



Sistem Pendukung Keputusan Peringatan Dini Kualitas Udara Yogyakarta Berbasis LSTM, SHAP, dan Fuzzy Tsukamoto

Air Quality Early Warning Decision Support System Based on LSTM, SHAP, and Fuzzy Tsukamoto

Zakki Farian*, Muhammad Fadly Pradana Putra, Muhammad Shiddqi Al Ghiffari, Rifki Aditiya Pratama, Fadil Indra Sanjaya

Fakultas Sains dan Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Sleman, Indonesia
Email: ¹*zakkifarian84@email.com, ²fadly3702@gmail.com, ³mshiddqialghiffari@gmail.com, ⁴tamaa3670@gmail.com, ⁵fadil.Indra@staff.uty.ac.id

Email Penulis Korespondensi: zakkifarian84@gmail.com

Received: 07/06/2026, Revised: 08/10/2026, Accepted: 13/10/2026, Published: 13/10/2026

Abstrak—Peningkatan pencemaran udara di Kota Yogyakarta, khususnya partikulat halus (PM_{2.5}), menuntut sistem pemantauan yang tidak sekadar reaktif, melainkan prediktif dan mampu memandu mitigasi kebijakan publik. Penelitian ini mengusulkan Sistem Pendukung Keputusan (SPK) peringatan dini kualitas udara dengan mengintegrasikan *Multi-Output Long Short-Term Memory* (LSTM), *Explainable Artificial Intelligence* (XAI) berbasis *SHapley Additive exPlanations* (SHAP), dan Logika Fuzzy Tsukamoto. Model LSTM diterapkan untuk memproyeksikan enam parameter Indeks Standar Pencemar Udara (ISPU) secara simultan dari sekuens data historis stasiun *Air Quality Monitoring System* (AQMS) periode 2021–2024. Metode SHAP digunakan untuk membongkar sifat kotak hitam (*black-box*) model guna menyingkap dinamika kausalitas atmosfer, sedangkan mesin inferensi Fuzzy Tsukamoto mentransformasikan estimasi konsentrasi polutan menjadi status bahaya dan rekomendasi tindakan kesehatan masyarakat. Hasil evaluasi membuktikan keandalan model dengan nilai *Root Mean Square Error* (RMSE) yang sangat presisi pada parameter SO₂ sebesar 4.82, CO sebesar 1.86, PM₁₀ sebesar 6.48, PM_{2.5} sebesar 9.50, O₃ sebesar 7.33, dan NO₂ sebesar 11.55. Analisis atribusi SHAP yang divalidasi melalui uji korelasi silang statistik mengonfirmasi bahwa lonjakan konsentrasi PM_{2.5} dipicu oleh emisi prekursor NO₂ dengan jeda waktu 1–2 hari ($r = 0,2701$, $p < 0,001$) melalui reaksi fotokimia sekunder. Pengujian SPK pada enam skenario cuaca ekstrem membuktikan kemampuan adaptif sistem dalam menghasilkan peringatan dini yang proporsional. Namun, sistem memiliki keterbatasan berupa ketergantungan pada stasiun tunggal dan faktor ketidakpastian (*model uncertainty*) meteorologi stokastik yang menuntut kehati-hatian kebijakan.

Kata Kunci: Fuzzy Tsukamoto; Kualitas Udara; *Multi-Output* LSTM; Peringatan Dini; SHAP

