

EVALUASI MEKANISME ATTENTION PADA ARSITEKTUR BIDIRECTIONAL LSTM DAN GRU UNTUK PREDIKSI INTENSITAS DAN TRAJEKTORI SIKLON TROPIS

Wisnu Syahid^{1*}, Aditya Mulya², Latifah Nurul Q³, Yosafat Donni Haryanto⁴

^{1,2,3,4} Program Studi Meteorologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika (STMKG), Tangerang City, Banten, Indonesia.

Keywords:

Mekanisme Attention,
Prediksi Intensitas, Prediksi
Trajektori, Siklon Tropis.

Correspondent Email:

wisnoesjahid@stmkg.ac.id

Abstrak. Penelitian ini mengevaluasi kontribusi mekanisme attention dalam meningkatkan akurasi prediksi intensitas dan trajektori siklon tropis di Pasifik Barat menggunakan tiga konfigurasi hyperparameter dari literatur, yaitu Nketiah (2023), Giffard-Roisin (2020), dan Mulia (2025). Enam arsitektur Recurrent Neural Network (RNN) yaitu LSTM, BiLSTM, Att-BiLSTM, GRU, BiGRU, dan Att-BiGRU. Model ini dilatih menggunakan data IBTrACS beresolusi 3 jam periode 1945-2025. Kinerja model dievaluasi dengan MAE, RMSE, dan MAPE pada *lead time* 12, 24, 48, dan 72 jam. Hasil menunjukkan bahwa model berbasis attention secara konsisten menghasilkan *error* lebih rendah dibandingkan model tanpa attention pada prediksi intensitas. Konfigurasi Nketiah (2023) dengan Att-BiLSTM memberikan performa terbaik dengan MAE intensitas 7,78 knot dan MAE trajektori 77,97 km pada *lead time* 12 jam. Konfigurasi Giffard-Roisin (2020) dengan Att-BiGRU unggul pada prediksi intensitas jangka pendek hingga menengah, sedangkan konfigurasi Mulia (2025) menghasilkan *error* intensitas terendah namun akurasi posisi lebih rendah. Analisis kasus menunjukkan attention efektif pada siklon dengan pergerakan gradual, tetapi masih terbatas pada siklon dengan translasi zonal cepat. Temuan ini mendukung penerapan attention dalam sistem peringatan dini siklon tropis operasional.



Copyright © 2026 The Author(s),
Published by Jurnal Informatika
dan Teknik Elektro Terapan. This
is an open-access article
distributed under the terms of the
Creative Commons Attribution-
NonCommercial 4.0 International
License (CC BY-NC 4.0).

Abstract. This study evaluates the contribution of attention mechanisms to improving the accuracy of predictions of the intensity and trajectory of tropical cyclones in the Western Pacific using three hyperparameter configurations from the literature, namely Nketiah (2023), Giffard-Roisin (2020) and Mulia (2025). Six Recurrent Neural Network (RNN) architectures, namely LSTM, BiLSTM, Att-BiLSTM, GRU, BiGRU, and Att-BiGRU. These models were trained using 3-hour resolution IBTrACS data covering the period 1945–2025. Model performance was evaluated using MAE, RMSE, and MAPE at lead times of 12, 24, 48, and 72 hours. The results show that attention-based models consistently produce lower errors than non-attention models in intensity predictions. The Nketiah (2023) configuration with Att-BiLSTM delivered the best performance, with an intensity MAE of 7.78 knots and a trajectory MAE of 77.97 km at a 12-hour lead time. The Giffard-Roisin (2020) configuration with Att-BiGRU outperformed others in short- to medium-term intensity predictions, whilst the Mulia (2025) configuration produced the lowest intensity error but had lower position accuracy. Case studies indicate that attention mechanisms are effective for cyclones with gradual movement, but remain limited for those with rapid zonal translation.

These findings support the implementation of attention mechanisms in operational tropical cyclone early warning systems.

1. PENDAHULUAN

Siklon tropis merupakan fenomena atmosfer yang paling destruktif di kawasan tropis, dicirikan oleh pembentukan pusat tekanan rendah yang dikelilingi angin kencang berputar dan konveksi intens [6]. Wilayah Pasifik Barat menjadi basin dengan aktivitas siklon tropis tertinggi secara global, yang dikendalikan oleh interaksi kompleks antara *Western Pacific Monsoon Trough*, *subtropical ridge*, *Madden-Julian Oscillation* (MJO), dan suhu permukaan laut (SPL) yang hangat [13]. Bagi Indonesia, siklon di basin ini memberikan dampak tidak langsung berupa hujan ekstrem dan gelombang tinggi di wilayah pesisir utara, menjadikan akurasi prediksinya krusial bagi operasional BMKG [16].

Prediksi siklon tropis mencakup dua aspek fundamental yaitu intensitas atau kecepatan angin maksimum di sekitar pusat sirkulasi dan trajektori atau jalur pergerakan spasial pusat siklon. Prediksi intensitas menghadapi tantangan pada fase *rapid intensification* (RI), ketika kecepatan angin meningkat lebih dari 30 knot dalam 24 jam, yang disebabkan oleh kerumitan representasi *upper-level warm core* dan *convective bursts* dalam model konvensional [23][24]. Prediksi trajektori, meski telah mengalami perbaikan signifikan, masih rentan terhadap variabilitas *steering flow* dan ketidakpastian atmosfer yang bersifat *chaotic* pada horizon prediksi panjang [5].

Pendekatan *deep learning* berbasis *Recurrent Neural Network* (RNN) telah menunjukkan keunggulan dalam menangkap ketergantungan temporal non-linear dari data deret waktu meteorologis [11][12]. Arsitektur *Long Short-Term Memory* (LSTM) mengatasi masalah *vanishing gradient* melalui cell state dan mekanisme gerbang [9], sedangkan *Gated Recurrent Unit* (GRU) menawarkan efisiensi komputasi serupa dengan struktur yang lebih ringkas [3]. Varian *bidirectional* dari keduanya yaitu Bi-LSTM dan Bi-GRU memiliki kemampuan dalam memproses sekuens dari arah maju dan mundur secara paralel, menghasilkan representasi konteks temporal yang lebih komprehensif [20].

