

Penerapan Temporal Fusion Transformer untuk Prediksi Emisi Karbon Indonesia

Daffa Ammar Mahendra^{1*}, Faisal Muttaqin², Yisti Vita Via³

¹Informatika/Ilmu Komputer

Universitas Pembangunan Nasional
Veteran Jawa Timur

^{1*}22081010189@student.upnjatim.ac.id

²Informatika/Ilmu Komputer

Universitas Pembangunan Nasional
Veteran Jawa Timur

²faisalmuttaqin.if@upnjatim.ac.id

³Informatika/Ilmu Komputer

Universitas Pembangunan Nasional
Veteran Jawa Timur

³yistivia.if@upnjatim.ac.id

Abstrak— Peningkatan emisi karbon dioksida (CO₂) menjadi salah satu penyebab utama perubahan iklim global sehingga diperlukan pendekatan yang bisa menghasilkan prediksi emisi karbon secara akurat sebagai dasar dalam mendukung pengambilan keputusan. Penelitian ini bertujuan menerapkan model TFT untuk memprediksi emisi karbon Indonesia menggunakan data historis periode 1970–2024 yang diperoleh dari Our World in Data. Variabel masukan yang digunakan meliputi coal_co2, oil_co2, dan gas_co2, sedangkan emisi karbon (CO₂) digunakan sebagai variabel target. Proses penelitian meliputi preprocessing data, pembangunan model TFT, pelatihan model, serta evaluasi menggunakan metrik MAE, MAPE, dan sMAPE. Hasil penelitian menunjukkan bahwa model menghasilkan nilai MAE sebesar 62,0155, MAPE sebesar 8,40%, dan sMAPE sebesar 8,90%. Selain itu, hasil prediksi berhasil mengikuti pola perubahan emisi karbon pada data aktual sehingga menunjukkan kemampuan model dalam mempelajari karakteristik temporal data. Berdasarkan hasil tersebut, TFT dapat diterapkan sebagai salah satu pendekatan yang efektif untuk prediksi emisi karbon Indonesia.

Kata kunci— Temporal Fusion Transformer, prediksi emisi karbon, deret waktu, deep learning, Indonesia.

Abstract— The increase in carbon dioxide (CO₂) emissions is one of the main causes of global climate change, making it necessary to develop an approach capable of generating accurate carbon emission predictions to support decision-making. This study aims to apply the TFT to predict Indonesia's carbon emissions using historical data from 1970 to 2024 obtained from Our World in Data. The input variables used include coal_co2, oil_co2, and gas_co2, while carbon (CO₂) emissions are used as the target variable. The research process included data preprocessing, TFT model development, model training, and evaluation using the MAE, MAPE, and sMAPE metrics. The results show that the model produced an MAE of 62.0155, a MAPE of 8.40%, and an sMAPE of 8.90%. Furthermore, the prediction results were able to follow the patterns of change in carbon emissions in the actual data, demonstrating the model's ability to learn the temporal characteristics of the data. Based on these results, the TFT can be applied as an effective approach for predicting Indonesia's carbon emissions.

Keywords— Temporal Fusion Transformer, carbon emissions forecasting, time series, deep learning, Indonesia.

I. PENDAHULUAN

Perubahan iklim menjadi salah satu tantangan global yang dihadapi oleh berbagai negara di dunia. Salah satu faktor utama yang mendorong terjadinya perubahan iklim adalah meningkatnya emisi karbon dioksida (CO₂) dalam beberapa dekade terakhir [1]. Peningkatan emisi tersebut sebagian besar dipengaruhi oleh aktivitas manusia, seperti sektor transportasi, kegiatan industri, dan perubahan penggunaan lahan. Kondisi ini berkontribusi terhadap kenaikan suhu permukaan bumi, penurunan kualitas udara, serta berbagai dampak lingkungan lainnya yang semakin mengkhawatirkan [2]. Tingginya emisi karbon tersebut tidak terlepas dari besarnya ketergantungan berbagai sektor terhadap penggunaan energi yang berasal dari bahan bakar

fosil non-terbarukan, yang menjadi salah satu sumber utama emisi karbon di atmosfer [3].

