

PERBANDINGAN ALGORITMA ARIMA DAN LSTM DALAM PERAMALAN TINGKAT KONSENTRASI CO₂ EMISI ATMOSFER UNTUK MASA MENDATANG

Mandala Anugrah Putra, Septi Andryana

Sistem Informasi, Universitas Nasional

Jalan Sawo Manila Jakarta, Indonesia

2021.mandala.anugrah.putra@student.unas.ac.id

ABSTRAK

Perubahan iklim saat ini menjadi ancaman dan tantangan utama bagi kesejahteraan manusia secara global serta juga kesehatan dari planet. Faktor utama yang berkontribusi terhadap fenomena ini adalah aktivitas dari manusia, khususnya melalui emisi gas rumah kaca secara gamblang yang menyebabkan pemanasan suhu secara global. Penelitian bertujuan untuk membandingkan model *AutoRegressive Integrated Moving Average* (ARIMA), *Seasonal AutoRegressive Integrated Moving Average* (SARIMA), dan Long Short-Term Memory (LSTM) dalam meramalkan konsentrasi CO₂ atmosfer sebagai rekomendasi dalam pemilihan metode peramalan untuk mendukung pengambilan keputusan berbasis data dalam mitigasi perubahan iklim. Model *TimeSeries* dan *Machine Learning* digunakan dalam meramalkan konsentrasi CO₂ atmosfer dengan pendekatan dua skenario data yang berasal dari *National Oceanic and Atmospheric Administration*: data original (18.502 baris) dan data yang di *filter* berdasarkan beberapa hari terakhir (380 baris) saja. Hasil penelitian menunjukkan bahwa LSTM memiliki performa terbaik pada data lengkap dengan MSE: 1.823, RMSE: 1.350, MAE: 1.201, dan MAPE: 0.29%, sedangkan SARIMA lebih unggul pada data terbatas dengan MSE: 1.317, RMSE: 1.148, MAE: 0.894, dan MAPE: 0.21%. Temuan ini menegaskan bahwa LSTM lebih cocok untuk dataset banyak dan kompleks, sementara SARIMA lebih efektif untuk data sedikit dan terbatas.

Kata kunci : Peramalan Emisi CO₂, ARIMA, SARIMA, LSTM, TimeSeries, Machine Learning

1. PENDAHULUAN

Perubahan iklim menjadi ancaman global yang didorong oleh aktivitas manusia, terutama emisi gas rumah kaca yang menyebabkan pemanasan suhu bumi. Sejak abad ke-19, ilmuwan telah mengamati efek rumah kaca, di mana CO₂ menyerap dan memancarkan kembali radiasi inframerah, meningkatkan suhu permukaan bumi [1].

Pada 2024, emisi CO₂ global dari bahan bakar fosil mencapai rekor tertinggi 41,6 miliar ton, diperparah oleh fenomena *El Niño* yang meningkatkan deforestasi dan kebakaran hutan. Peningkatan ini mempercepat pemanasan global dan memicu cuaca ekstrem, sehingga diperlukan strategi mitigasi, termasuk peramalan konsentrasi CO₂ untuk mendukung pengambilan keputusan berbasis data [2] [3].

Penelitian ini bertujuan untuk membandingkan performa model ARIMA dan LSTM dalam peramalan konsentrasi CO₂ dengan menggunakan data terkini dalam dua skenario: dataset kecil dan dataset besar. Untuk mencapai tujuan tersebut, penelitian ini akan melalui beberapa tahapan, yaitu pengumpulan dan pra-pemrosesan data, filterisasi ukuran dataset berdasarkan tahun terakhir yang ditentukan, pemilihan serta pembangunan model ARIMA dan LSTM, evaluasi performa model menggunakan metrik seperti MAE, RMSE, dan MAPE, serta analisis hasil dan penyusunan kesimpulan. Dengan pendekatan ini, diharapkan penelitian dapat memberikan kontribusi dalam pengembangan metode peramalan yang lebih akurat serta mendukung kebijakan mitigasi perubahan iklim secara lebih efektif.

2. TINJAUAN PUSTAKA

Terdapat beberapa penelitian terdahulu membahas perbandingan ARIMA dan LSTM dalam peramalan konsentrasi CO₂ maupun topik lainnya. Penelitian-penelitian tersebut, seperti yang dilakukan oleh [4], [5], [6], dan [7], menunjukkan bahwa LSTM lebih unggul dalam beberapa aspek, tetapi terdapat faktor tertentu yang memengaruhi performa masing-masing model. Oleh sebab itu, penelitian ini diharapkan dapat memberikan analisis lebih mendalam mengenai keunggulan dan keterbatasan kedua model dalam berbagai skenario, sehingga dapat digunakan sebagai dasar dalam pengambilan keputusan terkait mitigasi emisi berbasis data.