Inovasi kunci yang menjadi fokus penelitian ini adalah integrasi mekanisme *attention* [1] ke dalam arsitektur *bidirectional*, yang menghasilkan dua varian unggulan yaitu *Attention Bidirectional LSTM* (Att-BiLSTM) dan *Attention Bidirectional GRU* (Att-BiGRU). Mekanisme ini menghitung bobot konteks adaptif dari seluruh *hidden state* historis berdasarkan relevansinya terhadap *query state* saat ini, sehingga model dapat secara dinamis memusatkan perhatian pada *timestep* yang paling informatif. Kemampuan yang sangat kritis ini digunakan untuk menangkap transisi intensifikasi cepat dan perubahan *steering flow* yang mendadak [21]. Rahman dkk. (2025) mendokumentasikan keunggulan LSTM di Samudra Hindia Utara, sementara Song dkk. (2022) membuktikan bahwa Att-BiGRU memitigasi akumulasi *error* secara signifikan pada prediksi jangka panjang hingga 72 jam [19][21]. Namun, studi komparatif yang secara eksplisit mengevaluasi peran mekanisme *attention* versus *non-attention* pada Att-BiLSTM dan Att-BiGRU di wilayah Pasifik Barat dalam konteks operasional Indonesia masih sangat terbatas [11].

Penelitian ini bertujuan mengisi kesenjangan tersebut melalui evaluasi sistematis kontribusi mekanisme *attention* terhadap akurasi prediksi siklon tropis di Pasifik Barat. Tiga konfigurasi *hyperparameter* dari literatur terpilih Nketiah (2023), Giffard-Roisin (2020), dan Mulia (2025), masing-masing diujikan pada keenam variasi arsitektur, memungkinkan perbandingan langsung antara model bermekanisme *attention* dan tanpa *attention* dalam kondisi *hyperparameter* yang identik [7][15][18]. Dataset IBTrACS beresolusi 3 jam selama 79 tahun (1945–2025) digunakan untuk memastikan representasi yang kaya terhadap variabilitas siklon historis. Hasil penelitian diharapkan memberikan rekomendasi untuk pengembangan sistem prediksi siklon tropis berbasis *deep learning* oleh BMKG.

2. TINJAUAN PUSTAKA

2.1 Siklon Tropis

Siklon tropis merupakan sistem tekanan rendah yang terbentuk di atas lautan tropis hangat ($SPL \geq 26^\circ C$), dicirikan oleh angin rotasional kuat dan konveksi intens di sekitar pusat sirkulasi [6]. Sistem ini dikelompokkan berdasarkan kecepatan angin rata-rata 10 menit [23]:

- *Tropical Depression*: $< 34 \text{ knot}$
- *Tropical Cyclone I (gale-force)*: $34\text{--}47 \text{ knot}$
- *Tropical Cyclone II (storm-force)*: $48\text{--}63 \text{ knot}$
- *Severe Tropical Cyclone*: $\geq 64 \text{ knot}$

2.2 Prediksi Intensitas dan Trajektori Siklon Tropis

Prediksi intensitas berfokus pada variasi kecepatan angin maksimum, dengan tantangan utama pada fase *rapid intensification* (RI) yaitu peningkatan $\geq 30 \text{ knot}$ dalam 24 jam, yang disebabkan oleh keterbatasan model dalam menggambarkan dinamika internal inti siklon [24]. Prediksi trajektori mengevaluasi jalur perpindahan spasial pusat siklon yang dipengaruhi oleh *steering flow*, efek beta, dan gaya Coriolis [5]. Metode *deep learning* terbukti lebih unggul dibandingkan pendekatan statistik tradisional dalam mempelajari kedua aspek tersebut menggunakan data historis dalam skala besar [8][14][19].

2.3 Deep Learning untuk Prediksi Deret Waktu Meteorologis

Deep learning adalah subset *machine learning* yang menggunakan jaringan saraf tiruan berlapis banyak untuk mengekstraksi representasi fitur hierarkis secara otomatis dari data mentah [25]. Pendekatan ini unggul untuk pemodelan hubungan non-linear pada data atmosfer berskala besar karena kemampuannya menangkap pola temporal yang kompleks tanpa rekayasa fitur manual [11].

2.4 Recurrent Neural Network (RNN)

RNN adalah arsitektur jaringan saraf yang dirancang untuk memproses data sekuensial melalui mekanisme *hidden state* yang menyirkulasikan informasi antar langkah waktu [25]. Keterbatasan utamanya adalah masalah *vanishing gradient* yang menghalangi pembelajaran pola temporal jangka jauh,

mendorong pengembangan varian yang lebih canggih [26].

2.5 Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU)

LSTM mengatasi masalah *vanishing gradient* melalui penambahan *cell state* serta tiga mekanisme gerbang, yaitu *forget gate* (f_t), *input gate* (i_t), dan *output gate* (o_t), yang secara adaptif mengatur aliran informasi jangka panjang (Hochreiter & Schmidhuber, 1997). GRU menyederhanakan arsitektur tersebut menjadi dua gerbang, yaitu *reset gate* (r_t) dan *update gate* (z_t), dengan menyatukan *cell state* dan *hidden state*, sehingga menghasilkan efisiensi komputasi sekitar 25% lebih tinggi dibandingkan LSTM serta tetap mempertahankan performa yang kompetitif [3][4].

2.6 Arsitektur Bidirectional

Varian *Bidirectional* (Bi-LSTM, Bi-GRU) mengolah sekuens secara bersamaan dari dua arah, yaitu maju (*forward*) dan mundur (*backward*), kemudian menggabungkan *hidden state* dari keduanya menjadi $h_t = [\vec{h}_t; \bar{h}_t]$ [20]. Pendekatan ini menghasilkan representasi konteks temporal yang lebih komprehensif, serta terbukti mampu meningkatkan stabilitas prediksi trajektori siklon pada skala waktu menengah [21].

