-04-03	00:00	15	223.6
2	2023-04-03	06:00	15	231.5
3	2023-04-03	12:00	15	220.4
4	2023-04-04	18:00	15	229.7
5	2023-04-04	00:00	15	244.7
6	2023-04-04	06:00	15	250.7
7	2023-04-04	12:00	10	244.7
8	2023-04-05	18:00	15	229.7
9	2023-04-05	00:00	15	237.5
10	2023-04-05	06:00	15	248.6
... (total 38 sampel)				

1. Preprocessing Data

Tahap *preprocessing* data dimulai dengan normalisasi menggunakan metode *Min-Max Normalization* berdasarkan Persamaan 21. Normalisasi bertujuan untuk mentransformasi nilai data ke dalam rentang $[0, 1]$ sehingga semua fitur memiliki skala yang sama dan mempercepat proses konvergensi selama pelatihan model *neural network*. Nilai minimum dan maksimum diperoleh dari keseluruhan dataset observasi BMKG periode 2023-2025 sebagai berikut:

Kecepatan Angin:

$$x_{min} = 2 \text{ knots}, x_{max} = 30 \text{ knots}$$

Arah Angin:

$$x_{min} = 8,3^\circ, x_{max} = 351,4^\circ$$

Dengan menggunakan Persamaan 21, proses normalisasi menghasilkan rumus sebagai berikut:

Kecepatan angin:

$$x' = \frac{x - 2}{30 - 2} = \frac{x - 2}{28}$$

Arah angin:

$$x' = \frac{x - 8,3}{351,4 - 8,3} = \frac{x - 8,3}{343,1}$$

Perhitungan normalisasi untuk data pertama pada waktu 2023-01-01 00:00 dengan kecepatan angin 25 knots dan arah angin 192.9°:

Kecepatan angin:

$$x'_{\text{kec}} = \frac{25 - 2}{30 - 2} = \frac{23}{28} = 0,8214$$

Arah angin:

$$x'_{\text{arah}} = \frac{192,9 - 8,3}{351,4 - 8,3} = \frac{184,6}{343,1} = 0,5380$$

Hasil normalisasi untuk seluruh data training dan testing ditampilkan pada Tabel 9 dan Tabel 10.

Tabel 9. Hasil Normalisasi Data Training (5 sampel pertama)

No	Tanggal	Jam	Kec (knots)	Arah (°)	Kec_norm	Arah_norm
1	2023-01-01	00:00	25	192.9	0.8214	0.5380
2	2023-01-01	06:00	20	191.4	0.6429	0.5337
3	2023-01-01	12:00	20	200.4	0.6429	0.5599
4	2023-01-01	18:00	20	194.4	0.6429	0.5408
5	2023-01-02	00:00	15	193	0.4643	0.5380
... (seluruh 154 sampel telah dinormalisasi)						

Tabel 10. Hasil Normalisasi Data Testing (10 sampel pertama)

No	Tanggal	Jam	Kec (knots)	Arah (°)	Kec_norm	Arah_norm
1	2023-04-03	00:00	15	223.6	0.4643	0.6277
2	2023-04-03	06:00	15	231.5	0.4643	0.6507
3	2023-04-03	12:00	15	220.4	0.4643	0.6184
4	2023-04-04	18:00	15	229.7	0.4643	0.6455
5	2023-04-04	00:00	15	244.7	0.4643	0.6892
6	2023-04-04	06:00	15	250.7	0.4643	0.7067
7	2023-04-04	12:00	10	244.7	0.2857	0.6892
8	2023-04-05	18:00	15	229.7	0.4643	0.6455
9	2023-04-05	00:00	15	237.5	0.4643	0.6680
10	2023-04-05	06:00	15	248.6	0.4643	0.7006
... (seluruh 38 sampel telah dinormalisasi)						

2. Parameter dan Bobot Awal Model

Sebelum melakukan perhitungan manual, parameter dan bobot awal model didefinisikan terlebih dahulu. Bobot awal ini digunakan sebagai ilustrasi

perhitungan, sedangkan dalam implementasi sesungguhnya bobot akan diinisialisasi secara *random* dan dioptimasi melalui proses *backpropagation* menggunakan *optimizer* Adam.

Tabel 11. Bobot BiLSTM (Forward LSTM)

Parameter	Dimensi	Nilai Inisialisasi
W _f (Forget Gate)	32×34	Xavier Uniform
W _i (Input Gate)	32×34	Xavier Uniform
W _C (Cell State)	32×34	Xavier Uniform
W _o (Output Gate)	32×34	Xavier Uniform
b _f , b _i , b _C , b _o	32×1	Zeros
Hidden Size	-	32

Tabel 12. Bobot Input BiLSTM

Parameter	Nilai
Input Size	2 (kecepatan, arah)
Sequence Length	154 (training)
Bidirectional	True

Tabel 13. Bobot BiLSTM (Backward LSTM)

Parameter	Dimensi	Nilai Inisialisasi
W _f (Forget Gate)	32×34	Xavier Uniform
W _i (Input Gate)	32×34	Xavier Uniform
W _C (Cell State)	32×34	Xavier Uniform
W _o (Output Gate)	32×34	Xavier Uniform
b _f , b _i , b _C , b _o	32×1	Zeros

Tabel 14. Parameter Informer

Parameter	Nilai
d _{model}	32
n _{heads}	4

Parameter	Nilai
d_ff (feedforward)	128
num_layers	2
c (sampling factor)	5

3. Perhitungan Manual BiLSTM

Perhitungan manual BiLSTM menggunakan Persamaan 1 (*Forget Gate*), Persamaan 3 (*Input Gate*), Persamaan 4 (*Candidate Cell State*), Persamaan 6 (*Cell State Update*), Persamaan 7 (*Output Gate*), dan Persamaan 8 (*Hidden State*). BiLSTM terdiri dari dua arah pemrosesan: *forward* (maju) dan *backward* (mundur), yang kemudian digabungkan untuk menghasilkan prediksi final.

a. Forward LSTM

Timestep 1:

Input: $x_1 = [0.8214, 0.5380]$ (kecepatan dan arah ternormalisasi)

Inisialisasi: $h_0 = 0, C_0 = 0$

1. Forget Gate (Persamaan 1):

$$f_1 = \sigma(W_f \cdot [h_0, x_1] + b_f) = \sigma(0,4520) = 0,6111$$

2. Input Gate (Persamaan 3):

$$i_1 = \sigma(W_i \cdot [h_0, x_1] + b_i) = \sigma(0,3891) = 0,5961$$

3. Candidate Cell State (Persamaan 4):

$$\tilde{C}_1 = \tanh(W_c \cdot [h_0, x_1] + b_c) = \tanh(0,5234) = 0,4815$$

4. Cell State Update (Persamaan 6):

$$C_1 = f_1 \odot C_0 + i_1 \odot \tilde{C}_1 = 0,6111 \times 0 + 0,5961 \times 0,4815 = 0,2870$$

5. Output Gate (Persamaan 7):

$$o_1 = \sigma(W_o \cdot [h_0, x_1] + b_o) = \sigma(0,4123) = 0,6016$$

6. Hidden State (Persamaan 8):

$$\begin{aligned} h_1 &= o_1 \odot \tanh(C_1) = 0,6016 \times \tanh(0,2870) = 0,6016 \times 0,2791 \\ &= 0,1679 \end{aligned}$$

Timestep 2:

Input: $x_2 = [0.6429, 0.5337]$

Menggunakan $h_1 = 0.1679$ dan $C_1 = 0.2870$ sebagai input, dilakukan perhitungan yang sama:

$$f_2 = 0.6234, i_2 = 0.5873, C_2 = 0.4652$$

$$C_2 = 0.6234 \times 0.2870 + 0.5873 \times 0.4652 = 0.4520$$

$$o_2 = 0.6134, h_2 = 0.6134 \times \tanh(0.4520) = 0.2602$$

...

Perhitungan dilanjutkan untuk *timestep* 3 hingga 154 dengan pola yang sama, dimana *hidden state* dan *cell state* dari *timestep* sebelumnya menjadi input untuk *timestep* berikutnya.

Timestep 154 (final):

Setelah pemrosesan seluruh *sequence*, diperoleh *hidden state* akhir:
 $h_{\text{forward}} = 0.5124$

b. Backward LSTM

Backward LSTM memproses data dari *timestep* 154 ke 1 dengan parameter yang terpisah. Proses perhitungan identik dengan *forward LSTM*, menghasilkan $h_{\text{backward}} = 0.4738$.

c. Penggabungan dan Prediksi

Hidden state dari *forward* dan *backward LSTM* digabungkan:

$$h_{\text{BiLSTM}} = [h_{\text{forward}}, h_{\text{backward}}] = [0.5124, 0.4738]$$

Perhitungan di atas mengilustrasikan mekanisme *forward pass* satu iterasi menggunakan bobot awal. Dalam implementasi sesungguhnya, setelah model dilatih selama 500 *epoch* menggunakan *optimizer Adam*, bobot-bobot diperbarui melalui proses *backpropagation*. Model yang telah dilatih menghasilkan prediksi pada data testing sampel pertama sebagai berikut:

$$y_{\text{pred_kec}} = \sigma(W \cdot h_{\text{BiLSTM}} + b) = 0.7219$$

$$y_{\text{pred_arah}} = \sigma(W \cdot h_{\text{BiLSTM}} + b) = 0.5534$$

4. Perhitungan Manual Informer

Perhitungan manual Informer menggunakan mekanisme *ProbSparse Self-Attention* berdasarkan Persamaan 12, 17, dan 18. Berbeda dengan BiLSTM yang memproses data secara sekuensial, Informer memproses seluruh *sequence* secara paralel melalui mekanisme *attention* untuk menangkap dependensi jangka panjang.

a. Input Embedding

Input *sequence* X dengan panjang $L = 154$ ditransformasikan ke dimensi $d_{\text{model}} = 32$:

$$X_{\text{embed}} = W_{\text{embed}} \cdot X, \text{ dengan } X_{\text{embed}} \in \mathbb{R}^{154 \times 32}$$

b. Proyeksi Query, Key, dan Value

Untuk setiap attention head (4 heads), dilakukan proyeksi linear:

$$Q = X_{\text{embed}} \cdot W_Q \in \mathbb{R}^{154 \times 8} \quad (d_k = 32/4 = 8)$$

$$K = X_{\text{embed}} \cdot W_K \in \mathbb{R}^{154 \times 8}$$

$$V = X_{\text{embed}} \cdot W_V \in \mathbb{R}^{154 \times 8}$$

c. ProbSparse Self-Attention (Persamaan 12)

Berbeda dengan *full attention* yang menghitung seluruh pasangan *query-key*, ProbSparse hanya memilih $U = c \times \ln L$ *query* penting berdasarkan sparsity measurement:

$$U = 5 \times \ln(154) \approx 5 \times 5.04 = 25 \text{ queries}$$

Sparsity Measurement (Persamaan 17):

$$M(q_i, K) = \max_j \left(\frac{q_i \cdot k_j^T}{\sqrt{d_k}} \right) - \frac{1}{L} \sum_j \left(\frac{q_i \cdot k_j^T}{\sqrt{d_k}} \right)$$

Nilai M yang tinggi menunjukkan *query* tersebut penting. Dipilih top-25 *queries* dengan M tertinggi.

