

Nowcasting Trajektori dan Intensitas Siklon Tropis Seroja Menggunakan Temporal Convolutional Network

Pertiwi Risky Setyowati¹, Yosafat Donni Haryanto^{1*}, Adi Mulsandi¹, Latifah Nurul Qomariyatuazzamzami¹

¹Program Studi Meteorologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Kota Tangerang, Banten, Indonesia 15119

Info Artikel

Histori Artikel:

Diajukan: 3 Maret 2026

Direvisi: 10 Agustus 2026

Diterima: 30 September 2026

Kata kunci:

Deep Learning

Prediksi

Siklon Tropis

TCN

ABSTRAK

Siklon tropis dapat berkembang dengan cepat sehingga prediksi jangka pendek mengenai jalur dan intensitasnya diperlukan untuk mendukung kegiatan peringatan dini. Penelitian ini mengevaluasi kinerja *Temporal Convolutional Network* (TCN) dalam memprediksi jalur dan intensitas Siklon Tropis Seroja pada *lead time* 6, 12, 18, dan 24 jam. Data yang digunakan berupa *best-track* siklon tropis dari Bureau of Meteorology (BoM) Australia periode 1973–2026 yang mencakup *longitude*, *latitude*, tekanan pusat, dan kecepatan angin. Model dilatih menggunakan pendekatan *sliding window*, kemudian diuji secara terpisah pada Siklon Tropis Seroja. Kinerja model dievaluasi menggunakan *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). Hasil menunjukkan bahwa TCN memiliki kinerja lebih baik pada prediksi lintasan dibandingkan intensitas. RMSE *longitude* berkisar antara 1,60–4,12°, sedangkan RMSE *latitude* berkisar antara 0,32–1,79°. Pada *lead time* 24 jam, nilai R^2 *latitude* dan *longitude* masing-masing sebesar 0,919 dan 0,383 yang menunjukkan bahwa model masih dapat mengikuti pola umum pergerakan siklon meskipun akurasi arah lintasan menurun. Sebaliknya, RMSE tekanan pusat meningkat dari 3,95 menjadi 9,01 hPa dan RMSE kecepatan angin dari 2,73 menjadi 6,26 m/s, dengan MAPE kecepatan angin mencapai 20,58%. Nilai R^2 tekanan pusat dan kecepatan angin menjadi negatif pada *lead time* 24 jam, masing-masing sebesar -0,132 dan -0,365 yang menunjukkan keterbatasan model dalam menangkap perubahan intensitas. Temuan ini menunjukkan potensi TCN untuk prediksi jangka pendek lintasan siklon, tetapi pengembangan lebih lanjut masih diperlukan untuk meningkatkan akurasi prediksi intensitas.

Keywords:

Deep Learning

Prediction

TCN

Tropical Cyclone

Penulis Korespondensi:

Yosafat Donni Haryanto

Email: yosafat.haryanto@stmkg.ac.id

Tropical cyclones can intensify rapidly, making short-term prediction of their track and intensity essential for supporting early warning systems. This study evaluates the performance of a Temporal Convolutional Network (TCN) in predicting the track and intensity of Tropical Cyclone Seroja at lead times of 6, 12, 18, and 24 hours. The data used consist of tropical cyclone best-track records from the Bureau of Meteorology (BoM) Australia for the period 1973–2026, encompassing longitude, latitude, central pressure, and wind speed. The model was trained using a sliding window approach and subsequently tested independently on Tropical Cyclone Seroja. Model performance was evaluated using Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and the coefficient of determination (R^2). The results indicate that TCN performed better in predicting track than intensity. The RMSE for longitude ranged from 1.60–4.12°, while the RMSE for latitude ranged from 0.32–1.79°. At a 24-hour lead time, the R^2 values for latitude and longitude were 0.919 and 0.383, respectively, indicating that the model was still able to follow the general pattern of cyclone movement, although its directional accuracy declined. In contrast, the RMSE for central pressure increased from 3.95 to 9.01 hPa, and the RMSE for wind speed increased from 2.73 to 6.26 m/s, with the MAPE for wind speed reaching 20.58%. The R^2 values for central pressure and wind speed turned negative at the 24-hour lead time, at -0.132 and -0.365, respectively, reflecting the model's limitations in capturing intensity changes. These findings demonstrate the potential of TCN for short-term cyclone track prediction, although further development is still required to improve the accuracy of intensity prediction.