2.1. Emisi CO₂

Emisi CO₂ Karbon dioksida (CO₂) adalah gas rumah kaca utama yang berkontribusi pada pemanasan global dengan memerangkap panas di Atmosfer [8]. Meskipun penting dalam menjaga suhu bumi, peningkatan berlebih CO₂ menyebabkan perubahan iklim ekstrem [9].

2.2. Machine Learning

Machine Learning (ML) adalah cabang kecerdasan buatan yang memungkinkan komputer belajar dari data untuk membuat prediksi [10]. Dalam analisis data deret waktu, metode statistik seperti ARIMA serta pendekatan ML seperti LSTM digunakan untuk meningkatkan akurasi peramalan [11].

Emisi CO₂ Karbon dioksida (CO₂) adalah gas rumah kaca utama yang berkontribusi pada pemanasan

global dengan memerangkap panas di *atmosfer* [8]. Meskipun Emisi Karbon penting dalam menjaga suhu bumi, peningkatan berlebih CO₂ menyebabkan perubahan iklim ekstrem [9].

2.3. Time Series

Peramalan deret waktu merupakan teknik yang digunakan untuk memprediksi kejadian di masa depan berdasarkan data historis yang disusun secara kronologis [12].

2.4. Long Short-Term Memory (LSTM)

LSTM adalah jenis *Recurrent Neural Network* (RNN) yang mampu menangkap pola data jangka panjang, mengatasi kelemahan RNN seperti hilangnya gradien [13].

Dengan tiga gerbang utama *input*, *forget*, dan *output*—LSTM yang membuat model ini dapat menyimpan informasi penting dan meningkatkan akurasi peramalan [14].

2.5. Autoregressive Integrated Moving Average (ARIMA)

ARIMA adalah model statistik untuk peramalan deret waktu yang dikembangkan oleh Box dan Jenkins. Model ini efektif untuk prediksi jangka pendek, tetapi memiliki keterbatasan dalam menangani data *non-stasioner* tanpa transformasi yang tepat [15].

2.6. Evaluasi Model

Evaluasi *indicator* adalah sebuah *indicator* yang ukuran atau indikator yang digunakan untuk mengukur kinerja dari model *machine learning* [16].

- *Mean Squared Error* (MSE) adalah *indicator* untuk Mengukur rata-rata kuadrat kesalahan prediksi [16].

Untuk rumus dapat dilihat pada persamaan 1 berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

- *Mean Absolute Error* (MAE) adalah *indicator* untuk mencari Rata-rata kesalahan *absolut* antara prediksi dan data *aktual* [16]. Untuk rumus MAE dapat dilihat pada persamaan 2 berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (2)$$

- *Mean Absolute Percentage Error* (MAPE) adalah *indicator* untuk Persentase kesalahan rata-rata dalam peramalan [17]. Untuk rumus MAPE dapat dilihat pada persamaan 3 berikut:


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \quad (3)$$

- *Root Mean Square Error* (RMSE) adalah *indicator* untuk mencari Akar dari rata-rata kuadrat kesalahan, semakin kecil nilai RMSE, semakin akurat model [17]. Untuk rumus RMSE dapat dilihat pada persamaan 4 berikut ini:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (4)$$

3. METODE PENELITIAN

Penelitian ini bertujuan untuk membandingkan performa algoritma ARIMA dan LSTM dalam peramalan emisi CO₂ karbon atmosfer menggunakan dua pendekatan data yang berbeda, yaitu (1) keseluruhan data yang tersedia dari NOAA dan (2) data yang *difilter* hanya pada 300 hari terakhir. Perbandingan ini dilakukan untuk mengidentifikasi performa masing-masing algoritma dalam kondisi data besar dan kecil, ke kompleksitasan dari data, dan sebagainya.




Gambar 1. Flowchart penelitian

Gambar 1 menunjukkan *flowchart* penelitian ini. Tahapan dimulai dengan mengunduh data dari NOAA, di ikuti *preprocessing* yang mencakup penggabungan kolom tanggal dan interpolasi untuk mengisi data hilang. Data kemudian dibagi menjadi dua skenario: seluruh dataset dan 300 hari terakhir, lalu dilakukan *train test split*. Model ARIMA dan LSTM dibangun untuk masing-masing skenario, kemudian dievaluasi menggunakan metrik seperti RMSE, MAE, dan MAPE. Hasil evaluasi dibandingkan untuk menganalisis performa kedua model, dan penelitian diakhiri dengan kesimpulan terkait efektivitas algoritma berdasarkan ukuran dataset.

3.1. Raw Data


Penelitian ini menggunakan data sekunder dari NOAA (*National Oceanic and Atmospheric Administration*), berupa rekaman harian konsentrasi CO₂ di atmosfer yang diukur di *Observatorium Mauna Loa* dari 19 Mei 1974 hingga 12 Januari 2025. Data di unduh dan diproses menggunakan metode *non-participant observer* tanpa keterlibatan langsung dalam pengumpulan. Tahap *preprocessing* meliputi penggabungan kolom tanggal ke format YYYY-MM-DD dan *interpolasi linier* untuk mengisi data yang hilang, memastikan kelengkapan dan konsistensi sebelum analisis lebih lanjut.

