

ANALISIS KOMPARATIF ARIMA, SINGLE DAN DOUBLE EXPONENTIAL SMOOTHING UNTUK PERAMALAN KUALITAS UDARA MULTI-POLUTAN DENGAN PENYESUAIAN BERBASIS KORELASI

Suvriadi Panggabean^{1*)}, Faridawaty Marpaung², Zulfahmi Indra³, Lasker P Sinaga⁴
^{1,2,3,4}Universitas Negeri Medan, Medan, Sumatera Utara
^{*)}suvriadi@unimed.ac.id

Abstrak

Peramalan kualitas udara merupakan aspek krusial dalam perlindungan kesehatan masyarakat dan pengelolaan lingkungan. Penelitian ini mengembangkan sistem peramalan multi-polutan yang mempertimbangkan korelasi antar polutan untuk memprediksi Indeks Kualitas Udara (AQI) di Deli Tua, Sumatera Utara. Tiga metode time series dibandingkan: Single Exponential Smoothing (SES), Double Exponential Smoothing (DES), dan ARIMA. Dataset terdiri dari 247 pengamatan per jam dari 10-20 September 2025, mencakup parameter PM2.5, PM10, O₃, NO₂, SO₂, dan AQI. Hasil penelitian menunjukkan bahwa ARIMA mencapai kinerja terbaik dengan MAPE rata-rata 15,49%, diikuti SES (16,13%) dan DES (20,19%). Untuk prediksi AQI secara khusus, ARIMA memperoleh MAPE 24,04%, SES 25,36%, dan DES 30,23%. Korelasi kuat diidentifikasi antara PM2.5 dan PM10 ($r=0,995$) serta antara O₃ dan NO₂ ($r=-0,902$), yang dimanfaatkan melalui mekanisme penyesuaian untuk meningkatkan akurasi peramalan. Pendekatan multi-polutan ini mendemonstrasikan bahwa mengintegrasikan hubungan antar-polutan dapat meningkatkan reliabilitas prediksi untuk sistem peringatan dini kualitas udara.

Kata Kunci: Peramalan Kualitas Udara; Exponential Smoothing; ARIMA; Multi-Polutan; Indeks Kualitas Udara

Abstract

Air quality forecasting is crucial for public health protection and environmental management. This study develops a multi-pollutant forecasting system that considers correlations between pollutants to predict Air Quality Index (AQI) in Deli Tua, North Sumatra. Three time series methods were compared: Single Exponential Smoothing (SES), Double Exponential Smoothing (DES), and ARIMA. The dataset comprises 247 hourly observations from September 10-20, 2025, including PM2.5, PM10, O₃, NO₂, SO₂, and AQI parameters. Results demonstrate that ARIMA achieved the best performance with an average MAPE of 15.49%, followed by SES (16.13%) and DES (20.19%). For AQI prediction specifically, ARIMA obtained MAPE of 24.04%, SES 25.36%, and DES 30.23%. Strong correlations were identified between PM2.5 and PM10 ($r=0.995$) and between O₃ and NO₂ ($r=-0.902$), which were leveraged through an adjustment mechanism to improve forecasting accuracy. This multi-pollutant approach demonstrates that incorporating inter-pollutant relationships enhances prediction reliability for air quality early warning systems.

Keywords: Air Quality Forecastin; Exponential Smoothing; ARIMA; Multi-Pollutant; Air Quality Index

Pendahuluan

Kualitas udara telah menjadi perhatian kritis lingkungan dan kesehatan masyarakat secara global, khususnya di daerah perkotaan dan industri (Khusna et al., 2023). Indeks Kualitas

Udara (AQI) berfungsi sebagai indikator utama untuk mengukur tingkat polusi dan dampak kesehatan terhadap masyarakat (Oktavia & Witanti, 2024). Prediksi kualitas udara yang akurat sangat esensial untuk sistem peringatan dini dan pengambilan keputusan yang informatif dalam pengelolaan lingkungan (Perdana et al., 2023). Dalam konteks lokal, studi terkini di Deli Tua, Sumatera Utara, telah mengembangkan sistem peramalan multi-polutan berbasis time series dengan mempertimbangkan korelasi antar polutan (PM_{2.5}, PM₁₀, O₃, NO₂, SO₂) untuk memprediksi AQI, menunjukkan bahwa pendekatan ini mampu meningkatkan reliabilitas prediksi dibandingkan pendekatan univariat. Secara empiris, data pengamatan per jam selama periode 10–20 September 2025 menunjukkan rata-rata AQI sebesar 81,2 (kategori sedang) dengan fluktuasi signifikan, serta korelasi yang sangat kuat antara PM_{2.5} dan PM₁₀ ($r=0,995$) dan hubungan negatif kuat antara O₃ dan NO₂ ($r=-0,902$), yang menegaskan kompleksitas dinamika polutan di wilayah tersebut. Temuan ini mengindikasikan bahwa Deli Tua memang menghadapi tantangan signifikan terkait polusi udara yang bersifat dinamis dan saling terhubung antar polutan. Kemampuan untuk meramalkan kualitas udara secara akurat dapat membantu otoritas dan komunitas mengambil langkah preventif untuk melindungi kesehatan publik. Pencemaran udara di berbagai kota Indonesia telah menjadi isu serius, dengan dampak yang signifikan terhadap kesehatan masyarakat (Wahyudi et al., 2023). Pendekatan peramalan tradisional sering memperlakukan polutan secara independen, mengabaikan interaksi kompleks dan korelasi yang eksisten antara berbagai polutan di atmosfer (Nisa et al., 2024). Metode peramalan time series, khususnya teknik exponential smoothing, telah banyak diaplikasikan dalam prediksi lingkungan karena kesederhanaan dan efektivitasnya (Olivia, 2021).

Penelitian sebelumnya menunjukkan bahwa metode exponential smoothing dapat diterapkan dalam berbagai konteks peramalan, termasuk peramalan jumlah penduduk miskin dengan hasil yang memuaskan (Olivia, 2021). Metode ini telah mendemonstrasikan kesuksesan dalam berbagai aplikasi peramalan, mulai dari data ekonomi hingga parameter lingkungan (Yusuf et al., 2022). Namun demikian, kinerja komparatif dari berbagai varian exponential smoothing secara spesifik untuk peramalan kualitas udara multi-polutan masih kurang tereksplorasi secara komprehensif. Penelitian sebelumnya tentang prediksi kualitas udara telah mengutilisasi berbagai pendekatan metodologis. Beberapa studi telah menggunakan single exponential smoothing, double exponential smoothing, dan model ARIMA untuk meramalkan berbagai parameter lingkungan (Akolo, 2018; Djami & Nanlohy, 2022). Khaira et al. (2025) mengimplementasikan Long Short-Term Memory (LSTM) untuk peramalan kadar PM₁₀ dengan

hasil RMSE sebesar 0,021 dan MAPE 0,11%, menunjukkan akurasi yang sangat baik. Sejumlah peneliti juga telah mengeksplorasi pendekatan machine learning seperti Artificial Neural Networks dan jaringan LSTM untuk prediksi kualitas udara (Karyadi & Setiawan, 2022; Khumaidi et al., 2020).

