



ISSN : 2339 - 1871

# BETRIK

## BESEMAH TEKNOLOGI INFORMASI & KOMPUTER

Editor Office : Pusat Penelitian & Pengabdian Pada Masyarakat  
(PPPM) ITPA

Phone : 0857-9716-9578

email : [betrikitpa@itpa.ac.id](mailto:betrikitpa@itpa.ac.id)

## Prediksi Emisi Co2 Di Indonesia Menggunakan Pendekatan *Hybrid* Arima Dan LSTM

Syarifuddin Elmi<sup>1</sup>, Rini Yanti<sup>2</sup>,Mardainis<sup>3</sup>,Hadi Asnal<sup>4</sup>

Program Studi Teknik Informatika Universitas Sains Dan Teknologi Indonesia<sup>1,2,3</sup>  
Jl.Pendidikan No.17,Sidomulyo Barat.,Kec.Tuah Madani,Kota Pekanbaru,Riau 28293

Sur-el : [fuddinsyarif473@gmail.com](mailto:fuddinsyarif473@gmail.com)<sup>1</sup> , [riniyanti@usti.ac.id](mailto:riniyanti@usti.ac.id)<sup>2</sup> ,  
[mardainis@usti.ac.id](mailto:mardainis@usti.ac.id)<sup>3</sup>,[Hadiasnal@usti.ac.id](mailto:Hadiasnal@usti.ac.id)<sup>4</sup>

Penulis Korespondensi: Syarifuddin elmi,[fuddinsyarif473@gmail.com](mailto:fuddinsyarif473@gmail.com)

**Abstrak** : Perubahan iklim merupakan isu global yang semakin kompleks, dengan emisi karbon dioksida (CO<sub>2</sub>) menjadi kontributor utama terhadap pemanasan global. Di Indonesia, pertumbuhan sektor industri, transportasi, dan penggunaan energi berbasis fosil telah mempercepat peningkatan emisi CO<sub>2</sub> secara signifikan. Dalam konteks ini, kebutuhan akan prediksi emisi yang akurat menjadi semakin penting sebagai landasan dalam menyusun kebijakan mitigasi yang berbasis data. Penelitian ini bertujuan untuk mengembangkan model prediksi emisi CO<sub>2</sub> di Indonesia dengan pendekatan *hybrid* yang menggabungkan metode *AutoRegressive Integrated Moving Average* (ARIMA) dan *Long Short-Term Memory* (LSTM). ARIMA digunakan untuk menangkap pola *linear* dalam data deret waktu historis, sedangkan LSTM diterapkan untuk mengatasi pola *non-linear* yang kompleks. Data emisi yang digunakan dalam penelitian ini mencakup periode tahun 1970 hingga 2023, dengan pemisahan data pelatihan dan pengujian secara kronologis menggunakan rasio 80:20. Hasil evaluasi model menunjukkan bahwa pendekatan ARIMA menghasilkan kinerja yang kurang optimal (RMSE: 2342.5139, MAE: 2341.5775, MAPE: 414.77%), sedangkan model LSTM menunjukkan peningkatan signifikan dalam akurasi prediksi (RMSE: 49.3307, MAE: 45.5498, MAPE: 7,94%). Model hybrid ARIMA-LSTM memberikan hasil terbaik dengan nilai evaluasi RMSE sebesar 31.5788, MAE sebesar 25.0335, dan MAPE sebesar 4.34%. Temuan ini mengindikasikan bahwa kombinasi kedua metode mampu meningkatkan ketepatan prediksi secara substansial dibandingkan penggunaan model tunggal. Implikasi dari penelitian ini tidak hanya relevan bagi pengembangan kajian akademik di bidang analitik lingkungan, tetapi juga memberikan kontribusi praktis dalam mendukung penyusunan strategi penurunan emisi karbon yang lebih efektif dan berkelanjutan di Indonesia.

Kata kunci: Emisi CO<sub>2</sub>, ARIMA, LSTM, *Hybrid* Model, *Time Series*, Prediksi, Perubahan Iklim

**Abstract** : Climate change has emerged as a pressing global issue, with carbon dioxide (CO<sub>2</sub>) emissions serving as a major contributor to global warming. In Indonesia, the expansion of industrial activities, transportation, and the reliance on fossil fuel-based energy have significantly accelerated CO<sub>2</sub> emission levels. In this context, the need for accurate emission forecasting has become increasingly important as a basis for formulating data-driven mitigation policies. This study aims to develop a predictive model for CO<sub>2</sub> emissions in Indonesia using a hybrid approach that combines *AutoRegressive Integrated Moving Average* (ARIMA) and *Long Short-Term Memory* (LSTM) methods. ARIMA is employed to capture linear patterns in historical time series data, while LSTM is used to

Received: 17-07-2025 | Accepted: 28-07-2025 | Published Online: 30-08-2025

All author: Syarifuddin Elmi, Rini Yanti, Mardainis, Hadi Asnal

*model the non-linear and complex dynamics often present in environmental data. The emission data used spans from 1970 to 2023, with training and testing data separated chronologically in an 80:20 ratio. The evaluation results show that the ARIMA model alone yielded suboptimal performance (RMSE: 2342.5139, MAE: 2341.5775, MAPE: 414.77%), whereas the LSTM model significantly improved prediction accuracy (RMSE: 49.3307, MAE: 45.5498, MAPE: 7.94%). The hybrid ARIMA-LSTM model achieved the best results, with an RMSE of 31.5778, MAE of 25.0335, and MAPE of 4.34%. These findings indicate that the combination of both methods substantially enhances prediction performance compared to standalone models. The implications of this research are twofold: academically, it contributes to methodological development in environmental data analysis; practically, it offers valuable insights for policymakers in formulating more effective and sustainable carbon emission reduction strategies in Indonesia.*

*Keywords: CO2 Emissions, ARIMA, LSTM, Hybrid Model, Time Series, Forecasting, Climate Change*