Penggunaan energi berbasis bahan bakar fosil, seperti batu bara, minyak bumi, dan gas alam, masih menjadi sumber utama emisi karbon dioksida (CO₂) ke atmosfer. Emisi tersebut dihasilkan dari proses pembakaran bahan bakar fosil untuk memenuhi berbagai kebutuhan, termasuk kegiatan industri, sektor transportasi, dan pembangkit tenaga listrik [4]. Di Indonesia, pemanfaatan energi fosil masih mendominasi pemenuhan kebutuhan energi nasional. Kondisi ini sejalan dengan tren global yang menunjukkan bahwa sekitar 70% kebutuhan energi dunia masih bergantung pada bahan bakar fosil, sehingga berkontribusi terhadap peningkatan emisi karbon, pencemaran udara, serta perubahan iklim [5].

Permasalahan tersebut sejalan dengan komitmen Indonesia dalam mewujudkan *Net Zero Emissions* tahun 2060, hal itu disampaikan dalam roadmap sektor energi IEA dan Kementerian Energi dan Sumber Daya Mineral. Dalam roadmap tersebut, peningkatan efisiensi energi, pemanfaatan energi terbarukan, serta elektrifikasi sektor transportasi ditetapkan sebagai langkah-langkah strategis untuk mengurangi emisi karbon di Indonesia [6]. Untuk mendukung upaya tersebut, diperlukan suatu pendekatan yang dapat memanfaatkan data historis guna menghasilkan prediksi emisi karbon secara lebih akurat. Seiring berkembangnya permasalahan prediksi yang semakin kompleks, metode konvensional mulai menunjukkan keterbatasan dalam memodelkan hubungan yang bersifat nonlinier dan dinamis, sehingga perhatian beralih pada pendekatan heuristik dan machine learning yang lebih adaptif [7]. Salah satu pendekatan yang banyak digunakan adalah machine learning, yang bisa mempelajari pola dan hubungan kompleks pada data historis untuk menghasilkan prediksi yang mendukung perencanaan kebijakan serta evaluasi strategi pengendalian emisi karbon secara lebih efektif [8].

Data emisi karbon merupakan data deret waktu yang memiliki ketergantungan temporal antarpengamatan sehingga memerlukan model yang dapat menangkap pola historis secara efektif [9]. Dibandingkan metode *machine learning* konvensional, model *deep learning* memiliki kapasitas yang lebih baik dalam mempelajari pola nonlinier dan ketergantungan jangka panjang pada data deret waktu [10]. Salah satu model *deep learning* yang banyak diterapkan untuk permasalahan tersebut adalah *Temporal Fusion Transformer* (TFT). Model ini menggabungkan arsitektur LSTM dan attention mechanism sehingga bisa memodelkan hubungan temporal dan multivariat secara bersamaan. Selain menghasilkan prediksi yang akurat, TFT juga memiliki kemampuan interpretabilitas yang memungkinkan analisis terhadap kontribusi setiap variabel dalam proses prediksi [11]. Selain itu, TFT dikembangkan untuk mendukung peramalan jangka panjang (*multi-horizon*


forecasting) dengan memanfaatkan mekanisme *gating* dan *temporal self-attention* sehingga dapat menangkap hubungan temporal jangka panjang serta mengenali pola-pola penting pada data deret waktu [12].

Meskipun TFT telah menunjukkan kinerja yang baik pada berbagai permasalahan prediksi deret waktu, penerapannya pada prediksi emisi karbon, khususnya di Indonesia, masih relatif terbatas. Karakteristik data emisi karbon yang dipengaruhi oleh berbagai faktor, seperti emisi dari batu bara, minyak bumi, dan gas alam, menjadikan prediksi semakin kompleks sehingga diperlukan model yang dapat menangkap hubungan temporal dan multivariat secara bersamaan [13]. Berdasarkan uraian tersebut, penelitian ini bertujuan menerapkan *Temporal Fusion Transformer* (TFT) sebagai metode prediksi emisi karbon Indonesia. Hasil yang diperoleh diharapkan bisa menjadi referensi dalam pengembangan model prediksi berbasis *deep learning* serta mendukung pengambilan keputusan terkait pengendalian emisi karbon.

