

Prediksi Jangka Pendek Intensitas dan Jalur Lintasan Siklon Tropis di Selatan Indonesia Menggunakan Model *Temporal Convolutional Network*

Nowcasting of Tropical Cyclone Intensity and Trajectory over Southern Indonesia Using a Temporal Convolutional Network

Pertiwi Risky Setyowati^{1*}, Yosafat Donni Haryanto¹, Adi Mulsandi¹, Latifah Nurul Qomariyatuzzamzami¹

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

Email: *pertiwirisky118@gmail.com, yosafat.haryanto@stmkg.ac.id, adi.mulsandi@stmkg.ac.id, latifah.zamzami@stmkg.ac.id

Received: 03th July 2026; Revised: 15th August 2026; Accepted: 28th August 2026

Abstrak – Siklon tropis merupakan fenomena cuaca ekstrem yang menimbulkan angin kencang, hujan lebat, gelombang tinggi, dan kerusakan infrastruktur, sehingga diperlukan metode prediksi cepat dan akurat untuk mendukung sistem peringatan dini. Penelitian ini bertujuan mengembangkan model Temporal Convolutional Network (TCN) untuk memprediksi jalur dan intensitas siklon tropis jangka pendek pada lead time 6, 12, 18, dan 24 jam di wilayah Regional Association V (RA V) World Meteorological Organization (WMO), mencakup perairan selatan Indonesia. Data yang digunakan berupa data best-track siklon tropis periode 1973–2026 dari Bureau of Meteorology (BOM) Australia, meliputi parameter longitude, latitude, central pressure, dan maximum wind speed. Siklon Tropis Seroja, Cempaka, Dahlia, Anggrek, dan Savanna digunakan sebagai data uji independen, sedangkan data lainnya dibagi secara kronologis menjadi 90% (1973–2021) data pelatihan dan 10% (2022–2026) data validasi. Pada lead time 6 jam, Root Mean Square Error (RMSE) longitude, latitude, maximum wind speed, dan central pressure masing-masing sebesar 1,87°, 0,33°, 2,50 knot, dan 3,37 hPa dengan koefisien determinasi (R^2) 0,947–0,994. Pada 24 jam, RMSE meningkat menjadi 2,70°, 1,25°, 6,76 knot, dan 8,95 hPa serta R^2 longitude dan latitude tetap tinggi (0,955 dan 0,947) dengan R^2 maximum wind speed dan central pressure menurun menjadi 0,616 dan 0,658. Secara spasial, model mampu mengikuti pola lintasan utama pada sebagian besar siklon, meskipun performa pada Cempaka relatif rendah. TCN terbukti lebih andal dalam memprediksi jalur dibandingkan dengan intensitas. Penambahan variabel lingkungan direkomendasikan guna meningkatkan akurasi prediksi intensitas dan mendukung sistem peringatan dini siklon tropis di Indonesia.

Kata kunci: Deep learning; prediksi intensitas; prediksi jalur; siklon tropis; Temporal Convolutional Network.

Abstract – Tropical cyclones are extreme weather phenomena that generate strong winds, heavy rainfall, high waves, and infrastructure damage, necessitating rapid and accurate prediction methods to support early warning systems. This study aims to develop a Temporal Convolutional Network (TCN) model to forecast the short-term track and intensity of tropical cyclones at lead times of 6, 12, 18, and 24 hours within World Meteorological Organization (WMO) Regional Association V (RA V), covering waters south of Indonesia. Best-track data from the Australian Bureau of Meteorology (BOM) for 1973–2026 were used, comprising longitude, latitude, central pressure, and maximum wind speed. Cyclones Seroja, Cempaka, Dahlia, Anggrek, and Savanna served as independent test data, while the remaining data were chronologically split into 90% training (1973–2021) and 10% validation (2022–2026). At a 6-hour lead time, the RMSE for longitude, latitude, maximum wind speed, and central pressure were 1.87°, 0.33°, 2.50 knots, and 3.37 hPa, respectively, with R^2 values of 0.947–0.994. At 24 hours, RMSE increased to 2.70°, 1.25°, 6.76 knots, and 8.95 hPa; R^2 for longitude and latitude remained high (0.955 and 0.947), while R^2

for maximum wind speed and central pressure declined to 0.616 and 0.658. Spatially, the model captured the main trajectory pattern for most cyclones, though performance for Cempaka was relatively low. TCN proved more reliable for track than intensity prediction. Incorporating additional environmental variables is recommended to improve intensity prediction accuracy and strengthen Indonesia's tropical cyclone early warning system.

Keywords: Deep learning; intensity prediction; Temporal Convolutional Network; track prediction; tropical cyclone.

1. Pendahuluan

Siklon tropis merupakan salah satu fenomena cuaca ekstrem paling destruktif/merusak yang mampu menimbulkan dampak beruntun berupa angin kencang, hujan lebat, banjir, dan gelombang tinggi di wilayah pesisir [1]. Secara fisis, siklon tropis adalah sistem bertekanan rendah yang tumbuh di atas lautan hangat bersuhu lebih dari 26,5 °C dengan kecepatan angin di dekat pusatnya mencapai 34 knot dan bertahan minimal enam jam [2]. Fenomena ini terbentuk akibat interaksi kompleks antara panas laten dari penguapan air laut, kelembapan tinggi, ketidakstabilan atmosfer, serta kondisi angin di lapisan troposfer yang mendukung pembentukan sirkulasi siklonal [2]. Selain itu, semakin kuat suplai energi dari lautan melalui mekanisme *ocean-atmosphere coupling*, proses intensifikasi dapat berlangsung sehingga sistem dapat bertransformasi menjadi badai yang intens dan berbahaya [3].