Karyadi dan Setiawan (2022) membandingkan LSTM, Bidirectional LSTM, dan GRU untuk prediksi kualitas udara di Bandung, menemukan bahwa LSTM dan Bi-LSTM menunjukkan performa superior untuk parameter suhu, kelembaban, dan ISPU. Akan tetapi, mayoritas studi berfokus pada polutan individual daripada mempertimbangkan interaksi multi-polutan yang mengkarakterisasi dinamika kualitas udara di dunia nyata. Tantangan utama dalam peramalan kualitas udara mencakup beberapa aspek fundamental. Pertama, tingkat volatilitas yang tinggi serta sifat non-stasioner pada data polusi menjadi kendala utama dalam proses pemodelan (Khusna et al., 2023). Hal ini disebabkan karena data kualitas udara umumnya tidak memiliki rata-rata dan varians yang konstan, sehingga diperlukan tahapan pra-pemrosesan seperti uji kestasioneran dan transformasi differencing sebelum model time series seperti ARIMA dapat diterapkan secara optimal. Kedua, interaksi kompleks antara berbagai polutan menciptakan dinamika yang sulit diprediksi (Nisa et al., 2024). Ketiga, lonjakan mendadak yang disebabkan oleh kejadian eksternal menambah kompleksitas peramalan. Keempat, pola musiman dan tren yang bervariasi di berbagai polutan memerlukan pendekatan adaptif (Putri & Oktaviarina, 2024). Berbagai penelitian telah mengkaji perbandingan metode peramalan untuk kualitas udara. Safi dan Sanusi (2021) membandingkan ANN, ETS, ARIMA, dan model hibrid untuk peramalan COVID-19, menemukan bahwa ETS dan ARIMA mengungguli model hibrid yang lebih kompleks. Harini (2020) mengimplementasikan double exponential smoothing untuk identifikasi kasus COVID-19 di Indonesia dengan hasil yang mendekati model ARIMA (0,1,1).

Munarsih dan Saluza (2020) membandingkan exponential smoothing dan ARIMA untuk prediksi demam berdarah di Palembang, menemukan bahwa ARIMA (2,1,2) dengan MSE 108077.877 mengungguli exponential smoothing. Nurlela et al. (2025) menganalisis Moving Average, Exponential Smoothing, dan ARIMA untuk pengendalian stok, menemukan bahwa Moving Average 3 bulan menghasilkan akurasi terbaik dengan MAPE 2,935%. Hasil-hasil penelitian ini menunjukkan bahwa tidak ada metode universal yang superior untuk semua kasus, dan pemilihan metode harus disesuaikan dengan karakteristik data spesifik. Penelitian tentang peramalan kualitas udara dengan pendekatan multi-polutan juga telah dilakukan. Farhan et al. (2024) mengimplementasikan Generalized Space-Time Autoregressive (GSTAR) untuk

pemodelan pencemaran udara NO₂ dan SO₂ di Makassar, menemukan bahwa GSTAR (1,0,2) untuk NO₂ dan GSTAR (1,0,1) untuk SO₂ merupakan model terbaik dengan residual yang memenuhi asumsi white noise dan distribusi normal.

Pratama dan Setiawan (2017) mengembangkan sistem monitoring kualitas udara dengan peramalan exponential smoothing berbasis NodeMCU dan mobile Android, mengimplementasikan time series Cheng untuk prediksi karbon monoksida. Zikri et al. (2023) memanfaatkan Extra Trees Regression untuk memprediksi NO₂ di DKI Jakarta dengan nilai R² mencapai 73,14%, menunjukkan kemampuan model dalam menjelaskan variabilitas data. Sinaga et al. (2022) melakukan peramalan tingkat pencemaran udara akibat kendaraan bermotor dengan metode time series Cheng, memberikan wawasan tentang pentingnya injeksi volatilitas dalam model peramalan. Penelitian ini mengadres tantangan tersebut dengan mengembangkan sistem peramalan multi-polutan yang menginkorporasi penyesuaian berbasis korelasi antar polutan. Kontribusi utama dari penelitian ini meliputi empat aspek kunci: (1) membandingkan kinerja metode SES, DES, dan ARIMA untuk peramalan kualitas udara multi-polutan; (2) mengimplementasikan pendekatan peramalan sekuensial berdasarkan kekuatan korelasi polutan; (3) mengembangkan mekanisme penyesuaian yang memanfaatkan relasi antar-polutan untuk meningkatkan akurasi prediksi; dan (4) mengevaluasi kapabilitas sistem untuk memprediksi AQI dari konsentrasi polutan yang diramalkan.

Metode Penelitian

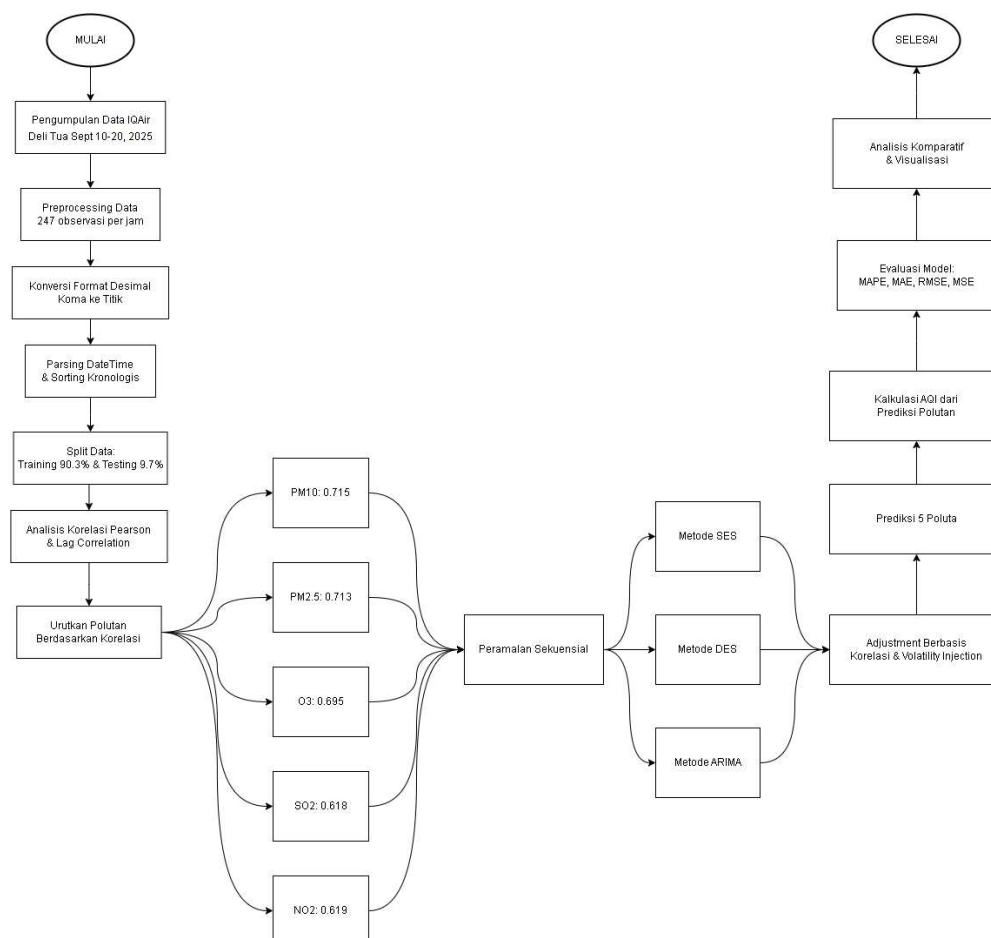
Penelitian ini mengadopsi pendekatan kuantitatif dengan mengutilisasi metode peramalan time series untuk memprediksi konsentrasi polutan udara dan nilai AQI. Metodologi mengikuti proses terstruktur yang terdiri dari pengumpulan data, preprocessing, analisis eksploratori, pengembangan model, evaluasi, dan validasi, dengan mengacu pada pendekatan metodologis yang telah divalidasi dalam penelitian sebelumnya (Wahyudi et al., 2023; Khusna et al., 2023).