II. METODOLOGI PENELITIAN

A. Tahapan Penelitian

Metode penelitian ini terdiri dari beberapa tahapan penelitian yang akan disajikan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian


Gambar 1 menunjukkan tahapan penelitian yang dilakukan dalam pengembangan model prediksi emisi karbon Indonesia menggunakan *Temporal Fusion Transformer* (TFT). Penelitian diawali dengan pengumpulan dan preprocessing data, kemudian dilanjutkan dengan pembangunan model yang meliputi konfigurasi, pelatihan, dan evaluasi model. Tahapan tersebut dilakukan untuk menghasilkan model prediksi emisi karbon yang optimal.

B. Pengumpulan Data

Penelitian ini menggunakan pendekatan kuantitatif dengan memanfaatkan data tabular sebagai objek analisis. Dataset yang digunakan merupakan data emisi karbon dunia periode 1970-2024 sebanyak 7.645 data yang diperoleh dari Our World in Data, sebuah situs penyedia data terbuka (*open source*). Data pada situs tersebut diperbarui secara berkala sehingga memiliki konsistensi dan relevansi yang baik untuk mendukung proses pengembangan model prediksi.

C. Preprocessing Data

Tahap preprocessing data dilakukan untuk mempersiapkan dataset sebelum digunakan pada proses pembangunan model. Tahapan ini bertujuan untuk memastikan data berkualitas, konsisten, dan sesuai dengan kebutuhan model [14]. Proses preprocessing meliputi feature selection, data cleaning, serta pembagian dataset menjadi data training, validation, dan testing.



Gambar 2. Diagram Alur Preprocessing Data

Gambar 2 menunjukkan alur preprocessing data yang diterapkan dalam penelitian ini. Tahapan tersebut meliputi seleksi fitur, pembersihan data, dan pembagian dataset, yang tiap tahapannya akan dijelaskan sebagai berikut.

1. Seleksi Fitur

Tahap seleksi fitur bertujuan untuk menentukan variabel yang digunakan dalam prediksi emisi karbon. Pemilihan variabel dilakukan berdasarkan keterkaitannya dengan emisi karbon, ketersediaan data, serta mengacu pada penelitian terdahulu. Variabel yang digunakan dalam penelitian ini ditampilkan pada tabel berikut.

Tabel 1. Tabel Variabel Penelitian


Variabel	Jenis Variabel
Co2	Target
Coal_co2	Input
Oil_co2	Input

Gas_co2	Input
---------	-------

Berdasarkan Tabel 1, penelitian ini menggunakan emisi karbon (CO₂) sebagai variabel target, serta coal_co2, gas_co2, dan oil_co2 sebagai variabel masukan. Seluruh variabel tersebut digunakan sebagai input pada model TFT untuk mempelajari hubungan antarvariabel dalam memprediksi emisi karbon.

2. Pembersihan Data

Tahap data cleaning dilakukan untuk meningkatkan kualitas dataset sebelum digunakan pada proses pelatihan model. Pada tahap ini, data diperiksa untuk memastikan konsistensi, kelengkapan, dan kesesuaian format sehingga siap digunakan dalam proses pemodelan. Diagram alur data cleaning pada penelitian ini ditunjukkan pada Gambar 3.



Gambar 3. Diagram Pembersihan Data

Berdasarkan Gambar 3, proses data cleaning meliputi penanganan nilai hilang, penyamaan format data, serta pengurutan waktu. Penanganan nilai hilang dilakukan untuk menangani data yang kosong, sedangkan penyamaan format bertujuan menjaga konsistensi data. Selanjutnya, data diurutkan berdasarkan waktu agar sesuai dengan karakteristik data deret waktu sebelum digunakan pada proses pelatihan model.

3. Pembagian Dataset

Tahap pembagian dataset bertujuan untuk membagi data menjadi data training, validation, dan testing yang digunakan pada proses pelatihan, validasi, dan evaluasi model. Diagram alur pembagian dataset ditunjukkan sebagai berikut.

Tabel 2. Tabel Pembagian Dataset

Pembagian	Tahun	Jumlah Data
Train	1970-2014	6.255
Validasi	2015-2019	695
Test (Indonesia)	2020-2024	5

Berdasarkan Tabel 2, data training digunakan untuk melatih model, data validation digunakan untuk mengevaluasi performa model selama

proses pelatihan, sedangkan data testing difokuskan pada periode pengamatan emisi karbon Indonesia yang belum pernah digunakan sebelumnya untuk mengukur kompetensi model dalam melakukan prediksi serta mengevaluasi kemampuan generalisasi model terhadap data baru. Pembagian dilakukan berdasarkan urutan waktu agar karakteristik data deret waktu tetap terjaga.