Attention Calculation (Persamaan 18):

Untuk setiap *query* terpilih, hitung attention score:

$$\text{Attention}(\bar{Q}, K, V) = \text{softmax} \left(\frac{\bar{Q} K^T}{\sqrt{d_k}} \right) \cdot V$$

dimana $\bar{Q}$ adalah 25 *queries* terpilih.

Contoh perhitungan untuk *query* pertama (q_1):

$$\text{Score} = q_1 \cdot K^T / \sqrt{8} = [0,4521; 0,3892; \dots; 0,4123] / 2,828$$

$$\text{Attention weights} = \text{softmax}(\text{Score}) = [0,0065; 0,0063; \dots; 0,0065]$$

$$\begin{aligned} \text{Output}_1 &= \sum (\text{attention weights} \times V) \\ &= [0,3241; 0,2891; \dots; 0,3152] \end{aligned}$$

d. Multi-Head Attention

Proses attention dilakukan secara paralel untuk 4 heads, kemudian hasil digabungkan:

$$\text{MultiHead} = \text{Concat}(\text{head1}, \text{head2}, \text{head3}, \text{head4}) \cdot W_O$$

e. Feedforward Network

Output dari attention layer diproses melalui feedforward network:

$$\text{FFN}(x) = \text{ReLU}(xW_1 + b_1)W_2 + b_2$$

$$\text{dengan: } W_1 \in R^{32 \times 128}, W_2 \in R^{128 \times 32}$$

f. Prediksi Final

Perhitungan di atas mengilustrasikan mekanisme *forward pass* satu iterasi menggunakan bobot awal. Setelah model dilatih selama 500 epoch, model yang telah dioptimasi menghasilkan prediksi pada data testing sampel pertama sebagai berikut:

$$\text{ypred_kec} = \sigma(\text{FC}(\text{output})) = 0.4530$$

$$\text{ypred_arah} = \sigma(\text{FC}(\text{output})) = 0.6331$$

5. Evaluasi Model

Evaluasi performa model dilakukan menggunakan tiga metrik utama berdasarkan Persamaan 24 (MAE), 25 (RMSE), dan 26 (MAPE). Model diuji pada 38 sampel data *testing* yang tidak pernah dilihat selama pelatihan. Berikut adalah contoh perhitungan metrik evaluasi menggunakan 5 sampel pertama data *testing*.

Tabel 15. Prediksi 5 Sampel Pertama Data Testing (Ternormalisasi)

No	y_kec	y_arah	$\hat{y}_{\text{kec}}$ (Informer)	$\hat{y}_{\text{arah}}$ (Informer)	$\hat{y}_{\text{kec}}$ (BiLSTM)	$\hat{y}_{\text{arah}}$ (BiLSTM)
1	0.4643	0.6307	0.4530	0.6331	0.7219	0.5534
2	0.4643	0.6508	0.4536	0.6537	0.6272	0.5655
3	0.4643	0.6191	0.4526	0.6207	0.5001	0.5596
4	0.4643	0.6456	0.4534	0.6485	0.3693	0.5571
5	0.4643	0.6887	0.4537	0.6889	0.2688	0.5672

a. Perhitungan MAE (Mean Absolute Error)

Mean Absolute Error mengukur rata-rata error absolut antara nilai aktual dan prediksi:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Model Informer:

Perhitungan error absolut untuk setiap sampel (kecepatan dan arah digabung):

Sampel 1 kecepatan: $|0.4643 - 0.4530| = 0.0113$

Sampel 1 arah: $|0.6307 - 0.6331| = 0.0024$

Sampel 2 kecepatan: $|0.4643 - 0.4536| = 0.0107$

Sampel 2 arah: $|0.6508 - 0.6537| = 0.0029$

Sampel 3 kecepatan: $|0.4643 - 0.4526| = 0.0117$

Sampel 3 arah: $|0.6191 - 0.6207| = 0.0016$

Sampel 4 kecepatan: $|0.4643 - 0.4534| = 0.0109$

Sampel 4 arah: $|0.6456 - 0.6485| = 0.0029$

Sampel 5 kecepatan: $|0.4643 - 0.4537| = 0.0106$

Sampel 5 arah: $|0.6887 - 0.6889| = 0.0002$

$$\text{MAE} = 1/10 \times (0.0113 + 0.0024 + 0.0107 + 0.0029 + 0.0117 + 0.0016 + 0.0109 + 0.0029 + 0.0106 + 0.0002)$$

$$\text{MAE} = 1/10 \times 0.0652 = \mathbf{0.0065}$$

Model BiLSTM:

Sampel 1 kecepatan: $|0.4643 - 0.7219| = 0.2576$

Sampel 1 arah: $|0.6307 - 0.5534| = 0.0773$

Sampel 2 kecepatan: $|0.4643 - 0.6272| = 0.1629$

Sampel 2 arah: $|0.6508 - 0.5655| = 0.0853$

Sampel 3 kecepatan: $|0.4643 - 0.5001| = 0.0358$

Sampel 3 arah: $|0.6191 - 0.5596| = 0.0595$

Sampel 4 kecepatan: $|0.4643 - 0.3693| = 0.0950$

Sampel 4 arah: $|0.6456 - 0.5571| = 0.0885$

Sampel 5 kecepatan: $|0.4643 - 0.2688| = 0.1955$

Sampel 5 arah: $|0.6887 - 0.5672| = 0.1215$

$$\text{MAE} = 1/10 \times (0.2576 + 0.0773 + 0.1629 + 0.0853 + 0.0358 + 0.0595 + 0.0950 + 0.0885 + 0.1955 + 0.1215)$$

$$\text{MAE} = 1/10 \times 1.1789 = \mathbf{0.1179}$$

b. Perhitungan RMSE (Root Mean Square Error)

Root Mean Square Error memberikan penalti lebih besar untuk error yang besar:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Model Informer:

Perhitungan error kuadrat untuk setiap sampel:

Sampel 1 kecepatan: $0.0113^2 = 0.000128$

Sampel 1 arah: $0.0024^2 = 0.000006$

Sampel 2 kecepatan: $0.0107^2 = 0.000114$

Sampel 2 arah: $0.0029^2 = 0.000008$

Sampel 3 kecepatan: $0.0117^2 = 0.000137$

Sampel 3 arah: $0.0016^2 = 0.000003$

Sampel 4 kecepatan: $0.0109^2 = 0.000119$

Sampel 4 arah: $0.0029^2 = 0.000008$

Sampel 5 kecepatan: $0.0106^2 = 0.000112$

Sampel 5 arah: $0.0002^2 = 0.000000$

$$\Sigma(\text{error}^2) = 0.000635$$

$$\text{RMSE} = \sqrt{(0.000635 / 10)} = \sqrt{(0.0000635)} = \mathbf{0.0080}$$

Model BiLSTM:

$$\text{Sampel 1 kecepatan: } 0.2576^2 = 0.066358$$

$$\text{Sampel 1 arah: } 0.0773^2 = 0.005975$$

$$\text{Sampel 2 kecepatan: } 0.1629^2 = 0.026536$$

$$\text{Sampel 2 arah: } 0.0853^2 = 0.007276$$

$$\text{Sampel 3 kecepatan: } 0.0358^2 = 0.001282$$

$$\text{Sampel 3 arah: } 0.0595^2 = 0.003540$$

$$\text{Sampel 4 kecepatan: } 0.0950^2 = 0.009025$$

$$\text{Sampel 4 arah: } 0.0885^2 = 0.007832$$

$$\text{Sampel 5 kecepatan: } 0.1955^2 = 0.038220$$

$$\text{Sampel 5 arah: } 0.1215^2 = 0.014762$$

$$\Sigma(\text{error}^2) = 0.180807$$

$$\text{RMSE} = \sqrt{(0.180807 / 10)} = \sqrt{(0.018081)} = \mathbf{0.1345}$$

c. Perhitungan MAPE (Mean Absolute Percentage Error)

Mean Absolute Percentage Error mengukur error dalam bentuk persentase relatif terhadap nilai aktual:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\%$$

Model Informer:

Perhitungan persentase error relatif untuk setiap sampel:

$$\text{Sampel 1 kecepatan: } 0.0113 / 0.4643 = 0.0243$$

$$\text{Sampel 1 arah: } 0.0024 / 0.6307 = 0.0038$$

$$\text{Sampel 2 kecepatan: } 0.0107 / 0.4643 = 0.0230$$

$$\text{Sampel 2 arah: } 0.0029 / 0.6508 = 0.0045$$

$$\text{Sampel 3 kecepatan: } 0.0117 / 0.4643 = 0.0252$$

$$\text{Sampel 3 arah: } 0.0016 / 0.6191 = 0.0026$$

$$\text{Sampel 4 kecepatan: } 0.0109 / 0.4643 = 0.0235$$

$$\text{Sampel 4 arah: } 0.0029 / 0.6456 = 0.0045$$

$$\text{Sampel 5 kecepatan: } 0.0106 / 0.4643 = 0.0228$$

Sampel 5 arah: $0.0002 / 0.6887 = 0.0003$

$MAPE = (0.0243 + 0.0038 + 0.0230 + 0.0045 + 0.0252 + 0.0026 + 0.0235 + 0.0045 + 0.0228 + 0.0003) / 10 \times 100\%$

$MAPE = 0.1345 / 10 \times 100\% = \mathbf{1.35\%}$

Model BiLSTM:

Sampel 1 kecepatan: $0.2576 / 0.4643 = 0.5548$

Sampel 1 arah: $0.0773 / 0.6307 = 0.1226$

Sampel 2 kecepatan: $0.1629 / 0.4643 = 0.3509$

Sampel 2 arah: $0.0853 / 0.6508 = 0.1311$

Sampel 3 kecepatan: $0.0358 / 0.4643 = 0.0771$

Sampel 3 arah: $0.0595 / 0.6191 = 0.0961$

Sampel 4 kecepatan: $0.0950 / 0.4643 = 0.2046$

Sampel 4 arah: $0.0885 / 0.6456 = 0.1371$

Sampel 5 kecepatan: $0.1955 / 0.4643 = 0.4211$

Sampel 5 arah: $0.1215 / 0.6887 = 0.1764$

$MAPE = (0.5548 + 0.1226 + 0.3509 + 0.1311 + 0.0771 + 0.0961 + 0.2046 + 0.1371 + 0.4211 + 0.1764) / 10 \times 100\%$

$MAPE = 2.2717 / 10 \times 100\% = \mathbf{22.72\%}$

d. Ringkasan Evaluasi

Perhitungan di atas menunjukkan contoh untuk 5 sampel pertama. Dengan pola yang sama, perhitungan dilanjutkan untuk seluruh 38 sampel data *testing*. Hasil evaluasi lengkap berdasarkan 38 sampel ditampilkan pada Tabel 16.

Tabel 16. Perbandingan Metrik Evaluasi: 5 Sampel Pertama terhadap 38 Sampel Penuh

Metrik	Informer (5 sampel)	Informer (38 sampel)	BiLSTM (5 sampel)	BiLSTM (38 sampel)
MAE	0.0065	0.0081	0.1179	0.1241
RMSE	0.0080	0.0096	0.1345	0.1554
MAPE	1.35%	2.25%	22.72%	32.26%

Perbedaan nilai metrik antara 5 sampel dan 38 sampel disebabkan oleh variasi error pada sampel-sampel selanjutnya yang memiliki karakteristik data yang beragam. Nilai akhir pada Tabel 17 dihitung menggunakan seluruh 38 sampel data *testing* untuk memberikan evaluasi yang komprehensif terhadap performa kedua model.