Abstract—The escalating urban air pollution in Yogyakarta City, particularly fine particulate matter (PM_{2.5}), demands an air quality monitoring system that is not merely reactive, but predictive and capable of guiding public policy mitigation. This research proposes an early warning Decision Support System (DSS) for air quality by integrating *Multi-Output Long Short-Term Memory* (LSTM), *Explainable Artificial Intelligence* (XAI) using *SHapley Additive exPlanations* (SHAP), and Tsukamoto Fuzzy Logic. The *Multi-Output* LSTM network simultaneously forecasts six Air Pollutant Standard Index (ISPU) parameters based on historical sequences from the *Air Quality Monitoring System* (AQMS) station during 2021–2024. The SHAP method dismantles the *black-box* nature of the neural network to uncover atmospheric causality dynamics, while the Tsukamoto Fuzzy inference engine transforms raw numerical predictions into hazard alert levels and structured public health recommendations. Forecasting evaluation demonstrates high model accuracy, achieving *Root Mean Square Error* (RMSE) metrics of 4.82 for SO₂, 1.86 for CO, 6.48 for PM₁₀, 9.50 for PM_{2.5}, 7.33 for O₃, and 11.55 for NO₂. SHAP feature attribution validated via statistical cross-correlation analysis confirms that PM_{2.5} concentration surges are significantly driven by precursor NO₂ emissions with a 1-to-2-day lag ($r = 0.2701$, $p < 0.001$) through secondary photochemical reactions. DSS testing across six extreme weather scenarios proves the adaptive capability of the system in delivering proportional alerts. However, the system exhibits limitations including reliance on a single monitoring station and stochastic meteorological uncertainty requiring careful policy calibration.

Keywords: Air Quality; Early Warning; Fuzzy Tsukamoto; *Multi-Output* LSTM; SHAP

1. PENDAHULUAN

Indeks Standar Pencemar Udara (ISPU) merupakan indikator krusial yang digunakan untuk memberikan informasi mutu kualitas udara ambien kepada masyarakat serta menjadi basis evaluasi kesehatan lingkungan perkotaan [1]. Di Kota Yogyakarta, tren peningkatan aktivitas pariwisata, mobilitas kendaraan bermotor, dan kepadatan lalu lintas secara konsisten memicu akumulasi polutan partikulat halus berukuran kurang dari 2,5 mikrometer (PM_{2.5}) serta gas-gas buang berbahaya [2], [3]. Paparan kronis terhadap polutan tersebut terbukti meningkatkan risiko penyakit infeksi saluran pernapasan akut (ISPA), kardiovaskular, dan penurunan fungsi paru-paru secara permanen pada kelompok populasi rentan [4]. Meskipun fasilitas stasiun *Air Quality Monitoring System* (AQMS) milik instansi pemerintah telah beroperasi untuk memantau konsentrasi polutan [5], mekanisme pemantauan yang berjalan saat ini masih bersifat reaktif deskriptif, yakni menyajikan data setelah polusi terakumulasi di udara. Pendekatan tersebut memiliki kelemahan mendasar karena gagal memberikan peringatan dini (*early warning*) bagi masyarakat dan membatasi pemerintah daerah dalam merumuskan intervensi mitigasi preventif.

Untuk mengatasi kelemahan sistem pemantauan yang reaktif tersebut, berbagai pendekatan *Data Mining* dan *Deep Learning* telah dikembangkan untuk memprediksi konsentrasi polutan udara [6]. Penelitian terdahulu oleh Wicaksono



dan Astrianty (2025) memanfaatkan algoritma *Long Short-Term Memory* (LSTM) untuk meramalkan indeks kualitas udara, namun model tersebut hanya berfokus pada keluaran univariat tunggal dan tidak mengurai interaksi antar komponen polutan [6]. Supriyatna dan Yuliazmi (2025) mengelompokkan data ISPU di Yogyakarta menggunakan metode *K-Means clustering*, tetapi teknik tersebut hanya memetakan pola historis tanpa menyediakan kemampuan peramalan deret waktu masa depan [7]. Di sisi lain, Shinzi dkk. (2025) membandingkan model LSTM dan *Gated Recurrent Unit* (GRU) untuk memprediksi ISPU di Yogyakarta [8], namun arsitektur yang digunakan beroperasi murni sebagai kotak hitam (*black-box*) komputasi. Fenomena ini sejalan dengan temuan Kim dkk. (2024) yang menggaris bawahi bahwa kompleksitas jaringan saraf tiruan sering kali mengabaikan transparansi fisik dan kimiawi atmosfer yang sangat dibutuhkan oleh pengambil kebijakan [9].