## 1. PENDAHULUAN

Perubahan iklim telah menjadi isu global yang semakin mendesak untuk ditangani, salah satunya disebabkan oleh peningkatan emisi karbon dioksida (CO<sub>2</sub>) yang signifikan dalam beberapa dekade terakhir. Di Indonesia, laju pertumbuhan ekonomi dan peningkatan aktivitas industri, transportasi, serta konsumsi energi berbasis bahan bakar fosil telah menjadi penyumbang utama emisi CO<sub>2</sub>. Data dari Kementerian Lingkungan Hidup dan Kehutanan menunjukkan bahwa Indonesia kini termasuk negara dengan tingkat emisi karbon tertinggi di Asia Tenggara [1]. Fenomena ini menimbulkan dampak multi-sektoral, mulai dari degradasi lingkungan hingga ancaman terhadap kesehatan publik dan ketahanan ekonomi nasional.

Peningkatan emisi CO<sub>2</sub> memiliki korelasi langsung dengan anomali iklim yang terjadi secara luas, seperti peningkatan suhu permukaan bumi, pola curah hujan yang tidak menentu, serta meningkatnya intensitas bencana alam seperti banjir dan kekeringan. Di Indonesia, dampak ini telah dirasakan secara konkret dalam bentuk penurunan kualitas udara dan produktivitas lahan, serta meningkatnya risiko bencana yang berulang. Oleh karena itu, urgensi untuk memahami dan memprediksi tren emisi CO<sub>2</sub> menjadi sangat penting dalam rangka mendukung kebijakan mitigasi yang lebih adaptif dan berbasis data [2],[3].

Dalam menghadapi tantangan tersebut, kemajuan teknologiz analisis data, khususnya dalam bidang data science dan kecerdasan buatan, memberikan peluang baru untuk menganalisis dan memodelkan pola emisi secara lebih akurat. Salah satu pendekatan yang banyak digunakan dalam konteks prediksi deret waktu adalah metode AutoRegressive Integrated Moving Average (ARIMA), sebuah teknik statistik yang efektif dalam mengenali pola linear pada data historis [4]. Namun, ARIMA memiliki keterbatasan dalam mengatasi struktur data yang bersifat non-linear dan kompleks, yang sering kali ditemukan dalam konteks data lingkungan.

Sebagai pelengkap, metode Long Short-Term Memory (LSTM) —sebuah arsitektur jaringan saraf dalam domain deep learning— hadir sebagai alternatif untuk mengatasi kelemahan tersebut. LSTM mampu mempelajari hubungan temporal jangka panjang dan menangkap dinamika non-linear dalam data sekuensial, sehingga menjadikannya sangat cocok

untuk aplikasi prediksi berbasis waktu. Kombinasi kedua pendekatan ini—ARIMA untuk pengenalan pola linear dan LSTM untuk identifikasi pola non-linear—menciptakan model hibrida yang diyakini lebih unggul dalam hal akurasi prediksi[5].

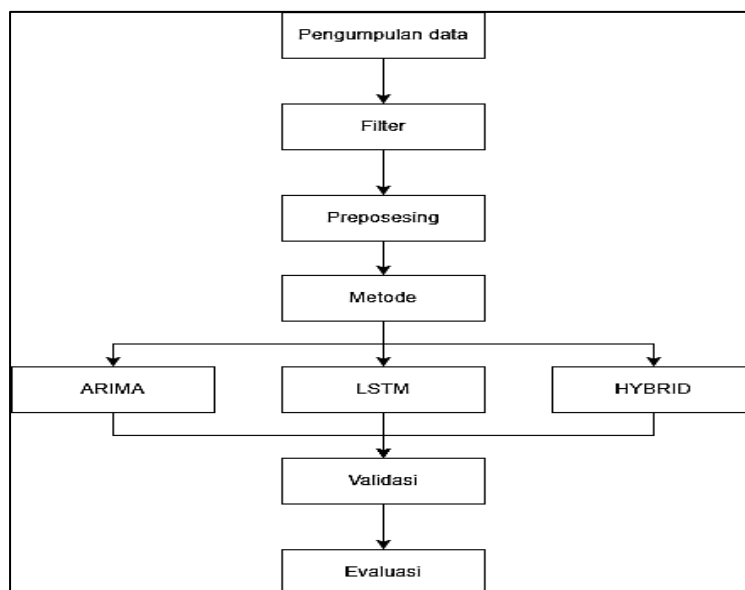
Penelitian ini bertujuan untuk mengevaluasi efektivitas kombinasi metode ARIMA dan LSTM dalam memodelkan dan memprediksi emisi CO2 di Indonesia dengan menggunakan data historis dari tahun 1970 hingga 2023. Dengan menerapkan pendekatan hybrid, penelitian ini diharapkan mampu memberikan hasil prediksi yang lebih akurat dan dapat diandalkan sebagai dasar pengambilan keputusan. Selain itu, penggunaan metrik evaluasi seperti Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE), dan Mean Absolute Error (MAE) akan membantu dalam mengukur kinerja masing-masing model secara kuantitatif.

Lebih jauh lagi, hasil dari penelitian ini memiliki implikasi yang signifikan, baik dari sisi akademis maupun praktis. Dari sisi akademis, penelitian ini berkontribusi terhadap pengembangan metodologi analisis data dalam domain lingkungan, khususnya prediksi emisi karbon berbasis teknologi machine learning. Sementara itu, dari sisi praktis, hasil penelitian ini dapat menjadi rujukan bagi pemerintah dan pemangku kepentingan dalam merumuskan strategi penurunan emisi karbon yang lebih efektif dan berkelanjutan [6],[7].

Dengan demikian, integrasi metode ARIMA dan LSTM dalam penelitian ini diharapkan tidak hanya menghasilkan prediksi yang lebih tepat, tetapi juga memperluas pemanfaatan teknologi analisis prediktif dalam upaya pelestarian lingkungan dan mitigasi perubahan iklim di Indonesia.