Setelah proses *preprocessing* dan pembersihan data selesai, langkah selanjutnya adalah memfilter 380 baris terakhir dari *dataset*. Data hasil pemfilteran ini kemudian disimpan dengan format nama yang baru. Sehingga, dalam penelitian ini, analisis dilakukan menggunakan dua skenario data yang sama dengan rentang panjangnya yang berbeda, guna untuk mengevaluasi bagaimana jumlah data yang digunakan dapat memengaruhi performa *algoritma* peramalan.



Gambar 2. Row data skenario pertama

Skenario pertama menggunakan keseluruhan dataset yang tersedia, terdiri dari 18.502 baris data dengan rentang waktu dari 19 Mei 1974 hingga 12 Januari 2025. Pendekatan ini memungkinkan model untuk mempelajari pola musiman jangka panjang serta tren emisi karbon yang terjadi dalam beberapa dekade terakhir. Penggunaan data dalam jumlah besar diharapkan dapat membantu model dalam memahami kompleksitas perubahan kadar CO₂ secara lebih mendetail dan akurat.



Gambar 3. Row data skenario kedua

Gambar 3 merupakan Row baris untuk Skenario kedua, ini menggunakan *subset* data yang hanya terdiri dari 380 hari terakhir, yaitu dari 2023-12-19 hingga 2024-12-31. Pemilihan rentang waktu ini dilakukan untuk melihat performa model dalam kondisi data yang lebih sedikit dan lebih baru, yang lebih relevan untuk peramalan jangka pendek. Pendekatan ini dapat mengungkap sejauh mana model tetap mampu menangkap pola tren dan fluktuasi dalam periode waktu yang lebih sempit.

3.2. ARIMA Model

Parameter model untuk ARIMA dalam peramalan ditentukan menggunakan dua pendekatan, yaitu pencarian *otomatis* dengan Auto-ARIMA dan pencarian manual melalui analisis karakteristik data. Pada pendekatan manual, pemilihan parameter dilakukan berdasarkan analisis plot ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*), serta melalui *Augmented Dickey-Fuller Test* (ADF) untuk pengujian stasioneritas untuk memastikan bahwa data telah memenuhi asumsi yang diperlukan dalam pemodelan ARIMA sehingga model mampu menangkap pola data secara akurat dan menghasilkan prediksi yang lebih baik.

3.2.1. Skenario Pertama ARIMA

Untuk skenario pertama yaitu skenario yang menggunakan keseluruhan data. Parameter yang direkomendasikan oleh Auto-ARIMA adalah parameter ARIMA (2,1,2)

```
Best model: ARIMA(2,1,2)(0,0,0)[0]
Total fit time: 464.790 seconds


SARIMAX Results
=====
Dep. Variable:      y      No. Observations:      18502
Model:              SARIMAX(2, 1, 2)      Log Likelihood: -12584.704
Date:              Wed, 19 Feb 2025      AIC: 25179.408
Time:              03:58:49      BIC: 25218.536
Sample:            - 18502      HQIC: 25192.258

Covariance Type:    opg
=====
coef    std err      z    P>|z|    [0.025    0.975]
-----
ar.L1      1.6129      0.007    246.033    0.000      1.600      1.626
ar.L2     -0.6196      0.007    -92.940    0.000     -0.633     -0.607
ma.L1     -1.9069      0.004   -482.063    0.000     -1.915     -1.899
ma.L2      0.9141      0.004    230.969    0.000      0.906      0.922
sigma2      0.2282      0.001    176.058    0.000      0.226      0.231
=====
Ljung-Box (L1) (Q):      0.09    Jarque-Bera (JB):      25331.70
```

Gambar 4. Auto-ARIMA hasil pencarian parameter skenario pertama

Pada Gambar 4 merupakan hasil dari summary pencarian parameter terbaik menggunakan Auto-ARIMA untuk skenario kedua ini, dan parameter Auto-ARIMA tidak mempertimbangkan komponen musiman, meskipun pengaturan *seasonal=True* telah diterapkan. Hal ini menunjukkan bahwa algoritma tidak mendeteksi pola musiman yang signifikan dalam data atau bahwa parameter lain, seperti *m* (periode musiman), tidak diatur dengan tepat. Akibatnya, model yang dihasilkan cenderung berperilaku seperti ARIMA *non*-musiman, yang dapat mempengaruhi akurasi peramalan dalam menangkap pola periodik dari data CO₂ atmosfer.

Auto-ARIMA merekomendasikan model ARIMA(2,1,2), akan tetapi model ini tidak mampu dalam menangkap pola musiman yang terlihat pada data, sehingga hasil peramalan kurang akurat dalam merepresentasikan tren yang ada pada data.



Gambar 5. Peramalan Auto-ARIMA skenario pertama

Dapat dilihat pada Gambar 5 bahwa hasil peramalan menggunakan parameter yang disarankan oleh Auto-ARIMA tidak mampu untuk menangkap pola musiman yang terlihat pada data.