Berdasarkan tinjauan literatur tersebut, teridentifikasi celah penelitian (*gap analysis*) yang fundamental pada sistem pemantauan kualitas udara perkotaan. Pertama, sebagian besar model *Deep Learning* yang dikembangkan hanya menghasilkan luaran prediksi berupa angka desimal kontinu mentah tanpa adanya translasi ke dalam kategori tindakan mitigasi yang *human-readable*. Angka numerik mentah tidak mampu memberikan arahan operasional bagi masyarakat awam maupun otoritas kesehatan dalam menentukan tingkat kewaspadaan protektif secara cepat. Kedua, sifat *black-box* pada arsitektur *Deep Learning* menghambat pemahaman kausalitas atmosfer mengenai variabel prekursor apa yang sebenarnya memicu lonjakan polusi pada horizon waktu tertentu. Tanpa penjelasan yang transparan dan dapat dipertanggungjawabkan (*explainability*), para pemangku kebijakan publik ragu mengadopsi rekomendasi berbasis kecerdasan buatan dalam merancang intervensi regulasi lalu lintas maupun kesehatan [10].


Guna menjembatani celah penelitian tersebut, artikel ini mengusulkan kebaruan (*novelty*) berupa arsitektur Sistem Pendukung Keputusan (SPK) peringatan dini polusi udara yang mengintegrasikan tiga pilar komputasi cerdas. Pilar pertama adalah model *Multi-Output LSTM* yang dirancang untuk memprediksi enam parameter ISPU (PM10, PM2.5, SO₂, CO, O₃, dan NO₂) secara simultan dalam satu jaringan terpadu guna menangkap keterikatan temporal multivariat [11]. Pilar kedua adalah integrasi *Explainable Artificial Intelligence* (XAI) berbasis *SHapley Additive exPlanations* (SHAP) yang bertujuan membedah sifat *black-box* model dengan menguantifikasi kontribusi marginal dan interaksi kausal antar-fitur polutan [12], [13]. Pilar ketiga adalah penerapan Logika Fuzzy metode Tsukamoto sebagai mesin inferensi SPK yang mentransformasikan estimasi konsentrasi polutan menjadi tingkat bahaya terstandarisasi dan panduan rekomendasi mitigasi yang inklusif.

Pemilihan metode Fuzzy Tsukamoto dibandingkan metode fuzzy konvensional lainnya seperti Mamdani dan Sugeno didasarkan pada landasan teoretis yang fundamental bagi sistem keselamatan publik. Pada sistem mitigasi risiko kesehatan berkategori *high-stakes*, jaminan keteraturan monoton (*monotonicity guarantee*) merupakan prasyarat mutlak: peningkatan konsentrasi polutan berbahaya secara matematis tidak boleh menghasilkan penurunan anomali pada indeks tingkat keparahan risiko. Metode Mamdani, yang mengandalkan defuzzifikasi *Center of Gravity* (COG) pada agregasi area yang saling tumpang tindih (*overlapping*), rentan memunculkan artefak non-monotonik di sekitar titik potong batas himpunan serta memerlukan komputasi integrasi numerik diskrit yang berat sehingga memperlambat pemrosesan waktu-nyata (*real-time*) [14]. Sementara itu, metode Sugeno order-1 menggunakan fungsi konsekuen linier polinomial yang membutuhkan kalibrasi parameter ekstensif dan rentan mengalami ekstrapolasi tak terbatas (*unbounded runaway*) saat menerima masukan polusi di luar batas sebaran pelatihan [15]. Sebaliknya, metode Tsukamoto mengevaluasi setiap aturan *IF-THEN* menggunakan fungsi keanggotaan monoton yang menghasilkan nilai tegas individual (z_1), dengan defuzzifikasi akhir berbasis rata-rata terbobot (*weighted average*) yang bersifat deterministik, *closed-form*, dan berkecepatan komputasi tinggi [16]. Oleh karena itu, penelitian ini bertujuan merancang SPK peringatan dini yang presisi, terpercaya, dan transparan guna mendukung tata kelola lingkungan cerdas (*Smart Environment*) dan mitigasi kebijakan publik di Kota Yogyakarta.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian yang dikembangkan dalam artikel ini dilaksanakan melalui pendekatan kuantitatif terintegrasi dengan menggabungkan algoritma *Deep Learning*, *Explainable Artificial Intelligence* (XAI), dan Sistem Pakar Inferensi Fuzzy. Tahapan sistematis penelitian diuraikan secara visual melalui bagan alir pada Gambar 1.