Wilayah Indonesia yang berada pada posisi strategis di daerah ekuatorial dengan karakteristik maritim tropis memiliki potensi untuk terdampak secara langsung maupun tidak langsung oleh siklon tropis, terutama yang terbentuk dan berkembang di perairan bagian selatan Indonesia [4]. Dampak yang ditimbulkan mencakup berbagai bencana hidrometeorologis signifikan seperti angin kencang, hujan lebat hingga ekstrem, peningkatan tinggi gelombang, banjir pesisir, kerusakan infrastruktur, hingga gangguan terhadap keselamatan pelayaran dan aktivitas ekonomi masyarakat pesisir [5]. Kondisi ini menjadikan Indonesia memiliki urgensi tinggi dalam mendapatkan prediksi siklon tropis yang tepat, cepat, dan *reliabel*, terlebih karena siklon dapat mengalami *rapid intensification* hanya dalam hitungan jam sehingga keterlambatan prediksi berisiko meningkatkan kerugian ekologis, ekonomi, bahkan korban jiwa secara signifikan [6, 7].

Metode prediksi konvensional yang selama ini digunakan, seperti Metode Dvorak dan *Advanced Dvorak Technique* (ADT), mengestimasi intensitas siklon berdasarkan pola awan pada citra satelit dan telah menjadi standar praktik selama puluhan tahun [8]. Namun, metode ini mengandung unsur subjektivitas, sensitif terhadap variabilitas pola awan dan tidak mengintegrasikan parameter dinamika atmosfer yang lebih menyeluruh seperti wind shear, vortisitas, maupun profil laut-atmosfer [9]. Di sisi lain, *Numerical Weather Prediction* (NWP) yang menjadi tulang punggung prakiraan cuaca global menghadapi tantangan berupa kebutuhan komputasi yang sangat tinggi dan waktu simulasi yang lama, serta sangat sensitif terhadap error kondisi awal, sehingga menghadapi tantangan dalam mendukung kebutuhan *early warning* yang dinamis dan adaptif pada kondisi operasional *real-time* [10, 11].

Perkembangan *deep learning* mendorong eksplorasi berbagai arsitektur untuk mengatasi keterbatasan metode konvensional dalam prediksi siklon tropis. Berdasarkan penelitian, *Recurrent Neural Networks* (RNN) terbukti mampu merepresentasikan evolusi temporal siklon lebih baik dibandingkan dengan metode statistik, namun terhambat oleh permasalahan *vanishing gradient* [12]. Lebih lanjut, terdapat perkembangan *deep learning* dalam memperdiksi siklon tropis dengan *Long Short-Term Memory* (LSTM) dengan hasil memperbaiki kelemahan model RNN sebelumnya dan lebih stabil dalam mempelajari evolusi intensitas siklon, sementara *Gated Recurrent Unit* (GRU) hadir sebagai alternatif yang lebih ringan dengan kinerja sebanding pada *dataset* berukuran menengah [13], [14]. Meskipun demikian, seluruh model berbasis rekuren ini masih memproses data secara sekuensial sehingga kurang efisien untuk data beresolusi tinggi dan tetap menghadapi tantangan stabilitas pada aplikasi prediksi operasional fenomena atmosfer yang kompleks [15].

Sebagai alternatif terhadap arsitektur rekuren, *Temporal Convolutional Network* (TCN) dikembangkan dengan memanfaatkan operasi konvolusi satu dimensi sepanjang dimensi temporal. Arsitektur ini menggunakan *causal convolution* untuk memastikan bahwa keluaran pada suatu waktu hanya bergantung pada informasi dari waktu sebelumnya, sehingga tidak terjadi penggunaan informasi masa depan dalam proses prediksi [16, 17]. Penggunaan *dilated causal convolution* pada TCN memberikan *receptive field* yang luas sehingga mampu menangkap dinamika perubahan kecepatan angin dan tekanan secara lebih

stabil, termasuk pada fase *rapid intensification* yang sulit diprediksi oleh pendekatan konvensional maupun model rekuren [18]. Karakteristik tersebut menjadikan TCN relevan untuk pemodelan evolusi parameter siklon tropis yang memiliki ketergantungan temporal, seperti perubahan posisi, tekanan pusat, dan kecepatan angin maksimum [18].


Penerapan TCN untuk prediksi siklon tropis telah dilakukan oleh Gan dkk. Pada wilayah *Northwest Pacific* dengan membandingkannya terhadap LSTM, ConvLSTM, dan Transformer [18]. Hasil penelitian tersebut menunjukkan bahwa TCN memiliki performa yang menjanjikan dalam memprediksi jalur dan intensitas siklon. Namun, kemampuan generalisasi TCN pada basin dan sumber data yang berbeda masih perlu diuji, khususnya di wilayah *Regional Association V (RA V) World Meteorological Organization (WMO)* menggunakan *data best-track BoM Australia*. Selain itu, evaluasi secara simultan terhadap parameter *longitude, latitude, central pressure, dan maximum wind speed* pada beberapa *lead time* jangka pendek masih diperlukan untuk mengetahui konsistensi performa model serta perbedaan kemampuannya dalam memprediksi jalur dan intensitas siklon.