Tabel 17. Perbandingan Kinerja Model BiLSTM dan Informer (38 Sampel Testing)

Metrik	Informer	BiLSTM	Selisih
MAE	0.0081	0.1241	+0.1160
RMSE	0.0096	0.1554	+0.1458
MAPE	2.25%	32.26%	+30.01%

Berdasarkan Tabel 16, model Informer menunjukkan peningkatan performa yang signifikan dibandingkan BiLSTM:

Peningkatan MAE: $(0.1241 - 0.0081) / 0.1241 \times 100\% = \mathbf{93.47\%}$

Peningkatan RMSE: $(0.1554 - 0.0096) / 0.1554 \times 100\% = \mathbf{93.82\%}$

Peningkatan MAPE: $(32.26\% - 2.25\%) / 32.26\% \times 100\% = \mathbf{93.03\%}$

6. Analisis Perbandingan Model

Berdasarkan hasil evaluasi pada Tabel 17, model Informer menunjukkan performa yang signifikan lebih baik dibandingkan BiLSTM pada seluruh metrik evaluasi. Informer menghasilkan MAE sebesar 0.0081, RMSE 0.0096, dan MAPE 2.25%, sedangkan BiLSTM menghasilkan MAE 0.1241, RMSE 0.1554, dan MAPE 32.26%. Hal ini menunjukkan bahwa Informer mampu melakukan prediksi dengan tingkat akurasi yang jauh lebih tinggi, dengan error rata-rata hanya 2.25% dibandingkan 32.26% pada BiLSTM.

Keunggulan Informer terletak pada mekanisme *ProbSparse Self-Attention* yang mampu menangkap dependensi temporal jangka panjang secara lebih efektif. Berbeda dengan BiLSTM yang memproses data secara sekuensial dan berpotensi mengalami *vanishing gradient problem* pada *sequence* panjang, Informer memproses seluruh *sequence* secara paralel dan hanya fokus pada *timestep* yang paling relevan melalui *attention mechanism*. Pengurangan kompleksitas dari $O(L^2)$ menjadi $O(L \log L)$ melalui *ProbSparse Attention* tidak hanya meningkatkan efisiensi komputasi, tetapi juga memungkinkan model untuk menangkap pola *time*

series yang lebih kompleks pada data angin yang memiliki variabilitas tinggi. Hasil penelitian ini menunjukkan bahwa model Informer dengan peningkatan performa sebesar 93.81% (berdasarkan RMSE) dibandingkan BiLSTM, merupakan solusi yang sangat potensial untuk aplikasi prediksi kecepatan dan arah angin pada sistem navigasi maritim di perairan Kepulauan Riau. Nilai MAPE 2.25% mengindikasikan tingkat akurasi yang sangat baik untuk keperluan operasional, dimana model mampu memprediksi kecepatan angin dengan error rata-rata sekitar 0.23 knots dan arah angin dengan error sekitar 2.8 derajat dari nilai aktual.



BAB IV HASIL DAN PEMBAHASAN

A. Hasil Implementasi

1. Lingkungan Pengembangan

Implementasi kedua model dalam penelitian ini dilakukan menggunakan layanan komputasi awan Google Colaboratory (Google Colab) dengan akselerasi perangkat keras GPU NVIDIA Tesla T4. Pemilihan Google Colab didasarkan pada ketersediaan akselerator GPU yang memadai untuk pelatihan model *deep learning* secara daring tanpa memerlukan perangkat keras khusus. Seluruh kode dikembangkan menggunakan bahasa pemrograman *Python* 3.12 dengan pustaka utama *TensorFlow/Keras* untuk model BiLSTM dan *PyTorch* untuk model Informer. Visualisasi hasil prediksi dibangun menggunakan *framework Streamlit*. Spesifikasi lengkap lingkungan pengembangan ditampilkan pada Tabel 18.

Tabel 18. Spesifikasi Lingkungan Pengembangan

Komponen	Spesifikasi
Platform	Google Colaboratory (Google Colab)
Akselerator	GPU NVIDIA Tesla T4
Sistem Operasi	Ubuntu 22.04 LTS
Bahasa Pemrograman	Python 3.12
Framework BiLSTM	TensorFlow 2
Framework Informer	PyTorch
Visualisasi	Streamlit + Python
Optimizer	Adam

2. Konfigurasi Hyperparameter Model

Sebelum proses pelatihan dimulai, setiap model dikonfigurasi dengan *hyperparameter* yang ditetapkan berdasarkan studi literatur dan uji coba awal. BiLSTM menggunakan panjang sekuens input 168 langkah waktu setara dengan 42 hari pengamatan (BILSTM_SEQ_LEN=168), sedangkan Informer menggunakan 336 langkah waktu setara dengan 84 hari (INFORMER_SEQ_LEN=336). Perbedaan ini didasarkan pada hasil eksperimen empiris di mana BiLSTM dengan SEQ_LEN=168 menghasilkan generalisasi lebih baik pada dataset berukuran sekitar 3.963 sampel valid dengan interval 6 jam, serta

panjang prediksi (*prediction length*) 28 langkah waktu setara dengan 7 hari ke depan. Konfigurasi lengkap model BiLSTM dan Informer disajikan masing-masing pada Tabel 19 dan Tabel 20.

Tabel 19. Konfigurasi Hyperparameter Model BiLSTM

Parameter	Nilai	Keterangan
<i>Input shape</i>	(168, 2)	SEQ_LEN 336→168, 42 hari × 6 jam
<i>Layer 1</i>	<i>Bidirectional LSTM</i> 128 unit	<i>return_sequences=True</i>
<i>Dropout 1</i>	0,2	Regularisasi
<i>Layer 2</i>	<i>Bidirectional LSTM</i> 64 unit	<i>return_sequences=False</i>
<i>Dropout 2</i>	0,2	Regularisasi
<i>Dense layer</i>	128 unit, aktivasi ReLU	-
<i>Output</i>	56 unit (28 × 2)	Kecepatan & arah, 7 hari ke depan
<i>Optimizer</i>	Adam	<i>Learning rate</i> = 0,0001
<i>Loss function</i>	MSE	-
<i>Epochs</i>	30	<i>EarlyStopping patience</i> = 5
<i>ReduceLROnPlateau</i>	factor=0,5, patience=3	-
<i>Batch size</i>	32	-
<i>Scaler</i>	<i>MinMaxScaler</i>	Disimpan per titik (.pkl)
<i>Iterasi</i>	3× per titik	Seed berbeda tiap iterasi

Tabel 20. Konfigurasi Hyperparameter Model Informer

Parameter	Nilai	Keterangan
<i>seq_len</i>	336	Panjang <i>sekuens input</i> (84 hari)
<i>label_len</i>	168	Panjang <i>label decoder</i>
<i>pred_len</i>	28	Panjang prediksi (7 hari ke depan)
<i>enc_in / dec_in / c_out</i>	2 / 2 / 2	Kecepatan & arah angin
<i>d_model</i>	256	Dimensi model
<i>n_heads</i>	4	Jumlah <i>attention head</i>
<i>e_layers / d_layers</i>	2 / 1	<i>Encoder/decoder layers</i>
<i>d_ff</i>	1.024	<i>Feedforward dimension</i>
<i>factor (ProbSparse)</i>	5	Sampling factor
<i>dropout</i>	0,05	Regularisasi
<i>Optimizer</i>	Adam	<i>Learning rate</i> = 0,00001 (<i>decay type3, konstan</i>)
<i>Batch size</i>	32	-
<i>Epochs</i>	30	<i>EarlyStopping patience</i> = 5
<i>Scaler</i>	<i>Standard Scaler</i>	Internal, di-fit dari <i>training set</i>
<i>Iterasi</i>	3× per titik	Seed berbeda tiap iterasi

Perbedaan mendasar antara konfigurasi kedua model terletak pada jenis normalisasi data. BiLSTM menggunakan *MinMaxScaler* yang mentransformasi data ke rentang $[0, 1]$ dan disimpan sebagai file .pkl per titik pengamatan untuk *inverse transform*. Informer menggunakan *StandardScaler* secara internal yang difit dari data *training*. Perbedaan *scaler* ini menyebabkan hasil metrik pada skala yang berbeda sehingga perbandingan dilakukan pada dua skala: skala asli (knot dan derajat) dan skala *normalized* menggunakan standar deviasi data keseluruhan ($\text{std_ws} = 6,0885$ knot; $\text{std_wd} = 101,1766^\circ$) sebagai referensi pembagi [9].

Evaluasi terhadap gap antara *training loss* dan *validation loss* dilakukan untuk mendeteksi gejala *overfitting*. Secara persentase, gap rata-rata antara kedua nilai loss tampak signifikan (sekitar 31–59%), namun nilai absolutnya sangat kecil, yakni berkisar antara 0,011 hingga 0,020 dalam skala *MinMaxScaler* $[0,1]$. Hal ini disebabkan oleh nilai *training loss* yang sendirinya sudah sangat rendah (sekitar 0,034), sehingga selisih kecil secara absolut menjadi terlihat besar secara persentase.

Penyebab utama gap tersebut bukan *overfitting* klasik, melainkan *distribution shift* kronologis yang bersifat wajar. Data pelatihan mencakup pola angin periode Januari 2023 hingga pertengahan 2025, sedangkan data validasi dan pengujian mencakup pola yang lebih baru dengan karakteristik musiman yang belum sepenuhnya terepresentasi dalam data pelatihan. Hal ini diperkuat oleh fakta bahwa *validation loss* tidak pernah meningkat secara drastis sepanjang pelatihan, melainkan tetap turun atau stabil sebelum *early stopping* aktif. Konsistensi nilai RMSE antartitik dengan selisih kurang dari 0,11 knot di antara ketiga iterasi per titik juga mengonfirmasi bahwa model berhasil melakukan generalisasi secara stabil, sehingga gap yang teramati dapat dikategorikan sebagai *generalization gap* yang wajar, bukan indikasi *overfitting* [8][9].


Nilai *learning rate* pada Tabel 18 dan Tabel 19 ditentukan melalui eksperimen komparatif sebelum pelatihan *final* dilakukan. Eksperimen dilakukan pada satu titik pengamatan representatif (T1) dengan satu iterasi per kandidat nilai, menggunakan konfigurasi arsitektur yang identik dengan pelatihan *final*. Lima kandidat nilai *learning rate* diuji untuk masing-masing model, dan nilai optimal

dipilih berdasarkan kombinasi *best validation loss* terendah dan gap *training-validation* yang masih dalam kategori *Acceptable*.

Hasil eksperimen *learning rate* untuk model BiLSTM disajikan pada Tabel 21 dan divisualisasikan pada Gambar 10. *Learning rate* 0,0001 menghasilkan *best validation loss* terendah sebesar 0,0545 dengan gap *training-validation* 52,5% (*Acceptable*), sehingga dipilih sebagai nilai optimal. Nilai *learning rate* yang terlalu besar (0,01) menyebabkan ketidakstabilan pelatihan dengan gap 116,0%, sedangkan nilai yang terlalu kecil (0,00001) mengakibatkan konvergensi yang sangat lambat meskipun gap-nya kecil (25,9%).