Sementara itu, akan dilakukan pemilihan parameter ARIMA secara manual melalui analisis Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF), serta pengujian stasioneritas menggunakan *Augmented Dickey-Fuller* Test (ADF). Didapatkan hasil parameter untuk model dalam skenario pertama ini adalah model (1,1,5)(1,1,12)

Berdasarkan plot *Seasonal Decomposition* menunjukkan bahwa data memiliki pola musiman tahunan, sehingga pemilihan *s* = 12 dianggap representatif. Uji ADF menunjukkan bahwa data tidak stasioner, sehingga *d* = 1, karena setelah *differencing* 1 data mencapai nilai stasioneritas.

Dan pada Plot ACF mengindikasikan nilai *Moving Average* (MA) = 5, karena setelah *lag* 5 tidak ada peningkatan signifikan dalam performa model. Sementara itu, plot PACF menunjukkan korelasi parsial signifikan pada *lag* 1, sehingga *p* = 1 yang dipilih. Sehingga didapatkan hasil parameter untuk model pada skenario pertama ini adalah model (1,1,5)(1,1,12)

Auto-ARIMA merekomendasikan ARIMA (2,1,2) tanpa komponen musiman, sedangkan analisis

manual menunjukkan bahwa ARIMA(1,1,5)(1,1,12) lebih mampu menangkap pola musiman. Dan untuk rasio data latih dan data uji, rasio yang dipilih adalah rasio 90:10 dipilih karena menghasilkan nilai error yang lebih rendah.



Gambar 6. Peramalan ARIMA seasonal manual pada skenario pertama

Pada gambar 6 menunjukkan bahwa model ARIMA(1,1,5)(1,1,12) mampu merepresentasikan pola kenaikan dalam data aktual, meskipun hasil peramalannya menunjukkan kenaikan terus-menerus dalam beberapa periode tertentu. Hal ini menunjukkan bahwa model berhasil menangkap tren serta pola musiman dengan periode 12, yang mengindikasikan adanya pengaruh


3.2.2. Skenario Kedua ARIMA

Untuk skenario kedua ini adalah skenario yang menggunakan 380 baris terakhir dan *parameter* yang direkomendasikan oleh Auto-ARIMA adalah *parameter* ARIMA(5,1,4).

SARIMAX Results						
Dep. Variable:	y	No. Observations:	378			
Model:	SARIMAX(5, 1, 4)	Log Likelihood	-353.245			
Date:	Thu, 20 Feb 2025	AIC	726.491			
Time:	05:16:11	BIC	765.813			
Sample:	0	HQIC	742.099			
Covariance Type:	- 378 opg					
	coef	std err	z	P> z	[0.025	0.975]
ar.L1	-0.0946	0.055	-1.719	0.086	-0.202	0.013
ar.L2	1.3829	0.066	20.984	0.000	1.254	1.512
ar.L3	0.2348	0.060	3.933	0.000	0.118	0.352
ar.L4	-0.5964	0.060	-9.934	0.000	-0.714	-0.479
ar.L5	0.0227	0.045	0.502	0.616	-0.066	0.111
ma.L1	-0.0781	0.048	-1.620	0.105	-0.173	0.016
ma.L2	-1.6870	0.055	-30.733	0.000	-1.795	-1.579
ma.L3	-0.0925	0.050	-1.854	0.064	-0.190	0.005
ma.L4	0.8897	0.047	18.775	0.000	0.797	0.983
sigma2	0.3694	0.019	19.183	0.000	0.332	0.407
Ljung-Box (L1) (Q):	0.00	Jarque-Bera (JB):	148.11			
Prob(Q):	0.96	Prob(JB):	0.00			
Heteroskedasticity (H):	0.51	Skew:	-0.34			
Prob(H) (two-sided):	0.00	Kurtosis:	5.99			

Gambar 7. Auto-ARIMA hasil pencarian parameter skenario kedua

Pada Gambar 7 merupakan hasil dari *summary* dari pencarian parameter terbaik menggunakan Auto-ARIMA terhadap skenario kedua ini, parameter yang disarankan oleh Auto-ARIMA lagi-lagi tidak mempertimbangkan komponen dari musiman. Dan Auto-ARIMA untuk skenario kedua ini merekomendasikan model ARIMA(5,1,4), tetapi model ini tidak mampu untuk menangkap pola musiman yang terlihat pada data, ARIMA tidak dapat untuk merepresentasikan tren yang ada pada data.



Gambar 8. Peramalan Auto-ARIMA skenario kedua

Pada Gambar 8, dapat dilihat bahwa hasil peramalan yang dilakukan oleh model Auto-ARIMA terhadap data aktual dari 380 baris, terlihat bahwa model tidak mampu dalam menangkap pola musiman yang ada, sehingga hasil prediksi cenderung lebih halus dan kurang *responsif* terhadap *fluktuasi* yang terjadi dalam data aktual. Hal ini tampak dari garis prediksi (kuning) yang tidak mengikuti puncak dan lembah data aktual (biru) secara optimal, terutama pada bagian data pengujian di luar periode pelatihan.