Berdasarkan hal tersebut, penelitian ini bertujuan mengembangkan dan mengimplementasikan model TCN untuk meningkatkan akurasi prediksi jangka pendek intensitas dan jalur lintasan siklon tropis dengan *lead time* 6, 12, 18, dan 24 jam di wilayah RA V WMO yang mencakup perairan selatan Indonesia. Model dievaluasi menggunakan beberapa kejadian siklon tropis dengan karakteristik berbeda untuk mengidentifikasi perubahan akurasi terhadap peningkatan *lead time* serta kemampuan model dalam memprediksi parameter jalur dan intensitas. Penelitian ini diharapkan dapat menunjukkan kemampuan dan keterbatasan TCN dalam memprediksi siklon tropis jangka pendek serta menjadi dasar untuk pengembangan model yang dapat mendukung sistem peringatan dini di Indonesia dan operasional *Tropical Cyclone Warning Centre (TCWC) Jakarta, BMKG*.

2. Material dan Metode

2.1. Lokus penelitian

Penelitian ini dilakukan di wilayah *Regional Association V (RA V) WMO* dengan cakupan koordinat 0°–40° LS dan 90°–160° BT yang meliputi kawasan perairan selatan Indonesia, terutama Samudra Hindia bagian selatan, sebagaimana ditampilkan pada Gambar 1. Wilayah ini berada dalam zona operasional *Tropical Cyclone Warning Centre (TCWC) Jakarta* yang terbagi atas *Area of Responsibility (AoR)* dan *Area of Monitoring (AoM)*. AoR meliputi koordinat 00°–10° LS dan 90°–118° BT, 00°–11° LS dan 118°–125° BT, serta 00°–9° LS dan 125°–141° BT. Selain itu, wilayah AoM di selatan Indonesia mencakup 0°–20° LS dan 90°–141° BT di luar batas AoR.



Gambar 1. Peta wilayah penelitian.

2.2. Data penelitian

Data yang digunakan dalam penelitian ini adalah data *best-track* siklon tropis yang diperoleh dari *Bureau of Meteorology* (BOM) Australia, mencakup periode dari Siklon Tropis Jean tahun 1973 hingga Siklon Tropis Iggy tahun 2026, yang diakses melalui laman <https://www.bom.gov.au/cyclone/tropical-cyclone-knowledge-centre/databases/> dalam format *comma-separated values* (*.csv). Data tersebut memuat empat parameter utama, yaitu posisi siklon dalam koordinat *longitude* dan *latitude* (derajat), tekanan pusat (*central pressure*) dalam satuan milibar, dan kecepatan angin maksimum (*maximum wind speed*) di sekitar pusat siklon dalam satuan knot, dengan interval perekaman setiap enam jam. Rentang data yang panjang dan resolusi temporal yang konsisten menjadikan *dataset* ini representatif sebagai basis pelatihan dan evaluasi model *deep learning* TCN dalam penelitian ini. Data penelitian yang digunakan dalam penelitian tersebut ditunjukkan pada Tabel 1.

Tabel 1. Data uji, validasi, dan *test* model TCN.

Data siklon	Parameter	Satuan
Siklon Tropis Jean (1973) hingga Siklon Tropis Iggy (2026)	Longitude	derajat
	Latitude	derajat
	Tekanan pusat siklon	milibar
	Kecepatan angin	knot

2.3. Pre-processing

Tahap *pre-processing* dilakukan untuk menghasilkan dataset yang berkualitas, konsisten, dan representatif sebelum digunakan dalam pelatihan model TCN. Proses ini diawali dengan *quality control* meliputi pemeriksaan format data, identifikasi duplikat, deteksi *missing values*, serta eliminasi data tidak realistis, anomali ekstrem, dan data di luar wilayah penelitian (AoM dan AoR). Nilai kosong yang tersisa diisi melalui interpolasi linier berdasarkan Persamaan (1) di mana (x_0, y_0) dan (x_1, y_1) merupakan dua titik pengamatan yang diketahui, serta (x, y) adalah titik yang diestimasi, sehingga terbentuk deret waktu yang kontinu dengan resolusi temporal seragam. Selanjutnya, dilakukan normalisasi *Min-Max Scaling* ke rentang -1 hingga 1 sesuai Persamaan (2) dengan (x) menyatakan nilai asli data, (x_{min}) dan (x_{max}) masing-masing merupakan nilai minimum dan maksimum variabel, serta (x') adalah nilai hasil normalisasi untuk menyeragamkan skala antarvariabel dan meningkatkan stabilitas pembelajaran model. *Dataset* kemudian dibagi menjadi data latih, validasi, dan data *test* dengan variabel masukan berupa *longitude*, *latitude*, *central pressure*, dan *maximum wind speed* untuk menghasilkan prediksi pada *lead time* 6, 12, 18, dan 24 jam yang ditunjukkan pada Tabel 2.