I. PENDAHULUAN

Siklon tropis merupakan sistem tekanan rendah yang terbentuk di atas lautan hangat bersuhu di atas 26,5°C dengan kecepatan angin maksimum melebihi 34 knot dan radius sistem sekitar 150–200 km akibat interaksi panas laten hasil penguapan laut, kelembapan atmosfer, serta dinamika troposfer yang mendukung pembentukan sirkulasi siklonal (Mulyana et al., 2018). Indonesia yang terletak di kawasan ekuatorial maritim tropis memiliki kerentanan tinggi terhadap dampak siklon tropis khususnya sistem yang tumbuh di perairan selatan Indonesia. Tercatat 51 siklon tropis terbentuk di wilayah tersebut sepanjang 1983–2017 dengan karakteristik tekanan pusat relatif tinggi dibandingkan wilayah lain (Mulyana et al., 2018).

Salah satu kejadian yang menegaskan urgensi tersebut adalah Siklon Tropis Seroja yang tumbuh di Laut Sawu, Nusa Tenggara Timur (NTT), pada awal April 2021. Pembentukan Seroja dipicu oleh interaksi gelombang ekuatorial Rossby dan gelombang konvektif Kelvin yang menciptakan kondisi atmosfer sangat kondusif bagi siklogenesis. Fenomena yang tergolong langka karena pusat pertumbuhannya berada sangat dekat garis ekuator (Latos et al., 2023). Selama fase aktifnya, Seroja menimbulkan hujan ekstrem di berbagai kabupaten NTT serta peningkatan tinggi gelombang laut di Samudra Hindia bagian selatan NTT dari sekitar 4 meter menjadi lebih dari 7 meter dalam rentang beberapa hari (Kurniawan et al., 2021). Dampak Seroja tergolong luar biasa besar, memicu banjir bandang dan tanah longsor yang meluas hingga 21 dari 22 kabupaten/kota di NTT, dengan Badan Nasional Penanggulangan Bencana melaporkan 184 korban jiwa, sebagian besar terjadi di Kabupaten Flores Timur dan Lembata (Setiawan et al., 2025).

Skala kerusakan ini menunjukkan bahwa wilayah kepulauan dengan populasi padat di kawasan pesisir maupun pegunungan seperti NTT sangat rentan terhadap siklon tropis yang berkembang dekat garis pantai (Latos et al., 2023). Selain itu, *lead time* antara deteksi awal hingga puncak dampak sering kali hanya berkisar beberapa hari, bahkan beberapa jam pada fase intensifikasi tercepatnya. Kondisi ini menegaskan bahwa Indonesia memerlukan sistem prediksi jangka sangat pendek yang mampu memperbarui estimasi jalur dan intensitas siklon secara cepat dan akurat untuk memberi waktu respons yang memadai bagi otoritas kebencanaan maupun masyarakat terdampak (Latos et al., 2023).


Metode Dvorak masih mengandung unsur subjektivitas karena bergantung pada interpretasi visual citra satelit oleh analis Knaff et al. (2010), sedangkan *Advanced Dvorak Technique* (ADT) dikembangkan untuk mengurangi subjektivitas tersebut melalui pendekatan semi-otomatis, namun tetap kurang adaptif terhadap perubahan intensitas yang berlangsung cepat (Olander & Velden, 2019). Model Prakiraan Cuaca Numerik (NWP) bersifat lebih objektif tetapi membutuhkan sumber daya komputasi besar sehingga pembaruan prediksi tidak dapat dilakukan secepat yang dibutuhkan pada kondisi *rapid intensification* (Pu et al., 2025). Perkembangan *deep learning* membuka peluang baru melalui model berbasis rekuren seperti RNN, LSTM, dan GRU (Alemany et al., 2019; Wang et al., 2023; Yuan et al., 2021), namun ketiganya tetap memproses data secara sekuensial sehingga kurang efisien untuk kebutuhan prediksi jangka pendek berbasis data beresolusi temporal tinggi (Safwan Mahmood Al-Selwi et al., 2023). *Temporal Convolutional Network* (TCN) menawarkan solusi atas keterbatasan tersebut melalui mekanisme dilated causal convolution yang memungkinkan pemrosesan data secara paralel dan lebih stabil dalam menangkap perubahan intensitas siklon yang cepat dan nonlinier (Gan et al., 2024). Bertolak dari besarnya dampak Siklon Seroja serta kebutuhan terhadap prediksi jangka pendek, penelitian ini menerapkan TCN untuk mengevaluasi kinerjanya dalam memprediksi lintasan dan intensitas Siklon Tropis Seroja pada *lead time* 6–24 jam. Hasil penelitian diharapkan dapat memberikan informasi awal mengenai potensi dan keterbatasan TCN dalam mendukung pengembangan prediksi jangka pendek siklon tropis di Indonesia.