2.7 Mekanisme Attention

Mekanisme *attention* menghitung vektor konteks c_t sebagai kombinasi berbobot dari seluruh *hidden state* historis [1]:

$$\alpha_{t,i} = \frac{\exp(e_{t,i})}{\sum_j \exp(e_{t,j})} \quad (1)$$

$$c_t = \sum_i \alpha_{t,i} \cdot h_i \quad (2)$$

Bobot $\alpha_{t,i}$ ditentukan secara adaptif berdasarkan relevansi setiap *timestep* terhadap prediksi saat ini, sehingga model dapat memusatkan perhatian pada momen kritis seperti fase RI atau perubahan *steering flow*. Integrasi mekanisme ini pada arsitektur *bidirectional* menghasilkan Att-BiLSTM dan Att-Bi-GRU, yang terbukti memitigasi akumulasi kesalahan pada prediksi trajektori hingga 72 jam [19][21]).

3. METODE PENELITIAN

Adapun tahapan dalam metode penelitian terbagi atas beberapa penjelasan yang meliputi tahapan berikut.

3.1 Data dan Wilayah Penelitian

Data best-track siklon tropis bersumber dari *International Best Track Archive for Climate Stewardship* (IBTrACS), yang dikelola oleh NOAA NCEI. Cakupan wilayah penelitian meliputi basin Pasifik Barat dalam batas koordinat 20°LU–20°LS dan 90°BT–160°BT. Dataset memuat informasi posisi pusat siklon (lintang, bujur), kecepatan angin maksimum, dan waktu kejadian dengan resolusi temporal 3 jam, sesuai dengan resolusi pencatatan JTWC. Pembagian temporal dataset mengikuti skema: data latih (1945–2020), validasi (2021–2024), dan uji independen (2025), yang menjaga prinsip kausalitas deret waktu dan menghindari *data leakage*.

3.2 Pra-pemrosesan Data

Pra-pemrosesan meliputi tiga tahap. Pertama, quality control dengan interpolasi linier terhadap nilai hilang (NaN) antara timestep berurutan menggunakan persamaan:

$$f(X) = f(X_0) + \frac{[f(X^1) - f(X^0)]}{(X_1 - X_0) \cdot (X - X_0)} \quad (3)$$

Kedua, normalisasi Min-Max ke rentang $[-1, 1]$, dengan parameter (xmin, xmax) dihitung eksklusif dari data latih untuk menghindari *data leakage*:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

Ketiga, pembentukan supervised sliding-window sequences. Empat fitur input yang digunakan yaitu lintang, bujur, kecepatan translasi (km/jam), dan *bearing* dari posisi sebelumnya. Target output mencakup posisi (lintang, bujur) dan kecepatan angin maksimum pada *lead time* 12, 24, 48, dan 72 jam.

3.3 Arsitektur Model

Penelitian ini mengevaluasi enam variasi arsitektur *Recurrent Neural Network* (RNN), yaitu LSTM, Bi-LSTM, Att-BiLSTM, GRU, Bi-GRU, dan Att-BiGRU. Arsitektur LSTM (*Long Short-Term Memory*) menggunakan tiga

mekanisme gerbang, yaitu *input gate*, *forget gate*, dan *output gate*, serta *cell state* (C_t) sebagai media penyimpanan informasi jangka panjang untuk mengatasi permasalahan *vanishing gradient* pada RNN konvensional [9]. Persamaan pembaruan pada LSTM dapat dinyatakan sebagai berikut [4]:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (5)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (7)$$

Sementara itu, GRU (*Gated Recurrent Unit*) menyederhanakan struktur LSTM dengan menggunakan dua mekanisme gerbang, yaitu *reset gate* (r_t) dan *update gate* (z_t), serta menggabungkan fungsi *cell state* dan *hidden state* ke dalam satu representasi memori. Penyederhanaan ini memungkinkan GRU memiliki kompleksitas komputasi yang lebih rendah tanpa mengurangi kemampuan dalam menangkap dependensi temporal jangka panjang [3].

Varian *Bidirectional* yang terdiri atas Bi-LSTM dan Bi-GRU memproses sekuens data secara paralel dari dua arah, yaitu maju (*forward*) dan mundur (*backward*). Hasil dari kedua proses tersebut kemudian dikonkatenasikan sehingga menghasilkan representasi *hidden state*:

$$h_t = [h \rightarrow t ; h \leftarrow t] \quad (8)$$

Representasi ini memungkinkan model memperoleh informasi temporal yang lebih lengkap karena mempertimbangkan konteks dari masa lalu maupun masa depan dalam suatu sekuens [20].

Untuk meningkatkan kemampuan model dalam mengekstraksi informasi yang relevan, penelitian ini juga menerapkan mekanisme *additive attention* pada arsitektur bidirectional sehingga menghasilkan model Att-BiLSTM dan Att-BiGRU. Mekanisme *attention* menghitung bobot perhatian ($\alpha_{\{t,i\}}$) berdasarkan tingkat relevansi setiap *hidden state* historis terhadap keadaan saat ini. Bobot tersebut kemudian digunakan untuk membentuk *context vector* (c_t) sebagai kombinasi berbobot dari seluruh *hidden state* yang tersedia [1].

Pada model Att-BiLSTM, mekanisme attention diterapkan pada keluaran Bi-LSTM, sedangkan pada model Att-BiGRU diterapkan pada keluaran Bi-GRU. Pendekatan ini memungkinkan model untuk secara adaptif memfokuskan perhatian pada *timestep* yang paling informatif sehingga mampu meningkatkan representasi pola temporal yang kompleks dalam proses prediksi trajektori dan intensitas siklon tropis.