Selain itu, dilakukan pula pencarian parameter manual menggunakan metode analisis plot ACF dan PACF, uji stasioneritas (ADF Test), dan analisis grafik *seasonal decomposition*.


Analisis data dengan analisis dekomposisi data 380 baris menunjukkan fluktuasi emisi CO₂ dengan pola yang berulang secara teratur. Komponen tren memperlihatkan peningkatan bertahap dalam jangka panjang, sementara komponen musiman menyoroti pola siklus tahunan. Pemilihan nilai $s = 12$ didasarkan pada asumsi yang didapat dari analisis, bahwa data memiliki pola musiman tahunan, di mana satu tahun terdiri dari 12 bulan. Dan karena karakteristik data harian menunjukkan siklus berulang dalam interval bulanan, sehingga pemilihan $s = 12$ lebih representatif dalam menangkap pola musiman yang ada.

Untuk skenario kedua ini juga hasil dari *Augmented Dickey-Fuller Test* (ADF) menunjukan hasil bahwa data asli dari 380 baris terkahir bersifat tidak stasioner, yang berarti terdapat tren atau pola yang berkembang seiring waktu. Oleh karena itu, diperlukan *differencing* sebanyak satu kali untuk menghilangkan tren dan mencapai kondisi stasioner. Sehingga dapat disimpulkan bahwa $d = 1$ adalah nilai *differencing* yang optimal untuk model ARIMA, karena nilai sudah mencapai stasioneritas.

Sedangkan untuk mencari parameter q atau *Moving Average* dari model pada data 380 baris terkahir juga digunakan dengan cara analisis plot Autocorrelation (ACF). Yang mana, menunjukan bahwa nilai q untuk baris 380 baris terkahir (skenario kedua) menunjukan bahwa nilai q sangat besar karena pada plot ACF menunjukan nilai *autokorelasi* yang tinggi dan positif pada banyak *lag*, ini mengindikasikan bahwa data 380 baris ini memiliki memori jangka panjang yang kuat. Artinya, nilai-nilai masa lalu hingga *lag* yang jauh masih memiliki pengaruh yang signifikan pada nilai saat ini

Dan berdasarkan analisis plot *Partial Autocorrelation* (PACF) yang terlihat bahwa batang *autokorelasi* pada *lag 1* sangat tinggi dan signifikan. Kemudian, batang-batang pada *lag 2* dan seterusnya menurun dengan cepat dan mendekati nol. Ini menunjukkan bahwa korelasi parsial yang signifikan hanya terjadi pada *lag 1*. Namun, jika dilihat kenaikan juga terjadi pada *lag 4* dan *14*. Kenaikan ini perlu dipertimbangkan karena dapat mengindikasikan adanya korelasi parsial yang signifikan pada lag-lag tersebut.

Sehingga, dapat disimpulkan bahwa nilai p yang sesuai untuk model ARIMA pada skenario kedua adalah 1 dan 4. Berdasarkan analisis plot ACF, PACF, serta uji stasioneritas (ADF Test), diperoleh bahwa parameter yang cocok untuk model dalam skenario ini adalah ARIMA *seasonal* dengan parameter ARIMA(1,1,1)(1,1,0,12) dan ARIMA(1,1,4)(1,1,0,12) dengan komponen musiman. Dari kedua model tersebut, model ARIMA(1,1,4)(1,1,0,12) dipilih sebagai model terbaik berdasarkan kinerja peramalan yang lebih akurat dalam menangkap pola tren dan musiman dalam data.



Gambar 9. Peramalan ARIMA seasonal manual pada skenario kedua

Dapat dilihat pada Gambar 9 yang merupakan Grafik hasil peramalan menggunakan model yang terpilih secara manual berdasarkan analisis *Seasonal Decompose*, PACF, ACF, dan stasioneritas. Yang mana model yang terpilih tersebut adalah model parameter ARIMA(1,1,4) dengan parameter *Seasonal* (1,1,0,12). Pada gambar 9 dapat dilihat bahwa ARIMA(1,1,4) (1,1,0,12) mampu merepresentasikan pola kenaikan dan penurunan secara naik turun dan bersiklus, atau dengan kata lain ini mengindikasikan bahwa model mampu untuk menangkap dan mendapatkan pola musiman dalam data actual 380 baris ini dengan cukup baik.

3.3. LSTM model

Untuk model *Long Short-Term Memory* (LSTM) merupakan pendekatan berbasis machine learning dan deep learning dalam peramalan konsentrasi CO₂ atmosfer. Arsitektur atau parameter yang digunakan dalam penelitian ini meliputi:

Tabel 1. Arsitektur dan parameter yang digunakan dalam model LSTM.