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

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

Tabel 2. Pembagian *dataset* penelitian.

Dataset	Proporsi	Jumlah Siklon	Periode Data	Fungsi
Data uji / <i>test</i>	5 siklon tropis	5	Siklon Tropis Seroja, Cempaka, Dahlia, Anggrek, dan Savanna	Mengevaluasi performa model pada kasus siklon yang tidak digunakan dalam pelatihan dan validasi
Data pelatihan	90%	453	1973-2021	Melatih parameter model TCN
Data validasi	10%	50	2022-2026	Mengevaluasi model selama proses pelatihan

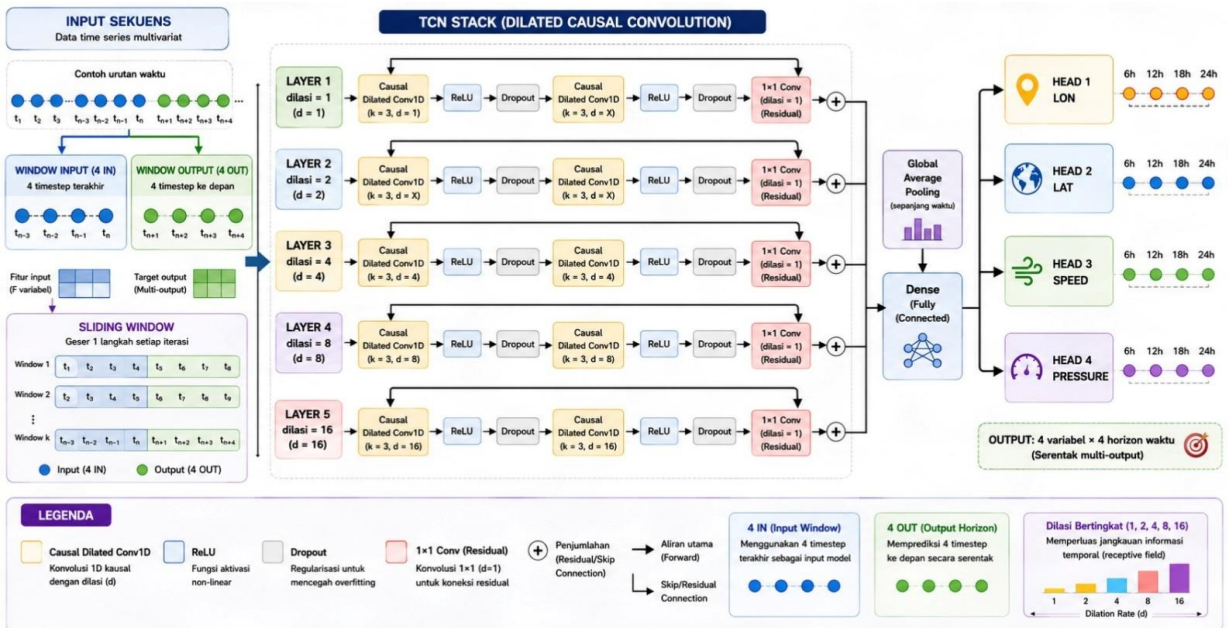
2.4. Processing

Proses pelatihan model TCN menggunakan data deret waktu yang disusun dengan mekanisme *sliding window* sebanyak empat langkah masukan dan empat langkah keluaran dengan interval enam jam, sehingga menghasilkan prediksi pada *lead time* 6, 12, 18, dan 24 jam. Setiap langkah waktu memuat variabel

longitude, latitude, maximum wind speed, dan central pressure. Sebelum pelatihan, lima siklon tropis, yaitu Seroja, Cempaka, Dahlia, Anggrek, dan Savanna, dipisahkan dari dataset berdasarkan ID unik dan digunakan sebagai data uji independen agar tidak terjadi *data leakage* ke dalam data latih maupun validasi. Kelima siklon tersebut dipilih karena relevan dengan wilayah penelitian, memiliki karakteristik lintasan dan intensitas yang beragam, serta memenuhi kebutuhan data untuk pembentukan *sliding window*. Model dilatih menggunakan data latih dan dipantau melalui data validasi dengan menyimpan bobot terbaik berdasarkan validation loss terendah. Kemudian, model terbaik diuji pada lima siklon tersebut, dan hasil prediksinya dibandingkan dengan data *best-track* BoM Australia.