3.4 Konfigurasi Hyperparameter

Tiga konfigurasi hyperparameter dari literatur terpilih digunakan dalam penelitian ini, sebagaimana ditampilkan pada Tabel 1. Setiap konfigurasi mengatur parameter pelatihan yang kemudian diterapkan secara identik pada keenam arsitektur, sehingga perbedaan performa yang teramati hanya mencerminkan kontribusi arsitektur.

Tabel 1. Konfigurasi hyperparameter yang dievaluasi

Konfigurasi	Nketiah (2023)	Giffard-Roisin (2020)	Mulia (2025)
Sequence Length	24	16	16
Batch Size	32	64	64
Epoch	100	100	200
Hidden Unit	128	128	10
Number Layer	3	2	2
Dropout	0.20	0.20	0.08
Learning Rate	0.001	0.001	0.0006

Tabel 1. Tiga konfigurasi hyperparameter yang digunakan dalam evaluasi. Setiap konfigurasi diujikan pada keenam variasi arsitektur (LSTM, BiLSTM, Att-BiLSTM, GRU, BiGRU, Att-BiGRU).

3.5 Metrik Evaluasi

Performa model dievaluasi menggunakan tiga metrik kuantitatif yang saling melengkapi. MAE mengukur rata-rata kesalahan absolut dalam satuan asli variabel, sehingga mudah diinterpretasikan secara operasional (Hodson, 2022):

$$MAE = \left(\frac{1}{n}\right) \sum_i |y_i - \hat{y}_i| \quad (9)$$

RMSE memberikan penekanan lebih besar pada deviasi ekstrem, relevan untuk mendeteksi kegagalan pada kejadian rapid intensification atau perubahan lintasan tiba-tiba (Hodson, 2022):

$$RMSE = \sqrt{\left[\left(\frac{1}{n}\right) \sum_i (y_i - \hat{y}_i)^2\right]} \quad (10)$$

MAPE menyatakan kesalahan dalam bentuk persentase relatif, memfasilitasi perbandingan performa lintas variabel (intensitas vs. trajektori) dan lintas konfigurasi (Naik dkk., 2024):

$$MAPE = \left(\frac{1}{n}\right) \sum_i \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100\% \quad (11)$$

Evaluasi dilakukan secara terpisah untuk prediksi intensitas (kecepatan angin dalam knot) dan prediksi trajektori (jarak posisi dalam km). Data uji independen tahun 2025 digunakan pada seluruh evaluasi untuk memastikan penilaian kemampuan generalisasi model yang objektif.

4. HASIL DAN PEMBAHASAN

Hasil penelitian dan pembahasan dalam bab ini disajikan melalui beberapa tahapan analisis yang diuraikan sebagai berikut.

4.1 Performa Model pada Tiap Lead time

Seluruh keenam arsitektur dievaluasi pada data uji independen tahun 2025 untuk empat *lead time* (12, 24, 48, 72 jam), mencakup prediksi intensitas angin (knot) dan trajektori posisi (km). Secara umum, *error* meningkat konsisten seiring bertambahnya horizon prediksi pada semua konfigurasi.

Tabel 2. Matriks evaluasi Att-BiLSTM konfigurasi Nketiah (2023).

Lead time	Wind MAE (kt)	Wind RMSE (kt)	Wind MAPE (%)	Traj MAE (km)	Traj RMSE (km)	Traj MAPE (%)
12 Jam	7,78	11,32	11	77,97	85,62	13
24 Jam	12,55	19,37	16	199,40	264,46	40
48 Jam	14,10	18,51	27	463,72	657,83	143

<i>Lead time</i>	Wind MAE (kt)	Wind RMSE (kt)	Wind MAPE (%)	Traj MAE (km)	Traj RMSE (km)	Traj MAPE (%)
72 Jam	13,64	15,51	53	582,67	845,32	208

Pada konfigurasi Att-BiLSTM Nketiah (2023) di Tabel 2, performa model menunjukkan peningkatan *error* yang konsisten seiring bertambahnya *lead time*, baik untuk prediksi intensitas angin maupun trajektori. Untuk prediksi angin, MAE naik dari 7,78 kt pada 12 jam menjadi 13,64 kt pada 72 jam, sementara RMSE mencapai puncak di 19,37 kt pada 24 jam kemudian sedikit menurun. MAPE angin meningkat tajam hingga 53% pada 72 jam. Pada trajektori, *error* jauh lebih signifikan dengan MAE melonjak dari 77,97 km menjadi 582,67 km dan MAPE mencapai 208% pada *lead time* terpanjang, menandakan model ini cukup akurat untuk prediksi jangka pendek (12-24 jam) tetapi mengalami degradasi yang cukup besar pada horizon yang lebih panjang.

Tabel 3. Matriks evaluasi Att-BiGRU konfigurasi Giffard-Roisin (2020).

<i>Lead time</i>	Wind MAE (kt)	Wind RMSE (kt)	Wind MAPE (%)	Traj MAE (km)	Traj RMSE (km)	Traj MAPE (%)
12 Jam	9,30	12,76	14	100,59	114,00	11
24 Jam	13,40	18,96	18	262,81	313,67	35
48 Jam	20,60	26,81	30	605,85	784,31	127
72 Jam	20,06	25,78	46	871,11	1156,93	237

Konfigurasi Att-BiGRU Giffard-Roisin (2020) yang ditampilkan pada Tabel 3 menampilkan *error* yang lebih tinggi dibandingkan model Nketiah pada hampir semua metrik dan *lead time*. Prediksi angin menunjukkan MAE yang naik dari 9,30 kt (12 jam) hingga 20,60 kt (48 jam), dengan MAPE mencapai 46% pada 72 jam. Untuk trajektori, performanya paling lemah di antara ketiga model dengan MAE trajektori mencapai 871,11 km dan MAPE 237% pada 72 jam. Meski pola peningkatan *error* seiring *lead time* tetap

terlihat, konfigurasi ini cenderung kurang stabil terutama pada prediksi jangka menengah hingga panjang (48-72 jam).