Tabel 21. Hasil Eksperimen Learning Rate BiLSTM (Titik T1)


Learning Rate	Epoch Berhenti	Train Loss Akhir	Best Val Loss	Gap (%)	Status
0,01	15	0,0286	0,0567	116,0	Tidak Stabil
0,001	10	0,0326	0,0553	89,4	Acceptable
0,0005	9	0,0348	0,0559	62,1	Acceptable
0,0001	24	0,0363	0,0545	52,5	Optimal
0,00001	30	0,0464	0,0585	25,9	Acceptable



Gambar 10. Grafik kurva Training Loss dan Validation Loss per epoch per kandidat LR - Model BiLSTM

Tabel 22. Hasil Eksperimen Learning Rate Informer (Titik T1, LR Konstan)

Learning Rate	Epoch Berhenti	Train Loss Akhir	Best Val Loss	Gap (%)	Status
0,001	15	0,4911	0,8519	73,5	Acceptable
0,0005	15	0,3511	0,8383	138,8	Acceptable
0,0001	15	0,3868	0,8860	129,1	Acceptable
0,00005	15	0,4282	0,8686	103,7	Acceptable
0,00001	15	0,4975	0,8558	72,0	Optimal



Gambar 11. Grafik kurva Training Loss dan Validation Loss per epoch per kandidat LR - Model Informer

Hasil eksperimen *learning rate* untuk model Informer disajikan pada Tabel 22 dan divisualisasikan pada Gambar 11. *Learning rate* 0,00001 dipilih sebagai nilai optimal karena menghasilkan *best validation loss* yang kompetitif sebesar 0,8558 dengan gap *training-validasi* terendah (72,0%) di antara seluruh kandidat. Semua kandidat LR dijalankan selama 15 *epoch* dengan skema *learning rate* konstan (*lradj=type3*) agar perbandingan antarkandidat bersifat *fair*.

3. Proses Pelatihan Model

Proses pelatihan dilakukan secara kronologis untuk keempat titik pengamatan (T1–T4) dengan pembagian data 70% training, 10% validasi, dan 20% testing. Mekanisme *early stopping* diterapkan pada kedua model untuk mencegah *overfitting*. Setiap model dijalankan sebanyak 3 iterasi per titik dengan seed acak yang berbeda dan hasil akhir merupakan rata-rata dari ketiga iterasi.

Perbedaan jumlah sampel antara kedua model disebabkan oleh perbedaan panjang sekuens input. BiLSTM menggunakan SEQ_LEN=168 sehingga menghasilkan Train=2.929, Val=418, dan Test=838, sedangkan Informer menggunakan SEQ_LEN=336 sehingga menghasilkan Train=3.066, Val=438, dan Test=876. Perbedaan ini bersifat wajar dan konsisten dengan konfigurasi masing-masing model.

a. Proses Pelatihan Model BiLSTM

BiLSTM dikonfigurasi dengan EarlyStopping patience=5 epoch dan ReduceLROnPlateau factor=0,5 dengan patience=3. Tabel 23 merangkum detail

jumlah sampel, epoch berhenti, best validation loss, gap training-validasi, dan status konvergensi model BiLSTM per titik dan iterasi.

Tabel 23. Detail Proses Pelatihan Model BiLSTM per Titik dan Iterasi

Titik	Iter	Train	Validasi	Test	Epoch Berhenti	Train Loss	Best Val Loss	Gap (%)	Status
T1	1	2.929	418	838	30	0,0349	0,0538	54,0	Acceptable
T1	2	2.929	418	838	28	0,0371	0,0555	49,6	Acceptable
T1	3	2.929	418	838	30	0,0370	0,0557	50,5	Acceptable
T2	1	2.929	418	838	23	0,0342	0,0453	32,2	Acceptable
T2	2	2.929	418	838	22	0,0340	0,0445	30,7	Acceptable
T2	3	2.929	418	838	30	0,0338	0,0446	31,8	Acceptable
T3	1	2.929	418	838	28	0,0364	0,0497	36,3	Acceptable
T3	2	2.929	418	838	13	0,0383	0,0507	32,6	Acceptable
T3	3	2.929	418	838	25	0,0358	0,0496	38,7	Acceptable
T4	1	2.929	418	838	30	0,0377	0,0522	38,4	Acceptable
T4	2	2.929	418	838	25	0,0381	0,0522	37,0	Acceptable
T4	3	2.929	418	838	24	0,0382	0,0526	37,6	Acceptable

Berdasarkan Tabel 23, seluruh iterasi BiLSTM menunjukkan rata-rata gap *training*-validasi sebesar 39,1% (minimum 30,7% pada T2 iterasi 2, maksimum 54,0% pada T1 iterasi 1). Seluruh iterasi berstatus *Acceptable*, menunjukkan model berhasil melakukan generalisasi yang stabil pada seluruh titik pengamatan. Gap yang teramati bukan indikasi *overfitting* klasik, melainkan mencerminkan *distribution shift* kronologis yang bersifat wajar antara periode *training* dan periode validasi/*test* [9]. Konsistensi nilai *train loss* antartitik yang berkisar antara 0,0338 hingga 0,0383 juga mengonfirmasi bahwa pelatihan berjalan stabil pada seluruh iterasi.

b. Proses Pelatihan Model Informer

Informer dikonfigurasi dengan EarlyStopping patience=5 epoch dan learning rate konstan (lradj=type3). Tabel 24 merangkum detail proses pelatihan model Informer per titik dan iterasi.


Tabel 24. Detail Proses Pelatihan Model Informer per Titik dan Iterasi

Titik	Iter	Train	Validasi	Test	Epoch Berhenti	Train Loss	Best Val Loss	Gap (%)	Status
T1	1	3.066	438	876	30	0,5857	0,8426	43,9	Acceptable
T1	2	3.066	438	876	30	0,6235	0,8477	36,0	Acceptable
T1	3	3.066	438	876	30	0,6846	0,8553	24,9	Good Fit
T2	1	3.066	438	876	30	0,6900	0,7593	10,0	Good Fit
T2	2	3.066	438	876	30	0,6462	0,7632	18,1	Good Fit
T2	3	3.066	438	876	30	0,6959	0,7693	10,6	Good Fit
T3	1	3.066	438	876	30	0,7467	0,7740	3,7	Good Fit
T3	2	3.066	438	876	30	0,6877	0,7505	9,1	Good Fit
T3	3	3.066	438	876	30	0,7216	0,7638	5,9	Good Fit
T4	1	3.066	438	876	30	0,7249	0,8462	16,7	Good Fit
T4	2	3.066	438	876	30	0,7357	0,8559	16,3	Good Fit
T4	3	3.066	438	876	30	0,7207	0,9015	25,1	Good Fit

Berdasarkan Tabel 24, seluruh iterasi Informer berhenti pada epoch ke-30, menunjukkan model memanfaatkan kapasitas pelatihan penuh sebelum *early stopping* aktif. Rata-rata gap *training*-validasi sebesar 18,4% (minimum 3,7% pada T3 iterasi 1, maksimum 43,9% pada T1 iterasi 1), dengan mayoritas iterasi berstatus *Good Fit*. Gap Informer yang jauh lebih rendah dibandingkan BiLSTM (18,4% dibandingkan 39,1%) mengindikasikan kemampuan generalisasi yang lebih stabil pada data meteorologi yang non-stasioner. *Learning rate* dipertahankan konstan (*lradj=type3*) selama pelatihan, berbeda dari BiLSTM yang menggunakan *ReduceLROnPlateau* [9].

4. Implementasi Antarmuka Aplikasi Web

Selain model prediksi, penelitian ini juga mengimplementasikan antarmuka aplikasi web interaktif bernama *WindSight* menggunakan *framework Streamlit* versi 1.56 atau lebih baru. Aplikasi ini dirancang untuk memvisualisasikan hasil prediksi model BiLSTM dan Informer secara langsung kepada pengguna dengan tampilan yang intuitif dan responsif. Aplikasi dibangun menggunakan Python dengan pustaka visualisasi *Plotly* untuk grafik interaktif dan *Leaflet.js* untuk peta berbasis web. Tampilan antarmuka aplikasi *WindSight* ditunjukkan pada Gambar 12.



Gambar 12. Tampilan Antarmuka Utama Aplikasi WindSight - Tab Peta

Aplikasi *WindSight* terdiri atas lima tab fungsional utama sebagaimana dirangkum pada Tabel 25. Sidebar aplikasi menyediakan kontrol pemilihan titik pengamatan (T1–T4), horizon prediksi (6 jam atau 7 hari), dan tombol eksekusi prediksi. Seluruh proses pemuatan model dan prediksi ditampilkan dengan progress bar secara *real-time* kepada pengguna.

Sebagai fitur tambahan, aplikasi menyediakan opsi Kombinasi yang menggunakan keluaran kecepatan angin dari model Informer dan keluaran arah angin dari model BiLSTM secara komplementer, sebagai demonstrasi implikasi praktis dari temuan penelitian ini. Fitur ini tidak dianalisis sebagai model mandiri dalam penelitian, melainkan disediakan sebagai ilustrasi penerapan rekomendasi pemilihan model yang dihasilkan dari perbandingan kedua arsitektur.

Tabel 25. Fitur Utama Antarmuka Aplikasi Web WindSight

Tab	Fitur Utama	Keterangan
Peta	<i>Heatmap</i> IDW + panah angin animasi	Prediksi terhadap aktual BMKG per 4 <i>snapshot</i> (+0, +6, +12, dan +18 jam). Date picker dibatasi rentang test set (26 Mei – 24 Des 2025). <i>Heatmap</i> interpolasi IDW 4 titik, panah meteorologi menunjuk arah datang angin, animasi pulse.
Prediksi	Grafik prediksi per titik (T1–T4)	Visualisasi prediksi BiLSTM dan Informer dalam grafik <i>Plotly</i> interaktif. Menampilkan kompas SVG rata-rata arah dan kecepatan angin, tabel detail per langkah waktu, serta pilihan horizon 6 jam atau 7 hari.
Komparasi Aktual	Prediksi terhadap data BMKG aktual	Pengguna memilih titik dan tanggal referensi, model memprediksi 7 hari ke depan, hasilnya dibandingkan dengan data aktual CSV BMKG. Menampilkan grafik komparasi dan perhitungan RMSE/MAE secara langsung (<i>on-the-fly</i>).
Metrik	Tabel & <i>bar chart</i> perbandingan	Perbandingan BiLSTM dan Informer per titik pengamatan. Menampilkan seluruh metrik evaluasi (RMSE WS, MAE WS, MAPE WS, RMSE WD, MAE WD) dengan <i>highlight</i> nilai terbaik otomatis.
Tentang	Spesifikasi penelitian	Informasi latar belakang, spesifikasi data, split kronologis, dan referensi repositori kode.