## 2. METODOLOGI PENELITIAN

Proses prediksi dilakukan secara bertahap dan sistematis. Berikut adalah tahapan-tahapan penelitian ini, yang dijabarkan dalam gambar dibawah:



Gambar 1. Tahapan-Tahapan Analisis

Pada tahap awal dilakukan proses pengumpulan data, selanjutnya filter/filtering tujuannya menghapus data yang tidak diperlukan. Langkah selanjutnya prosesing tujuannya adalah untuk memproses data. Setelah tahap prosesing, langkah berikutnya adalah metode, metode yang digunakan ada tiga pertama metode arima, kedua metode lstm dan ke tiga hybrid. Hbrid adalah gabungan dari dua metode. selanjutnya validasi, proses validasi digunakan untuk mendapat mean squared error (mse), root mean squared error (rmse) dan mean absolute error (mae). Setelah validasi ada evaluasi bertujuan untuk memberikan gambaran kuantitatif maupun kualitatif mengenai seberapa baik suatu pendekatan mampu merepresentasikan atau memprediksi fenomena yang diteliti.

### **2.1 Pengumpulan Data**

Pengumpulan data adalah tahapan dalam mendapatkan atau memperoleh data untuk kebutuhan dalam penelitian ini. Penelitian ini menggunakan data EDGAR (*Emissions Database for Global Atmospheric Research*) dari tahun 1970 sampai 2023. Data ini didapat dari [8].

### **2.2 Filter**

*Filter/filtering* merupakan tahap awal dalam proses pra-pemrosesan data, filter bertujuan untuk menyeleksi dan relevan yang digunakan dalam proses analisis. Data yang diperoleh dari sumber terbuka sering kali mengandung sejumlah masalah seperti informasi yang tidak lengkap, duplikat dan nilai-nilai yang menyimpang.

### **2.3 Preprocessing**

Proses pra-pemrosesan data merupakan tahap krusial dalam analisis data, karena pada tahap ini bertujuan untuk menyeleksi data yang digunakan dalam proses analisis. Data yang diperoleh dari sumber terbuka sering kali mengandung sejumlah masalah seperti informasi yang tidak lengkap, duplikat dan nilai-nilai yang menyimpang dan dilakukan berbagai langkah untuk memastikan kualitas dan konsistensi data sebelum digunakan dalam pemodelan. Salah satu langkah yang umum dilakukan adalah penanganan data yang memiliki nilai kosong (*missing values*), yang biasanya dihapus agar tidak mengganggu hasil analisis.

Setelah itu, tahap penting berikutnya adalah normalisasi. Normalisasi merupakan teknik yang digunakan untuk mengubah skala data numerik ke dalam rentang yang lebih kecil dan seragam. Tujuannya adalah untuk memastikan bahwa setiap variabel memiliki kontribusi yang seimbang dalam proses analisis atau pelatihan model. Salah satu metode yang sering digunakan dalam normalisasi adalah dengan membagi setiap nilai data dengan nilai rentang (*range*) dari variabel tersebut.

Hasil dari proses ini adalah data yang terletak dalam interval tertentu, seperti [ , tergantung pada metode normalisasi yang digunakan. Normalisasi tidak hanya membantu dalam meningkatkan efisiensi proses analisis, tetapi juga berperan dalam mengurangi kompleksitas data, menghindari adanya duplikasi nilai, serta memudahkan proses modifikasi dan interpretasi data di tahap-tahap selanjutnya.

## 2.4 METODE

### 2.4.1 ARIMA

ARIMA adalah metode statistik yang sering digunakan dalam analisis deret waktu. Metode ini menggabungkan tiga komponen utama: autoregressive (AR), Model *Autoregressive Moving Average* (ARMA), dan *moving average* (MA). ARIMA sangat cocok untuk memodelkan data deret waktu yang stasioner setelah proses differencing, menjadikannya alat yang efektif untuk memprediksi pola jangka pendek [9].

ARIMA adalah singkatan dari *AutoRegressive Integrated Moving Average*. Model ARIMA adalah salah satu model seri waktu univariat yang hanya menggunakan variabel gabungan *differencing* dengan model *autoregressive* (AR), Model *Autoregressive Moving Average* (ARMA), dan *moving average* (MA). Sebagai contoh, model lengkap dapat ditulis sebagai berikut:

#### 1. Model *Autoregressive* (AR)

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t \quad (1)$$

Keterangan:

$Y_t$  = data pada periode ke-t, dimana  $t = 1, 2, \dots, n$

$Y_i$  = nilai lampau data ke i ( $i = t-1, t-2, t-3, \dots, t-p$ )

$\phi_0$  = konstanta

$\phi_i$  = parameter koefisien Autoregressive  $\phi_i$  ( $i=1, 2, 3, \dots, p$ )

$e_t$  = erro

#### 2. Model *Moving Average* (MA)

$$Y_t = \phi_0 + e_t - \phi_1 e_{t-1} + \phi_2 e_{t-2} - \dots - \phi_q e_{t-q} \quad (2)$$

Keterangan:

$Y_t$  = data pada periode ke-t

$e_t$  = galat pada periode ke-t

$\phi_0$  = konstanta

$\phi_i$  = parameter koefisien Moving Average  $\phi_i$  ( $i=1, 2, 3, \dots, p$ )

#### 3. Model *Autoregressive Moving Average* (ARMA)

$$Y_t = \phi_0 + \phi_1 Y_{t-1} \dots + \phi_p Y_{t-p} - \phi_1 e_{t-1} \dots - \phi_q e_{t-q} \quad (3)$$

Keterangan:

$Y_t$  = data pada periode ke-t, dimana  $t = 1, 2, \dots, n$

$Y_{t-1}$  = nilai lampau series yang bersangkutan

$e_{t-1}$  = kesalahan (error)

$e_t$  = kesalahan peramalan

$\phi_0$  = konstanta

$\phi_i$  = parameter koefisien Autoregressive  $\phi_i$  ( $i=1, 2, 3, \dots, p$ )

$\phi_i$  = parameter koefisien Moving Average  $\phi_i$  ( $i=1,2,3,..p$ )

Komponen ARIMA meliputi [10] :

AR (*Autoregressive*) adalah salah satu komponen dalam model deret waktu yang digunakan untuk memprediksi nilai masa depan berdasarkan nilai-nilai masa lalu. Dalam model AR, nilai saat ini dari suatu variabel bergantung secara linear pada sejumlah nilai sebelumnya dari variabel yang sama.