Arsitektur	Fungsi
Batch Size	Menentukan jumlah sampel dalam setiap iterasi pelatihan sebelum parameter model diperbarui.
Epochs	Jumlah iterasi penuh melalui dataset pelatihan yang dilakukan selama proses pelatihan model.
Neurons	Jumlah unit dalam lapisan LSTM yang digunakan untuk menangkap pola dan hubungan dalam data.
Dense Layer	Lapisan feedforward setelah LSTM yang digunakan untuk menghasilkan output akhir dari model.
Optimizer	Algoritma optimasi yang digunakan untuk memperbarui bobot model berdasarkan gradien error.
Sequential Model	Arsitektur model yang disusun secara berurutan dengan beberapa lapisan LSTM dan lapisan Dense untuk menghasilkan prediksi.

Dalam tabel 1 dijelaskan *arsitektur* model yang akan digunakan pada penelitian ini. Pencarian nilai *arsitektur* model akan di sesuaikan berdasarkan hasil *eksplorasi* hiperparameter untuk memastikan model memiliki performa optimal dalam peramalan konsentrasi CO₂ atmosfer. Pemilihan jumlah *neurons*, *batch size*, *epochs*, dan konfigurasi lapisan lainnya dilakukan melalui percobaan bertahap untuk mendapatkan keseimbangan antara akurasi dan efisiensi komputasi.


3.3.1. LSTM Pada Skenario Pertama

Pada skenario pertama, yang mana skenario yang menggunakan data keseluruhan (1.8502 Rows). Dan untuk *parameter* atau *arsitektur* terbaik LSTM untuk skenario pertama ini adalah dapat dilihat pada Tabel 2.

Tabel 2. Parameter terbaik untuk model LSTM pada skenario Pertama

Arsitektur	Fungsi
Batch Size	32
Epochs	100
Neurons	100
Dense Layer	1
Optimizer	Adam Optimizer
Model	Sequential
Rasio	90:10

Tabel 2 merupakan deskripsi tentang *arsitektur parameter* LSTM yang digunakan pada skenario pertama ini. Arsitektur tersebut dipilih karena konfigurasi tersebutlah yang memberikan performa Terbaik dalam peramalan berdasarkan *metrik* evaluasi dibanding dengan *parameter arsitektur* yang lain. pada skenario pertama (data banyak) ini.



Gambar 10. Kinerja LSTM yang dipilih pada skenario pertama

Pada Gambar 10 merupakan grafik dari Kinerja parameter LSTM yang dipilih pada skenario pertama. Yang mana pada gambar tersebut terlihat perbandingan antara data emisi CO₂ aktual, data latih, dan data peramalan yang dihasilkan oleh model LSTM. Secara visual, terlihat bahwa garis peramalan (berwarna merah) sangat dekat mengikuti garis data aktual (berwarna biru), terutama pada bagian data uji yang mana data peramalan menutupi garis dari data uji. Hal ini menunjukkan bahwa model LSTM mampu menangkap pola dan tren data dengan baik pada skenario pertama (1.8502 Rows).

3.3.2. LSTM Pada Skenario Kedua


Pada LSTM skenario kedua, merupakan skenario yang menggunakan data (380 Rows) didapatkan bahwa *parameter* atau *arsitektur* terbaik LSTM untuk skenario kedua ini dapat dilihat pada Tabel 3 berikut ini.

Tabel 3. Parameter terbaik untuk model LSTM pada skenario Pertama

Arsitektur	Fungsi
Batch Size	64
Epochs	50
Neurons	50
Dense Layer	1
Optimizer	Adam Optimizer
Model	Sequential
Rasio	90:10

Pada Tabel 3 berisi tentang parameter untuk LSTM yang digunakan untuk skenario kedua, yang mana parameter tersebut merupakan parameter dengan performa *metrik* evaluasi yang terbaik di bandingkan dengan parameter konfigurasi lainnya Terhadap Kasus skenario kedua ini.

Pada Gambar 11 merupakan Kinerja dari parameter LSTM yang terpilih yang mana merupakan parameter yang Terbaik pada Kasus skenario kedua. Dapat dilihat bahwa perbandingan antara data emisi CO₂ aktual, data latih, dan data prediksi yang dihasilkan oleh model LSTM pada skenario kedua. Berbeda dengan skenario pertama, terlihat bahwa garis prediksi (berwarna merah) tidak dapat mengikuti garis data aktual (berwarna biru). Prediksi model LSTM tersebut terlihat tidak Mampu untuk menangkap pola data dengan baik pada Kasus skenario kedua ini (data yang sedikit).