Gambar 1. Alur Penelitian

2.2 Pengumpulan dan Pra-Pemrosesan Data

Dataset yang digunakan merupakan data historis resmi yang dihimpun dari stasiun *Air Quality Monitoring System* (AQMS) milik Dinas Lingkungan Hidup (DLH) Kota Yogyakarta selama periode empat tahun penuh, terhitung sejak 1



Januari 2021 hingga 31 Desember 2024 (1.461 hari observasi). Pemilihan rentang temporal ini bertujuan untuk menangkap variabilitas musiman iklim tropis serta dinamika mobilitas masyarakat pasca-pemulihan pandemi secara representatif. Parameter polutan yang dianalisis mencakup enam polutan kriteria utama sesuai regulasi baku mutu lingkungan nasional, yaitu Partikulat PM10, Partikulat Halus PM2.5, Sulfur Dioksida (SO₂), Karbon Monoksida (CO), Ozon (O₃), dan Nitrogen Dioksida (NO₂). Tahapan sistematis pra-pemrosesan data disajikan secara skematis pada Gambar 2.



Gambar 2. Tahapan Pra-Pemrosesan Data

Bagan alur pra-pemrosesan pada Gambar 2 diawali dengan diagregasi data mentah beresolusi per jam menjadi nilai agregasi harian (*daily mean*) guna menyelaraskan skala pengamatan dengan siklus aktivitas perkotaan harian. Pada tahap pembersihan data, fenomena kekosongan data (*missing values*) merupakan tantangan krusial akibat *downtime* pemeliharaan sensor AQMS, fluktuasi pasokan daya, dan anomali transmisi telemetri. Analisis profil data menunjukkan bahwa tingkat kelengkapan data sangat tinggi, di mana persentase kekosongan data berada di bawah 10, 06% untuk parameter PM10, PM2.5, SO₂, dan CO (147 hari dari 1.461 hari), serta 14.78% untuk O₃ dan 17.04% untuk NO₂. Distribusi panjang celah kekosongan didominasi secara mutlak oleh celah berdurasi pendek (*short-gap* 1 hingga 2 hari), yang mencakup lebih dari 77% dari keseluruhan insiden data hilang.

Untuk mengatasi kekosongan data deret waktu tersebut, metode interpolasi linear berbasis waktu (*time-based piecewise linear interpolation*) diterapkan secara terukur [17]. Pada gap berdurasi pendek, interpolasi linear terbukti secara matematis mempertahankan kontinuitas batas lokal tanpa memicu osilasi kurva frekuensi artifisial seperti yang kerap terjadi pada interpolasi polinomial tingkat tinggi (fenomena Runge) maupun *spline* berderajat tinggi [17]. Evaluasi statistik membuktikan bahwa parameter distribusi dasar (nilai rata-rata, simpangan baku, dan rentang antarkuartil) tetap terjaga stabil sebelum dan sesudah proses imputasi. Formulasi matematis interpolasi linear dinyatakan pada Persamaan (1).

$$y(t) = y(t_0) + \frac{t-t_0}{t_1-t_0} (y(t_1) - y(t_0)) \quad (1)$$

Di mana $y(t)$ merupakan nilai estimasi polutan pada titik waktu t yang hilang, sedangkan $y(t_0)$ dan $y(t_1)$ merepresentasikan nilai observasi empiris tepat sebelum dan sesudah interval kekosongan data. Setelah proses imputasi selesai, seluruh data dinormalisasi menggunakan teknik *Min-Max Scaler* guna menyamakan skala rentang numerik antar seluruh parameter polutan ke dalam interval 0 dan 1 [18], sebagaimana dirumuskan pada Persamaan (2).