ARMA (*Autoregressive Moving Average*) adalah model statistik yang digunakan untuk menganalisis dan meramalkan data deret waktu stasioner dengan menggabungkan dua komponen utama, yaitu AR (*Autoregressive*) dan MA (*Moving Average*). Komponen AR memodelkan ketergantungan nilai saat ini terhadap nilai-nilai sebelumnya, sedangkan komponen MA memodelkan pengaruh kesalahan (*residual*) masa lalu terhadap nilai saat ini.

MA (*Moving Average*) adalah model dalam analisis deret waktu yang memprediksi nilai sekarang berdasarkan rata-rata tertimbang dari kesalahan (*error*) prediksi pada periode sebelumnya. Berbeda dengan AR yang menggunakan nilai masa lalu dari variabel itu sendiri, MA menggunakan residual-residual masa lalu sebagai dasar peramalan

#### 2.4.2 LSTM

LSTM adalah model turunan dari *Recurrent Neural Network* (RNN) yang dapat digunakan untuk memprediksi rangkaian data waktu dan dirancang untuk mengolah rangkaian data. Mengidentifikasi jumlah lapisan tersembunyi dan menentukan hyperparameter input yang tepat adalah beberapa hal yang harus dipertimbangkan saat membuat model LSTM yang baik. Arsitektur LSTM terdiri dari tiga lapisan: lapisan input, lapisan tersembunyi, dan lapisan output[11].

LSTM dapat mempertahankan ketergantungan pada jangka panjang antara data dan waktu tertentu dari banyak langkah waktu dengan menggunakan LSTM. Setiap jaringan saraf tiruan LSTM terdiri dari tiga gerbang kontrol: gerbang lupa (*forget gate*), gerbang masukan (*input gate*), dan gerbang keluaran [12].

LSTM memiliki beberapa keunggulan teknis yang menjadikannya pilihan utama dalam penelitian ini. Algoritma ini mampu mengatasi masalah yang sering kali menjadi kendala pada model RNN tradisional, sehingga memungkinkan pembelajaran yang lebih stabil dan efektif. Selain itu, LSTM dirancang dengan mekanisme *memory cell* yang dapat menyimpan informasi penting dari data berurutan dalam jangka waktu yang lebih panjang. Kemampuan ini sangat penting dalam prediksi CO<sub>2</sub>, karena pola tertentu dalam data historis mungkin memiliki dampak signifikan pada prediksi CO<sub>2</sub> di masa depan [13].

LSTM adalah syarat tiruan yang di gunakan khusus untuk menangani data sekuensial dengan ketergantungan jangka panjang. LSTM memiliki memori internal yang memungkinkan model untuk mengingat informasi penting dari data sebelumnya [14]. Struktur utama LSTM terdiri dari tiga gerbang:

- a. *Forget Gate*: Menghapus informasi yang tidak relevan dari memori.
- b. *Input Gate*: Menentukan informasi baru yang akan disimpan.
- c. *Output Gate*: Memutuskan informasi mana yang akan diteruskan ke langkah berikutnya.

LSTM sangat efektif untuk menganalisis data deret waktu yang kompleks dan memiliki ketergantungan temporal yang panjang.

#### 2.4.3 Hybrid

Dalam bidang pemodelan deret waktu (*time series forecasting*), pendekatan hibrida (*hybrid*) yang menggabungkan model statistik tradisional dengan model berbasis pembelajaran mesin telah menjadi salah satu strategi yang efektif untuk meningkatkan akurasi prediksi. Salah satu kombinasi yang banyak digunakan dalam berbagai studi empiris adalah gabungan antara metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Long Short-Term Memory* (LSTM). Pendekatan ini bertujuan untuk memanfaatkan kelebihan masing-masing metode sekaligus mengatasi keterbatasan yang ada jika hanya menggunakan salah satu pendekatan secara terpisah.

Metode ARIMA merupakan model statistik klasik yang digunakan untuk menganalisis dan meramalkan data deret waktu yang bersifat linier. ARIMA mampu menangkap struktur ketergantungan jangka pendek maupun jangka panjang dari data historis melalui komponen autoregressive (AR), differencing (I), dan moving average (MA). Model ini bekerja dengan baik apabila data memiliki pola yang stabil dan linier, serta mengikuti asumsi-asumsi dasar statistik seperti stasioneritas dan normalitas residual.

Namun demikian, dalam praktiknya, data deret waktu di dunia nyata sering kali mengandung pola-pola yang kompleks dan non-linier, seperti fluktuasi musiman yang tidak beraturan, perubahan mendadak, serta efek jangka panjang yang sulit dimodelkan hanya dengan metode linier seperti ARIMA. Di sinilah peran metode LSTM menjadi sangat penting. LSTM adalah salah satu varian dari Recurrent Neural Network (RNN) yang dirancang secara khusus untuk menangani masalah long-term dependencies dalam data sekuensial. Melalui arsitektur berbasis gates (input, forget, dan output gates), LSTM memiliki kemampuan untuk menyimpan informasi dalam jangka waktu yang lebih panjang dan menghindari masalah vanishing gradient yang umum terjadi pada RNN konvensional.