Gambar 11. Kinerja LSTM yang dipilih pada skenario kedua

4. HASIL DAN PEMBAHASAN


4.1. Perbandingan Skenario Pertama

Perbandingan skor evaluasi masing-masing model pada skenario pertama dapat dilihat pada Tabel 4 berikut

Tabel 4. Perbandingan evaluasi model skenario pertama

Model	MSE	RMSE	MAE	MAPE
Auto-ARIMA	40.7306	6.3821	5.2242	1.24%
SARIMA	13.2456	3.6394	3.0166	0.72%
LSTM	1.823	1.350	1.201	0.29%

Tabel 4 merupakan record untuk hasil Evaluasi dari masing-masing skor pada skenario pertama (data 1.8501 Rows) yang menunjukkan bahwa LSTM memiliki nilai yang terbaik dibandingkan dengan model lainnya, yaitu Auto-ARIMA dan SARIMA. LSTM menunjukkan nilai MSE, RMSE, MAE, dan MAPE yang lebih kecil, yang menandakan bahwa model ini memiliki tingkat kesalahan prediksi yang lebih rendah dibandingkan model lainnya. Serta model yang paling baik dalam melakukan peramalan CO₂ untuk Kasus skenario pertama (data yang banyak).



Gambar 12. Grafik perbandingan model pada skenario pertama

Di gambar 12, model LSTM (garis ungu) mampu untuk menangkap pola data dengan sangat baik, sementara ARIMA Seasonal atau SARIMA (garis hijau) hanya menangkap tren kenaikan secara bertahap tanpa menunjukkan fluktuasi siklus naik turun. Sedangkan Model yang direkomendasikan Auto-ARIMA (garis biru) juga cenderung menghasilkan peramalan mendatar setelah kenaikan awal, menunjukkan keterbatasan dalam menangkap pola kompleks pada data skala besar.

Hasil ini menunjukkan bahwa ARIMA dan SARIMA kurang efektif dalam menangani *variabilitas* data emisi CO₂ dalam jumlah besar, sedangkan LSTM lebih unggul karena kemampuannya dalam mempelajari pola *temporal* yang lebih kompleks. Dengan *arsitektur* jaringan saraf rekurensya, LSTM dapat menangkap dinamika jangka panjang yang sulit ditangkap oleh model statistik *konvensional*, menghasilkan prediksi yang lebih akurat.


4.2. Perbandingan Skenario Kedua

Perbandingan skor evaluasi masing-masing model pada skenario kedua dapat dilihat pada tabel 5 berikut ini.

Tabel 5. Perbandingan evaluasi model skenario kedua

Model	MSE	RMSE	MAE	MAPE
Auto-ARIMA	1.125	1.060	0.858	0.20%
SARIMA	0.546	0.739	0.481	0.11%
LSTM	1.317	1.148	0.894	0.21%

Berdasarkan Tabel 5, model SARIMA menunjukkan performa terbaik pada skenario kedua dengan nilai MSE, RMSE, MAE, dan MAPE yang lebih rendah dibandingkan Auto-ARIMA dan LSTM. MAPE SARIMA hanya 0.11%, lebih kecil dari Auto-ARIMA (0.20%) dan LSTM (0.21%), menunjukkan akurasi yang lebih tinggi. Sebaliknya, meskipun unggul pada skenario pertama, LSTM kurang optimal dalam skenario kedua dengan MSE dan RMSE yang lebih tinggi. Oleh karena itu, SARIMA merupakan model terbaik untuk skenario kedua karena menghasilkan kesalahan prediksi paling rendah.



Gambar 12. Grafik perbandingan model pada skenario pertama

Pada skenario kedua (380 baris data), LSTM gagal menangkap pola, menghasilkan prediksi mendatar dan tidak sensitif terhadap perubahan data. ARIMA menunjukkan kinerja lebih baik tetapi masih cenderung linear dan kurang fleksibel terhadap fluktuasi jangka pendek. SARIMA (ARIMA(1,1,4)(1,1,0,12)) memiliki kinerja terbaik, mampu menangkap tren dan fluktuasi dengan lebih akurat dibandingkan model lainnya. Secara keseluruhan, SARIMA adalah model terbaik dalam skenario ini, diikuti oleh ARIMA, sementara LSTM menunjukkan kinerja terburuk karena keterbatasan data.

5. KESIMPULAN DAN SARAN

Penelitian ini mengevaluasi kinerja ARIMA, SARIMA, dan LSTM dalam meramalkan emisi CO₂ atmosfer menggunakan dua skenario data: lengkap (18.502 baris) dan terbatas (380 baris). Hasil menunjukkan bahwa LSTM unggul dalam skenario data lengkap dengan akurasi prediksi tertinggi, berkat kemampuannya menangkap pola temporal dan hubungan non-linear. Namun, pada data terbatas, SARIMA memberikan hasil terbaik karena lebih mampu mengadaptasi pola musiman dan tren. Temuan ini menegaskan bahwa pemilihan model peramalan harus disesuaikan dengan karakteristik dan jumlah data, di mana LSTM lebih sesuai untuk dataset besar dan kompleks, sedangkan SARIMA lebih optimal untuk data yang terbatas. Hasil penelitian ini dapat menjadi panduan dalam memilih metode prediksi emisi CO₂ yang paling efektif untuk mendukung upaya mitigasi perubahan iklim. Sebagai saran, penelitian selanjutnya dapat mengeksplorasi kombinasi model ARIMA, SARIMA, dan LSTM yang dikombinasikan untuk meningkatkan akurasi peramalan, terutama untuk menghadapi dataset dengan karakteristik yang beragam.