Kerangka Penelitian dan Pengumpulan Data

Penelitian ini menerapkan kerangka kerja sistematis yang mengintegrasikan analisis korelasi dengan tiga metode peramalan utama untuk menghasilkan prediksi multi-polutan yang komprehensif, mengadopsi pendekatan yang telah diimplementasikan dalam penelitian peramalan kualitas udara sebelumnya (Oktavia & Witanti, 2024; Putri & Oktaviarina, 2024). Dataset penelitian terdiri dari pengukuran kualitas udara per jam yang diperoleh dari stasiun

pemantauan IQAir di Deli Tua, Sumatera Utara. Periode pengamatan mencakup rentang waktu dari 10 September 2025 hingga 20 September 2025, menghasilkan total 247 observasi. Data mencakup enam parameter utama yaitu AQI (Air Quality Index), PM2.5, PM10, O₃ (Ozon), NO₂ (Nitrogen Dioksida), dan SO₂ (Sulfur Dioksida).

Dataset dibagi menjadi set training dan testing dengan rasio yang telah ditentukan secara cermat untuk memaksimalkan pembelajaran model sambil mempertahankan set validasi yang memadai, konsisten dengan praktik yang direkomendasikan dalam literatur peramalan time series (Khumaidi et al., 2020; Karyadi & Setiawan, 2022). Secara spesifik, 223 pengamatan (90,3%) dialokasikan untuk training, mencakup periode dari 10 September 2025 pukul 01:00 hingga 19 September 2025 pukul 07:00. Sementara itu, 24 pengamatan (9,7%) dicadangkan untuk testing, mencakup periode dari 19 September 2025 pukul 08:00 hingga 20 September 2025 pukul 07:00. Pembagian ini dirancang untuk menyediakan horizon peramalan 24 jam yang representatif untuk evaluasi kinerja model.



Gambar 1. Diagram alur kerangka kerja penelitian peramalan kualitas udara multi-polutan dengan penyesuaian berbasis korelasi

Analisis Korelasi Antar Polutan

Sebelum mengimplementasikan model peramalan, analisis korelasi komprehensif dilakukan untuk mengidentifikasi dan mengkuantifikasi relasi antar polutan, mengadopsi pendekatan yang telah diterapkan dalam penelitian multi-polutan sebelumnya (Nisa et al., 2024; Farhan et al., 2024). Metodologi ini mengutilisasi Matriks Korelasi Pearson untuk mengukur kekuatan dan arah hubungan linier antara semua pasangan polutan, serta Analisis Korelasi Lag untuk mengeksplorasi efek tertunda antar polutan pada interval lag 1-3 jam.

Analisis korelasi mengungkapkan beberapa temuan signifikan. Korelasi positif yang sangat kuat diidentifikasi antara PM2.5 dan PM10 dengan koefisien korelasi $r=0,995$, mengindikasikan bahwa kedua polutan ini memiliki sumber emisi yang sama dan menunjukkan perilaku atmosfer yang serupa, konsisten dengan temuan Wahyudi et al. (2023) tentang korelasi partikulat. Korelasi negatif yang kuat ditemukan antara O₃ dan NO₂ dengan koefisien $r=-0,902$, mencerminkan reaksi fotokimia dimana NO₂ dikonsumsi dalam proses pembentukan O₃, sejalan dengan penelitian Nisa et al. (2024) tentang dinamika O₃ dan NO₂. Korelasi positif yang sangat kuat juga diobservasi antara partikulat (PM2.5 dan PM10) dengan AQI dengan koefisien $r\approx 0,976$, mengkonfirmasi bahwa PM merupakan kontributor dominan terhadap nilai AQI di lokasi penelitian.

Tabel 1. Matriks Korelasi Pearson Antar Polutan

	AQI	PM2.5	PM10	O ₃	NO ₂	SO ₂
AQI	1,000	0,976	0,976	0,622	-0,420	0,526
PM2.5	0,976	1,000	0,995	0,627	-0,426	0,540
PM10	0,976	0,995	1,000	0,637	-0,434	0,535
O ₃	0,622	0,627	0,637	1,000	-0,902	0,678
NO ₂	-0,420	-0,426	-0,434	-0,902	1,000	-0,713
SO ₂	0,526	0,540	0,535	0,678	-0,713	1,000

Berdasarkan nilai korelasi absolut rata-rata dengan polutan lainnya, polutan diurutkan untuk menentukan sekuens peramalan optimal. Urutan yang diperoleh adalah: PM10 (korelasi rata-rata absolut: 0,715), PM2.5 (0,713), O₃ (0,695), SO₂ (0,618), dan NO₂ (0,619). Urutan ini menjadi dasar untuk implementasi pendekatan peramalan sekuensial yang memanfaatkan informasi korelasi.

Metode Peramalan Time Series

Tiga metode exponential smoothing diimplementasikan dan dibandingkan secara komprehensif untuk mengevaluasi performa relatif mereka dalam konteks peramalan kualitas udara multi-polutan, dengan mengacu pada kerangka komparatif yang telah dikembangkan

dalam penelitian sebelumnya (Djami & Nanlohy, 2022; Munarsih & Saluza, 2020; Yusuf et al., 2022).

Single Exponential Smoothing (SES)

Merupakan metode fundamental yang cocok untuk data tanpa tren atau pola musiman yang signifikan, sebagaimana telah diaplikasikan dalam berbagai konteks peramalan (Olivia, 2021; Safi & Sanusi, 2021). Metode ini mengoperasikan prinsip pembobotan eksponensial dimana observasi terkini diberikan bobot lebih besar dibandingkan observasi historis. Persamaan peramalan SES diformulasikan sebagai:

$$F(t + 1) = \alpha \times Y(t) + (1 - \alpha) \times F(t)$$

dimana $F(t+1)$ merepresentasikan peramalan untuk periode berikutnya, $Y(t)$ adalah nilai aktual pada waktu t , α adalah koefisien smoothing dengan domain $0 < \alpha < 1$, dan $F(t)$ adalah peramalan pada waktu t .

Double Exponential Smoothing (DES)

Memperluas SES dengan menginkorporasi komponen tren, membuatnya apropriasi untuk data yang menunjukkan pola tren linier (Harini, 2020; Akolo, 2018). Metode ini mengutilisasi dua persamaan smoothing yang saling berinteraksi untuk komponen level dan tren, kemudian menghasilkan forecast dengan menambahkan proyeksi tren ke level saat ini.

$$\text{Level: } L(t) = \alpha \times Y(t) + (1 - \alpha) \times [L(t - 1) + T(t - 1)]$$

$$\text{Trend: } T(t) = \beta \times [L(t) - L(t - 1)] + (1 - \beta) \times T(t - 1)$$

ARIMA (AutoRegressive Integrated Moving Average)

Merupakan metode yang lebih sophisticated yang mengkombinasi komponen autoregressive, differencing, dan moving average, telah terbukti efektif dalam berbagai aplikasi peramalan kualitas udara (Khusna et al., 2023; Putri & Oktaviarina, 2024). Untuk penelitian ini, ARIMA(2,1,2) diimplementasikan berdasarkan analisis fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF), konsisten dengan metodologi yang direkomendasikan oleh Putri dan Oktaviarina (2024).