II. METODE

2.1 Lokasi Penelitian

Wilayah kajian penelitian ini mengacu pada batas operasional Regional Association V (RA V) WMO yaitu 0°–40° LS dan 90°–160° BT, yang mencakup perairan selatan Indonesia terutama Samudra Hindia bagian selatan di bawah kewenangan *Tropical Cyclone Warning Centre* (TCWC) Jakarta dengan dua zona tanggung jawab yaitu *Area of Responsibility* (AoR: 0°–10° LS/90°–118° BT, 0°–11° LS/118°–

125° BT, dan 0°–9° LS/125°–141° BT) dan Area of Monitoring (AoM: 0°–20° LS dan 90°–141° BT). Kasus uji penelitian ini yaitu Siklon Tropis Seroja yang tumbuh di Laut Sawu, bagian selatan Nusa Tenggara Timur yang dapat dilihat pada Gambar 1.



Gambar 1 Lokasi penelitian

2.2 Data Penelitian

Penelitian ini menggunakan data rekam jejak historis *best-track* siklon tropis dari basis data resmi *Bureau of Meteorology* (BOM) Australia mencakup periode Siklon Tropis Jean (1973) hingga Siklon Tropis Iggy (2026), yang diunduh dalam format .csv dan memuat empat variabel yang dicatat setiap enam jam sehingga layak digunakan sebagai basis pelatihan dan evaluasi model TCN sebagaimana dirangkum pada Tabel 1.

Tabel 1 Data penelitian

Data Siklon	Parameter	Satuan
Siklon Tropis Jean (1973) hingga	<i>Longitude</i>	Derajat
	<i>Latitude</i>	Derajat
Siklon Tropis Iggy (2026)	Tekanan Pusat Siklon	Milibar
	Kecepatan Angin	Knot

2.3 Preprocessing dan Processing

Data mentah terlebih dahulu melalui tahap *quality control* (verifikasi format, penghapusan duplikat, identifikasi nilai hilang, dan penyaringan data anomali atau di luar batas AoM/AoR), kemudian nilai yang masih kosong dilengkapi melalui interpolasi linier pada Persamaan (1), dan seluruh variabel dinormalisasi menggunakan *Min-Max Scaling* ke rentang -1 hingga 1 pada Persamaan (2) untuk menyetarakan skala antarvariabel sekaligus menjaga kestabilan pelatihan. *Dataset* selanjutnya dibagi menjadi data latih (465 siklon tropis periode 1973–2022, 90%), data validasi (50 siklon tropis periode 2022–2026, 10%). Penerapan skema *sliding window* pada data latih dan data validasi menghasilkan masing-masing sebanyak 10579 *training sequences* dan 1161 *validation sequences*. Adapun data uji berupa Siklon Tropis Seroja yang secara keseluruhan terpisah dari proses pelatihan dan validasi model menghasilkan sebanyak 32 sekuens melalui skema *sliding window* digunakan sebagai masukan model untuk prediksi pada *lead time* 6, 12, 18, dan 24 jam ke depan. Pelatihan model TCN diorganisasikan melalui pendekatan *sliding window* dengan empat langkah masukan dan empat langkah keluaran (setara 24 jam) di mana kinerja model dipantau menggunakan data validasi, bobot dengan *loss* terendah disimpan sebagai bobot terbaik dan pelatihan dihentikan otomatis melalui *early stopping* apabila performa tidak lagi membaik. Model terbaik tersebut kemudian diujikan terhadap Siklon Tropis Seroja sehingga hasil prediksi jalur dan intensitas pada setiap *lead time* dapat dibandingkan langsung dengan data observasi *best-track* BOM Australia.