D. Pembangunan Model

Tahap pembangunan model dilakukan untuk membangun model TFT menggunakan dataset hasil preprocessing. Pada tahap ini dilakukan penentuan konfigurasi model dan proses pelatihan menggunakan data training serta validation. Konfigurasi model yang digunakan pada penelitian ini disajikan pada Tabel 3.

Tabel 3. Konfigurasi Parameter Model

Konfigurasi Parameter	
Learning Rate	0.0007
Hidden Units	64
Dropout Rate	0.4
Batch Size	64

Berdasarkan Tabel 3, konfigurasi model TFT menggunakan learning rate sebesar 0,0007, hidden units sebanyak 64, dropout rate sebesar 0,4, dan batch size sebesar 64. Konfigurasi tersebut digunakan selama proses pelatihan model untuk mempelajari pola historis emisi karbon dan menghasilkan prediksi yang optimal.

Selanjutnya, model dilatih menggunakan data training, sedangkan data validation digunakan untuk memantau performa model selama proses pelatihan. Melalui proses ini, model mempelajari pola historis emisi karbon berdasarkan variabel masukan sehingga bisa menghasilkan prediksi terhadap data yang akan datang.

E. Evaluasi Model

Tahap evaluasi model dilakukan untuk mengukur kemampuan TFT dalam memprediksi emisi karbon menggunakan data testing. Evaluasi dilakukan dengan membandingkan nilai hasil prediksi terhadap data aktual menggunakan metrik Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan Symmetric Mean Absolute Percentage Error (sMAPE) sebagai berikut.

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

Pada Persamaan MAE (1), y_i menyatakan nilai aktual, $\hat{y}_i$ merupakan nilai prediksi, n adalah jumlah data observasi, sedangkan $|y_i - \hat{y}_i|$ menunjukkan nilai absolut selisih antara nilai aktual dan prediksi.

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

Kemudian pada Persamaan MAPE (2), y_i menunjukkan nilai aktual dan $\hat{y}_i$ merupakan nilai prediksi pada observasi ke- i . Nilai $\frac{|y_i - \hat{y}_i|}{y_i}$ digunakan untuk menghitung besar kesalahan relatif terhadap nilai aktual, sedangkan n menyatakan jumlah data observasi.

Symmetric Mean Absolute Percentage Error (sMAPE)

$$sMAPE = \frac{100\%}{m} \sum_{i=1}^m \frac{|X_i - Y_i|}{\frac{|X_i| + |Y_i|}{2}} \quad (3)$$

Selanjutnya pada Persamaan sMAPE (3), nilai kesalahan dihitung berdasarkan selisih antara hasil prediksi (X_i) dan nilai aktual (Y_i) yang kemudian dinormalisasi menggunakan rata-rata nilai absolut keduanya. Pendekatan tersebut menghasilkan ukuran kesalahan yang bersifat simetris, sedangkan m menyatakan jumlah observasi yang digunakan dalam proses evaluasi.


MAE digunakan untuk mengukur rata-rata selisih absolut antara nilai aktual dan hasil prediksi. MAPE mengukur tingkat kesalahan prediksi dalam bentuk persentase terhadap nilai aktual, sedangkan sMAPE digunakan untuk mengurangi sensitivitas terhadap nilai aktual yang sangat kecil sehingga menghasilkan evaluasi yang lebih seimbang. Semakin kecil nilai MAE, MAPE, dan sMAPE, maka semakin baik performa model dalam melakukan prediksi.

III. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil penelitian mengenai penerapan Temporal Fusion Transformer (TFT) untuk memprediksi emisi karbon Indonesia. Hasil yang diperoleh meliputi proses pelatihan model, evaluasi performa, serta hasil prediksi yang selanjutnya dianalisis untuk menilai kemampuan model dalam memprediksi emisi karbon berdasarkan data historis.