Dalam pendekatan hybrid ARIMA-LSTM, proses pemodelan umumnya dilakukan dalam dua tahap utama. Pertama, model ARIMA digunakan untuk menangkap dan memodelkan komponen linier dari data. Setelah model ARIMA selesai dilatih, residual atau kesalahan prediksi (selisih antara nilai aktual dan prediksi ARIMA) dihitung. Residual ini mengandung informasi pola non-linier yang tidak mampu dijelaskan oleh ARIMA. Pada tahap kedua, residual tersebut kemudian digunakan sebagai input bagi model LSTM. Model LSTM kemudian dilatih untuk mempelajari dan memprediksi komponen non-linier ini.

Hasil akhir dari pendekatan hybrid ini diperoleh dengan menjumlahkan output prediksi dari kedua model: prediksi linier dari ARIMA dan prediksi non-linier dari LSTM. Dengan demikian, model hybrid ARIMA-LSTM secara simultan mampu menangkap karakteristik linier dan non-linier dari data deret waktu, yang pada akhirnya meningkatkan akurasi dan keandalan prediksi secara keseluruhan.

Beberapa studi sebelumnya telah membuktikan efektivitas pendekatan hybrid ini, terutama dalam konteks data ekonomi, cuaca, permintaan energi, dan bahkan emisi gas rumah kaca. Hasil penelitian menunjukkan bahwa metode hybrid ini mampu mengurangi forecasting error secara signifikan jika dibandingkan dengan penggunaan metode ARIMA atau LSTM secara tunggal.

## 2.5 Validasi

Kinerja model prediksi dievaluasi menggunakan metrik seperti *Mean Absolute percentage Error* (MAPE), *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE). Metrik ini membantu menilai akurasi prediksi dengan membandingkan nilai prediksi dan nilai aktual. Nilai aktual dan nilai estimasi parameter model dapat dengan mudah diplot dengan RMSE [15].

### 2.5.1 RMSE

RMSE menghitung rata-rata dari selisih antara nilai prediksi dan nilai actual kemudian di ambil akar kuadratnya, semakin kecil nilai RMSE maka semakin bagus kualitas model. Jika nilai RMSE berada di bawah 10% dari rata-rata data aktual, model dianggap memiliki akurasi yang baik [16].

Rumus RMSE ditampilkan pada (2.4)

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - \hat{y}_1)^2} \quad (4)$$

### 2.5.2 MAE

RMSE menghitung rata-rata dari selisih antara nilai prediksi dan nilai actual kemudian di ambil akar kuadratnya, semakin kecil nilai RMSE maka semakin bagus kualitas model. Jika nilai RMSE berada di bawah 10% dari rata-rata data aktual, model dianggap memiliki akurasi yang baik [16].

Rumus MAE ditampilkan pada (2.5)

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i - \hat{y}_1| \quad (5)$$

### 2.5.3 MAPE

MAPE menghitung rata-rata dari selisih persentase antara nilai prediksi dan aktual. Dengan kata lain, MAPE menghitung beberapa rata-rata kesalahan dalam prediksi sebagai persentase dari nilai aktual. Semakin kecil nilai MAPE, semakin bagus kualitas model tersebut [17].

Jika nilai MAPE kurang dari 10% maka kemampuan model sangat baik

Jika nilai MAPE antara 10% - 20% maka kemampuan model baik

Jika nilai MAPE kisaran 20% - 50% maka kemampuan model layak

Jika nilai MAPE kisaran lebih dari 50% maka kemampuan model buruk

Rumus MAPE ditampilkan pada (2.6)

$$MAPE = \left(\frac{1}{n}\right) \sum_{i=1}^n |y_i - \hat{y}_1| \times 100\% \quad (6)$$

Keterangan pada rumus (2.4),(2.5)dan (2.6)

$y_i$ =actual


$\hat{y}_1$ =predict

$\tilde{y}$  = mean

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil

Berdasarkan hasil penelitian yang dilakukan, diperoleh prediksi jumlah emisi CO2 di Indonesia pada periode mendatang. Hasil prediksi ini diharapkan dapat menjadi acuan bagi pihak-pihak terkait, khususnya pembuat kebijakan di sektor lingkungan, untuk merancang strategi mitigasi yang lebih tepat sasaran. Prediksi dilakukan dengan membandingkan kinerja dua algoritma pemodelan deret waktu, yaitu ARIMA dan LSTM, guna memperoleh hasil yang lebih akurat dalam memproyeksikan tren emisi di masa depan. Gambar 3.1 merupakan data emisi CO2 yang di .ambil dari Emissions Database for Global Atmospheric Research (EDGAR) dari tahun 1970 sampai 2023