Peramalan Multi-Polutan dengan Mekanisme Penyesuaian

Inovasi metodologis utama dari penelitian ini adalah implementasi enhancement terhadap peramalan univariat tradisional dengan mengintegrasikan informasi dari polutan lain berdasarkan kekuatan korelasi mereka, terinspirasi dari pendekatan GSTAR multi-lokasi yang dikembangkan oleh Farhan et al. (2024) dan pendekatan VAR multi-polutan oleh Nisa et al.

(2024). Pendekatan ini menciptakan hybrid antara kesederhanaan peramalan univariat dengan awareness terhadap hubungan multivariat.

Algoritma peramalan sekuensial mengikuti langkah-langkah sistematis: (1) menghitung matriks korelasi komprehensif antar semua polutan; (2) mengurutkan polutan berdasarkan kekuatan korelasi absolut rata-rata; (3) untuk setiap polutan dalam urutan yang telah ditentukan, dilakukan fitting model peramalan dasar, menghasilkan peramalan dasar, menerapkan mekanisme penyesuaian yang memanfaatkan prediksi dari polutan yang telah diramalkan sebelumnya, menambahkan noise volatilitas realistis (Sinaga et al., 2022), dan menyimpan peramalan untuk digunakan sebagai input dalam prediksi polutan berikutnya.

Mekanisme penyesuaian berbasis korelasi diimplementasikan melalui formula matematis dimana adjustment dihitung sebagai penjumlahan dari weight dikalikan dengan predicted change dari setiap polutan yang sudah diprediksi. Adjusted forecast kemudian diformulasikan dengan menambahkan adjustment yang telah dikali smoothing factor (0,3) ke base forecast. Injeksi volatilitas diimplementasikan untuk menambahkan fluktuasi realistis dengan menggenerate noise dari distribusi normal berdasarkan standar deviasi perubahan data training.

Perhitungan AQI dan Metrik Evaluasi

AQI dikalkulasi dari konsentrasi polutan yang diramalkan menggunakan standar US Environmental Protection Agency (EPA), konsisten dengan metodologi yang digunakan dalam penelitian kualitas udara Indonesia (Wahyudi et al., 2023; Khaira et al., 2025). Formula interpolasi AQI mengikuti persamaan:

$$AQI = \frac{(I_{high} - I_{low})}{(C_{high} - C_{low})} \times (C - C_{low}) + I_{low}$$

dimana C adalah konsentrasi polutan, C_{low} dan C_{high} adalah batas konsentrasi, I_{low} dan I_{high} adalah batas AQI.

Kinerja model dievaluasi menggunakan empat metrik standar yang telah digunakan secara luas dalam penelitian peramalan kualitas udara (Khaira et al., 2025; Zikri et al., 2023; Nurlela et al., 2025):

Mean Absolute Percentage Error (MAPE):

$$MAPE = \frac{1}{n} \times \sum \frac{|Y_{actual} - Y_{predicted}|}{Y_{actual}} \times 100\%$$

Mean Absolute Error (MAE):

$$MAE = \frac{1}{n} \times \sum |Y_{actual} - Y_{predicted}|$$

Root Mean Square Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \times \sum (Y_{actual} - Y_{predicted})^2}$$

Mean Squared Error (MSE):

$$MSE = \frac{1}{n} \times \sum (Y_{actual} - Y_{predicted})^2$$

Seluruh model diimplementasikan menggunakan Python 3.8 dengan pustaka pandas, numpy, statsmodels, scikit-learn, matplotlib, dan seaborn, mengikuti best practices dalam implementasi model time series (Khumaidi et al., 2020; Oktavia & Witanti, 2024).

Output dari eksekusi program menunjukkan proses peramalan yang sistematis dengan urutan berdasarkan kekuatan korelasi:

Hasil dan Pembahasan

Statistik Deskriptif dan Karakteristik Data

Data training yang terdiri dari 223 pengamatan per jam menunjukkan karakteristik yang informatif tentang kondisi kualitas udara di Deli Tua selama periode penelitian. AQI rata-rata 81,2 mengindikasikan kondisi kualitas udara "Sedang" menurut standar EPA, dengan variabilitas substansial (CV 27,2%) yang mencerminkan fluktuasi kondisi polusi, pola yang juga diobservasi dalam penelitian Wahyudi et al. (2023) di Makassar. PM2.5 dan PM10 menunjukkan variabilitas tertinggi dengan coefficient of variation mendekati 35%, mengindikasikan bahwa konsentrasi partikulat mengalami fluktuasi signifikan, konsisten dengan temuan Khaira et al. (2025) di Jambi. Sebaliknya, polutan gas menunjukkan stabilitas relatif dengan CV berkisar antara 6% hingga 20%, dimana SO₂ merupakan yang paling stabil (CV 6,3%) dan O₃ menunjukkan variabilitas moderat (CV 19,5%). Pola stabilitas relatif pada polutan gas ini juga sejalan dengan karakteristik umum yang dilaporkan dalam studi peramalan kualitas udara berbasis time series (Khusna et al., 2023).

Tabel 2. Statistik Deskriptif Data Training

Parameter	Mean	Std Dev	Min	Max	CV (%)
AQI	81,2	22,1	60,0	130,0	27,2
PM2.5 (µg/m ³)	23,88	8,45	15,2	48,0	35,4
PM10 (µg/m ³)	24,39	8,98	16,1	50,8	36,8
O ₃ (ppb)	4,20	0,82	3,1	5,6	19,5
NO ₂ (ppb)	8,63	1,15	7,8	10,6	13,3
SO ₂ (ppb)	23,97	1,52	20,6	26,0	6,3

Perbandingan Kinerja Metode Peramalan

Evaluasi komparatif tiga metode peramalan menghasilkan wawasan komprehensif tentang kekuatan dan keterbatasan relatif masing-masing pendekatan dalam konteks peramalan kualitas udara multi-polutan. Hasil menunjukkan bahwa ARIMA mencapai kinerja keseluruhan superior dengan MAPE rata-rata 15,49%, yang mengkuilifikasi sebagai "Baik" menurut kriteria akurasi peramalan. Dominasi ARIMA konsisten di mayoritas polutan, khususnya untuk PM2.5, PM10, SO₂, dan AQI. Keunggulan ARIMA dapat diatribusi kepada kapabilitasnya untuk menangkap struktur temporal kompleks melalui komponen autoregressive dan moving average, serta kemampuan differencing untuk mengatasi non-stasioneritas, sejalan dengan temuan Khusna et al. (2023) di Semarang dan Putri dan Oktaviarina (2024) di Gresik.