$$\frac{y - y_0}{x - x_0} = \frac{y_1 - y_0}{x_1 - x_0} \quad (1)$$


$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

2.4 Temporal Convolutional Network (TCN)

Temporal Convolutional Network (TCN) merupakan arsitektur *deep learning* untuk pemodelan deret waktu yang mengandalkan *dilated causal convolution* agar mampu mempelajari hubungan temporal jangka panjang tanpa penambahan parameter berlebihan (Bai et al., 2018). Sifat kausal konvolusi ini memastikan keluaran pada waktu (t) hanya ditentukan oleh data pada waktu tersebut dan sebelumnya pada Persamaan (3), dengan $F(t)$ sebagai hasil konvolusi, f sebagai kernel, k sebagai ukuran kernel, dan d sebagai faktor dilasi. Guna menjaga kestabilan pelatihan dan meminimalkan *vanishing gradient*, arsitektur ini dilengkapi koneksi residual yang menghubungkan masukan asli dengan hasil transformasi konvolusi pada Persamaan (4), fungsi aktivasi ReLU, dengan setiap blok residual umumnya tersusun atas dua lapisan *dilated causal convolution*, normalisasi bobot, aktivasi ReLU, dan *dropout*, sebagaimana konfigurasi arsitektur TCN pada penelitian ini disajikan pada Gambar 2.

$$F(t) = (t * f)(t) = \sum_{i=0}^{k-1} f(i) \cdot x_t - d \cdot i \quad (3)$$

$$o = \text{Activation}(x + F(x)) \quad (4)$$



Gambar 2 Arsitektur TCN

2.5 Evaluasi

Kinerja model TCN dievaluasi menggunakan tiga metrik statistik, yaitu *Root Mean Square Error* (RMSE) yang dihitung dari akar rata-rata kuadrat selisih prediksi dan observasi Persamaan (5) dan peka terhadap kesalahan bernilai besar. *Mean Absolute Percentage Error* (MAPE) yang mengukur rata-rata persentase kesalahan ternormalisasi terhadap nilai observasi Persamaan (6), tidak berdimensi sehingga memudahkan perbandingan antarvariabel dengan satuan berbeda di mana nilai yang rendah menunjukkan model lebih stabil (Gan et al., 2024) serta koefisien determinasi (R^2) yang menggambarkan proporsi variasi data observasi yang mampu dijelaskan model melalui perbandingan jumlah kuadrat residu terhadap jumlah kuadrat total deviasi observasi Persamaan (7), dengan nilai mendekati 1 menunjukkan model mampu mengikuti dinamika perubahan siklon dengan sangat baik (Gan et al., 2024).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (5)$$