Gambar 2. Data Emisi CO2 di Indonesia

#### 3.1.1 ARIMA

RMSE : 2342.5139

MAE : 2341.5775

MAPE : 414.77%



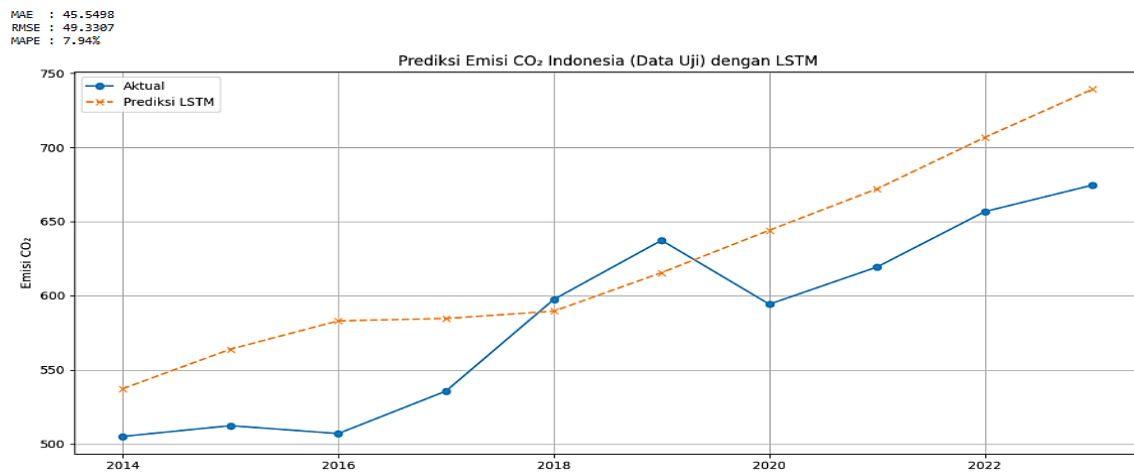
Gambar 3. Visualisasi Hasil ARIMA

Gambar yang ditampilkan merupakan hasil visualisasi prediksi emisi CO2 yang dihasilkan melalui penerapan metode ARIMA. Secara umum, model ini mampu menangkap arah tren jangka

panjang berdasarkan data historis yang menunjukkan kecenderungan peningkatan emisi dari tahun ke tahun. Namun demikian, bentuk grafik hasil prediksi tampak kurang dinamis, cenderung membentuk garis lurus, dan tidak secara akurat mencerminkan variasi naik-turun yang ada pada data aktual. Hal ini menunjukkan keterbatasan model ARIMA dalam merepresentasikan fluktuasi yang lebih kompleks dalam pola emisi CO<sub>2</sub>.

Untuk menilai kualitas prediksi yang dihasilkan, digunakan sejumlah indikator evaluasi, antara lain nilai *Root Mean Square Error* (RMSE) sebesar 2342.5139, nilai *Mean Absolute Error* (MAE) sebesar 2341.5775, dan *Mean Absolute Percentage Error* (MAPE) yang mencapai 414.77%. Nilai MAPE yang tinggi mengindikasikan adanya perbedaan persentase yang cukup signifikan antara hasil prediksi dengan data sebenarnya. Hal ini dapat disebabkan oleh cakupan nilai yang cukup besar dalam data atau adanya perubahan nilai yang bersifat ekstrem, yang tidak mampu ditangkap secara optimal oleh model. Meskipun demikian, model ARIMA tetap memberikan gambaran umum terhadap tren pertumbuhan emisi CO<sub>2</sub>, meskipun dengan akurasi yang terbatas dalam mencerminkan detail variasi tahunannya.

### 3.1.2 LSTM



Gambar 4. Visualisasi Hasil LSTM

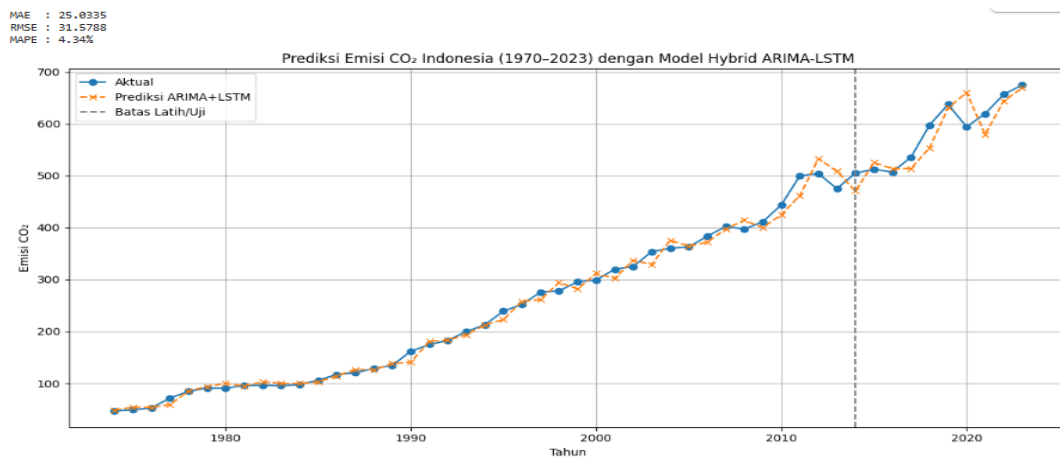
Gambar hasil peramalan emisi CO<sub>2</sub> menggunakan metode Long Short-Term Memory (LSTM) menunjukkan pola prediksi yang cenderung meningkat dari tahun ke tahun. Model LSTM berhasil mengenali tren jangka panjang dalam data historis, yang mencerminkan kecenderungan naiknya jumlah emisi CO<sub>2</sub> secara bertahap. Namun, meskipun tren yang ditunjukkan cukup jelas, pola prediksi LSTM terlihat lebih halus dan linier dibandingkan dengan fluktuasi aktual yang ada dalam data historis. Hal ini merupakan karakteristik umum dari model berbasis neural network yang cenderung melakukan generalisasi terhadap data input.

Berdasarkan hasil evaluasi performa, model LSTM memberikan nilai Mean Absolute Error (MAE) sebesar 45.5498, nilai Root Mean Square Error (RMSE) sebesar 49.3307, serta Mean Absolute Percentage Error (MAPE) sebesar 7,94%. Nilai-nilai tersebut menunjukkan bahwa model LSTM memiliki tingkat akurasi yang cukup tinggi, dengan tingkat kesalahan yang relatif kecil dalam

memprediksi data emisi CO<sub>2</sub>. Rendahnya nilai MAPE secara khusus menunjukkan bahwa prediksi model memiliki deviasi persentase yang sangat minim terhadap data aktual. Hal ini mengindikasikan bahwa LSTM mampu memberikan estimasi yang cukup presisi dan dapat diandalkan untuk memproyeksikan tren emisi CO<sub>2</sub> di masa mendatang.

Dengan demikian, meskipun grafik LSTM cenderung menampilkan pola prediksi yang lebih lurus, akurasi model berdasarkan metrik evaluasi menunjukkan kinerja yang sangat baik. Model ini dapat menjadi pilihan yang efektif dalam konteks peramalan jangka panjang, terutama ketika tujuan utama adalah untuk memahami arah umum atau tren pertumbuhan dari variabel yang diprediksi.