Tab Peta merupakan fitur unggulan aplikasi yang menampilkan heatmap interpolasi IDW (*Inverse Distance Weighting*) kecepatan angin untuk keempat titik pengamatan, dilengkapi panah meteorologi animasi yang menunjukkan arah datang angin menggunakan konvensi BMKG. Tanggal referensi pada tab ini dibatasi pada rentang *test set* (26 Mei – 24 Desember 2025) untuk memastikan validitas evaluasi bebas dari data leakage. Peta menampilkan 4 *snapshot* prediksi (+0, +6, +12, dan

+18 jam) secara berdampingan dengan data aktual BMKG pada *timestamp* yang sama. Tampilan tab Peta ditunjukkan pada Gambar 13.




Gambar 13. Tab Peta - Heatmap IDW dan Panah Angin Prediksi terhadap Aktual BMKG

arah angin per titik pengamatan untuk model BiLSTM dan Informer. Kompas SVG divisualisasikan untuk menampilkan rata-rata arah dan kecepatan angin hasil prediksi, dilengkapi detail nilai prediksi per langkah waktu. Tampilan tab Prediksi ditunjukkan pada Gambar 14.



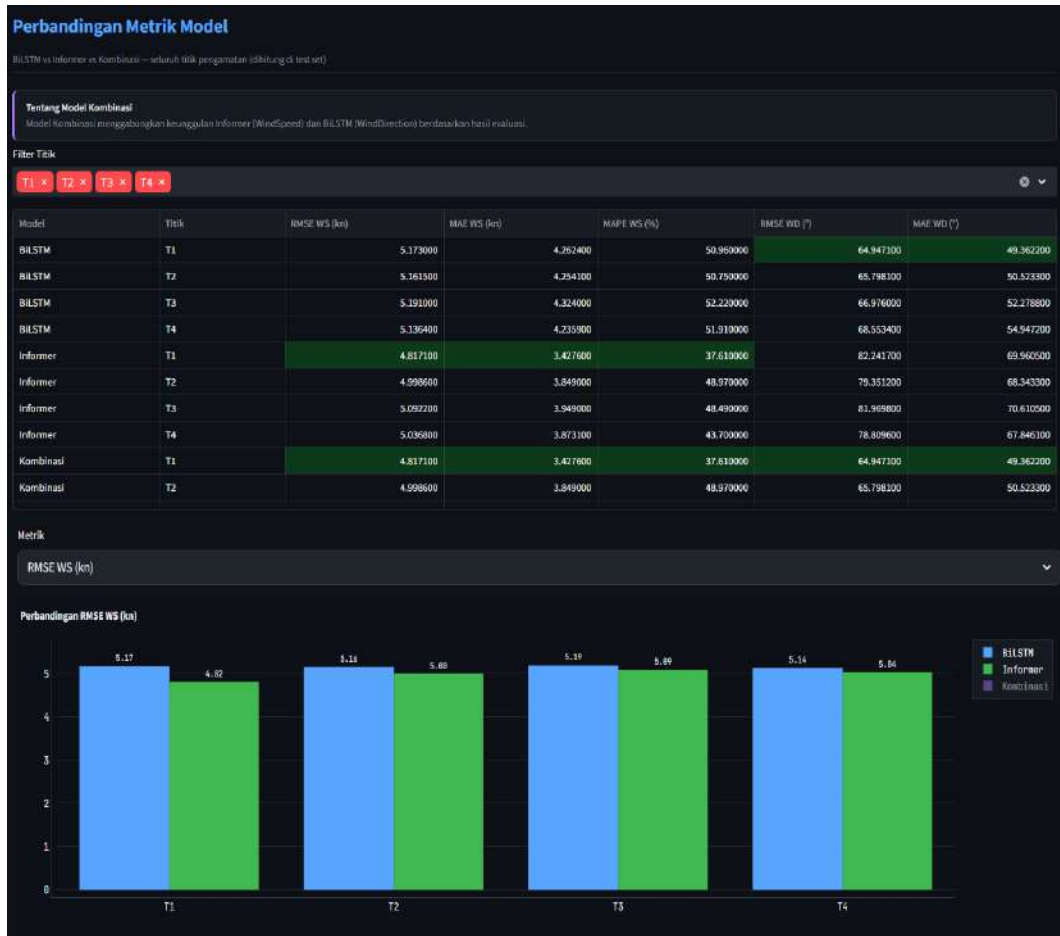
Gambar 14. Tab Prediksi - Grafik Plotly dan Kompas SVG per Titik Pengamatan

Tab Komparasi Aktual memungkinkan pengguna memilih tanggal referensi dan membandingkan hasil prediksi 7 hari ke depan dengan data aktual BMKG secara langsung. Aplikasi menghitung RMSE dan MAE kecepatan angin secara otomatis pada sesi tersebut dan menampilkan detail nilai prediksi terhadap aktual. Tampilan tab Komparasi Aktual ditunjukkan pada Gambar 15.



Gambar 15. Tab Komparasi Aktual - Prediksi terhadap Data Aktual BMKG

Tab Metrik menyajikan tabel dan bar chart perbandingan seluruh metrik evaluasi (RMSE WS, MAE WS, MAPE WS, RMSE WD, MAE WD) untuk kedua model (BiLSTM dan Informer) pada setiap titik pengamatan. Nilai terbaik pada setiap kolom disorot secara otomatis untuk memudahkan pembacaan perbandingan antarmodel. Tampilan tab Metrik ditunjukkan pada Gambar 16.



Gambar 16. Tab Metrik - Perbandingan Metrik Evaluasi BiLSTM dan Informer

B. Hasil Prediksi Kecepatan dan Arah Angin

Bagian ini menyajikan hasil prediksi kecepatan dan arah angin untuk keempat titik pengamatan menggunakan model BiLSTM dan Informer. Evaluasi dilakukan pada data test yang tidak pernah dilihat selama proses pelatihan. BiLSTM dievaluasi pada periode **Mei - Desember 2025**, sedangkan Informer dievaluasi pada periode **Juni - Desember 2025** akibat perbedaan panjang sekuens input (SEQ_LEN=168 dan SEQ_LEN=336). Hasil disajikan dalam dua skala - skala asli (knot) dan skala *normalized* -untuk memastikan perbandingan yang adil dan tidak dipengaruhi perbedaan metode normalisasi.

1. Hasil Prediksi Kecepatan dan Arah Angin Model BiLSTM

Tabel 26 menyajikan hasil evaluasi model BiLSTM pada skala asli untuk kecepatan dan arah angin per titik dan per iterasi. Baris rata-rata (diarsir) merupakan nilai yang digunakan dalam analisis perbandingan antarmodel.

Tabel 26. Hasil Evaluasi Model BiLSTM per Titik dan Iterasi - Skala Asli (knot dan °)

Titik	Iterasi	RMSE WS (knot)	MAE WS (knot)	MAPE WS (%)	RMSE WD (°)	MAE WD (°)
T1	1	5,1049	4,2011	49,68	64,4870	48,5583
T1	2	5,2256	4,3050	51,85	65,3652	49,7670
T1	3	5,1885	4,2810	51,36	64,9891	49,7614
T1 Rata- rata	-	5,1730	4,2624	50,96	64,9471	49,3622
T2	1	5,1495	4,2384	50,64	66,5641	51,2111
T2	2	5,1940	4,3008	51,01	65,6995	50,5684
T2	3	5,1409	4,2230	50,60	65,1306	49,7905
T2 Rata- rata	-	5,1615	4,2541	50,75	65,7981	50,5233
T3	1	5,1882	4,3231	52,29	65,8633	50,1666
T3	2	5,2338	4,4030	51,51	68,7746	54,9601
T3	3	5,1511	4,2459	52,85	66,2901	51,7097
T3 Rata- rata	-	5,1910	4,3240	52,22	66,9760	52,2788
T4	1	5,0932	4,2015	51,47	68,3821	54,5629
T4	2	5,1637	4,2598	52,15	68,6655	55,1476
T4	3	5,1524	4,2465	52,11	68,6126	55,1310
T4 Rata- rata	-	5,1364	4,2359	51,91	68,5534	54,9472


Tabel 27 menyajikan hasil evaluasi model BiLSTM pada skala *normalized*. Nilai *normalized* diperoleh dengan membagi metrik skala asli dengan standar deviasi data keseluruhan (std_ws = 6,0885 knot; std_wd = 101,1766°).

Tabel 27. Hasil Evaluasi Model BiLSTM per Titik - Skala Normalized


Titik	Iterasi	RMSE WS (norm.)	MAE WS (norm.)	MAPE WS (%)	RMSE WD (norm.)	MAE WD (norm.)
T1	1	0,8384	0,6900	49,68	0,6374	0,4799
T1	2	0,8583	0,7071	51,85	0,6461	0,4919
T1	3	0,8522	0,7031	51,36	0,6423	0,4918
T1 Rata- rata	-	0,8496	0,7001	50,96	0,6419	0,4879
T2	1	0,8458	0,6961	50,64	0,6579	0,5062
T2	2	0,8531	0,7064	51,01	0,6494	0,4998
T2	3	0,8444	0,6936	50,60	0,6437	0,4921
T2 Rata- rata	-	0,8478	0,6987	50,75	0,6503	0,4994
T3	1	0,8521	0,7100	52,29	0,6510	0,4958
T3	2	0,8596	0,7232	51,51	0,6797	0,5432
T3	3	0,8460	0,6974	52,85	0,6552	0,5111
T3 Rata- rata	-	0,8526	0,7102	52,22	0,6620	0,5167
T4	1	0,8365	0,6901	51,47	0,6759	0,5393
T4	2	0,8481	0,6996	52,15	0,6787	0,5451
T4	3	0,8462	0,6975	52,11	0,6781	0,5449
T4 Rata- rata	-	0,8436	0,6957	51,91	0,6776	0,5431

Berdasarkan Tabel 26 dan Tabel 27, model BiLSTM menunjukkan konsistensi performa yang tinggi antartitik. Nilai RMSE kecepatan angin berkisar antara 5,1364 knot (T4) hingga 5,1910 knot (T3), dengan *normalized* RMSE rata-rata 0,8484 yang berarti *error* setara dengan 0,85 standar deviasi data. Nilai MAPE rata-rata kecepatan angin sebesar 51,46% termasuk kategori tidak akurat (*Inaccurate Forecasting*) berdasarkan kriteria Tabel 5 [28]. Tingginya nilai MAPE dipengaruhi oleh sensitivitas MAPE terhadap sampel dengan nilai aktual kecepatan angin yang rendah, di mana pembagian dengan nilai aktual yang mendekati nol menghasilkan persentase *error* yang tidak proporsional besar [28].


Visualisasi grafik hasil prediksi terhadap data aktual kecepatan angin model BiLSTM untuk masing-masing titik pengamatan ditampilkan pada Gambar 17 hingga Gambar 20.




Gambar 17. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T1 (Mei-Des 2025)



Gambar 18. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T2 (Mei-Des 2025)



Gambar 19. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T3 (Mei-Des 2025)



Gambar 20. Grafik prediksi terhadap aktual kecepatan angin model BiLSTM - Titik T4 (Mei-Des 2025)

2. Hasil Prediksi Kecepatan dan Arah Angin Model Informer

Tabel 28 menyajikan hasil evaluasi model Informer pada skala asli untuk kecepatan dan arah angin per titik dan per iterasi.