Tabel 3. Perbandingan Kinerja Model Berdasarkan MAPE

Polutan	SES MAPE (%)	DES MAPE (%)	ARIMA MAPE (%)	Metode Terbaik
PM2.5	31,51	38,18	29,68	ARIMA
PM10	31,92	34,37	30,25	ARIMA
O₃	2,17	2,79	2,61	SES
NO₂	0,81	6,39	1,41	SES
SO₂	5,04	9,18	4,95	ARIMA
AQI	25,36	30,23	24,04	ARIMA
Rata-rata	16,13	20,19	15,49	ARIMA

Temuan menarik adalah bahwa SES mengungguli metode yang lebih sophisticated untuk O₃ dan NO₂, dengan MAPE yang sangat rendah yaitu 0,81% untuk NO₂. Fenomena ini konsisten dengan prinsip parsimony dalam pemodelan dimana untuk data dengan pola yang relatif halus dan dapat diprediksi, metode sederhana dapat mengungguli metode kompleks yang cenderung overfit atau menangkap noise sebagai sinyal, hasil yang juga diobservasi oleh Safi dan Sanusi (2021) dalam perbandingan mereka terhadap metode peramalan COVID-19. Khumaidi et al. (2020) juga melaporkan bahwa SES dapat berkinerja baik untuk parameter yang stabil seperti suhu dan kelembaban di Bandung. DES menunjukkan kinerja terburuk dengan MAPE rata-rata 20,19%. Underperformance DES sangat jelas untuk NO₂ (6,39% vs 0,81% untuk SES), mengindikasikan bahwa penambahan komponen tren justru memperkenalkan kompleksitas yang tidak perlu dan mendegradasi akurasi untuk data dengan pola yang pada dasarnya level, temuan yang konsisten dengan hasil penelitian Djami dan Nanlohy (2022) yang menemukan bahwa ARIMA mengungguli double exponential smoothing untuk peramalan IHK di Ambon.

Tabel 4. Perbandingan Metrik Evaluasi Lengkap untuk ARIMA

Polutan	MAPE (%)	MAE	RMSE	MSE
PM2.5	29,68	11,45	13,84	191,55

PM10	30,25	11,95	14,59	212,87
O₃	2,61	0,09	0,10	0,01
NO₂	1,41	0,13	0,16	0,03
SO₂	4,95	1,21	1,50	2,25
AQI	24,04	26,25	31,36	983,45

Analisis Peramalan Berdasarkan Jenis Polutan

Partikulat Matter (PM2.5 dan PM10)

Kedua polutan partikulat menunjukkan kesalahan prediksi tertinggi dengan MAPE berkisar 30-38%, yang dapat dikategorikan pada batas antara "Baik" dan "Dapat Diterima". Analisis mendalam mengungkapkan bahwa tantangan utama dalam peramalan PM adalah volatilitas ekstrem yang diobservasi selama periode pengujian. Data testing menunjukkan lonjakan dramatis dari konsentrasi baseline sekitar 23 $\mu\text{g}/\text{m}^3$ menjadi puncak mendekati 48 $\mu\text{g}/\text{m}^3$, merepresentasikan peningkatan sekitar 100% yang secara signifikan melebihi variabilitas historis yang ditangkap dalam data training. Besaran lonjakan ini sangat mengindikasikan kejadian episodik atau peristiwa luar biasa yang tidak diantisipasi oleh model berbasis data historis, fenomena yang juga dilaporkan oleh Wahyudi et al. (2023) dalam penelitian mereka tentang PM10 di Makassar. Model ARIMA menunjukkan ketahanan relatif yang superior dalam menghadapi volatilitas ini, kemungkinan karena komponen moving average dapat secara parsial menyerap efek kejutan (Putri & Oktaviarina, 2024), namun tetap tidak mampu untuk sepenuhnya menangkap besaran perubahan yang belum pernah terjadi sebelumnya. Khaira et al. (2025) juga melaporkan bahwa LSTM dengan optimizer SGD dapat mencapai RMSE 0,021 untuk PM10 di Jambi, menunjukkan potensi metode deep learning untuk menangani volatilitas yang tinggi.

Polutan Gas (O₃, NO₂, SO₂)

Kontras yang tajam dengan kinerja pada PM, model menunjukkan akurasi yang sangat baik untuk polutan gas dengan MAPE secara konsisten di bawah 10%, mengindikasikan kinerja peramalan "Sangat Baik". Karakteristik yang membedakan polutan gas adalah stabilitas relatif dengan coefficient of variation yang lebih rendah dan ketiadaan lonjakan episodik ekstrem yang mengkarakterisasi partikulat. O₃ dengan rentang MAPE 2,17-2,79% menunjukkan prediktabilitas tinggi yang dapat diatribusi kepada pola diurnal yang konsisten yang didorong oleh reaksi fotokimia yang relatif dapat diprediksi dengan kondisi meteorologis yang stabil. Keunggulan sedikit SES dibanding ARIMA (2,17% vs 2,61%) mendemonstrasikan bahwa untuk data dengan pola yang halus, pembobotan eksponensial sederhana sudah cukup untuk peramalan yang akurat, konsisten dengan prinsip parsimony yang diadvokasi oleh Safi dan Sanusi (2021).

Nisa et al. (2024) melaporkan korelasi negatif kuat antara O_3 dan NO_2 ($r=-0,902$) di Jakarta, yang konsisten dengan temuan penelitian ini.

NO_2 mencapai akurasi peramalan yang luar biasa dengan MAPE SES hanya 0,81%, merepresentasikan prediksi jangka pendek yang hampir sempurna. Stabilitas tinggi NO_2 (CV 13,3%) dan ketiadaan kejutan mendadak memungkinkan SES untuk secara efektif melacak dan memprediksi konsentrasi dengan kesalahan minimal. Kinerja yang luar biasa ini memvalidasi penggunaan metode parsimonious untuk karakteristik data yang apropriasi. Zikri et al. (2023) menggunakan Extra Trees Regression untuk prediksi NO_2 di DKI Jakarta dengan R^2 mencapai 73,14%, menunjukkan bahwa berbagai pendekatan dapat efektif untuk polutan yang stabil ini. SO_2 dengan MAPE 4,95–9,18% menunjukkan prediktabilitas yang baik dengan ARIMA dan SES yang memiliki kinerja relatif sebanding. Stabilitas SO_2 (CV terendah 6,3% di antara semua polutan) berkontribusi terhadap tingginya akurasi peramalan, dimana tren yang cenderung gradual dapat ditangkap secara efektif oleh pendekatan exponential smoothing. Karakteristik ini menunjukkan bahwa polutan dengan variabilitas rendah cenderung lebih mudah diprediksi menggunakan metode time series tradisional.

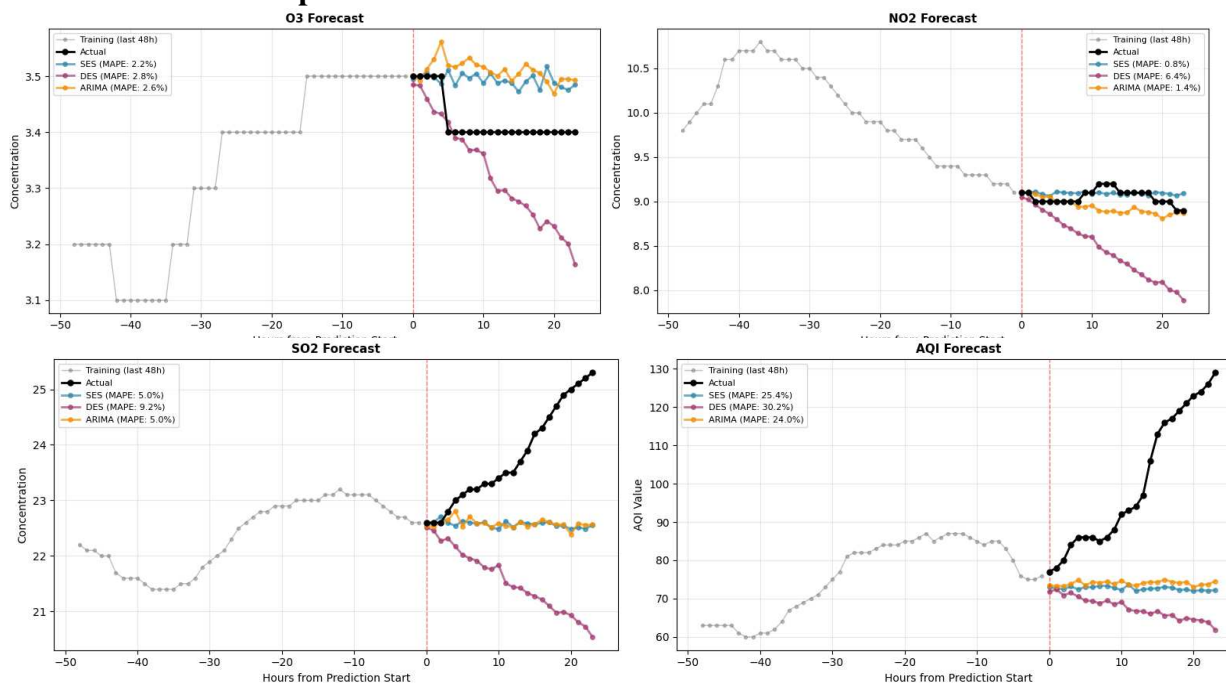
Indeks Kualitas Udara (AQI)