### 3.1.3 HYBRID



Gambar 5. Visualisasi Hasil ARIMA Dan LSTM

Gambar visualisasi hasil prediksi emisi CO<sub>2</sub> dengan pendekatan hybrid menunjukkan kecenderungan pola yang meningkat secara konsisten dari tahun ke tahun, mencerminkan tren jangka panjang yang teridentifikasi dalam data historis. Pendekatan ini memanfaatkan kekuatan model statistik untuk menangkap pola linier serta keunggulan jaringan saraf dalam mengolah ketergantungan jangka panjang dan pola non-linear. Hasilnya, prediksi yang dihasilkan menunjukkan kestabilan serta kesesuaian yang tinggi terhadap data aktual, dengan fluktuasi yang lebih mendekati kenyataan dibandingkan penggunaan metode tunggal.

Dari hasil evaluasi kuantitatif, pendekatan hybrid menghasilkan nilai *Mean Absolute Error* (MAE) sebesar 25.0335, *Root Mean Square Error* (RMSE) sebesar 31.5788, dan *Mean Absolute Percentage Error* (MAPE) sebesar 4,34%. Nilai-nilai tersebut menunjukkan tingkat kesalahan yang lebih rendah dibandingkan model individual, sekaligus mengindikasikan bahwa integrasi antara dua pendekatan mampu menghasilkan estimasi yang lebih presisi.

Dengan akurasi yang tinggi dan deviasi prediksi yang minimal terhadap data historis, model hybrid ini menunjukkan kinerja yang sangat baik dalam konteks peramalan deret waktu. Oleh karena itu, pendekatan ini dapat diandalkan sebagai alat prediktif untuk mendukung perencanaan strategis dalam pengelolaan emisi CO<sub>2</sub> jangka panjang.

### 3.2 Pembahasan

Berdasarkan hasil yang didapat di simpulkan bahwa hasil kombinasi/hybrid lebih baik dari pada menggunakan satu metode.berikut ini hasil pembahasan dari metode arima,metode lstm dan metode hybrid arima dan LSTM.

Hasil.

Tabel 1. Akurasi Predisi Setiap Metode

	<b>MAE</b>	<b>RMSE</b>	<b>MAPE</b>
<b>ARIMA</b>	2341.5775	2342.5139	414.77%),
<b>LSTM</b>	45.5498	49.3307	7.94%)
<b>HYBRID</b>	25.0335	31.5788	4.34%.

Tabel 1 menunjukkan perbandingan performa dari tiga pendekatan peramalan, yaitu ARIMA, LSTM, dan model hybrid ARIMA-LSTM. Evaluasi dilakukan berdasarkan tiga metrik utama: *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). Ketiga metrik ini digunakan untuk mengukur sejauh mana prediksi model mendekati nilai aktual emisi CO2.

Model ARIMA menghasilkan nilai MAE sebesar 2341.5775, RMSE sebesar 2342.5139, dan MAPE mencapai 414.77%. Nilai-nilai yang cukup besar tersebut menandakan bahwa model ARIMA memiliki tingkat kesalahan prediksi yang signifikan terhadap data aktual. Hal ini dapat disebabkan oleh keterbatasan model ARIMA dalam menangkap fluktuasi atau variasi non-linier yang terdapat pada data, serta kecenderungannya untuk hanya mengikuti pola tren secara linier. Nilai MAPE yang sangat tinggi menunjukkan bahwa prediksi yang dihasilkan oleh ARIMA tidak proporsional terhadap nilai sebenarnya, sehingga menghasilkan deviasi yang besar.

Sebaliknya, model LSTM menunjukkan performa yang jauh lebih baik dengan MAE sebesar 45.5498, RMSE sebesar 49.3307, dan MAPE sebesar 7.94%. LSTM, sebagai model berbasis deep learning yang dirancang untuk menangani data deret waktu non-linier dan jangka panjang, mampu memahami pola kompleks dan hubungan temporal dalam data emisi CO2. Nilai MAPE yang jauh lebih rendah menunjukkan bahwa model ini secara signifikan lebih akurat dalam memprediksi data dibandingkan dengan ARIMA.

Lebih lanjut, pendekatan hybrid ARIMA-LSTM menunjukkan hasil yang paling optimal, dengan MAE sebesar 25.0335, RMSE sebesar 31.5788, dan MAPE sebesar 4.34%. Pendekatan hybrid ini menggabungkan keunggulan ARIMA dalam menangani komponen linier dan LSTM dalam menangani pola non-linier. Kombinasi ini terbukti efektif dalam meningkatkan akurasi prediksi. Penurunan nilai kesalahan prediksi pada semua metrik menunjukkan bahwa integrasi kedua metode dapat menghasilkan model yang lebih robust dan adaptif terhadap karakteristik data yang kompleks.

Secara keseluruhan, hasil evaluasi ini mengindikasikan bahwa pemodelan berbasis LSTM dan hybrid ARIMA-LSTM memiliki keunggulan signifikan dibandingkan dengan metode ARIMA konvensional, khususnya dalam konteks peramalan emisi CO<sub>2</sub> yang memiliki karakteristik fluktuatif dan kecenderungan jangka panjang.

#### 4. KESIMPULAN

Dalam penelitian ini dilakukan evaluasi terhadap tiga pendekatan pemodelan untuk prediksi emisi CO<sub>2</sub>, yaitu model linier, model berbasis pembelajaran mendalam, serta kombinasi keduanya.