Tabel 4. Matriks evaluasi Att-BiGRU konfigurasi Mulia (2025).

<i>Lead time</i>	Wind MAE (kt)	Wind RMSE (kt)	Wind MAPE (%)	Traj MAE (km)	Traj RMSE (km)	Traj MAPE (%)
12 Jam	8,29	12,08	12	92,40	109,74	10
24 Jam	12,03	18,16	16	248,19	293,66	33
48 Jam	20,18	25,79	31	584,71	764,69	122
72 Jam	20,47	25,26	50	841,93	1137,12	229


Tabel 4 model Att-BiGRU dengan konfigurasi Mulia (2025) menunjukkan performa yang cukup kompetitif, bahkan sedikit lebih baik daripada Giffard-Roisin pada sebagian besar metrik. *Error* angin relatif terkendali dengan MAE 8,29 kt pada 12 jam dan sekitar 20 kt pada 48-72 jam, serta MAPE yang mencapai 50% pada *lead time* terpanjang. Pada trajektori, model ini menghasilkan *error* yang lebih rendah dibandingkan Giffard-Roisin (MAE 841,93 km dan MAPE 229% pada 72 jam). Secara keseluruhan, konfigurasi ini memberikan keseimbangan yang baik antara akurasi angin dan trajektori, khususnya pada *lead time* pendek hingga menengah.

Secara keseluruhan, ketiga arsitektur menunjukkan pola degradasi performa yang konsisten seiring bertambahnya horizon prediksi, di mana *error* trajektori meningkat jauh lebih drastis dibandingkan *error* intensitas angin. Konfigurasi Att-BiLSTM Nketiah (2023) unggul pada *lead time* pendek, sementara Att-BiGRU Mulia (2025) menawarkan performa yang paling seimbang di berbagai horizon. Att-BiGRU Giffard-Roisin (2020) cenderung menjadi yang paling lemah, terutama pada prediksi trajektori jangka panjang. Hal ini mengindikasikan bahwa meskipun model berbasis attention dan bidirectional recurrent network mampu menangkap pola, tantangan utama tetap berada pada akurasi prediksi jangka panjang (48-72 jam) untuk trajektori badai.

4.2 Perbandingan Tiap Konfigurasi

Pada pembahasan ini disajikan perbandingan performa tiga konfigurasi model (Giffard-Roisin Att-BiGRU, Mulia Att-BiGRU, dan Nketiah Att-BiLSTM) berdasarkan jumlah (sum) metrik evaluasi MAE, RMSE, dan MAPE untuk prediksi angin dan trajektori pada *lead time* 12 jam dan 24 jam. Perbandingan ini memberikan gambaran komparatif keseluruhan performa model pada horizon prediksi jangka pendek.

Gambar 1. Perbandingan representatif model terbaik pada *lead time* 12 dan 24 jam untuk intensitas siklon




Pada Gambar 1 perbandingan intensitas siklon, konfigurasi Nketiah (Att-BiLSTM) menunjukkan performa terbaik dengan nilai sum yang paling rendah di hampir semua metrik. Secara detail, untuk *lead time* 12 jam, Nketiah memiliki Sum of Wind MAE sekitar 8, Sum of Wind RMSE sekitar 11, dan Sum of Wind MAPE sekitar 12%. Pada *lead time* 24 jam, nilainya naik menjadi Sum of Wind MAE sekitar 12 kt, Sum of Wind RMSE sekitar 19 kt, dan Sum of Wind MAPE sekitar 16%. Dibandingkan dengan model lain, Nketiah unggul secara konsisten, terutama pada metrik MAE dan RMSE.

Sementara itu, Giffard-Roisin (Att-BiGRU) mencatatkan *error* tertinggi dengan Sum of Wind MAE 12 jam sekitar 12 kt, RMSE sekitar 14 kt, MAPE sekitar 18% untuk 12 jam, dan nilai yang lebih tinggi lagi pada 24 jam. Mulia (Att-BiGRU) berada di tengah, dengan Sum of Wind MAE 12 jam sekitar 9 kt, RMSE sekitar 12 kt, MAPE sekitar 13%, serta pada 24 jam sekitar 12 kt untuk MAE, 18 kt untuk RMSE, dan 16% untuk MAPE. Dengan demikian terlihat bahwa konfigurasi Nketiah

paling unggul dalam akurasi prediksi intensitas angin jangka pendek.

Gambar 2. Perbandingan representatif model terbaik pada *lead time* 12 dan 24 jam untuk lintasan siklon



Pada Gambar 2 perbandingan lintasan siklon, Nketiah (Att-BiLSTM) kembali mendominasi dengan sum *error* trajektori yang paling rendah. Untuk *lead time* 12 jam, model ini mencatat Sum of Traj MAE sekitar 78 km, Sum of Traj RMSE sekitar 86 km, dan Sum of Traj MAPE sekitar 13%. Pada *lead time* 24 jam, nilainya meningkat menjadi Sum of Traj MAE sekitar 199 km, Sum of Traj RMSE sekitar 264 km, dan Sum of Traj MAPE sekitar 40%. Perbedaan dengan model lain sangat mencolok, terutama pada batang kuning (MAPE) dan oranye (RMSE) yang jauh lebih rendah.

Giffard-Roisin menunjukkan performa terlemah dengan Sum of Traj MAE 12 jam sekitar 101 km, RMSE sekitar 114 km, MAPE sekitar 11% untuk 12 jam, serta melonjak drastis pada 24 jam (MAE ~263, RMSE ~314, MAPE ~35). Mulia sedikit lebih baik dari Giffard-Roisin dengan Sum of Traj MAE 12 jam sekitar 92 km, RMSE sekitar 110 km, MAPE sekitar 10%, dan pada 24 jam MAE ~248 km, RMSE ~294 km, MAPE ~33%. Secara keseluruhan, Nketiah unggul jauh dalam memprediksi posisi trajektori.