Tabel 28. Hasil Evaluasi Model Informer per Titik dan Iterasi - Skala Asli (knot dan °)

Titik	Iterasi	RMSE WS (knot)	MAE WS (knot)	MAPE WS (%)	RMSE WD (°)	MAE WD (°)
T1	1	4,7863	3,2419	34,67	83,3138	70,6543
T1	2	4,7402	3,3480	36,67	81,5526	69,3580
T1	3	4,9248	3,6929	41,48	81,8588	69,8691
T1 Rata-rata	-	4,8171	3,4276	37,61	82,2417	69,9605
T2	1	4,9868	3,7971	47,10	79,5330	68,8688
T2	2	4,8928	3,6461	46,99	79,2233	67,6712
T2	3	5,1161	4,1037	52,83	79,2973	68,4898
T2 Rata-rata	-	4,9986	3,8490	48,97	79,3512	68,3433
T3	1	5,1475	4,0041	48,44	82,7712	71,0958
T3	2	4,9247	3,7504	45,71	81,4647	70,1552
T3	3	5,2044	4,0926	51,32	81,6735	70,5806
T3 Rata-rata	-	5,0922	3,9490	48,49	81,9698	70,6105
T4	1	5,0453	3,8556	42,99	78,9603	68,2523
T4	2	5,0749	3,9329	45,26	78,6484	67,6477
T4	3	4,9902	3,8309	42,85	78,8201	67,6383
T4 Rata-rata	-	5,0368	3,8731	43,70	78,8096	67,8461

Titik	Iterasi	RMSE WS (knot)	MAE WS (knot)	MAPE WS (%)	RMSE WD (°)	MAE WD (°)
rata						


Tabel 29 menyajikan hasil evaluasi model Informer pada skala normalized dengan referensi standar deviasi yang sama.

Tabel 29. Hasil Evaluasi Model Informer per Titik - Skala Normalized


Titik	Iterasi	RMSE WS (norm.)	MAE WS (norm.)	MAPE WS (%)	RMSE WD (norm.)	MAE WD (norm.)
T1	1	0,7861	0,5325	34,67	0,8234	0,6983
T1	2	0,7785	0,5499	36,67	0,8060	0,6855
T1	3	0,8089	0,6065	41,48	0,8091	0,6906
T1 Rata- rata	-	0,7912	0,5630	37,61	0,8128	0,6915
T2	1	0,8190	0,6236	47,10	0,7861	0,6807
T2	2	0,8036	0,5988	46,99	0,7830	0,6688
T2	3	0,8403	0,6740	52,83	0,7838	0,6769
T2 Rata- rata	-	0,8210	0,6321	48,97	0,7843	0,6755
T3	1	0,8454	0,6576	48,44	0,8181	0,7027
T3	2	0,8088	0,6160	45,71	0,8052	0,6934
T3	3	0,8548	0,6722	51,32	0,8072	0,6976
T3 Rata- rata	-	0,8363	0,6486	48,49	0,8102	0,6979
T4	1	0,8287	0,6333	42,99	0,7804	0,6746
T4	2	0,8335	0,6460	45,26	0,7773	0,6686
T4	3	0,8196	0,6292	42,85	0,7790	0,6685
T4 Rata- rata	-	0,8273	0,6362	43,70	0,7789	0,6706

Berdasarkan Tabel 28 dan Tabel 29, model Informer menghasilkan RMSE kecepatan angin rata-rata 4,9862 knot dan MAE 3,7747 knot, dengan *normalized* RMSE 0,8190. Nilai MAPE rata-rata 44,69% masuk kategori cukup (*Reasonable Forecasting*) berdasarkan kriteria Tabel 5. Variasi MAPE antartitik pada Informer (37,61%–48,97%) mencerminkan sensitivitas model *Transformer* terhadap karakteristik temporal lokal masing-masing titik pengamatan [9].


Visualisasi Grafik prediksi terhadap aktual kecepatan angin model Informer untuk masing-masing titik pengamatan ditampilkan pada Gambar 21 hingga Gambar 24.




Gambar 21. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T1 (Jun-Des 2025)



Gambar 22. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T2 (Jun-Des 2025)



Gambar 23. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T3 (Jun-Des 2025)




Gambar 24. Grafik prediksi terhadap aktual kecepatan angin model Informer - Titik T4 (Jun-Des 2025)

C. Analisis Hasil Prediksi Arah Angin


Prediksi arah angin (*wind direction*/WD) merupakan tantangan yang lebih besar dibandingkan prediksi kecepatan angin karena data arah angin bersifat sirkular (0° – 360°). Evaluasi menggunakan *Circular RMSE* yang menghitung jarak angular minimal: $circular_diff = \min(|\text{aktual} - \text{prediksi}|, 360^{\circ} - |\text{aktual} - \text{prediksi}|)$ [9]. Standar deviasi arah angin pada dataset ini sangat tinggi ($std_wd = 101,18^{\circ}$), hampir mendekati sepertiga lingkaran penuh, mencerminkan variabilitas arah angin yang besar. Evaluasi arah angin menggunakan MAE dan RMSE karena MAPE tidak bermakna secara fisis pada data bersifat sirkular. Data hasil evaluasi arah angin per titik dan iterasi telah disajikan secara terintegrasi pada Tabel 25 hingga Tabel 28.

1. Analisis Prediksi Arah Angin Model BiLSTM


Berdasarkan Tabel 26 dan Tabel 27, model BiLSTM menghasilkan RMSE arah angin rata-rata $66,5686^{\circ}$ (*normalized*: 0,6580) dan MAE rata-rata $51,7779^{\circ}$ (*normalized*: 0,5118). Performa terbaik diperoleh pada Titik T1 dengan MAE $49,3622^{\circ}$ dan performa terlemah pada Titik T4 dengan MAE $54,9472^{\circ}$. Nilai *normalized RMSE* sebesar 0,6580 menunjukkan bahwa *error* arah angin BiLSTM setara dengan 0,66 standar deviasi data, yang relatif lebih baik dibandingkan Informer. Visualisasi Grafik prediksi terhadap aktual arah angin model BiLSTM ditampilkan pada Gambar 25 hingga Gambar 28.




Gambar 25. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T1 (Mei-Des 2025)



Gambar 26. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T2 (Mei-Des 2025)



Gambar 27. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T3 (Mei-Des 2025)




Gambar 28. Grafik prediksi terhadap aktual arah angin model BiLSTM - Titik T4 (Mei-Des 2025)


2. Analisis Prediksi Arah Angin Model Informer

Berdasarkan Tabel 28 dan Tabel 29, model Informer menghasilkan RMSE arah angin rata-rata $80,5931^\circ$ (*normalized*: 0,7966) dan MAE rata-rata $69,1901^\circ$ (*normalized*: 0,6839). Nilai *normalized* RMSE 0,7966 menunjukkan bahwa *error* arah angin Informer setara dengan 0,80 standar deviasi data, lebih tinggi dibandingkan BiLSTM (0,6580). Kelemahan Informer pada prediksi arah angin disebabkan oleh kecenderungan mekanisme *self-attention* untuk merata-ratakan pola temporal jangka panjang, menghasilkan prediksi yang cenderung halus (*smooth/flat*) dan kurang responsif terhadap perubahan arah yang mendadak [9][12].


Visualisasi Grafik prediksi terhadap aktual arah angin model Informer ditampilkan pada Gambar 29 hingga Gambar 32.




Gambar 29. Grafik prediksi terhadap aktual arah angin model Informer - Titik T1 (Jun-Des 2025)



Gambar 30. Grafik prediksi terhadap aktual arah angin model Informer - Titik T2 (Jun-Des 2025)



Gambar 31. Grafik prediksi terhadap aktual arah angin model Informer - Titik T3 (Jun-Des 2025)



Gambar 32. Grafik prediksi terhadap aktual arah angin model Informer - Titik T4 (Jun-Des 2025)

D. Perbandingan Model Informer dan BiLSTM

Bagian ini menyajikan perbandingan komprehensif performa model Informer dan BiLSTM berdasarkan rata-rata keempat titik pengamatan. Perbandingan dilakukan pada dua skala secara berurutan: pertama skala asli kemudian skala *normalized*, untuk memastikan konsistensi temuan dan validitas perbandingan yang bebas dari pengaruh perbedaan jenis normalisasi antara kedua model.

1. Perbandingan pada Skala Asli

Tabel 30 merangkum rekap hasil evaluasi seluruh titik dan kedua model pada skala asli. Tabel 31 menyajikan perbandingan langsung rata-rata keempat titik beserta selisih dan model yang lebih unggul pada setiap metrik.

Tabel 30. Rekap Hasil Evaluasi Seluruh Titik Pengamatan - Skala Asli

Model - Titik	RMSE WS (knot)	MAE WS (knot)	MAPE WS (%)	RMSE WD (°)	MAE WD (°)	Keunggulan
BiLSTM - T1	5,1730	4,2624	50,96	64,9471	49,3622	-
BiLSTM - T2	5,1615	4,2541	50,75	65,7981	50,5233	-
BiLSTM - T3	5,1910	4,3240	52,22	66,9760	52,2788	-
BiLSTM - T4	5,1364	4,2359	51,91	68,5534	54,9472	-
Rata-rata BiLSTM	5,1655	4,2691	51,46	66,5686	51,7779	WD
Informer - T1	4,8171	3,4276	37,61	82,2417	69,9605	-
Informer - T2	4,9986	3,8490	48,97	79,3512	68,3433	-
Informer - T3	5,0922	3,9490	48,49	81,9698	70,6105	-
Informer - T4	5,0368	3,8731	43,70	78,8096	67,8461	-
Rata-rata Informer	4,9862	3,7747	44,69	80,5931	69,1901	WS

Tabel 31. Perbandingan Langsung Rata-rata Informer dan BiLSTM - Skala Asli

Metrik	BiLSTM	Informer	Selisih	Persentase	Model Unggul
RMSE WS (knot)	5,1655	4,9862	0,1793	3,5%	Informer
MAE WS (knot)	4,2691	3,7747	0,4944	11,6%	Informer
MAPE WS (%)	51,46	44,69	6,77 poin	13,2%	Informer
RMSE WD (°)	66,5686	80,5931	14,0245	17,4%	BiLSTM
MAE WD (°)	51,7779	69,1901	17,4122	25,1%	BiLSTM

2. Perbandingan pada Skala Normalized

Untuk memastikan perbandingan yang adil terlepas dari perbedaan jenis *scaler*, kedua model juga dibandingkan pada skala *normalized* menggunakan standar deviasi data keseluruhan sebagai referensi ($\text{std_ws} = 6,0885 \text{ knot}$; $\text{std_wd} = 101,1766^\circ$). Tabel 32 menyajikan hasil perbandingan pada skala *normalized*.

Tabel 32. Perbandingan Langsung Rata-rata Informer dan BiLSTM - Skala Normalized

Metrik	BiLSTM	Informer	Selisih	Persentase	Model Unggul
RMSE WS (norm.)	0,8484	0,8190	0,0294	3,5%	Informer
MAE WS (norm.)	0,7012	0,6200	0,0812	11,6%	Informer
MAPE WS (%)	51,46	44,69	6,77 poin	13,2%	Informer
RMSE WD (norm.)	0,6580	0,7966	0,1386	17,4%	BiLSTM
MAE WD (norm.)	0,5118	0,6839	0,1721	25,1%	BiLSTM

Pola perbandingan pada skala *normalized* konsisten dengan hasil skala asli: Informer unggul pada kecepatan angin dan BiLSTM unggul pada arah angin. Konsistensi temuan di kedua skala mengonfirmasi bahwa hasil penelitian tidak dipengaruhi oleh perbedaan metode normalisasi antara kedua model, sehingga perbandingan dapat dinyatakan valid dan adil [9].