2.5 Temporal Convolutional Network (TCN)

Temporal Convolutional Network (TCN) merupakan arsitektur *deep learning* untuk pemodelan data deret waktu yang memanfaatkan *dilated causal convolution* guna menangkap hubungan temporal jangka panjang secara efisien tanpa meningkatkan jumlah parameter secara signifikan [19]. Operasi konvolusi ini mempertahankan sifat kausal sehingga prediksi pada waktu (t) hanya dipengaruhi oleh data saat ini dan masa lalu yang dirumuskan dalam Persamaan (3). $(F(t))$ sebagai keluaran konvolusi, $*$ operasi konvolusi (f) kernel konvolusi, (k) ukuran kernel konvolusi, (d) faktor dilasi, dan $(X_{t-d.i})$ data masukan pada waktu sebelumnya. Untuk menjaga stabilitas pelatihan dan mengurangi *vanishing gradient*, TCN menerapkan residual connection yang menghubungkan masukan langsung dengan hasil transformasi konvolusi melalui Persamaan (4) dengan (o) sebagai keluaran blok residual, (x) masukan, $(F(x))$ hasil transformasi konvolusi, dan *Activation* menggunakan fungsi ReLU. Kedua komponen tersebut diintegrasikan dalam residual block yang umumnya terdiri atas dua lapisan *dilated causal convolution*, *weight normalization*, fungsi aktivasi ReLU, dan *dropout*, sehingga TCN mampu mempelajari pola temporal yang kompleks dengan efisiensi komputasi dan stabilitas pelatihan yang tinggi. Arsitektur TCN yang digunakan divisualisasikan pada Gambar 2.



Gambar 2. Arsitektur TCN.

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

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

2.6 Evaluasi

Evaluasi kinerja model TCN dilakukan secara kuantitatif menggunakan tiga metrik statistik, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi (R^2). RMSE menghitung rata-rata akar kuadrat dari selisih antara nilai prediksi ($\hat{y}_i$) dan nilai observasi (y_i) sebagaimana didefinisikan pada Persamaan (5), di mana metrik ini memberikan penalti lebih besar terhadap kesalahan yang besar sehingga sensitif dalam mengidentifikasi prediksi yang jauh dari nilai aktual. MAPE mengukur rata-rata kesalahan relatif antara nilai prediksi ($\hat{y}_i$) dan nilai observasi (y_i) yang dinormalkan terhadap nilai observasi kemudian dirata-ratakan sebagaimana dinyatakan pada Persamaan (6) sehingga bersifat tidak berdimensi dan memudahkan perbandingan akurasi antar variabel yang memiliki satuan berbeda, di mana model dengan MAPE rendah cenderung lebih stabil terhadap variasi nilai observasi [18]. Adapun R^2 mengukur proporsi variasi nilai observasi yang dapat dijelaskan oleh model melalui selisih antara jumlah kuadrat residu prediksi ($\hat{y}_i - y_i$) terhadap jumlah kuadrat total deviasi observasi dari rata-ratanya ($y_i - \bar{y}$) sebagaimana diformulasikan pada Persamaan (7) dengan nilai mendekati 1 mengindikasikan bahwa model mampu mengikuti pola perubahan dinamika siklon dengan sangat baik [18].

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


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

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

3. Hasil dan Pembahasan

3.1 Evaluasi model TCN

Kinerja model TCN dievaluasi menggunakan metrik RMSE, MAPE, dan R^2 pada lead time 6, 12, 18, dan 24 jam terhadap empat parameter prediksi, yaitu bujur (LON), lintang (LAT), kecepatan angin (SPEED), dan tekanan udara (PRESSURE) yang divisualisasikan pada Gambar 3.



Gambar 3. Evaluasi model TCN terhadap *lead time* (6, 12, 18, dan 24 jam) dengan (a) RMSE, (b) MAPE, dan (c) R^2 .

Pada Gambar 3 tampak bahwa, secara umum, hasil evaluasi menunjukkan bahwa performa model mengalami degradasi seiring bertambahnya *lead time*, yang tercermin dari peningkatan nilai RMSE dan MAPE serta penurunan nilai R^2 pada seluruh parameter. Pada *lead time* 6 jam, model menunjukkan performa terbaik dengan nilai RMSE yang relatif rendah untuk parameter LON (1,87), LAT (0,33), SPEED (2,50), dan PRESSURE (3,37), serta nilai R^2 yang tinggi berkisar antara 0,947 hingga 0,994. Namun, pada *lead time* 24 jam, nilai RMSE meningkat secara signifikan menjadi 2,70 (LON), 1,25 (LAT), 6,76 (SPEED), dan 8,95 (PRESSURE), disertai penurunan R^2 yang cukup tajam pada parameter SPEED dan PRESSURE menjadi masing-masing 0,616 dan 0,658, mengindikasikan melemahnya kemampuan model

dalam menangkap pola intensitas siklon pada *horizon* prediksi yang lebih jauh. Sementara itu, parameter posisi (LON dan LAT) mempertahankan nilai R^2 yang relatif stabil, yakni 0,955 dan 0,947 pada *lead time* 24 jam, menunjukkan bahwa model TCN lebih andal dalam memprediksi pergerakan posisi dibandingkan parameter intensitas pada jangkauan prediksi yang panjang. Fenomena degradasi performa ini sejalan dengan karakteristik umum model prediksi *time series*, di mana akumulasi ketidakpastian cenderung meningkat secara progresif pada *horizon* prediksi yang lebih panjang.