A. Hasil Pelatihan Model

Model TFT dibangun menggunakan konfigurasi parameter yang telah ditentukan pada tahap metodologi. Proses pelatihan dilakukan menggunakan data training, sedangkan data validation digunakan untuk memantau performa model selama proses pembelajaran sekaligus mencegah terjadinya overfitting. Selama pelatihan, model mempelajari hubungan temporal antarvariabel serta pola historis emisi karbon pada setiap periode untuk membentuk representasi yang digunakan dalam memprediksi emisi karbon pada periode berikutnya. Performa model dievaluasi secara bertahap berdasarkan nilai validation loss pada setiap epoch, sehingga proses pelatihan dapat menghasilkan model dengan nilai prediksi yang lebih optimal sebelum dilakukan pengujian menggunakan data testing.



Gambar 4. Grafik Pelatihan Model

Berdasarkan Gambar 4, nilai training loss dan validation loss menunjukkan tren penurunan hingga mencapai kondisi yang stabil. Hal tersebut menunjukkan bahwa model bisa mempelajari pola historis pada data emisi karbon secara bertahap. Selain itu, tidak terlihat adanya perbedaan yang terlalu besar antara training loss dan validation loss, sehingga mengindikasikan bahwa model berhasil melakukan generalisasi yang baik terhadap data validasi.

Stabilnya proses pelatihan menunjukkan bahwa konfigurasi parameter yang digunakan bisa mendukung proses pembelajaran model secara optimal. Dengan demikian, model TFT telah siap digunakan pada tahap evaluasi menggunakan data testing.

B. Hasil Evaluasi Model

Setelah proses pelatihan selesai, model TFT dievaluasi menggunakan data testing untuk

mengukur kemampuan model dalam memprediksi emisi karbon. Evaluasi dilakukan menggunakan metrik Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan Symmetric Mean Absolute Percentage Error (sMAPE). Hasil evaluasi model disajikan pada Tabel 3.

Tabel 4. Hasil Evaluasi Model


Metrik Evaluasi	Nilai
MAE	62,0155
MAPE	8,40%
sMAPE	8,90%

Berdasarkan Tabel 3, model TFT menghasilkan nilai MAE sebesar 62,0155, MAPE sebesar 8,40%, dan sMAPE sebesar 8,90%. Nilai MAPE dan sMAPE yang berada di bawah 10% menunjukkan bahwa model menghasilkan prediksi dengan tingkat kesalahan yang relatif rendah terhadap data aktual. Sementara itu, nilai MAE menunjukkan rata-rata selisih absolut antara hasil prediksi dan nilai aktual sebesar 62,0155 juta ton emisi karbon.

Secara keseluruhan, hasil evaluasi tersebut menunjukkan bahwa model berhasil mempelajari pola historis emisi karbon Indonesia dengan baik sehingga menghasilkan prediksi yang mendekati nilai aktual.


C. Visualisasi Hasil Prediksi

Visualisasi hasil prediksi dilakukan untuk membandingkan nilai aktual dengan hasil prediksi yang dihasilkan oleh model TFT pada data testing. Perbandingan ini bertujuan untuk memberikan gambaran mengenai kinerja model dalam mengikuti pola perubahan emisi karbon Indonesia dari waktu ke waktu.



Gambar 5. Grafik Perbandingan Data Aktual dan Hasil Prediksi Emisi Karbon Indonesia

Berdasarkan Gambar 5, hasil prediksi model secara umum dapat mengikuti tren perubahan emisi karbon pada data aktual. Model berhasil merepresentasikan pola kenaikan emisi dari tahun 2021 hingga 2024, meskipun masih ada selisih prediksi pada beberapa periode. Selisih yang paling terlihat terjadi pada tahun 2022 dan 2023, di mana nilai prediksi berada di bawah data aktual, sedangkan pada tahun 2024 hasil prediksi semakin mendekati nilai sebenarnya. Kondisi tersebut menunjukkan bahwa model berhasil menangkap pola historis emisi karbon meskipun belum sepenuhnya merepresentasikan besarnya perubahan pada setiap periode.



Gambar 6. Grafik Error Pertama

Berdasarkan Gambar 6, besarnya kesalahan prediksi (*absolute prediction error*) menunjukkan variasi pada setiap tahun pengujian. Nilai kesalahan terkecil diperoleh pada tahun 2021 sebesar 20,0, diikuti tahun 2020 sebesar 34,1 dan tahun 2024 sebesar 35,6. Sementara itu, kesalahan prediksi terbesar terjadi pada tahun 2022 dengan nilai 140,3, kemudian diikuti tahun 2023 sebesar 80,1. Hasil tersebut menunjukkan bahwa model bisa menghasilkan prediksi yang relatif akurat pada sebagian besar periode pengujian, meskipun masih mengalami peningkatan kesalahan pada tahun 2022 dan 2023. Kondisi ini mengindikasikan bahwa perubahan pola emisi karbon pada kedua tahun tersebut lebih sulit dipelajari oleh model dibandingkan periode lainnya.