E. Pembahasan

1. Interpretasi Akurasi Prediksi

Berdasarkan kriteria interpretasi MAPE pada Tabel 5, Informer menghasilkan prediksi kecepatan angin dalam kategori cukup (*Reasonable Forecasting*) dengan MAPE 44,69%, sedangkan BiLSTM masuk kategori tidak akurat (*Inaccurate Forecasting*) dengan MAPE 51,46% [28]. Tabel 33 merangkum kategori akurasi berdasarkan MAPE untuk kedua model.

Tabel 33. Interpretasi Kategori Akurasi Berdasarkan Nilai MAPE

Model	Parameter	Nilai MAPE (%)	Kategori
Informer	Kecepatan Angin	44,69	Cukup (Reasonable Forecasting)
BiLSTM	Kecepatan Angin	51,46	Tidak Akurat (<i>Inaccurate Forecasting</i>)
Informer & BiLSTM	Arah Angin	-	Tidak dihitung (data sirkular)

Nilai MAPE BiLSTM yang melebihi batas 50% sebesar 1,46 poin tidak serta merta menyatakan model tidak dapat digunakan. Sebagaimana dikemukakan Kosanoglu (2022) [27], MAPE untuk data kecepatan angin cenderung membengkak akibat sampel dengan nilai aktual mendekati nol yang menyebabkan persentase *error* membesar secara tidak proporsional [28]. Evaluasi menggunakan MAE memberikan gambaran yang lebih representatif: Informer mampu memprediksi kecepatan angin dengan rata-rata *error* absolut 3,7747 knot, sementara BiLSTM menghasilkan MAE 4,2691 knot yang masih dalam rentang yang dapat diterima untuk prakiraan maritim. Hal ini konsisten dengan penelitian Kosanoglu pada tahun 2022 yang menyatakan RMSE dan MAE lebih representatif dari pada MAPE untuk data kecepatan angin [27].

2. Keunggulan Informer pada Prediksi Kecepatan Angin

Informer mengungguli BiLSTM dalam prediksi kecepatan angin dengan penurunan RMSE sebesar 3,5% (5,1655 - 4,9862 knot) dan MAE sebesar 11,6% (4,2691 - 3,7747 knot), konsisten pada skala *normalized* (RMSE: 0,8484 - 0,8190). Keunggulan ini sejalan dengan temuan Zhou et al. pada tahun 2021 yang menunjukkan mekanisme *ProbSparse self-attention* Informer lebih efektif

menangkap dependensi temporal jangka panjang dibandingkan arsitektur *recurrent* [9]. Data kecepatan angin di Kepulauan Riau memiliki pola semi-periodik monsun bersiklus 6 bulanan [3]. Dengan sekuens *input* 336 langkah (84 hari), Informer dapat memanfaatkan pola ini melalui seleksi *timestep* yang relevan berdasarkan *Query Sparsity Measurement* (Persamaan 17). BiLSTM, meskipun mampu menangkap konteks *bidirectional*, memiliki keterbatasan menangani sekuens panjang akibat kompleksitas $O(Ld^2)$ [8].

3. Keunggulan BiLSTM pada Prediksi Arah Angin

BiLSTM mengungguli Informer dalam prediksi arah angin dengan RMSE lebih rendah 17,4% ($66,5686^\circ$ dibandingkan $80,5931^\circ$) dan MAE lebih rendah 25,1% ($51,7779^\circ$ dibandingkan $69,1901^\circ$), konsisten pada skala normalized (RMSE: 0,6580 dibandingkan 0,7966). Mekanisme *recurrent* BiLSTM lebih sensitif terhadap perubahan arah angin jangka pendek. Data arah angin memiliki standar deviasi sangat tinggi ($101,18^\circ$) yang mencerminkan fluktuasi besar, terutama pada masa peralihan monsun yang menyumbang 40% variasi *irregular* [3]. Kemampuan BiLSTM memproses sekuens dari dua arah memungkinkan penangkapan perubahan arah yang mendadak secara lebih akurat [4][6]. Sebaliknya, sifat *permutation-invariant* dari *self-attention* Informer dapat mengurangi sensitivitas terhadap urutan temporal jangka pendek [12], sehingga prediksi arah angin cenderung halus (*flat*) dan kurang responsif terhadap fluktuasi tajam.

Temuan ini diperkuat oleh analisis korelasi spasial arah angin antar keempat titik pengamatan, yang menunjukkan korelasi sedang hingga kuat (0,692-0,814) serta dominasi arah yang berganti tajam antarmusim: sektor Selatan-Barat Daya pada monsun barat (83,1%) dan Utara-Timur Laut pada monsun timur (83,8%). Pergantian dominasi arah yang tajam antarmusim ini lebih mampu ditangkap oleh mekanisme *recurrent* dua arah BiLSTM yang memproses konteks lokal secara berurutan, dibandingkan *self-attention* Informer yang cenderung merata-ratakan bobot atensi pada sekuens panjang sehingga kurang sensitif terhadap pergantian dominasi arah yang terjadi dalam skala waktu lebih pendek.

4. Implikasi Pemilihan Model

Temuan bahwa tidak ada satu model yang mutlak unggul untuk semua parameter merupakan kontribusi ilmiah utama penelitian ini, konsisten dengan argumen Zeng et al. (2023) bahwa pemilihan arsitektur model harus disesuaikan dengan karakteristik data [12]. Informer direkomendasikan untuk prediksi kecepatan angin (RMSE 4,9862 knot, MAE 3,7747 knot) yang relevan untuk perencanaan pelayaran dan peringatan dini maritim, sedangkan BiLSTM direkomendasikan untuk prediksi arah angin (RMSE 66,5686°, MAE 51,7779°) yang relevan untuk navigasi [1]. Kedua model dapat diimplementasikan bersama dalam sistem terintegrasi, sebagaimana telah didemonstrasikan melalui Fitur Kombinasi pada aplikasi WindSight.

Relevansi antara model dan hasil uji tercermin dari konsistensi keunggulan tiap model pada metrik yang sesuai karakteristik arsitekturnya: kemampuan Informer menangkap dependensi jangka panjang sejalan dengan keunggulannya pada kecepatan angin yang berpola semi-periodik, sedangkan sensitivitas BiLSTM terhadap konteks lokal dua arah sejalan dengan keunggulannya pada arah angin yang fluktuatif jangka pendek-menunjukkan bahwa hasil uji bukan sekadar angka metrik, melainkan cerminan langsung dari karakteristik mekanisme masing-masing arsitektur terhadap sifat data yang diujikan.

5. Variasi yang Memengaruhi Angin dan Keterbatasan Model

Secara meteorologis, kecepatan dan arah angin di suatu lokasi dipengaruhi oleh beberapa variasi fisik yang tidak dimodelkan secara eksplisit dalam penelitian ini, di antaranya gradien tekanan udara antar wilayah yang menjadi gaya penggerak utama angin, perbedaan suhu permukaan laut dan daratan yang memicu angin darat-laut (*land-sea breeze*) skala lokal, kelembapan udara yang memengaruhi densitas dan pola konveksi, serta topografi dan kekasaran permukaan (*surface roughness*) di sekitar titik pengamatan. Sebagaimana dijelaskan pada BAB II, pendekatan *data-driven* yang digunakan dalam penelitian ini hanya mempelajari pola numerik historis kecepatan dan arah angin tanpa mempertimbangkan variabel fisik tersebut secara eksplisit, sehingga variasi-variasi ini terabstraksi secara implisit ke dalam pola deret waktu yang dipelajari model, bukan dimodelkan sebagai hubungan sebab-akibat yang dapat diinterpretasi.

Terkait pengaruh arah angin terhadap arah angin pada *timestep* berikutnya, secara fisis perubahan arah angin umumnya bersifat kontinu dan dipengaruhi oleh pergeseran gradien tekanan serta gaya Coriolis, bukan perubahan acak. Pola ini tercermin secara implisit dalam autokorelasi temporal yang dipelajari kedua model melalui mekanisme *recurrent* (BiLSTM) maupun *self-attention* (Informer), namun penelitian ini tidak melakukan analisis eksplisit terhadap derajat autokorelasi arah angin antar-*lag* waktu. Analisis lebih lanjut menggunakan fungsi autokorelasi (*Autocorrelation Function*/ACF) pada data arah angin dapat menjadi arah penelitian selanjutnya untuk mengukur secara kuantitatif seberapa besar arah angin pada satu waktu memengaruhi arah angin pada waktu berikutnya.

Variasi lain yang berpotensi meningkatkan akurasi model prediksi mencakup tekanan udara permukaan, suhu udara, kelembapan relatif, dan suhu permukaan laut (*sea surface temperature*) sebagai variabel eksogen tambahan, sebagaimana telah disarankan pada bagian Saran. Selain itu, representasi sirkular arah angin melalui dekomposisi komponen *u* dan *v* (komponen angin zonal dan meridional) berpotensi menangkap sifat periodik arah angin secara lebih akurat dibandingkan representasi derajat (0° – 360°) yang digunakan saat ini, mengingat nilai 359° dan 1° secara fisis berdekatan namun secara numerik berjauhan.

Pola prediksi Informer yang cenderung stagnan (*flat*) dibandingkan fluktuasi data aktual, sebagaimana terlihat pada Gambar 25 hingga Gambar 32, disebabkan oleh dua faktor utama. Pertama, mekanisme *self-attention* yang bersifat *permutation-invariant* cenderung merata-ratakan bobot atensi pada *sequence* panjang, sehingga *output* yang dihasilkan condong ke nilai rata-rata historis dan kurang responsif terhadap perubahan mendadak [12]. Kedua, model *data-driven* tanpa variabel eksogen tidak memiliki informasi awal mengenai pemicu fisik perubahan arah angin yang mendadak, seperti pergeseran sistem tekanan pada masa peralihan monsun, sehingga model cenderung memprediksi kelanjutan pola yang sudah dipelajari (*persistence-like behavior*) alih-alih mengantisipasi perubahan abrupt yang belum pernah terlihat polanya pada data pelatihan.

BAB V

SIMPULAN DAN SARAN

A. Simpulan

Berdasarkan hasil penelitian dan pembahasan yang telah diuraikan, berikut simpulan sebagai jawaban atas tiga rumusan masalah yang ditetapkan.