Fenomena degradasi performa seiring bertambahnya *lead time* ini sangat sejalan dengan temuan-temuan pada penelitian terdahulu yang secara spesifik mengevaluasi model TCN menggunakan metrik RMSE, MAPE, dan R^2 . Dalam studi komprehensifnya, terdapat penelitian yang menunjukkan bahwa meskipun TCN secara keseluruhan mengungguli model *deep learning* lainnya dengan mencatatkan nilai MAPE terendah dan yang sangat tinggi (di atas 0,97) untuk memprediksi empat parameter utama (Garis Lintang, Garis Bujur, Tekanan Pusat, dan Kecepatan Angin), nilai kesalahan prediksi (RMSE) pada seluruh parameter secara konsisten terus membesar setiap kali target waktu prediksi (*lead time*) diperpanjang [18]. Lebih lanjut, penelitian tersebut juga menegaskan bahwa model sering kali menghasilkan *error* yang lebih besar dan lebih sensitif pada prediksi parameter intensitas (seperti tekanan udara) dibandingkan dengan posisi spasial lintasan, terutama ketika siklon mengalami dinamika atau fluktuasi yang kompleks. Keterbatasan model *deep learning* berbasis konvolusi temporal dalam menjangkau horizon prediksi yang panjang ini juga didukung penelitian menggunakan model hibrida MT-CNN-TCN yang menunjukkan bahwa tingkat kesalahan metrik (termasuk RMSE dan *Mean Distance Error*) secara alami akan melonjak progresif seiring bertambahnya rentang waktu prediksi dari 12 jam, 24 jam, hingga 48 jam [20]. Oleh karena itu, bukti-bukti empiris dari literatur-literatur tersebut secara kuat memvalidasi argumen bahwa terlepas dari keandalan TCN dalam memodelkan pergerakan posisi siklon, akumulasi ketidakpastian pada data deret waktu tetap tidak terhindarkan sehingga memicu penurunan akurasi yang tajam pada jangkauan prediksi yang jauh, khususnya untuk dinamika intensitas.


3.2 *Prediksi intensitas dan trajektori siklon tropis*

Evaluasi spasial dilakukan pada lima siklon tropis yaitu Seroja, Cempaka, Dahlia, Anggrek, dan Savanna dengan membandingkan lintasan serta perubahan intensitas hasil prediksi model terhadap data *best-track* yang ditunjukkan pada Gambar 4. Berdasarkan gambar tersebut, secara umum, model mampu mengikuti arah pergerakan utama seluruh siklon terutama pada fase awal perkembangan. Namun, deviasi spasial cenderung meningkat pada fase pertengahan hingga akhir siklus hidup siklon sehingga jarak antara lintasan prediksi dan observasi semakin besar pada *lead time* yang lebih panjang. Kondisi tersebut menunjukkan bahwa meskipun TCN mampu mempelajari pola temporal pergerakan siklon, ketidakpastian prediksi tetap meningkat akibat akumulasi kesalahan pada setiap langkah prediksi.

Hasil prediksi lintasan lima siklon menunjukkan bahwa model mampu merepresentasikan pola pergerakan siklon secara umum dengan tingkat kesesuaian yang bervariasi terhadap lintasan *best track*. Hasil visualisasi dengan lintasan prediksi (berwarna biru) dan lintasan observasi (berwarna merah) dengan simbol yang merepresentasikan kategori intensitas BOM pada setiap titik waktu. Secara umum, model TCN berhasil menangkap arah dominan pergerakan siklon namun terdapat deviasi spasial yang cukup signifikan pada beberapa kasus terutama pada fase awal dan akhir lintasan di mana ketidakpastian dinamika atmosfer cenderung lebih tinggi. Siklon Tropis Seroja dan Siklon Tropis Savanna menampilkan kemiripan lintasan yang relatif baik antara prediksi dan observasi yang mengindikasikan bahwa model dapat menangkap pola pergerakan ke arah barat-selatan yang konsisten pada kedua siklon tersebut. Sebaliknya, Siklon Tropis Anggrek menunjukkan deviasi yang lebih besar dengan lintasan prediksi yang cenderung menyimpang dari observasi yang disebabkan oleh kompleksitas interaksi sistem cuaca di sekitar wilayah tersebut yang sulit ditangkap oleh model berbasis data historis.

Persebaran kategori intensitas pada lintasan observasi menunjukkan variabilitas yang cukup tinggi dengan transisi antarkategori yang terjadi secara dinamis sepanjang siklus hidup masing-masing siklon. Model TCN terbukti mampu merepresentasikan kategori intensitas yang sesuai dengan observasi pada sebagian besar titik lintasan, sebagaimana terlihat pada Siklon Tropis Seroja yang terprediksi pada kategori 1–2 sesuai observasi di segmen tengah, Siklon Tropis Anggrek yang konsisten terprediksi pada kategori 3–4 sepanjang fase puncak, serta Siklon Tropis Savanna yang kategorinya mendekati observasi

pada fase intensifikasi. Meskipun demikian, terdapat beberapa segmen di mana model cenderung *underestimate*, terutama pada fase puncak Siklon Tropis Cempaka dan fase pelemahan Siklon Tropis Dahlia yang berada satu kategori di bawah observasi. Kondisi ini mengindikasikan bahwa TCN telah mampu mempelajari pola temporal intensitas secara umum, namun masih terbatas dalam menangkap transisi intensitas yang berlangsung cepat dan bersifat non-linear. Kondisi ini mengindikasikan bahwa TCN telah mampu mempelajari pola temporal intensitas secara umum, namun masih terbatas dalam menangkap transisi intensitas yang berlangsung cepat dan bersifat non-linear. Peningkatan performa lebih lanjut dapat dicapai melalui integrasi fitur atmosferik tambahan seperti suhu permukaan laut (SST), *vertical wind shear*, dan kelembapan relatif sebagai variabel prediktor pendukung.