DAFTAR PUSTAKA

- [1] The Carbon Dioxide Greenhouse Effect, "The Discovery of Global Warming," The Carbon Dioxide Greenhouse Effect. Accessed: Sep. 12, 2024. [Online]. Available: <https://history.aip.org/climate/index.htm>
- [2] Global Karbon Project, "Fossil fuel CO₂ emissions increase again in 2024," Global Karbon Project. Accessed: Sep. 20, 2024. [Online]. Available: <https://globalcarbonbudget.org/fossil-fuel-co2-emissions-increase-again-in-2024/>
- [3] S. Giannelos, F. Bellizio, G. Strbac, and T. Zhang, "Machine learning approaches for predictions of CO₂ emissions in the building sector," *Electric Power Systems Research*, vol. 235, Oct. 2024, doi: 10.1016/j.epsr.2024.110735.
- [4] T. Wen, Y. Liu, Y. he Bai, and H. Liu, "Modeling and forecasting CO₂ emissions in China and its regions using a novel ARIMA-LSTM model," *Heliyon*, vol. 9, no. 11, Nov. 2023, doi: 10.1016/j.heliyon.2023.e21241.
- [5] S. Ilma, N. Suwandi, R. Tyasnurita, and H. Muhayat, "Peramalan Emisi Karbon Menggunakan Metode SARIMA dan LSTM (Forecasting Carbon Emissions Using the SARIMA and LSTM Methods)," Jun. 2022. [Online]. Available: <http://jcosine.if.unram.ac.id/>
- [6] Q. Ai *et al.*, "Comparative Analysis of ARIMA and LSTM Model-Based Anomaly Detection for Unannotated Structural Health Monitoring Data in an Immersed Tunnel," *CMES - Computer Modeling in Engineering and Sciences*, vol. 139, no. 2, pp. 1797–1827, 2024, doi: <https://doi.org/10.32604/cmes.2023.045251>.
- [7] L. Ji, Y. Zou, K. He, and B. Zhu, "Carbon futures price forecasting based with ARIMA-CNN-LSTM model," in *Procedia Computer Science*, Elsevier B.V., 2019, pp. 33–38. doi: 10.1016/j.procs.2019.11.254.
- [8] European Union, "Glossary:Carbon dioxide emissions," European Union. Accessed: Sep. 12, 2024. [Online]. Available: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:Carbon_dioxide_emissions
- [9] Climate Kids, "Why Is Carbon Important," Nasa Government. Accessed: Feb. 21, 2025. [Online]. Available: <https://climatekids.nasa.gov/carbon/>
- [10] IBM, "What is Machine Learning," IBM. Accessed: Dec. 30, 2023. [Online]. Available: https://www-ibm-com.translate.goog/topics/machine-learning?_x_tr_sl=en&_x_tr_tl=id&_x_tr_hl=id&_x_tr_pto=tc
- [11] Marita Sulistyaningwarni Nurjamil, "Metode Analisis ARIMA Untuk Peramalan Jumlah Penumpang Kereta Api di Pulau Jawa," RPub by RStudio. Accessed: Apr. 01, 2024. [Online]. Available: <https://rpubs.com/MaritaNurjamil/prakkomstatG>
- [12] Md. R. Sarkar *et al.*, "GATE: A guided approach for time series ensemble forecasting," *Expert Syst Appl*, vol. 235, p. 121177, 2024, doi: <https://doi.org/10.1016/j.eswa.2023.121177>.
- [13] R. Zhang, H. Song, Q. Chen, Y. Wang, S. Wang, and Y. Li, "Comparison of ARIMA and LSTM for prediction of hemorrhagic fever at different time scales in China," *PLoS One*, vol. 17, no. 1, p. e0262009, Jan. 2022, doi: 10.1371/journal.pone.0262009.
- [14] Konstantin Kutzkov, "ARIMA vs Prophet vs LSTM for Time Series Prediction," neptune.ai. Accessed: May 30, 2024. [Online]. Available: <https://neptune.ai/blog/arima-vs-prophet-vs-lstm>
- [15] William W.S. Wei, *Time Series Analysis Univariate and Multivariate Methods*, 2nd Edition., vol. ISBN: 0-321-32216-9. Pearson Addison, 2006.
- [16] Administrator, "Metrik Untuk Mengukur Peforma Machine Learning," ivosights. Accessed: Feb. 21, 2025. [Online]. Available: <https://ivosights.com/read/artikel/machine-learning-metrik-untuk-mengukur-peforma>
- [17] Belajar Data Science di Rumah, "Kriteria Jenis Teknik Analisis Data dalam Forecasting," dqlab. Accessed: Feb. 21, 2025. [Online]. Available: <https://dqlab.id/kriteria-jenis-teknik-analisis-data-dalam-forecasting>