- a. Model linier menunjukkan kemampuan dalam mengikuti tren umum data historis, namun masih menghasilkan tingkat kesalahan yang cukup tinggi, dengan nilai RMSE sebesar 2342,5139, MAE sebesar 2341,5775, dan MAPE mencapai 414,77%. Hal ini menunjukkan bahwa pendekatan linier belum mampu menangkap kompleksitas dinamika data emisi CO<sub>2</sub> yang bersifat non-linear.
- b. Model berbasis pembelajaran mendalam menggunakan jaringan saraf sekuensial menunjukkan hasil yang lebih baik, dengan nilai MAE sebesar 45.5498, RMSE sebesar 49.3307, dan MAPE sebesar 7.94%. Peningkatan ini mencerminkan kemampuan model dalam mengidentifikasi pola temporal jangka panjang secara lebih akurat.
- c. Adapun pendekatan hybrid, yang merupakan gabungan antara teknik statistik dan pembelajaran mesin, menghasilkan performa terbaik dengan MAE sebesar 25.0335, RMSE sebesar 31.5788, dan MAPE hanya sebesar 4,34%. Hasil ini mengindikasikan bahwa kombinasi kedua metode mampu saling melengkapi, sehingga menghasilkan prediksi yang lebih akurat dan stabil dibandingkan penggunaan metode tunggal.

## DAFTAR PUSTAKA

- [1] A. Ahdiat, "Volume Emisi Gas Rumah Kaca Negara Asia Tenggara (2022)," databoks. [Online]. Available: <https://databoks.katadata.co.id/demografi/statistik/becca804ed928a4b/ini-perbandingan-emisi-gas-rumah-kaca-negara-asia-tenggara-pada-2022>
- [2] R. D. Purnomoasri and D. Handayani, "Analisis dan Mitigasi Emisi Gas Buang Akibat Transportasi (Studi Kasus Kabupaten Magetan)," *ENVIRO J. Trop. Environ. Res.*, vol. 24, no. 1, p. 29, 2022, doi: 10.20961/enviro.v24i1.65043.
- [3] M. Febriani Irma, "Tingginya Kenaikan Suhu Akibat Peningkatan Emisi Gas Rumah Kaca Di Indonesia," *JSSIT J. Sains dan Sains Terap.*, vol. 2, no. 1, pp. 26–32, 2024, doi: 10.30631/jssit.v2i1.49.
- [4] S. Ilma, N. Suwandi, R. Tyasnurita, and H. Muhayat, "Peramalan Emisi Karbon Menggunakan Metode SARIMA dan LSTM," vol. 6, no. 1, pp. 73–80, 2022.
- [5] A. Mutiara, N. Fitriyati, P. S. Matematika, U. Islam, N. Syarif, and H. Jakarta, "Analisis Laju Prediksi Inflasi Di Indonesia : Perbandingan Model Garch / Arch Dengan Long Short," vol. 4, no. 1, pp. 94–112, 2023.
- [6] Darajati, D. Nugroho, and A. Rianto, "Strategi Indonesia Dalam Mengurangi Emisi Karbon Dioksida (Co2) Di Masa New Normal," *Pros. Ilmu Pemerintah.*, vol. 1, no. 1, pp. 228–242, 2022, [Online]. Available: <https://e-journal.umc.ac.id/index.php/IP/article/view/2712>
- [7] I. S. I. Margareth, W. M. E. Pasaribu, Y. Pradjanata, and S. Pontoh, "Peramalan Kadar Konsentrasi Co 2 di Atmosfer Indonesia," 2023.
- [8] E. Commission, "Europaen Commission," *EDGAR - Emiss. Database Glob. Atmos. Res.*, 2023, [Online]. Available: <https://edgar.jrc.ec.europa.eu/>
- [9] A. Pramita, Nur Kholisoh, and Rohil Agatha Lusia, "Prediksi Emisi Gas Rumah Kaca Pada Sektor Energi Di Indonesia Menggunakan Model Arima," *Fraction J. Teor. dan Terap. Mat.*, vol. 3, no. 2, pp. 63–70, 2023, doi: 10.33019/fraction.v3i2.47.
- [10] H. Queenty and Sutarman, "Metode Autoregressive Integrated Moving Average (Arima) dalam Memprediksi Jumlah Penumpang Kereta Api Kota Binjai," *J. Arjuna Publ. Ilmu Pendidikan, Bhs. dan Mat.*, vol. 2, no. 2, pp. 69–85, 2024, doi: 10.61132/arjuna.v2i2.621.
- [11] D. Rizkya, H. Roosaputri, and C. Dewi, "Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan," *J. Penerapan Sist. Infomatika (Komputer Manajemen)*, vol. 4, no. 3, pp. 507–517, 2023.
- [12] W. Hastomo, N. Aini, A. S. B. Karno, and L. M. R. Rere, "Metode Pembelajaran Mesin untuk Memprediksi Emisi Manure Management," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 11, no. 2, pp. 131–139, 2022.
- [13] N. R. Hanum, "Implementation of Machine Learning for Stock Price Prediction Using the LSTM Algorithm," vol. 1, no. 1, pp. 31–37, 2024.
- [14] S. Sudriyanto, M. Faid, K. Malik, and A. Supriadi, "Evaluasi Model Jaringan Saraf Tiruan Berbasis LSTM dalam Memprediksi Fluktuasi Harga Bitcoin," *J. Adv. Res. Inform.*, vol. 2, no. 2, pp. 15–22, 2024, doi: 10.24929/jars.v2i2.3398.
- [15] W. Hastomo, N. Aini, A. Satyo, B. Karno, and L. M. R. Rere, "Metode Pembelajaran Mesin untuk Memprediksi Emisi Manure Management," vol. 11, no. 2, pp. 131–139, 2022.
- [16] Trivusi, "Perbedaan MAE, MSE, RMSE, dan MAPE pada Data Science," Trivusi. [Online]. Available: <https://www.trivusi.web.id/2023/03/perbedaan-mae-mse-rmse-dan-mape.html?>
- [17] R. Maulid, "Kriteria Jenis Teknik Analisis Data dalam Forecasting," dqqlab.