Gambar 4. Hasil visualisasi prediksi intensitas dan trajektori dengan observasi pada siklon tropis (a) Seroja, (b) Cempaka, (c) Dahlia, (d) Anggrek, dan (e) Savanna.

Hasil penelitian ini sejalan dengan penelitian yang menyatakan bahwa TCN mampu menangkap ketergantungan temporal jangka panjang secara efektif melalui mekanisme *dilated causal convolution* dan *residual connection* [18]. Pada penelitian ini, prediksi lintasan Seroja dan Savanna relatif baik karena pola pergerakannya lebih konsisten sehingga lebih mudah dipelajari dari deret waktu yang tersedia [18]. Sebaliknya, performa pada Cempaka lebih rendah karena durasi hidup dan jumlah *window* yang lebih terbatas sehingga informasi temporal yang dapat dipelajari model lebih sedikit, sejalan dengan penelitian yang menunjukkan pentingnya ketersediaan data historis yang lebih panjang dalam prediksi lintasan siklon untuk menghasilkan prediksi yang lebih akurat [12]. Dengan demikian, perbedaan performa antarsiklon menunjukkan bahwa keberhasilan TCN tidak hanya ditentukan oleh arsitektur model, tetapi juga oleh panjang deret waktu dan kompleksitas pola pergerakan masing-masing siklon.

Akurasi prediksi intensitas yang lebih rendah berkaitan dengan kompleksitas proses intensifikasi yang dipengaruhi oleh kondisi atmosfer dan laut, seperti suhu permukaan laut, *vertical wind shear*, kelembapan, dan kondisi lingkungan di sekitar pusat siklon [21, 22]. Sementara itu, model dalam penelitian ini hanya menggunakan *longitude*, *latitude*, *maximum wind speed*, dan *central pressure* sebagai variabel masukan. Keterbatasan variabel tersebut menyebabkan informasi lingkungan yang berperan dalam perubahan

intensitas cepat belum sepenuhnya dipertimbangkan model sehingga akurasi cenderung menurun pada *lead time* yang lebih panjang. Penambahan variabel lingkungan tersebut dapat dipertimbangkan untuk meningkatkan kemampuan prediksi intensitas.

4. Kesimpulan

Model TCN mampu digunakan untuk memprediksi jalur dan intensitas siklon tropis di wilayah selatan Indonesia berdasarkan data *best track*. Hasil penelitian menunjukkan bahwa model memiliki kemampuan yang lebih baik dalam memprediksi jalur dibandingkan intensitas siklon tropis. Prediksi lintasan pada Siklon Tropis Seroja, Dahlia, Anggrek, dan Savanna mampu mengikuti pola pergerakan utama siklon dengan baik, sedangkan performa pada Siklon Tropis Cempaka relatif lebih rendah. Pada prediksi intensitas, model telah mampu menggambarkan kecenderungan proses penguatan dan pelemahan siklon, meskipun akurasinya menurun pada perubahan intensitas yang berlangsung cepat dan pada *lead time* yang lebih panjang. Secara keseluruhan, hasil penelitian menunjukkan bahwa model TCN berpotensi menjadi metode pendukung untuk prediksi jangka pendek jalur dan intensitas siklon tropis.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada semua pihak yang telah mendukung pelaksanaan penelitian ini. Penulis mengucapkan terima kasih kepada STMKG yang telah menyediakan fasilitas untuk mendukung terciptanya penelitian ini.

Pustaka

- [1] D. Surinati dan D. A. Kusuma, “Karakteristik dan Dampak Siklon Tropis yang Tumbuh di Sekitar Wilayah Indonesia,” *Oseana*, vol. 43, no. 2, hlm. 1–12, Okt 2018, doi: 10.14203/oseana.2018.Vol.43No.2.16.
- [2] J. R. Holton dan G. J. Hakim, *An introduction to dynamic meteorology*, vol. 88. Academic press, 2013.
- [3] K. Emanuel, “Increasing destructiveness of tropical cyclones over the past 30 years,” *Nature*, vol. 436, no. 7051, hlm. 686–688, 2005.
- [4] E. Mulyana dkk., “Tropical cyclones characteristic in southern Indonesia and the impact on extreme rainfall event,” *MATEC Web Conf.*, vol. 229, hlm. 02007, 2018, doi: 10.1051/mateconf/201822902007.
- [5] M. Ye, P. J. Ward, N. Bloemendaal, S. Nirandjan, dan E. E. Koks, “Risk of Tropical Cyclones and Floods to Power Grids in Southeast and East Asia,” *Int J Disaster Risk Sci*, vol. 15, no. 4, hlm. 494–507, Agu 2024, doi: 10.1007/s13753-024-00573-7.
- [6] C.-Y. Lee, M. K. Tippett, A. H. Sobel, and S. J. Camargo, “Rapid intensification and the bimodal distribution of tropical cyclone intensity,” *Nat Commun*, vol. 7, no. 1, hlm. 10625, Feb 2016, doi: 10.1038/ncomms10625.
- [7] A. Lamers dkk., “Forecasting tropical cyclone rainfall and flooding hazards and impacts,” *Tropical Cyclone Research and Review*, vol. 12, no. 2, hlm. 100–112, Jun 2023, doi: 10.1016/j.tccr.2023.06.005.
- [8] T. L. Olander dan C. S. Velden, “The Advanced Dvorak Technique (ADT) for Estimating Tropical Cyclone Intensity: Update and New Capabilities,” *Weather and Forecasting*, vol. 34, no. 4, hlm. 905–922, Agu 2019, doi: 10.1175/WAF-D-19-0007.1.
- [9] J. A. Knaff, D. P. Brown, J. Courtney, G. M. Gallina, dan J. L. Beven, “An Evaluation of Dvorak Technique–Based Tropical Cyclone Intensity Estimates,” *Weather and Forecasting*, vol. 25, no. 5, hlm. 1362–1379, Okt 2010, doi: 10.1175/2010WAF2222375.1.
- [10] J.-I. Yano dkk., “Scientific Challenges of Convective-Scale Numerical Weather Prediction,” *Bulletin of the American Meteorological Society*, vol. 99, no. 4, hlm. 699–710, Apr 2018, doi: 10.1175/BAMS-D-17-0125.1.