Hasil peramalan AQI menunjukkan pola yang menarik dan signifikan secara praktis. ARIMA mencapai kinerja terbaik dengan MAPE 24,04%, diikuti oleh SES 25,36% dan DES 30,23%. Yang patut dicatat adalah bahwa MAPE AQI secara substansial lebih rendah dibandingkan MAPE $PM_{2.5}/PM_{10}$ individual, meskipun PM adalah kontributor dominan terhadap AQI ($r\approx 0,976$), hasil yang juga diobservasi oleh Oktavia dan Witanti (2024) dalam penelitian Prophet forecasting untuk AQI di Yogyakarta.

Fenomena ini dapat dijelaskan melalui beberapa mekanisme. Pertama, efek agregasi dimana menggabungkan berbagai polutan ke dalam indeks tunggal menyediakan penghalusan statistik yang mengurangi kesalahan relatif melalui efek rata-rata (Perdana et al., 2023). Kedua, transformasi nonlinier melalui sistem breakpoint EPA dapat meredam dampak dari kesalahan prediksi absolut, khususnya ketika prediksi dan aktual jatuh dalam kategori AQI yang sama atau berdekatan. Ketiga, efek kompensatori dimana prediksi berlebih dalam satu polutan dapat secara parsial diimbangi oleh prediksi kurang dalam polutan lain, menghasilkan AQI komposit yang lebih akurat, mekanisme yang juga diidentifikasi dalam penelitian multi-polutan oleh Farhan et al. (2024).

Dari sudut pandang praktis, MAPE 24% termasuk dalam rentang "Dapat Diterima" dan memberikan utilitas untuk sistem peringatan dini dimana tren arah dan klasifikasi kategori sering kali lebih kritis daripada nilai numerik yang tepat, sebagaimana diargumentasikan oleh Pratama dan Setiawan (2017) dalam sistem monitoring kualitas udara berbasis IoT mereka. Sistem dapat secara andal mengidentifikasi apakah kualitas udara membaik, memburuk, atau stabil, memungkinkan saran kesehatan publik dan keputusan intervensi yang tepat waktu.

Visualisasi dan Interpretasi Hasil Peramalan



Gambar 2. Visualisasi - Multi-Pollutant Forecasting Results

Analisis visual dari plot peramalan memberikan pemahaman intuitif tentang perilaku model dan sumber kesalahan prediksi. Gambar 5 menunjukkan hasil peramalan untuk semua polutan menggunakan ketiga metode yang dibandingkan dengan nilai aktual.

Plot PM2.5 dan PM10 mengungkapkan divergensi tajam antara prediksi ($22\text{-}23 \mu\text{g}/\text{m}^3$) dan nilai aktual yang melonjak ke $45\text{-}48 \mu\text{g}/\text{m}^3$, menciptakan kesenjangan sekitar $23\text{-}26 \mu\text{g}/\text{m}^3$. Kesenjangan ini mengilustrasikan tantangan fundamental dalam meramalkan kejadian polusi episodik yang belum pernah terjadi dalam data training, tantangan yang juga diidentifikasi oleh Wahyudi et al. (2023) dalam penelitian SVR untuk PM10 di Makassar.

Plot O₃ mendemonstrasikan peramalan yang sukses dengan nilai aktual stabil sekitar 3,4 ppb. Prediksi SES dan ARIMA mengikuti nilai aktual dengan sangat dekat, sementara DES menunjukkan tren menurun yang tidak tepat, manifestasi overfitting komponen tren terhadap fluktuasi acak (Djami & Nanlohy, 2022). Plot NO₂ menampilkan kinerja teladan dengan prediksi

SES dan ARIMA yang hampir tidak dapat dibedakan dari nilai aktual, mengkonfirmasi MAPE luar biasa 0,81% (Nurlela et al., 2025).

Plot SO₂ mengungkapkan adanya underestimation yang konsisten pada semua metode, dimana model belum mampu mengantisipasi tren peningkatan meskipun tingkat kesalahan relatif kecil karena variabilitas SO₂ yang rendah. Plot AQI mencerminkan perilaku PM (korelasi $r \approx 0,976$), dengan lonjakan nilai aktual dari 85 ke 130 sementara hasil prediksi cenderung stabil pada kisaran 72–75. Meskipun terdapat kesalahan secara kuantitatif, model masih mampu mengidentifikasi pola umum yang relevan untuk kebutuhan sistem peringatan dini kesehatan publik (Pratama & Setiawan, 2017).

Mekanisme Penyesuaian Multi-Polutan dan Dampaknya

Mekanisme penyesuaian berbasis korelasi merepresentasikan inovasi metodologis kunci dalam penelitian ini, menciptakan sinergi antara kesederhanaan univariat dan kesadaran multivariat, terinspirasi dari pendekatan spatial-temporal yang dikembangkan oleh Farhan et al. (2024) dalam penelitian GSTAR mereka. Efektivitas mekanisme dapat dievaluasi melalui berbagai perspektif.

Pemeliharaan konsistensi merupakan manfaat fundamental dimana penyesuaian memastikan hubungan logis antar polutan dipertahankan dalam prediksi. Ketika PM₁₀ diprediksi untuk meningkat, mekanisme secara otomatis menyesuaikan prediksi PM_{2.5} ke atas secara proporsional dengan korelasi kuat ($r=0,995$), mempertahankan kelayakan fisik dari prediksi bersama. Demikian pula, hubungan terbalik antara O₃ dan NO₂ ($r=-0,902$) dipaksakan, memastikan kopling fotokimia tercermin dalam peramalan, konsisten dengan prinsip yang diidentifikasi oleh Nisa et al. (2024) dalam penelitian VAR mereka tentang O₃ dan NO₂ di Jakarta.

Efek penghalusan menyediakan regularisasi yang meredam prediksi individual ekstrem melalui inkorporasi informasi dari berbagai polutan. Prediksi outlier dimoderasi oleh informasi konsensus dari polutan yang berkorelasi, mengurangi dampak kesalahan idiosinkratik dalam model individual. Peningkatan sekuensial menciptakan efek kaskade dimana polutan yang diprediksi kemudian mendapat manfaat dari informasi yang disempurnakan dari prediksi sebelumnya, secara progresif meningkatkan akurasi di sepanjang rantai prediksi.