Secara keseluruhan, kedua gambar memperkuat superioritas konfigurasi Att-BiLSTM Nketiah dibandingkan kedua model Att-BiGRU, baik pada prediksi angin maupun trajektori untuk *lead time* 12-24 jam. Nketiah secara konsisten menunjukkan angka sum metrik terendah, sementara Giffard-Roisin paling lemah dan Mulia berada di posisi menengah. Temuan ini selaras dengan analisis tabel sebelumnya dan merekomendasikan

Nketiah sebagai pilihan terbaik untuk prediksi badai jangka pendek.

4.3 Konvergensi dan Stabilitas Model

Bagian ini membahas konvergensi dan stabilitas ketiga model selama proses pelatihan, dilihat dari grafik *train loss* dan *validation loss* terhadap jumlah *epoch*. Grafik menunjukkan seberapa cepat model belajar dan apakah terjadi *overfitting* atau *underfitting*.


Gambar 3. Grafik *Training* dan *Loss Validation* Nketiah (2023)



Pada Gambar 3. Grafik Att-BiLSTM konfigurasi Nketiah (2023), terlihat konvergensi yang sangat cepat dan stabil. *Train Loss* mengalami penurunan drastis dari sekitar 600-650 pada epoch 0 menjadi mendekati nol hanya dalam 5 epoch pertama, kemudian terus stabil rendah hingga akhir pelatihan di epoch 30. *Validation Loss* juga menunjukkan pola yang sangat baik, mulai dari nilai rendah dan tetap stabil di kisaran 0-20 tanpa fluktuasi berarti sepanjang epoch, mencerminkan generalisasi model yang kuat.

Secara keseluruhan, grafik ini menunjukkan bahwa model Nketiah belajar dengan sangat efisien dan tidak mengalami *overfitting*. Kurva *Train* dan *Validation Loss* yang saling mendekat dan stabil sejak dini mengindikasikan arsitektur Att-BiLSTM dengan konfigurasi ini sangat cocok untuk tugas prediksi, dengan konvergensi yang cepat dan kestabilan tinggi selama pelatihan.


Gambar 4. Grafik *Training* dan *Loss Validation* Giffard-Roisin (2020)



Grafik Att-BiGRU konfigurasi Giffard-Roisin (2020) yang ditunjukkan oleh Gambar 4, menampilkan pola konvergensi yang baik meskipun membutuhkan sedikit lebih banyak epoch dibandingkan model Nketiah. *Train Loss* turun tajam dari lebih dari 1000 pada epoch awal menjadi mendekati nol sekitar epoch 5-10, dan kemudian tetap stabil hingga akhir pelatihan di epoch 70. *Validation Loss* juga rendah dan stabil sejak awal, menandakan proses pelatihan yang lancar tanpa gejala *overfitting* yang signifikan.

Meski skala loss awal sedikit lebih tinggi, model ini tetap menunjukkan kestabilan yang baik sepanjang pelatihan. Kurva yang mulus dan konvergen cepat setelah epoch awal mengonfirmasi bahwa konfigurasi Giffard-Roisin mampu menangani kompleksitas data dengan baik, walaupun memerlukan waktu pelatihan yang lebih panjang untuk mencapai kestabilan optimal.

Gambar 5. Grafik *Training* dan *Loss Validation* Mulia (2025)



Pada grafik Att-BiGRU konfigurasi Mulia (2025) di Gambar 5, konvergensi terjadi dengan sangat cepat meskipun nilai *loss* awal cukup tinggi. *Train Loss* turun dramatis dari lebih dari 4500-5000 pada epoch pertama menjadi mendekati nol pada sekitar epoch 5, sementara *validation loss* mulai dari kisaran 600-700 lalu cepat turun dan stabil rendah hingga epoch 40. Pola penurunan yang tajam ini menunjukkan konvergensi yang sangat cepat.

menunjukkan kemampuan model dalam menyerap pola data dengan efisien.


Selain itu, kedekatan antara *train loss* dan *validation loss* setelah epoch awal mengindikasikan tidak adanya *overfitting* yang jelas. Model Mulia menunjukkan kestabilan yang tinggi setelah fase inisial, meski skala loss awalnya lebih besar dibandingkan kedua model lain, sehingga tetap menjadi pilihan yang solid dalam hal konvergensi dan generalisasi.

Secara keseluruhan, ketiga model menunjukkan konvergensi yang cepat dan kestabilan yang baik selama pelatihan, dengan *train* dan *validation loss* yang turun tajam dan stabil setelah epoch awal tanpa indikasi *overfitting* yang berarti. Model Nketiah memiliki konvergensi paling efisien dengan loss awal terendah, sementara Mulia dan Giffard-Roisin juga stabil meski dengan skala loss awal yang berbeda.

4.4 Studi Kasus: Koto dan Fung-Wong 3

Bagian ini menyajikan studi kasus pada dua siklon tropis representatif menggunakan konfigurasi terbaik (Att-BiLSTM Nketiah 2023).

Gambar 6. Prediksi Trajektori Siklon Koto dengan Konfigurasi Nketiah (2023)




Siklon Koto memiliki karakteristik pergerakan yang relatif lambat dengan pola rekurvatif yang berlangsung secara bertahap ke arah utara hingga barat. Kondisi ini menjadi keuntungan bagi model prediksi karena pola pergerakannya cenderung konsisten dan masih dapat direpresentasikan dengan baik oleh

informasi historis pada data pelatihan. Dalam kemampuan prediksi lintasan, model Att-BiGRU mampu menghasilkan positional *error* sekitar 79 km, dengan performa yang lebih kompetitif dibandingkan model GRU standar yang mencatat *error* sekitar 73 km.

Pada prediksi intensitas, Att-BiLSTM menunjukkan performa terbaik dengan menghasilkan akumulasi kecepatan angin sebesar 842,91 knot, sangat dekat dengan nilai aktual sebesar 841 knot. Selisih yang hanya mencapai 1,91 knot atau sekitar 0,23% menjadikannya sebagai tingkat akurasi tertinggi yang diperoleh dalam keseluruhan analisis intensitas. Keunggulan Att-BiLSTM pada prediksi intensitas mengindikasikan bahwa penerapan mekanisme attention memberikan kontribusi dalam menangkap dinamika perubahan intensitas dibandingkan dalam meningkatkan akurasi prediksi lintasan.