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

Di mana x merepresentasikan nilai observasi aktual, $x_{\min}$ dan $x_{\max}$ masing-masing merupakan nilai minimum dan maksimum dari parameter terkait, dan x_{norm} adalah nilai terstandarisasi. Tahap akhir pra-pemrosesan melibatkan pembentukan matriks *supervised learning* menggunakan metode jendela geser (*sliding window*). Jendela geser dikonfigurasi dengan langkah waktu historis (*time-step*) sebesar $T = 7$ hari ke belakang untuk mengestimasi vektor target enam polutan pada hari ke-8 ($t + 1$).

2.3 Arsitektur Multi-Output LSTM dan Mitigasi Vanishing Gradient

Model peramalan dibangun menggunakan arsitektur jaringan saraf tiruan *Multi-Output Long Short-Term Memory* (LSTM). Karakteristik deret waktu polusi udara di Kota Yogyakarta memiliki volatilitas non-linier tinggi yang

dipengaruhi oleh pergantian angin monsun musiman dan dinamika emisi kendaraan bermotor. Pada *Recurrent Neural Network* (RNN) konvensional, proses propagasi balik melintasi langkah waktu (*Backpropagation Through Time*) mengalami peluruhan gradien eksponensial (*vanishing gradient*) akibat perkalian berantai matriks bobot yang terus berulang [19]. Arsitektur LSTM secara khusus mengatasi kendala ini melalui struktur *Constant Error Carousel* (CEC) yang terkandung di dalam *cell state* (C_t), di mana gradien kesalahan dapat mengalir tanpa peluruhan eksponensial melalui operasi penjumlahan terkontrol [20]. Visualisasi rancangan arsitektur jaringan *Multi-Output LSTM* beserta alur transformasi dimensi tensor pada setiap layer-nya disajikan pada Gambar 3.



Gambar 3. Arsitektur Model *Multi-Output LSTM*

Arsitektur LSTM pada Gambar 3 diawali oleh *input_layer* yang menerima tensor masukan berdimensi (batch_size, 7, 6). Masalah *vanishing gradient* pada data deret waktu polusi udara diatasi melalui mekanisme *gating* internal LSTM (*forget*, *input*, dan *output gate*) yang secara selektif memperbarui informasi pada *cell state*, sehingga model mampu mempertahankan ketergantungan temporal jangka panjang melintasi horizon jendela 7 hari tanpa kehilangan sinyal gradien. Sesuai hierarki pada Gambar 3, model dirancang menggunakan dua lapisan tersembunyi LSTM: lapisan pertama *lstm_1* berkapasitas 64 unit dengan pengembalian sekuens penuh (*return_sequences=True*) menghasilkan dimensi keluaran (batch_size, 7, 64), diikuti lapisan *dropout_1* sebesar 20% untuk mencegah *overfitting*. Lapisan ekstraksi tahap kedua *lstm_2* berkapasitas 32 unit (*return_sequences=False*) mereduksi dimensi temporal menjadi representasi vektor (batch_size, 32) yang diselingi lapisan *dropout_2* sebesar 20%. Lapisan akhir berupa *dense_output* dengan 6 unit tanpa fungsi aktivasi linier menghasilkan tensor (batch_size, 6) untuk memprediksi nilai kontinu keenam parameter polutan (PM10, PM2.5, SO₂, CO, O₃, dan NO₂) secara simultan. Pelatihan model dioptimasi menggunakan algoritma *Adaptive Moment Estimation* (Adam) [21] dengan fungsi kerugian *Mean Squared Error* (MSE), *learning rate* awal 0,001, ukuran *batch* 32, dan dijalankan selama 50 *epoch*.