1. **Performa model Informer** dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau menunjukkan RMSE kecepatan angin rata-rata 4,9862 knot, MAE 3,7747 knot, dan MAPE 44,69% (kategori cukup). Pada skala *normalized*, RMSE kecepatan angin 0,8190 dan MAE 0,6200. Untuk arah angin, Informer menghasilkan RMSE 80,5931° (*normalized*: 0,7966) dan MAE 69,1901° (*normalized*: 0,6839). MAPE tidak dihitung untuk arah angin karena sifat data yang sirkular (0°–360°) menyebabkan nilai MAPE tidak bermakna secara fisis. Mekanisme *ProbSparse self-attention* Informer efektif menangkap pola temporal jangka panjang kecepatan angin, namun kurang optimal dalam menangkap perubahan arah angin jangka pendek yang sangat fluktuatif.
2. **Performa model BiLSTM** dalam memprediksi kecepatan dan arah angin di perairan Kepulauan Riau menunjukkan RMSE kecepatan angin rata-rata 5,1655 knot, MAE 4,2691 knot, dan MAPE 51,46% (kategori tidak akurat). Pada skala *normalized*, RMSE kecepatan angin 0,8484 dan MAE 0,7012. Untuk arah angin, BiLSTM menghasilkan RMSE 66,5686° (*normalized*: 0,6580) dan MAE 51,7779° (*normalized*: 0,5118). MAPE tidak dihitung untuk arah angin karena sifat data yang sirkular (0°–360°) menyebabkan nilai MAPE tidak bermakna secara fisis. Mekanisme *recurrent bidirectional* BiLSTM lebih sensitif terhadap perubahan arah angin jangka pendek sehingga menghasilkan prediksi arah angin yang lebih akurat dibandingkan Informer.
3. **Perbandingan akurasi** antara Informer dan BiLSTM menunjukkan bahwa tidak ada satu model yang mutlak lebih unggul untuk semua parameter. Informer unggul dalam prediksi kecepatan angin dengan penurunan RMSE 3,5% dan MAE 11,6% dibandingkan BiLSTM, konsisten pada skala asli

maupun *normalized*. Sebaliknya, BiLSTM unggul dalam prediksi arah angin dengan RMSE lebih rendah 17,4% dan MAE lebih rendah 25,1%, juga konsisten di kedua skala. Berdasarkan temuan ini, disarankan penggunaan model Informer untuk prediksi kecepatan angin dan model BiLSTM untuk prediksi arah angin dalam aplikasi prakiraan cuaca di perairan Kepulauan Riau.

Keunggulan Informer pada kecepatan angin konsisten dengan kemampuannya memanfaatkan pola monsun semi-periodik melalui seleksi *timestep* jangka panjang (336 langkah), sedangkan BiLSTM lebih responsif terhadap fluktuasi *irregular* pada prediksi arah angin - didukung oleh korelasi spasial arah angin antar titik (0,692-0,814) dan dominasi arah yang berganti tajam antarmusim (Selatan-Barat Daya pada monsun barat, Utara-Timur Laut pada monsun timur) yang lebih peka ditangkap mekanisme *recurrent* BiLSTM. Temuan ini menunjukkan bahwa karakteristik data angin yang semi-periodik dan *sparse* (interval 6 jam) berkontribusi pada pemisahan keunggulan kedua model secara komplementer. Pola prediksi yang cenderung stagnan (*flat*) dibandingkan fluktuasi data aktual, terutama pada Informer, juga dipengaruhi oleh pembagian data secara kronologis: data *training* (Januari 2023-Februari 2025) didominasi pola musiman yang relatif reguler, sedangkan data *testing* (Mei-Desember 2025) mencakup masa peralihan dan pergantian monsun dengan fluktuasi lebih tinggi, sehingga kedua model cenderung mereproduksi pola rata-rata historis alih-alih mengantisipasi perubahan mendadak yang karakteristiknya belum terwakili dalam data pelatihan.

B. Saran

Berdasarkan keterbatasan dan temuan penelitian ini, saran untuk penelitian selanjutnya adalah sebagai berikut.

1. Penelitian selanjutnya dapat mengeksplorasi representasi sirkular untuk arah angin, seperti dekomposisi ke komponen u dan v (komponen angin zonal dan meridional), sebelum dimasukkan ke model. Pendekatan ini berpotensi meningkatkan akurasi prediksi arah angin khususnya pada model berbasis *Transformer* seperti Informer.

2. Penggunaan arsitektur yang lebih mutakhir seperti *PatchTST* atau *iTransformer* sebagai pengembangan dari Informer dapat dieksplorasi. Studi Nie et al. Pada tahun 2023 menunjukkan *PatchTST* mampu meningkatkan performa Informer hingga 21% pada berbagai *benchmark* prediksi deret waktu [10].
3. Penelitian selanjutnya dapat mempertimbangkan penambahan variabel eksogen seperti tekanan udara, kelembapan, dan suhu permukaan laut sebagai fitur input tambahan untuk meningkatkan akurasi prediksi pada data angin.
4. Cakupan titik pengamatan dapat diperluas untuk mencakup seluruh perairan strategis Kepulauan Riau, termasuk Selat Malaka dan perairan Natuna, sehingga sistem prediksi dapat dimanfaatkan lebih luas oleh pemangku kepentingan maritim nasional.
5. Integrasi model prediksi dengan sistem peringatan dini cuaca maritim BMKG dapat menjadi arah pengembangan praktis untuk meningkatkan keselamatan pelayaran dan efisiensi operasional di perairan Kepulauan Riau [1].
6. Berdasarkan temuan penelitian, BMKG Tanjungpinang dapat mempertimbangkan penggunaan model Informer sebagai pendukung prakiraan kecepatan angin dan BiLSTM untuk prakiraan arah angin pada skala operasional lokal sebagai sistem pendukung keputusan (*decision support system*), sebelum dilakukan validasi lebih lanjut dengan data *real-time* dan pengujian pada kondisi monsun barat.

DAFTAR PUSTAKA

- [1] A. N. Efendi *et al.*, “Karakteristik Gelombang Laut Indoneisa Untuk Mendukung Kegiatan Laut dan Keamanan Maritim,” *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 2, pp. 346–357, Mar. 2023, doi: 10.33379/gtech.v7i2.1989.
- [2] F. A. Rachma, M. N. Estri, and A. Wardayani, “Penggunaan Metode Long Short Term Memory untuk Peramalan Kecepatan Angin di PLTB Jeneponto,” 2025. [Online]. Available: <https://cds.climate.copernicus.eu/>.
- [3] R. Kurniawan and M. Najib Habibie, “Variasi Bulanan Gelombang Laut di Indonesia Monthly Ocean Waves Variation Over Indonesia.”
- [4] L. Li *et al.*, “Temporally Correlated Deep Learning-Based Horizontal Wind-Speed Prediction,” *Sensors*, vol. 24, no. 19, Oct. 2024, doi: 10.3390/s24196254.
- [5] M. Ryan and S. Alfiandy, “Prediksi Kecepatan Angin 12 Jam Kedepan Menggunakan Automatic Weather Observing System (AWOS) Berbasis Regresi Linear,” *Buletin GAW Bariri*, vol. 3, no. 2, pp. 1–7, Dec. 2022, doi: 10.31172/bgb.v3i2.63.
- [6] Q. Wang and L. Zhang, “Short-term wind speed prediction of wind farm based on TSO-VMD-BiLSTM,” *PeerJ Computer Science*, vol. 10, p. e2032, 2024.
- [7] I. P. B. Priadinata, I. G. I. Sudipa, N. P. S. Meinarni, I. M. L. Radhitya, and I. K. D. G. Supartha, “Comparative Analysis of LSTM, GRU, and Bi-LSTM Deep Learning Models for Time Series Cryptocurrency Price Forecasting,” *sinkron*, vol. 9, no. 3, pp. 1024–1035, Jul. 2025, doi: 10.33395/sinkron.v9i3.14795.
- [8] Y. Kong *et al.*, “Unlocking the Power of LSTM for Long Term Time Series Forecasting,” Feb. 2025, [Online]. Available: <http://arxiv.org/abs/2408.10006>
- [9] H. Zhou *et al.*, “Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting,” Mar. 2021, [Online]. Available: <http://arxiv.org/abs/2012.07436>

- [10] Y. Nie, N. H. Nguyen, P. Sinthong, and J. Kalagnanam, "A Time Series is Worth 64 Words: Long-term Forecasting with Transformers," Mar. 2023, [Online]. Available: <http://arxiv.org/abs/2211.14730>
- [11] J. Jun and H. K. Kim, "Informer-Based Temperature Prediction Using Observed and Numerical Weather Prediction Data," *Sensors*, vol. 23, no. 16, Aug. 2023, doi: 10.3390/s23167047.
- [12] A. Zeng, M. Chen, L. Zhang, and Q. Xu, "Are Transformers Effective for Time Series Forecasting?," Aug. 2022, [Online]. Available: <http://arxiv.org/abs/2205.13504>
- [13] A. Hanafiah, Y. Arta, H. O. Nasution, and Y. D. Lestari, "Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham," *Bulletin of Computer Science Research*, vol. 4, no. 1, pp. 27–33, Dec. 2023, doi: 10.47065/bulletincsr.v4i1.321.
- [14] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 346, Jul. 2023, doi: 10.26418/justin.v11i2.57395.
- [15] N. Selle, N. Yudistira, and C. Dewi, "Perbandingan Prediksi Penggunaan Listrik Dengan Menggunakan Metode Long Short Term Memory (LSTM) Dan Recurrent Neural Network (RNN)," vol. 9, no. 1, pp. 155–162, 2022, doi: 10.25126/jtiik.202295585.
- [16] Z. Ben Bouallègue *et al.*, "The Rise of Data-Driven Weather Forecasting A First Statistical Assessment of Machine Learning–Based Weather Forecasts in an Operational-Like Context," *Bull. Am. Meteorol. Soc.*, vol. 105, no. 6, pp. E864–E883, Jun. 2024, doi: 10.1175/BAMS-D-23-0162.1.
- [17] Y. Wu and W. Xue, "Data-Driven Weather Forecasting and Climate Modeling from the Perspective of Development," Jun. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/atmos15060689.
- [18] D. Alves, F. Mendonça, S. S. Mostafa, and F. Morgado-Dias, "A deep learning approach for improving spatiotemporal resolution of numerical

- weather prediction forecasts,” *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-17867-5.
- [19] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles & Practice*, 3rd ed. Melbourne: OTexts, 2016.
- [20] P. Das and S. Barman, “Perspective Chapter: An Overview of Time Series Decomposition and Its Applications,” in *Applied and Theoretical Econometrics and Financial Crises*, IntechOpen, 2025, doi: 10.5772/intechopen.1009268.
- [21] V. Masti, “Unit 3-Time Series Analysis.”
- [22] K. dan G. Badan Meteorologi, *Peraturan Badan Meteorologi, Klimatologi, dan Geofisika Republik Indonesia*. 2025.
- [23] World Meteorological Organization, “Guide to Meteorological Instruments and Methods of Observation,” Geneva, 2022. [Online]. Available: www.wmo.int
- [24] A. Allen *et al.*, “End-to-end data-driven weather prediction,” *Nature*, vol. 641, no. 8065, pp. 1172–1179, May 2025, doi: 10.1038/s41586-025-08897-0.
- [25] M. Schuster and K. K. Paliwal, “Bidirectional Recurrent Neural Networks,” 1997.
- [26] A. Vaswani *et al.*, “Attention Is All You Need,” 2023.
- [27] F. Kosanoglu, “Wind Speed Forecasting with a Clustering-Based Deep Learning Model,” *Applied Sciences (Switzerland)*, vol. 12, no. 24, Dec. 2022, doi: 10.3390/app122413031.
- [28] C. Barış, C. Yanarateş, and A. Altan, “A robust chaos-inspired artificial intelligence model for dealing with nonlinear dynamics in wind speed forecasting,” *PeerJ Comput. Sci.*, vol. 10, 2024, doi: 10.7717/PEERJ-CS.2393.