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

III. HASIL DAN DISKUSI

3.1 Evaluasi Model TCN

Berdasarkan Gambar 3, visualisasi hasil evaluasi model TCN untuk prediksi Siklon Tropis Seroja dengan tiga evaluasi yakni RMSE, MAPE, dan R^2 . Pada RMSE, terdapat pola peningkatan error yang konsisten seiring bertambahnya waktu prediksi (*lead time*) dengan tekanan pusat mengalami peningkatan paling tajam (3,95 hingga 9,01 hPa), diikuti kecepatan angin (2,73 hingga 6,26 m/s), sementara *longitude* dan *latitude* menunjukkan peningkatan yang lebih landai dibandingkan kedua parameter sebelumnya (1,60 hingga 4,12 dan 0,32 hingga 1,79). Hasil MAPE pada parameter kecepatan angin menunjukkan tingkat kesalahan relatif lebih tinggi (8,47% menjadi 20,58%), sedangkan tekanan pusat memiliki MAPE terendah di seluruh *lead time* (0,26% hingga 0,60%) meskipun RMSE absolutnya besar, yang mengindikasikan bahwa magnitudo nilai tekanan pusat yang tinggi membuat kesalahan absolut tersebut secara proporsional kecil. Evaluasi koefisien determinasi (R^2) menunjukkan pola yang sejalan, di mana *latitude* tetap mempertahankan nilai yang tinggi hingga *lead time* 24 jam (0,995 menjadi 0,919), sedangkan *longitude* meskipun masih bernilai positif mengalami penurunan yang cukup tajam (0,922 menjadi 0,383). Sementara itu, kecepatan angin dan tekanan pusat menurun jauh lebih tajam hingga bernilai negatif pada *lead time* 18–24 jam (kecepatan angin dari 0,705 menjadi -0,365, dan tekanan pusat dari 0,751 menjadi -0,132), yang menunjukkan performa model pada parameter intensitas menjadi lebih buruk dibandingkan sekadar memprediksi nilai rata-rata (*baseline mean*). Nilai R^2 negatif mengindikasikan bahwa model belum mampu mengikuti perubahan temporal tekanan pusat dan kecepatan angin secara memadai terutama pada *lead time* yang lebih panjang. Hal tersebut dapat dipengaruhi oleh keterbatasan jumlah sampel pengujian, kecenderungan model menghasilkan prediksi yang lebih halus, keterlambatan dalam menangkap fase intensifikasi dan pelemahan, serta kompleksitas dinamika intensitas Siklon Seroja. Interaksi Siklon Seroja dan Siklon Tropis Odette melalui efek Fujiwhara dapat dipertimbangkan sebagai salah satu konteks meteorologis yang berpotensi meningkatkan kompleksitas dinamika siklon. Namun, berdasarkan evaluasi model yang dilakukan dalam penelitian ini, kontribusi interaksi tersebut terhadap kesalahan prediksi belum dapat dibuktikan secara langsung (Trenngono et al., 2024).



Gambar 3 Evaluasi prediksi intensitas dan lintasan Siklon Tropis Seroja menggunakan (a) RMSE, (b) MAPE, dan (c) R^2


Pola relatif performa TCN pada penelitian ini turut didukung oleh temuan pada Gan et al. (2024) di mana model TCN pada penelitian tersebut juga menunjukkan tingkat kesalahan yang jauh lebih rendah pada parameter lintasan dibandingkan intensitas, tercermin dari MAPE latitude dan longitude yang hanya 1,21% dan 0,30% dibandingkan MAPE kecepatan angin sebesar 5,36% pada skenario dasar ($N_{in}=6$, $N_{out}=1$, $\Delta T=6$ jam), serta R^2 latitude dan longitude yang sangat tinggi (0,9987 dan 0,9978).

Kesesuaian arah pola ini juga teramati pada penelitian ini di mana R^2 *latitude* dan *longitude* tetap terjaga tinggi (0,995 dan 0,922 pada *lead time* 6 jam) sementara R^2 kecepatan angin dan tekanan pusat jauh lebih rendah (0,705 dan 0,751 pada *lead time* yang sama). Perbedaan performa antara *latitude* dan *longitude* dapat dikaitkan dengan karakteristik pergerakan Siklon Seroja. Nilai R^2 *latitude* tetap tinggi hingga 0,919 pada *lead time* 24 jam karena pergerakan siklon ke arah selatan berlangsung relatif konsisten sehingga pola temporalnya lebih mudah dipelajari oleh TCN. Namun, peningkatan RMSE *latitude* dari 0,32 menjadi 1,79 derajat menunjukkan bahwa nilai R^2 yang tinggi tidak selalu berarti kesalahan posisi absolutnya kecil.