Metodologi merepresentasikan kompromi praktis antara model multivariat penuh seperti Vector Autoregression (VAR) yang intensif secara komputasi (Nisa et al., 2024; Putri & Oktaviarina, 2024) dan pendekatan univariat murni yang mengabaikan informasi antar-polutan

yang berharga. Pendekatan hybrid mempertahankan efisiensi komputasi yang sesuai untuk deployment operasional sambil menangkap struktur hubungan kunci, sejalan dengan filosofi desain sistem monitoring real-time yang dikembangkan oleh Pratama dan Setiawan (2017).

Karakteristik Spesifik Metode Peramalan

Evaluasi komparatif mengungkapkan karakteristik distinktif dari ketiga metode peramalan yang diimplementasikan. ARIMA(2,1,2) menunjukkan kinerja konsisten superior di berbagai polutan yang beragam, sejalan dengan temuan penelitian sebelumnya (Khusna et al., 2023; Putri & Oktaviarina, 2024). Kekuatan fundamental ARIMA terletak pada fleksibilitas arsitektural yang memungkinkan penangkapan pola temporal yang kompleks. Komponen autoregressive (AR) dengan orde 2 menangkap dependensi pada dua observasi sebelumnya, memungkinkan model mempelajari dinamika jangka pendek dalam perubahan konsentrasi. Komponen differencing ($d=1$) berperan dalam mentransformasikan data non-stasioner menjadi stasioner, sehingga memenuhi asumsi dasar pemodelan time series dan meningkatkan validitas model. Komponen moving average (MA) dengan orde 2 mengintegrasikan informasi dari kesalahan prediksi sebelumnya, sehingga menyediakan mekanisme koreksi adaptif terhadap hasil peramalan. Namun demikian, superioritas ARIMA disertai dengan biaya komputasi yang lebih tinggi dibandingkan metode exponential smoothing. Proses penentuan parameter memerlukan analisis yang cermat melalui plot ACF/PACF atau pendekatan optimasi seperti grid search (Wahyudi et al., 2023), yang menambah kompleksitas implementasi. Selain itu, ARIMA masih memiliki keterbatasan dalam memprediksi nilai ekstrem yang belum pernah muncul dalam data historis, sebagaimana juga diidentifikasi dalam penelitian sebelumnya (Munarsih & Saluza, 2020; Harini, 2020).

Single Exponential Smoothing mendemonstrasikan efektivitas tinggi untuk polutan dengan karakteristik stabil, mencapai kinerja yang hampir optimal dengan overhead komputasi minimal. MAPE 0,81% untuk NO_2 memvalidasi prinsip bahwa kompleksitas model harus sesuai dengan kompleksitas data, prinsip yang juga diadvokasi oleh Safi dan Sanusi (2021) dalam analisis komparatif mereka. Ketika proses yang mendasari pada dasarnya level dengan fluktuasi acak, komponen tren atau musiman yang sophisticated tidak hanya tidak perlu tetapi berpotensi merugikan, memperkenalkan varians tanpa pengurangan bias yang sesuai. Parameter smoothing yang dioptimalkan $\alpha \approx 0,28$ mengindikasikan bahwa strategi optimal melibatkan bobot substansial pada rata-rata historis daripada adaptasi cepat terhadap nilai terkini, mencerminkan stabilitas yang mendasari dalam konsentrasi polutan gas. Kesederhanaan implementasi SES

menjadikannya menarik untuk aplikasi real-time dimana sumber daya komputasi terbatas atau pembaruan model cepat diperlukan, sebagaimana didemonstrasikan dalam sistem monitoring IoT oleh Pratama dan Setiawan (2017). Keterbatasan utama SES adalah ketidakmampuan menangkap tren, yang menjadi bermasalah untuk polutan seperti PM yang mendemonstrasikan pola meningkat atau menurun (Olivia, 2021). Degradasi kinerja dengan data volatilitas tinggi juga membatasi aplikabilitas untuk polutan dengan lonjakan episodik.

Double Exponential Smoothing menunjukkan kinerja di bawah kedua metode lainnya, dimana keuntungan teoretis dalam pemodelan tren gagal diterjemahkan ke dalam kinerja empiris yang superior. DES menempati peringkat terakhir di hampir semua polutan, dengan kinerja NO_2 yang MAPE-nya 6,39% hampir 8 kali lebih buruk dibandingkan SES 0,81%, hasil yang konsisten dengan temuan Djami dan Nanlohy (2022) yang menunjukkan ARIMA mengungguli double exponential smoothing untuk IHK di Ambon. Beberapa faktor berkontribusi pada underperformance ini. Pertama, risiko overfitting dimana komponen tren berusaha memodelkan fluktuasi yang sebenarnya noise acak daripada tren sistematis, menyebabkan prediksi out-of-sample yang buruk (Akolo, 2018). Kedua, sensitivitas parameter dimana optimasi bersama dari parameter α dan β menciptakan ruang pencarian lebih besar dengan potensi konvergensi ke minimum lokal yang suboptimal. Ketiga, horizon peramalan pendek (24 jam) membatasi manfaat dari ekstrapolasi tren, karena fluktuasi intra-hari mungkin tidak menunjukkan tren linier yang konsisten yang dirancang untuk ditangkap DES. Hasil ini menggarisbawahi bahwa model yang lebih kompleks tidak secara otomatis menghasilkan prediksi yang lebih baik, prinsip yang juga ditekankan oleh Safi dan Sanusi (2021). Pemilihan model harus didorong oleh karakteristik data dan tujuan peramalan daripada kecanggihan teoretis semata, sebagaimana diargumentasikan oleh Nurlala et al. (2025) dalam analisis komparatif mereka untuk pengendalian stok.

Simpulan dan Saran

Penelitian ini berhasil membandingkan tiga metode peramalan (SES, DES, dan ARIMA) untuk kualitas udara multi-polutan di Deli Tua dengan evaluasi komprehensif terhadap enam parameter termasuk AQI. Hasil menunjukkan bahwa ARIMA memberikan kinerja terbaik dengan MAPE rata-rata 15,49%, mengungguli SES (16,13%) dan DES (20,19%). Untuk prediksi AQI, ARIMA mencapai MAPE sebesar 24,04% yang masih berada dalam kategori dapat diterima untuk kebutuhan sistem peringatan dini.

Polutan gas yang relatif stabil (O_3 , NO_2 , SO_2) menunjukkan tingkat akurasi yang sangat baik dengan nilai MAPE di bawah 10%, dimana SES menghasilkan performa terbaik untuk NO_2 . Sebaliknya, polutan partikulat ($PM_{2.5}$ dan PM_{10}) memiliki tingkat kesalahan yang lebih tinggi akibat adanya lonjakan konsentrasi yang tidak terduga. Hal ini menunjukkan bahwa metode berbasis data historis memiliki keterbatasan dalam menangkap kejadian ekstrem.

Analisis korelasi menunjukkan adanya hubungan yang kuat antar polutan, khususnya antara $PM_{2.5}$ dan PM_{10} , serta hubungan terbalik antara O_3 dan NO_2 . Pemanfaatan korelasi ini dalam mekanisme peramalan sekuensial terbukti mampu meningkatkan konsistensi dan reliabilitas prediksi. Sistem yang dikembangkan mampu mendukung peramalan jangka pendek (1–24 jam) yang berguna untuk pengambilan keputusan operasional dan sistem peringatan dini kesehatan publik.