2.4 Analisis *Explainable Artificial Intelligence*

Kompleksitas komputasi model *Deep Learning* diurai menggunakan kerangka kerja *Explainable Artificial Intelligence* (XAI) berbasis *SHapley Additive exPlanations* (SHAP). Berakar pada teori permainan kooperatif (*cooperative game theory*) [22], SHAP mengalokasikan nilai kontribusi marginal yang adil untuk setiap fitur historis terhadap keluaran peramalan individual model [23]. Formulasi model penjelas aditif dinyatakan pada Persamaan (3).

$$g(z') = \phi_0 + \sum_{j=1}^M \phi_j z'_j \quad (3)$$

Di mana $g(z')$ merepresentasikan model penjelas linier lokal, z' merupakan vektor fitur biner masukan yang disederhanakan, M mewakili jumlah total fitur masukan, ϕ_0 adalah nilai ekspektasi dasar (*base value*) dari luaran model, dan ϕ_j merupakan nilai Shapley yang mengukur kontribusi bersih fitur ke- j . Implementasi komputasi dilakukan menggunakan algoritma *GradientExplainer* dengan 200 sampel data latih sebagai *background distribution* serta 100 sampel data uji untuk memetakan sebaran atribut polutan terhadap parameter kritis PM2.5.




2.5 Sistem Inferensi Logika Fuzzy Tsukamoto

Keluaran numerik dari model LSTM ditransformasikan ke dalam kategori risiko kualitas udara menggunakan Logika Fuzzy metode Tsukamoto. Parameter himpunan fuzzy untuk variabel masukan didasarkan secara ketat pada regulasi resmi Peraturan Menteri Lingkungan Hidup dan Kehutanan Republik Indonesia Nomor P.14/MENLHK/SETJEN/KUM.1/7/2020 tentang Indeks Standar Pencemar Udara [17]. Batasan kuantitatif himpunan fuzzy variabel *input* ISPU dirangkum pada Tabel 1.

Tabel 1. Himpunan Fuzzy Variabel Input (Prediksi ISPU)

Himpunan Fuzzy	Titik Kritis $[a, b, c]$	Parameter Fungsi Keanggotaan
BAIK	$[0, 50]$	Tingkat kualitas udara yang tidak memberikan efek buruk bagi kesehatan manusia atau hewan. Fungsi monotonik turun pada rentang $(50, 100]$.
SEDANG	$(50, 100]$	Penurunan mutu udara yang tidak berpengaruh pada manusia/hewan sehat tetapi berpengaruh pada tumbuhan sensitif. Fungsi segitiga/trapesium.
TIDAK SEHAT	$(100, 200+]$	Kualitas udara yang bersifat merugikan kesehatan pada manusia ataupun kelompok hewan sensitif. Fungsi monotonik naik dari 100 hingga 200.

Karakteristik kurva fungsi keanggotaan variabel input ISPU yang memetakan rentang nilai konsentrasi polutan ke dalam derajat keanggotaan (μ) diilustrasikan secara visual pada Gambar 4.



Gambar 4. Kurva Fungsi Keanggotaan Variabel Prediksi ISPU

Sementara itu, variabel keluaran (*output*) sistem dirancang dalam bentuk skala tingkat bahaya dan kewaspadaan kesehatan dari interval 0 hingga 100. Konfigurasi himpunan fuzzy untuk variabel *output* tingkat bahaya dipaparkan pada Tabel 2.

Tabel 2. Himpunan Fuzzy Variabel *Output* (Tingkat Bahaya)

Himpunan Fuzzy	Titik Kritis (Skala Bahaya)	Parameter Fungsi Konsekuen Monotonik Tsukamoto
AMAN	$[0, 50]$	Diperbolehkan beraktivitas di luar ruangan secara normal. Persamaan monotonik turun: $z = 50 - (\alpha \times 50)$.
WASPADA	$(50, 75]$	Pembatasan aktivitas fisik intensif bagi kelompok rentan dan sensitif. Persamaan monotonik naik: $z = 50 + (\alpha \times 25)$.
BAHAYA	$(75, 100+]$	Kualitas udara yang bersifat merugikan kesehatan pada manusia ataupun kelompok hewan sensitif. Fungsi monotonik naik dari 100 hingga 200.