Sementara itu, R^2 *longitude* menurun tajam menjadi 0,383 pada *lead time* 24 jam. Model masih mampu mengikuti arah umum pergerakan Seroja ke barat daya, tetapi kurang akurat dalam menangkap perubahan arah, kelengkungan lintasan, dan besarnya pergeseran zonal pada fase lanjut. Akumulasi kesalahan tersebut menyebabkan deviasi *longitude* semakin besar seiring bertambahnya *lead time*, terlihat dari peningkatan RMSE *longitude* dari 1,60 menjadi 4,12 derajat. Secara umum, performa prediksi lintasan yang lebih baik diduga berkaitan dengan kontinuitas temporal pada perubahan *longitude* dan *latitude*. Sebaliknya, perubahan tekanan pusat dan kecepatan angin bersifat lebih kompleks karena turut dipengaruhi oleh kondisi atmosfer dan laut, seperti suhu permukaan laut, kelembapan atmosfer, vertical wind shear, serta proses konvektif dan struktur inti siklon (Chen et al., 2023; Gray, 1977; Houze, 2010). Variabel-variabel tersebut belum digunakan sebagai masukan model dalam penelitian ini sehingga diduga membatasi kemampuan TCN dalam menangkap perubahan intensitas Siklon Seroja. Pada studi kasus ini, model TCN lebih mampu mengikuti perubahan lintasan dibandingkan perubahan intensitas siklon. Temuan tersebut sejalan dengan Gan et al. (2024) yang juga melaporkan bahwa performa TCN pada parameter lintasan lebih baik daripada parameter intensitas. Meskipun terdapat perbedaan tingkat akurasi yang diduga dipengaruhi oleh keterbatasan jumlah sampel dan kompleksitas dinamika Siklon Seroja, pola performa yang dihasilkan menunjukkan kecenderungan yang serupa dengan penelitian yang telah dilakukan Gan et al. (2024). Namun, hasil penelitian ini belum dapat dijadikan dasar untuk menyatakan bahwa TCN lebih unggul daripada metode atau arsitektur lainnya karena tidak dilakukan pengujian secara langsung menggunakan model pembandingan.

3.2 Visualisasi Prediksi Trajektori dan Intensitas Siklon Tropis Seroja

Visualisasi trajektori Siklon Tropis Seroja pada Gambar 4 menunjukkan lintasan yang bergerak dari wilayah utara dekat Nusa Tenggara Timur ke arah barat daya hingga mendekati perairan selatan Australia Barat. Intensitas siklon meningkat secara bertahap dari kategori *Tropical Low* menjadi Kategori 1–2 di bagian tengah lintasan, kemudian mencapai puncak pada Kategori 3 di sekitar 25°S–30°S, sebelum akhirnya melemah menjelang akhir siklus hidupnya. Garis lintasan hasil prediksi (biru) masih mengikuti arah garis observasi (merah) pada segmen utara. Namun, deviasi posisi antara kedua lintasan tersebut semakin melebar pada segmen selatan, khususnya di sekitar lintang 20°S ke atas, di mana lintasan prediksi cenderung bergeser ke arah barat menjauhi lintasan observasi. Pola pelebaran deviasi pada fase lanjut siklus hidup siklon ini konsisten dengan penurunan nilai R^2 pada parameter *longitude* dan *latitude* yang telah dibahas sebelumnya. Kondisi ini juga mengindikasikan bahwa model mengalami kesulitan yang lebih besar dalam menangkap perubahan arah pergerakan siklon pada fase intensifikasi dan pelemahan menjelang wilayah lintang tinggi.



Gambar 4 Visualisasi prediksi (biru) trajektori dan intensitas terhadap observasi (merah) pada Siklon Tropis Seroja

Hasil visualisasi trajektori TCN menunjukkan bahwa prediksi jalur dan intensitas pada studi kasus tiga topan nyata, yaitu Mangkhut, Hagupit, dan In-fa, berhimpitan sangat dekat dengan data observasinya yang mengindikasikan kemampuan generalisasi TCN (Gan et al., 2024). Pola berhimpitan yang serupa juga teramati pada penelitian ini, khususnya pada segmen lintasan Siklon Seroja dari wilayah Nusa Tenggara Timur hingga sekitar lintang 16°S, di mana lintasan prediksi masih mengikuti lintasan observasi dengan deviasi yang kecil. Namun, ketika Siklon Seroja memasuki wilayah sekitar 18°LS dan berdekatan dengan posisi Siklon Tropis Odette yang berada di sekitar 15°LS, lintasan prediksi mulai menunjukkan deviasi yang lebih nyata dibandingkan lintasan observasi (Trenggono et al., 2024). Kedekatan posisi kedua sistem siklon tersebut dapat menimbulkan interaksi melalui efek Fujiwhara yang memengaruhi arah dan kecepatan pergerakan Siklon Seroja sehingga pola pergerakannya menjadi sedikit berbeda dari kondisi normal dan menjadi tantangan model dibandingkan segmen lintasan sebelumnya (Trenggono et al., 2024)..