Untuk implementasi operasional, ARIMA direkomendasikan sebagai metode utama, sementara SES dapat digunakan untuk prediksi real-time pada polutan dengan karakteristik stabil seperti NO_2 . Pengembangan lebih lanjut dapat dilakukan melalui integrasi variabel eksternal seperti data meteorologis dan aktivitas antropogenik, serta penerapan pembaruan model secara berkala untuk menyesuaikan perubahan pola data.

Penelitian selanjutnya disarankan untuk mengeksplorasi model dengan komponen musiman, pendekatan machine learning, serta model multivariat yang lebih kompleks. Selain itu, penggunaan dataset dengan periode yang lebih panjang dan validasi pada berbagai lokasi geografis diperlukan untuk meningkatkan generalisasi dan ketahanan model. Implementasi pendekatan hybrid juga berpotensi meningkatkan akurasi, meskipun perlu mempertimbangkan kompleksitas yang ditambahkan.

Referensi

- Akolo, I. R. (2018). Perbandingan exponential smoothing Holt-Winters dan ARIMA pada peramalan produksi padi di Provinsi Gorontalo. *JTech*, 7(1), 20-26. <https://doi.org/10.30869/jtech.v7i1.314>
- Djami, R. J., & Nanlohy, Y. W. A. (2022). Peramalan indeks harga konsumen di Kota Ambon menggunakan autoregressive integrated moving average (ARIMA) dan double exponential smoothing. *Variance Journal of Statistics and Its Applications*, 4(1), 1-14. <https://doi.org/10.30598/variancevol4iss1page1-14>
- Farhan, M., Sanusi, W., & Ihsan, H. (2024). Pemodelan pencemaran udara sebagai solusi penurunan kualitas udara menggunakan generalized space-time autoregressive di Kota Makassar. *JMATHCOS: Journal of Mathematics, Computation and Statistics*, 7(2), 258-274. <https://doi.org/10.35580/jmathcos.v7i2.4304>

- Harini, S. (2020). Identification COVID-19 cases in Indonesia with the double exponential smoothing method. *Jurnal Matematika MANTIK*, 6(1), 66-75. <https://doi.org/10.15642/mantik.2020.6.1.66-75>
- Karyadi, Y., & Setiawan, E. B. (2022). Prediksi kualitas udara dengan metoda LSTM, bidirectional LSTM, dan GRU. *Jurnal Teknik Informatika dan Sistem Informasi (Jatisi)*, 9(1), 671-684.
- Khaira, U., Putri, M. F., & Yanova, S. (2025). Peramalan kadar PM10 menggunakan algoritma Long Short-Term Memory (LSTM) sebagai acuan ketersediaan ruang terbuka hijau di Kota Jambi. *DECODE: Jurnal Pendidikan Teknologi Informasi*, 5(1), 289-302. <http://dx.doi.org/10.51454/decode.v5i1.866>
- Khumaidi, A., Raafiudin, R., & Solihin, I. P. (2020). Pengujian algoritma Long Short Term Memory untuk prediksi kualitas udara dan suhu Kota Bandung. *Jurnal Telematika*, 15(1), 48-57.
- Khusna, N. F., Aulia, S., Amaria, S., Rahmah, A., Sanmas, S. A., & Fauzi, F. (2023). Peramalan kualitas udara di Semarang menggunakan metode autoregressive integrated moving average (ARIMA). *Prosiding Seminar Nasional UNIMUS*, 6, 512-523.
- Munarsih, E., & Saluza, I. (2020). Comparison of exponential smoothing method and autoregressive integrated moving average (ARIMA) method in predicting dengue fever cases in the city of Palembang. *Journal of Physics: Conference Series*, 1521, 032100. <https://doi.org/10.1088/1742-6596/1521/3/032100>
- Nisa, I. H., Mirtawati, & Prabowo, S. H. (2024). Pemodelan vector autoregressive (VAR) pada peramalan tingkat pencemaran udara oleh ozon (O₃) dan nitrogen dioksida (NO₂) di DKI Jakarta. *Matematika Sains*, 2(1), 45-58.
- Nurlela, W., Pratiwi, A. I., & Yulianti, H. T. (2025). Analisis metode moving average, exponential smoothing, dan ARIMA dalam peramalan permintaan untuk pengendalian stok floor rear (Studi kasus: PT. SAI). *Jurnal Teknologi dan Manajemen Industri Terapan (JTMIT)*, 4(3), 1066-1075.
- Oktavia, F., & Witanti, A. (2024). Implementasi Prophet forecasting model dalam prediksi kualitas udara Daerah Istimewa Yogyakarta. *Jurnal Teknik Informatika dan Sistem Informasi (Jatisi)*, 11(1), 64-74.
- Olivia, M. (2021). Metode exponential smoothing untuk forecasting jumlah penduduk miskin di Kota Langsa. *Gamma-Pi: Jurnal Matematika dan Terapan*, 3(1), 34-44.
- Perdana, D., Muklason, A., & Merdeka, J. (2023). Machine learning untuk peramalan kualitas indeks standar pencemar udara DKI Jakarta dengan metode hibrid ARIMAX-LSTM. *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, 5(3), 209-222. <https://doi.org/10.28926/ilkomnika.v5i3.588>
- Pratama, K., & Setiawan, E. B. (2017). Implementasi monitoring kualitas udara menggunakan peramalan exponential smoothing dan NodeMCU berbasis mobile Android. *ULTIMA Computing*, 9(2), 58-66.
- Putri, I. D., & Oktaviarina, A. (2024). Penerapan vector autoregressive integrated moving average (VARIMA) pada prediksi indeks standar pencemaran udara di Kabupaten Gresik. *MATHunesa: Jurnal Ilmiah Matematika*, 12(2), 387-401.

- Safi, S. K., & Sanusi, O. I. (2021). A hybrid of artificial neural network, exponential smoothing, and ARIMA models for COVID-19 time series forecasting. *Model Assisted Statistics and Applications*, 16(1), 25-35. <https://doi.org/10.3233/MAS-210512>
- Sinaga, L. P., Fathoni, M. Y., & Prabowo, D. A. (2022). Peramalan tingkat pencemaran udara akibat kendaraan bermotor dengan metode time series Cheng. *JURIKOM (Jurnal Riset Komputer)*, 9(4), 912-920. <https://doi.org/10.30865/jurikom.v9i4.4587>
- Wahyudi, R., Annas, S., & Rais, Z. (2023). Analisis support vector regression (SVR) untuk meramalkan indeks kualitas udara di Kota Makassar. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 5(3), 104-117. <https://doi.org/10.35580/variansiunm107>
- Yusuf, A., Kusriani, & Muhammad, A. H. (2022). Perbandingan additive dan multiplicative exponential smoothing terhadap prakiraan kualitas udara di Banjarmasin. *Jurnal ELTIKOM: Jurnal Teknik Elektro, Teknologi Informasi dan Komputer*, 6(1), 40-55. <http://doi.org/10.31961/eltikom.v6i1.507>
- Zikri, M. A., Taruna, I. W. J. J., Merdeka, J., & Saputra, A. H. (2023). Pemanfaatan pemodelan machine learning dalam memprediksi parameter kualitas udara nitrogen dioksida (NO₂) berdasarkan algoritma Extra Trees Regression di DKI Jakarta. *JC-T (Journal Cis-Trans): Jurnal Kimia dan Terapannya*, 7(2), 30-38. <https://doi.org/10.17977/um0260v7i22023p031>