- [11] J. Pu, M. Mu, J. Feng, X. Zhong, dan H. Li, “A fast physics-based perturbation generator of machine learning weather model for efficient ensemble forecasts of tropical cyclone track,” *npj Clim Atmos Sci*, vol. 8, no. 1, hlm. 128, Mar 2025, doi: 10.1038/s41612-025-01009-9.
- [12] S. Alemany, J. Beltran, A. Perez, dan S. Ganzfried, “Predicting Hurricane Trajectories Using a Recurrent Neural Network,” *AAAI*, vol. 33, no. 01, hlm. 468–475, Jul 2019, doi: 10.1609/aaai.v33i01.3301468.
- [13] S. Yuan, C. Wang, B. Mu, F. Zhou, dan W. Duan, “Typhoon Intensity Forecasting Based on LSTM Using the Rolling Forecast Method,” *Algorithms*, vol. 14, no. 3, hlm. 83, Mar 2021, doi: 10.3390/a14030083.
- [14] L. Wang, B. Wan, S. Zhou, H. Sun, dan Z. Gao, “Forecasting tropical cyclone tracks in the northwestern Pacific based on a deep-learning model,” *Geosci. Model Dev.*, vol. 16, no. 8, hlm. 2167–2179, Apr 2023, doi: 10.5194/gmd-16-2167-2023.
- [15] Safwan Mahmood Al-Selwi, Mohd Fadzil Hassan, Said Jadid Abdulkadir, dan Amgad Muneer, “LSTM Inefficiency in Long-Term Dependencies Regression Problems,” *ARASET*, vol. 30, no. 3, hlm. 16–31, Mei 2023, doi: 10.37934/araset.30.3.1631.
- [16] P. Lara-Benítez, M. Carranza-García, dan J. M. Luna-Romera, “Temporal convolutional networks applied to energy-related time series forecasting,” 2020.
- [17] W.-H. Lin, P. Wang, K.-M. Chao, H.-C. Lin, Z.-Y. Yang, dan Y.-H. Lai, “Wind Power Forecasting with Deep Learning Networks: Time-Series Forecasting,” *Applied Sciences*, vol. 11, no. 21, hlm. 10335, Nov 2021, doi: 10.3390/app112110335.
- [18] S. L. Gan, J. Y. Fu, G. F. Zhao, P. W. Chan, dan Y. C. He, “Short-term prediction of tropical cyclone track and intensity via four mainstream deep learning techniques,” *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 244, hlm. 105633, Jan 2024, doi: 10.1016/j.jweia.2023.105633.
- [19] S. Bai, J. Z. Kolter, dan V. Koltun, “An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling,” 19 April 2018, *arXiv*: arXiv:1803.01271. doi: 10.48550/arXiv.1803.01271.
- [20] P. Yang dan G. Ye, “Tropical cyclone track prediction model for multidimensional features and time differences series observation,” *Alexandria Engineering Journal*, vol. 111, hlm. 432–445, Jan 2025, doi: 10.1016/j.aej.2024.10.090.
- [21] X.-Y. Xu, M. Shao, P.-L. Chen, dan Q.-G. Wang, “Tropical Cyclone Intensity Prediction Using Deep Convolutional Neural Network,” *Atmosphere*, vol. 13, no. 5, hlm. 783, Mei 2022, doi: 10.3390/atmos13050783.
- [22] C. Wang, X. Li, and G. Zheng, “Tropical cyclone intensity forecasting using model knowledge-guided deep learning model,” *Environ. Res. Lett.*, vol. 19, no. 2, hlm. 024006, Feb 2024, doi: 10.1088/1748-9326/ad1bde.
- [23] BMKG. Jakarta: Badan Meteorologi, Klimatologi, dan Geofisika; 2015. Available from: <https://web-meteo.bmkg.go.id/id/model-prediksi-cuaca/special-events-nwp-product/37-siklon-tropis/268-siklon-tropis>. [Cited 2025 Dec 1].