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa model *Temporal Convolutional Network* (TCN) mampu memprediksi lintasan dan intensitas Siklon Tropis Seroja dengan performa yang berbeda signifikan antarparameter. Pada aspek lintasan, model mempertahankan akurasi tinggi. Nilai R^2 *latitude* tetap tinggi dari 0,995 pada *lead time* 6 jam menjadi 0,919 pada *lead time* 24 jam, meskipun RMSE *latitude* meningkat dari 0,32° menjadi 1,79°. Sementara itu, R^2 *longitude* menurun lebih tajam dari 0,922 menjadi 0,383 seiring RMSE *longitude* yang meningkat dari 1,60° menjadi 4,12°. Hasil tersebut mengindikasikan bahwa model masih mampu mengikuti arah umum pergerakan siklon, namun kurang akurat dalam menangkap kelengkungan lintasan pada fase lanjut. Performa prediksi intensitas menurun jauh lebih drastis dibandingkan lintasan. R^2 kecepatan angin turun dari 0,705 menjadi -0,365, sedangkan R^2 tekanan pusat turun dari 0,751 menjadi -0,132 pada *lead time* 24 jam. Penurunan tersebut diikuti peningkatan RMSE kecepatan angin dari 2,73 menjadi 6,26 m/s dan MAPE dari 8,47% menjadi 20,58%. Hasil ini menunjukkan bahwa model belum mampu menangkap dinamika perubahan intensitas secara memadai pada *lead time* panjang. Hasil visualisasi trajektori turut memperkuat temuan ini. Lintasan prediksi berhimpit dengan lintasan observasi pada segmen utara hingga sekitar lintang 16°S. Namun, deviasi posisi melebar secara nyata pada segmen selatan setelah memasuki wilayah sekitar 18°LS, bertepatan dengan kedekatan posisi Siklon Tropis Odette. Kondisi ini diduga menjadi salah satu konteks meteorologis yang meningkatkan kompleksitas dinamika pergerakan Seroja pada fase tersebut. Secara keseluruhan, temuan ini menegaskan bahwa arsitektur TCN lebih andal dalam memprediksi dinamika lintasan dibandingkan dinamika intensitas siklon tropis pada studi kasus Seroja. Oleh karena itu, penelitian selanjutnya perlu mempertimbangkan penambahan variabel dinamika atmosfer, seperti suhu permukaan laut, kelembapan, dan *vertical wind shear* untuk meningkatkan akurasi prediksi intensitas siklon tropis di masa mendatang.

DAFTAR PUSTAKA

- Aleman, S., Beltran, J., Perez, A., & Ganzfried, S. (2019). Predicting Hurricane Trajectories Using a Recurrent Neural Network. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01), 468–475. <https://doi.org/10.1609/aaai.v33i01.3301468>
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling (arXiv:1803.01271). *arXiv*. <https://doi.org/10.48550/arXiv.1803.01271>
- Chen, X., Rozoff, C. M., Rogers, R. F., Corbosiero, K. L., Tao, D., Gu, J.-F., Judt, F., Hendricks, E. A., Wang, Y., Bell, M. M., Stern, D. P., Musgrave, K. D., Knaff, J. A., & Kaplan, J. (2023). Research advances on internal processes affecting tropical cyclone intensity change from 2018–2022. *Tropical Cyclone Research and Review*, 12(1), 10–29. <https://doi.org/10.1016/j.tcr.2023.05.001>
- Gan, S. L., Fu, J. Y., Zhao, G. F., Chan, P. W., & He, Y. C. (2024). Short-term prediction of tropical cyclone track and intensity via four mainstream deep learning techniques. *Journal of Wind Engineering and Industrial Aerodynamics*, 244, 105633. <https://doi.org/10.1016/j.jweia.2023.105633>