Meskipun masih diperoleh selisih prediksi pada beberapa periode, model tetap mampu mengikuti arah perubahan emisi karbon dari waktu ke waktu. Hal ini menunjukkan bahwa TFT bisa mempelajari hubungan temporal pada

data historis sehingga dapat merepresentasikan pola perubahan emisi karbon Indonesia dengan baik.

D. Pembahasan

Berdasarkan hasil pelatihan, evaluasi, dan visualisasi prediksi yang telah dilakukan, model TFT mampu menghasilkan prediksi emisi karbon Indonesia yang mendekati data aktual. Hal tersebut ditunjukkan melalui nilai kesalahan prediksi yang relatif rendah serta kinerja model dalam mengikuti tren perubahan emisi karbon pada periode pengujian. Meskipun masih terdapat selisih prediksi pada beberapa titik pengamatan, secara umum model berhasil untuk merepresentasikan pola historis emisi karbon dengan baik.

Kemampuan tersebut didukung oleh karakteristik TFT yang dirancang untuk menangani data deret waktu multivariat dengan ketergantungan temporal yang kompleks. Kombinasi arsitektur LSTM dan attention mechanism memungkinkan model memanfaatkan informasi historis sekaligus menangkap hubungan antarvariabel masukan, yaitu *coal_co2*, *oil_co2*, dan *gas_co2*. Dengan mekanisme tersebut, model dapat mengenali pola perubahan emisi karbon dari waktu ke waktu sehingga menghasilkan prediksi yang mengikuti tren data aktual.

Hasil penelitian ini sejalan dengan penelitian terdahulu yang menyatakan bahwa TFT memiliki performa yang baik dalam berbagai permasalahan prediksi deret waktu karena bisa memodelkan hubungan temporal dan multivariat secara efektif. Oleh karena itu, penerapan TFT pada penelitian ini menunjukkan bahwa model tersebut layak digunakan sebagai salah satu pendekatan dalam memprediksi emisi karbon Indonesia. Informasi yang dihasilkan dari model ini dapat dimanfaatkan sebagai pendukung dalam memantau tren emisi karbon, mengevaluasi efektivitas kebijakan yang telah diterapkan, serta membantu pemerintah dalam menyusun strategi pengendalian emisi dan perencanaan transisi menuju energi yang lebih berkelanjutan berbasis data.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, penerapan Temporal Fusion Transformer (TFT) berhasil memprediksi emisi karbon Indonesia dengan performa yang baik. Model menghasilkan nilai MAE sebesar 62,0155, MAPE sebesar 8,40%, dan sMAPE sebesar 8,90%, yang menunjukkan tingkat kesalahan prediksi relatif rendah. Selain itu, visualisasi hasil prediksi memperlihatkan bahwa model mampu mengikuti pola perubahan emisi karbon pada data aktual sehingga dapat merepresentasikan tren historis secara efektif.

Hasil tersebut menunjukkan bahwa tujuan penelitian untuk menerapkan TFT dalam prediksi emisi karbon Indonesia telah tercapai. Dengan kemampuannya dalam mempelajari hubungan temporal dan multivariat, TFT berpotensi menjadi salah satu pendekatan untuk prediksi emisi karbon Indonesia. Temuan penelitian ini diharapkan dapat mendukung pengembangan penelitian di bidang prediksi emisi karbon serta menjadi referensi dalam upaya pencapaian target Net Zero Emissions Indonesia.

Penelitian ini masih memiliki beberapa keterbatasan. Proses evaluasi model dilakukan menggunakan lima observasi pada data testing sehingga kemampuan generalisasi model masih perlu dikaji pada data dengan periode pengamatan yang lebih panjang. Selain itu, variabel yang digunakan masih terbatas pada coal_co2, oil_co2, dan gas_co2, serta penelitian ini belum membandingkan performa TFT dengan metode prediksi lainnya. Penelitian selanjutnya diharapkan dapat memanfaatkan data dengan cakupan yang lebih luas, menambahkan variabel yang lebih beragam, serta membandingkan performa TFT dengan berbagai metode prediksi untuk memperoleh evaluasi yang lebih komprehensif.