Gambar 7. Prediksi Trajektori Siklon Fung-Wong 3 dengan Konfigurasi Nketiah (2023)



Siklon Fung-Wong 3 menunjukkan karakteristik pergerakan yang relatif cepat ke arah barat-barat daya dengan pergeseran posisi longitudinal sekitar $6,6^\circ$ selama delapan periode prakiraan. Berdasarkan hasil evaluasi, seluruh model mengalami kesulitan dalam merepresentasikan pola pergerakan tersebut, yang ditunjukkan oleh kecenderungan prediksi berada terlalu ke arah timur dibandingkan lintasan observasi. Kondisi ini menghasilkan longitude bias lebih dari 4° serta positional

error rata-rata pada rentang 455–510 km. Di antara seluruh model yang diuji, Att-BiLSTM memberikan performa terbaik dengan *positional error* sekitar 455 km, meskipun tingkat kesalahan tersebut masih tergolong tinggi. Pada aspek intensitas, seluruh model juga menunjukkan kecenderungan overestimasi dengan selisih sekitar 34–41 knot terhadap nilai observasi.

Rendahnya akurasi prediksi pada kasus ini mengindikasikan adanya keterbatasan representasi informasi yang digunakan model. Variabel masukan yang tersedia belum mampu menggambarkan secara eksplisit pengaruh *steering flow* skala besar yang berperan penting dalam mengendalikan arah pergerakan siklon, seperti penguatan subtropical ridge. Selain itu, pola translasi zonal yang cepat seperti yang terjadi pada Fung-Wong 3 diduga memiliki proporsi yang relatif kecil dalam distribusi data pelatihan sehingga kemampuan model untuk mengenali karakteristik tersebut menjadi terbatas. Hasil ini terlihat jelas pada Att-BiGRU yang tetap menghasilkan penyimpangan lintasan yang cukup besar meskipun telah memanfaatkan mekanisme *attention*. Temuan tersebut menunjukkan bahwa *attention* tidak mampu memberikan peningkatan yang signifikan ketika informasi penting yang diperlukan untuk menjelaskan dinamika pergerakan siklon tidak tersedia dalam fitur masukan model.

Kontras antara kedua kasus tersebut menunjukkan bahwa efektivitas mekanisme *attention* sangat bergantung pada kualitas dan representativitas informasi yang tersedia pada data masukan. Peningkatan kinerja paling nyata diperoleh ketika pola temporal yang dipelajari bersifat konsisten, berkembang secara gradual, dan memiliki representasi yang memadai dalam data pelatihan. Sebaliknya, pada kasus dengan pergerakan cepat yang dipengaruhi faktor lingkungan berskala besar yang tidak tercakup dalam *feature space*, kontribusi *attention* menjadi terbatas sehingga hanya menghasilkan perbaikan kinerja yang marginal.

5. KESIMPULAN

Penelitian ini berhasil mengevaluasi kontribusi mekanisme *attention* pada arsitektur Bidirectional LSTM dan GRU untuk prediksi intensitas dan trajektori siklon tropis di Pasifik Barat. Hasil evaluasi menunjukkan bahwa integrasi *attention* secara konsisten meningkatkan akurasi prediksi intensitas di seluruh konfigurasi hyperparameter yang diuji (Nketiah, Giffard-Roisin, dan Mulia). Model Att-BiLSTM dengan konfigurasi Nketiah (2023) terbukti memberikan performa terbaik secara keseluruhan pada *lead time* 12 jam, dengan Wind MAE sebesar 7,78 knot dan Trajectory MAE 77,97 km, yang merepresentasikan peningkatan akurasi 22–27% dibandingkan model tanpa *attention* pada konfigurasi yang sama.

Secara arsitektural, Att-BiLSTM dan Att-BiGRU menunjukkan karakteristik yang saling melengkapi: Att-BiLSTM unggul dalam menjaga keseimbangan akurasi intensitas dan posisi, sementara Att-BiGRU menawarkan efisiensi komputasi yang lebih tinggi dengan performa yang tetap kompetitif. Penelitian ini juga mengungkap bahwa pertumbuhan *error* bersifat asimetris, di mana *error* intensitas (7,78–14,10 knot) jauh lebih terkendali dibandingkan *error* trajektori yang melonjak drastis hingga 582,67 km pada *lead time* 72 jam. Berdasarkan nilai MAPE, model ini memiliki reliabilitas operasional tertinggi pada horizon 12–24 jam (MAPE intensitas 11–16% dan trajektori 13–40%), sehingga sangat layak diintegrasikan ke dalam sistem peringatan dini.

Meskipun mekanisme *attention* memberikan dampak signifikan pada siklon dengan pergerakan gradual, seperti pada kasus Siklon Koto dengan *error* intensitas minimal +1,91 knot. Kemampuan ini masih terbatas pada siklon dengan translasi zonal cepat seperti Siklon Fung-Wong 3. Hal ini mengindikasikan bahwa ruang fitur saat ini belum sepenuhnya mampu merepresentasikan pengaruh *steering flow* skala besar secara eksplisit. Sebagai penutup, penelitian ini menegaskan bahwa integrasi mekanisme *attention* merupakan pendekatan yang efektif untuk meningkatkan keandalan prediksi intensitas siklon tropis pada skala operasional di wilayah Pasifik Barat.