- Gray, W. M. (1977). Tropical Cyclone Genesis in the Western North Pacific. *Journal of the Meteorological Society of Japan*, Ser. II, 55(5), 465–482. https://doi.org/10.2151/jmsj1965.55.5_465
- Houze, R. A. (2010). Clouds in Tropical Cyclones. *Monthly Weather Review*, 138(2), 293–344. <https://doi.org/10.1175/2009MWR2989.1>
- Knaff, J. A., Brown, D. P., Courtney, J., Gallina, G. M., & Beven, J. L. (2010). An Evaluation of Dvorak Technique–Based Tropical Cyclone Intensity Estimates. *Weather and Forecasting*, 25(5), 1362–1379. <https://doi.org/10.1175/2010WAF2222375.1>
- Kurniawan, R., Harsa, H., Nurrahmat, M. H., Sasmito, A., Florida, N., Makmur, E. E. S., Swarinoto, Y. S., Habibie, M. N., Hutapea, T. F., Sudewi, R. S., Fitria, W., Praja, A. S., & Adrianita, F. (2021). The Impact of Tropical Cyclone Seroja to The Rainfall and Sea Wave Height in East Nusa Tenggara. *IOP Conference Series: Earth and Environmental Science*, 925(1), 012049. <https://doi.org/10.1088/1755-1315/925/1/012049>
- Latos, B., Peyrillé, P., Lefort, T., Baranowski, D. B., Flatau, M. K., Flatau, P. J., Riama, N. F., Permana, D. S., Rydbeck, A. V., & Matthews, A. J. (2023). The role of tropical waves in the genesis of Tropical Cyclone Seroja in the Maritime Continent. *Nature Communications*, 14(1), 856. <https://doi.org/10.1038/s41467-023-36498-w>
- Mulyana, E., Prayoga, M. B. R., Yananto, A., Wirahma, S., Aldrian, E., Harsoyo, B., Seto, T. H., & Sunarya, Y. (2018). Tropical cyclones characteristic in southern Indonesia and the impact on extreme rainfall event. *MATEC Web of Conferences*, 229, 02007. <https://doi.org/10.1051/mateconf/201822902007>
- Olander, T. L., & Velden, C. S. (2019). The Advanced Dvorak Technique (ADT) for Estimating Tropical Cyclone Intensity: Update and New Capabilities. *Weather and Forecasting*, 34(4), 905–922. <https://doi.org/10.1175/WAF-D-19-0007.1>
- Pu, J., Mu, M., Feng, J., Zhong, X., & Li, H. (2025). A fast physics-based perturbation generator of machine learning weather model for efficient ensemble forecasts of tropical cyclone track. *Npj Climate and Atmospheric Science*, 8(1), 128. <https://doi.org/10.1038/s41612-025-01009-9>
- Safwan Mahmood Al-Selwi, Mohd Fadzil Hassan, Said Jadid Abdulkadir, & Amgad Muneer. (2023). LSTM Inefficiency in Long-Term Dependencies Regression Problems. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 30(3), 16–31. <https://doi.org/10.37934/araset.30.3.1631>
- Setiawan, M. A., Winastuti, R., Hayat, D. M., Christanto, N., Wahyu Rahmadana, A. D., Meilinarti, Ngurah, I., Ndapareda, E., Swastanto, G. A., & Amri, I. (2025). Tropical cyclone Seroja's aftermath: Flash flood inundation modeling and recovery efforts in rural coastal Lembata, East Nusa Tenggara Province, Indonesia. *Tropical Cyclone Research and Review*, 14(4), 323–339. <https://doi.org/10.1016/j.terr.2025.11.010>
- Trenggono, M., Berlianty, D., Priyono, B., Wei, Z., Li, S., & Xu, T. (2024). Impact of the Fujiwhara effect from tropical cyclones Seroja and Odette on ocean dynamic in Southern Indonesia: Insights from argo data and model analysis. *Regional Studies in Marine Science*, 80, 103877. <https://doi.org/10.1016/j.rsma.2024.103877>
- Wang, L., Wan, B., Zhou, S., Sun, H., & Gao, Z. (2023). Forecasting tropical cyclone tracks in the northwestern Pacific based on a deep-learning model. *Geoscientific Model Development*, 16(8), 2167–2179. <https://doi.org/10.5194/gmd-16-2167-2023>
- Wang, L., Wan, B., Zhou, S., Sun, H., & Gao, Z. (2023). Forecasting tropical cyclone tracks in the northwestern Pacific based on a deep-learning model. *Geoscientific Model Development*, 16(8), 2167–2179. <https://doi.org/10.5194/gmd-16-2167-2023>
- Yuan, S., Wang, C., Mu, B., Zhou, F., & Duan, W. (2021). Typhoon Intensity Forecasting Based on LSTM Using the Rolling Forecast Method. *Algorithms*, 14(3), 83. <https://doi.org/10.3390/a14030083>