REFERENSI

- [1] S. Elmi, R. Yanti, H. Asnal Prediksi Emisi Co, D. Indonesia Menggunakan Pendekatan, and H. Asnal, "Hybrid Arima Dan LSTM."
- [2] Parid Pakaya, Fitryane Lihawa, and Dewi Wahyuni K. Baderan, "Efektivitas Ruang Terbuka Hijau Publik dalam Menyerap Emisi Karbon Dioksida untuk Mendukung Keberlanjutan Lingkungan Perkotaan," *Hidroponik J. Ilmu Pertan. Dan Teknol. Dalam Ilmu Tanam.*, vol. 1, no. 3, pp. 54–75, Nov. 2024, doi: 10.62951/hidroponik.v1i3.199.
- [3] G. Justice, G. Nyantakyi, and S. Hayford, "Heliyon The effect of renewable energy on carbon emissions through globalization," *Heliyon*, vol. 10, no. 5, p. e26894, 2024, doi: 10.1016/j.heliyon.2024.e26894.
- [4] Regina Citra Kurnia Pangestu and Anak Agung Ketut Ayuningsasi, "Pengaruh Konsumsi Energi Sektor Industri, Rumah Tangga, dan Transportasi terhadap Emisi Karbon di Indonesia," *Inisiat. J. Ekon. Akunt. dan Manaj.*, vol. 3, no. 4, pp. 297–311, 2024, doi: 10.30640/inisiatif.v3i4.3154.
- [5] I. Salsabila Nur Amalina, H. Wahyudi, and U. Ciptawaty, "Pengaruh GDP Per Kapita, dan Konsumsi Energi Terhadap Emisi CO2 di Indonesia," *J. Educ.*, vol. 6, no. 1, pp. 6508–6517, 2023, doi: 10.31004/joe.v6i1.3872.
- [6] "An Energy Sector Roadmap to Net Zero Emissions in Indonesia." [Online]. Available: www.ica.org/t&c/
- [7] Y. V. Via, "OPTIMASI PENCAPAIAN TARGET PADA SIMULASI PERENCANAAN JALUR ROBOT BERGERAK DI LINGKUNGAN DINAMIS".
- [8] E. Pitaloka *et al.*, "Penerapan Machine Learning untuk Prediksi Bencana Banjir," vol. 01, 2024, doi: 10.21456/vol14iss1pp62-76.
- [9] A. Zeng, M. Chen, L. Zhang, and Q. Xu, "Are Transformers Effective for Time Series Forecasting?," *Proc. 37th AAAI Conf. Artif. Intell. AAAI 2023*, vol. 37, pp. 11121–11128, 2023, doi: 10.1609/aaai.v37i9.26317.
- [10] D. Muchlinski, "Machine learning and deep learning," *Elgar Encycl. Technol. Polit.*, pp. 114–118, 2022, doi: 10.4337/9781800374263.machine.learning.deep.
- [11] B. Lim, S. Arik, N. Loeff, and T. Pfister, "Temporal Fusion Transformers for interpretable multi-horizon time series forecasting," *Int. J. Forecast.*, vol. 37, no. 4, pp. 1748–1764, 2021, doi: 10.1016/j.ijforecast.2021.03.012.
- [12] F. Falchi, M. Girardi, G. Gurioli, N. Messina, C. Padovani, and D. Pellegrini, "Deep learning and structural health monitoring: Temporal Fusion Transformers for anomaly detection in masonry towers," *Mech. Syst. Signal Process.*, vol. 215, Jun. 2024, doi: 10.1016/j.ymssp.2024.111382.
- [13] A. A. Alhussan and M. Metwally, "Enhanced CO2 Emissions Prediction Using Temporal Fusion Transformer Optimized by Football Optimization Algorithm," *Mathematics*, vol. 13, no. 10, pp. 1–47, 2025, doi: 10.3390/math13101627.
- [14] F. Muttaqin, L. Rahmadi, and D. Januarita, "Implementation of CLAE and CLAGAMTWO in Medical Images," vol. 8106, pp. 22–27, 2025.