DAFTAR PUSTAKA

- [1] D. Bahdanau, K. Cho, and Y. Bengio, "Neural machine translation by jointly learning to align and translate," arXiv preprint arXiv:1409.0473, 2016.
- [2] J. Brownlee, *Long Short-Term Memory Networks With Python*. Melbourne, Australia: Machine Learning Mastery, 2017.
- [3] K. Cho, B. van Merriënboer, D. Bahdanau, and Y. Bengio, "On the properties of neural machine translation: Encoder-decoder approaches," arXiv preprint arXiv:1409.1259, 2014.
- [4] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical evaluation of gated recurrent neural networks on sequence modeling," arXiv preprint arXiv:1412.3555, 2014.
- [5] R. L. Elsberry, "Advances in research and forecasting of tropical cyclones from 1963–2013," *Asia-Pacific Journal of Atmospheric Sciences*, vol. 50, no. 1, pp. 3–16, 2014, doi: 10.1007/s13143-014-0013-y.
- [6] K. Emanuel, "100 years of progress in tropical cyclone research," *Meteorological Monographs*, vol. 59, pp. 15.1–15.68, 2018, doi: 10.1175/AMSMONOGRAPHS-D-18-0016.1.
- [7] S. Giffard-Roisin, M. Yang, G. Charpiat, C. Kumler Bonfanti, B. Kégl, and C. Monteleoni, "Tropical cyclone track forecasting using fused deep learning from aligned reanalysis data," *Frontiers in Big Data*, vol. 3, 2020, doi: 10.3389/fdata.2020.00001.
- [8] S. M. Griffin, A. Wimmers, and C. S. Velden, "Predicting rapid intensification in North Atlantic and Eastern North Pacific tropical cyclones using a convolutional neural network," *Weather and Forecasting*, vol. 37, no. 8, pp. 1333–1355, 2022, doi: 10.1175/WAF-D-21-0201.1.
- [9] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [10] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," *Geoscientific Model Development*, vol. 15, no. 14, pp. 5481–5487, 2022, doi: 10.5194/gmd-15-5481-2022.
- [11] H. Huang, D. Deng, L. Hu, Y. Chen, and N. Sun, "Beyond the backbone: A quantitative review of deep-learning architectures for tropical cyclone track forecasting," *Remote Sensing*, vol. 17, no. 15, 2025, doi: 10.3390/rs17152620.
- [12] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, pp. 620–627, Aug. 2023, doi: 10.23960/jitet.v11i3.3250.
- [13] T. Knutson, J. Camargo, J. C. L. Chan, K. Emanuel, C.-H. Ho, J. Kossin, K. Walsh, and L. Wu, "Tropical cyclones and climate change assessment Part I: Detection and attribution," *Bulletin of the American Meteorological Society*, vol. 100, no. 10, pp. 1987–2007, 2019, doi: 10.1175/BAMS-D-18-0189.1.
- [14] J. S. Kumar, V. Venkataraman, S. Meganathan, and K. Krithivasan, "Tropical cyclone intensity and track prediction in the Bay of Bengal using LSTM-CSO method," *IEEE Access*, vol. 11, pp. 81613–81622, 2023, doi: 10.1109/ACCESS.2023.3298997.
- [15] I. E. Mulia, U. Shimada, N. Ueda, T. Miyoshi, and M. T. Maulana, "Multi-horizon prediction of tropical cyclone intensity and its interpretability with temporal fusion transformer," *Scientific Reports*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-87000-7.
- [16] E. Mulyana, M. B. R. Prayoga, A. Yananto, S. Wirahma, E. Aldrian, B. Harsoyo, T. H. Seto, and Y. Sunarya, "Tropical cyclones characteristic in southern Indonesia and the impact on extreme rainfall event," *MATEC Web of Conferences*. Les Ulis, France: EDP Sciences, 2018.
- [17] B. S. Naik, V. C. Karthik, B. Manjunatha, G. H. Veershetty, B. S. Varshini, and S. G. Rao, "Stock price forecasting using N-Beats deep learning architecture," *Journal of Scientific Research and Reports*, vol. 30, no. 9, pp. 483–494, 2024.
- [18] E. A. Nketiah, L. Chenlong, J. Yingchuan, and S. A. Aram, "Recurrent neural network modeling of multivariate time series and its application in temperature forecasting," *PLoS ONE*, vol. 18, no. 5, 2023, doi: 10.1371/journal.pone.0281828.
- [19] S. Rahman, M. F. Faisal, P. Mondal, and M. M. Rahman, "Tropical cyclone track prediction harnessing deep learning algorithms: A comparative study on the Northern Indian Ocean," *Results in Engineering*, vol. 26, 2025, doi: 10.1016/j.rineng.2025.104491.
- [20] M. Schuster and K. K. Paliwal, "Bidirectional recurrent neural networks," *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997, doi: 10.1109/78.650093.
- [21] T. Song, Y. Li, F. Meng, P. Xie, and D. Xu, "A novel deep learning model by BiGRU with attention mechanism for tropical cyclone track prediction in the Northwest Pacific," *Journal of Applied Meteorology and Climatology*, vol. 61, no. 1, pp. 3–12, 2022, doi: 10.1175/JAMC-D-21-0020.1.

- [22] L. Wang, B. Wan, S. Zhou, H. Sun, and Z. Gao, "Forecasting tropical cyclone tracks in the northwestern Pacific based on a deep-learning model," *Geoscientific Model Development*, vol. 16, no. 8, pp. 2167–2179, 2023, doi: 10.5194/gmd-16-2167-2023.
- [23] World Meteorological Organization, *Glossary. Tropical Cyclone Programme*. Geneva, Switzerland: WMO, 2017. [Online]. Available: <https://cyclone.wmo.int/pdf/Glossary.pdf>
- [24] D.-L. Zhang and H. Chen, "Importance of the upper-level warm core in the rapid intensification of a tropical cyclone," *Geophysical Research Letters*, vol. 39, no. 2, 2012, doi: 10.1029/2011GL050578.
- [25] F. Chollet, *Deep Learning with Python*, 2nd ed. Shelter Island, NY, USA: Manning Publications, 2021.
- [26] Z. C. Lipton, J. Berkowitz, and C. Elkan, "A critical review of recurrent neural networks for sequence learning," *arXiv preprint arXiv:1506.00019*, 2015.