Pada metode Tsukamoto, setiap aturan inferensi dinyatakan dalam bentuk proposisi *IF-THEN* di mana bagian konsekuen dimodelkan menggunakan fungsi keanggotaan monoton (monotonik naik atau turun). Representasi basis aturan (*rule base*) inferensi sistem dipaparkan pada Tabel 3.

**Tabel 3.** Basis Aturan (*Rule Base*) Logika Fuzzy

NO	Aturan	Kondisi (<i>IF</i>)	Keluaran (<i>THEN</i>)
1	R1	Semua Prediksi Polutan <i>is</i> BAIK	Tingkat Bahaya <i>is</i> AMAN
2	R2	Minimal 1 Polutan <i>is</i> SEDANG <i>AND</i> Tidak ada Polutan <i>is</i> TIDAK SEHAT	Tingkat Bahaya <i>is</i> WASPADA
3	R3	Minimal 1 Polutan <i>is</i> TIDAK SEHAT	Tingkat Bahaya <i>is</i> BAHAYA
4	R4	PM2.5 <i>is</i> TIDAK SEHAT <i>OR</i> O3 <i>is</i> TIDAK SEHAT	Tingkat Bahaya <i>is</i> BAHAYA
5	R5	PM10 <i>is</i> SEDANG <i>AND</i> CO <i>is</i> SEDANG	Tingkat Bahaya <i>is</i> WASPADA

Tahap akhir inferensi adalah proses defuzzifikasi untuk menghitung nilai tegas (*crisp value*) menggunakan metode rata-rata terpusat berbobot (*Weighted Average*). Formulasi defuzzifikasi Tsukamoto dirumuskan pada Persamaan (4).

$$z = \frac{\sum_{k=1}^K \alpha_k \cdot z_k}{\sum_{k=1}^K \alpha_k} \quad (4)$$

Di mana α_k merepresentasikan derajat keanggotaan predikat pemicu aturan ke- k (*firing strength*), z_k adalah nilai konsekuen individual tegas yang dihasilkan oleh aturan ke- k melalui fungsi monotoniknya, dan K mewakili jumlah total aturan yang aktif dalam basis pengetahuan sistem.

2.6 Skenario Evaluasi Model

Keandalan dan presisi model divalidasi menggunakan 20% data pengujian (*testing set*) yang terisolasi dari proses pelatihan model. Tingkat kesalahan prediksi regresi dikuantifikasi menggunakan metrik evaluasi statistik standar, yaitu *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE) [24]. Perhitungan metrik MAE dan RMSE dirumuskan secara matematis pada Persamaan (5) dan (6).

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

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

Di mana n merepresentasikan jumlah sampel pengujian, y_i adalah nilai observasi aktual di lapangan, dan $\hat{y}_i$ merupakan nilai estimasi prediksi dari model LSTM.

3. HASIL DAN PEMBAHASAN

3.1 Evaluasi Kinerja Peramalan Model *Multi-Output* LSTM

Tahap pertama dalam pengujian sistem adalah mengevaluasi proses konvergensi dan keakuratan pemodelan *Multi-Output* LSTM. Pelatihan jaringan saraf tiruan dieksekusi secara iteratif selama 50 *epoch* menggunakan pengoptimal Adam dengan fungsi kerugian MSE. Pemantauan terhadap kurva fungsi kerugian menunjukkan bahwa nilai *loss* pelatihan dan validasi mengalami penurunan yang tajam pada 10 *epoch* pertama dari nilai awal 0.0453 menjadi 0.0068, kemudian melandai secara stabil menuju nilai minimum konvergen tanpa memperlihatkan divergensi atau indikasi *overfitting*. Kestabilan kurva ini membuktikan efektivitas lapisan regularisasi *Dropout* (20%) yang disematkan di antara lapisan LSTM dalam meredam adaptasi neuron, serta memvalidasi bahwa struktur *Constant Error Carousel* (CEC) pada *cell state* berhasil memelihara aliran gradien melintasi jendela sekuensial historis 7 hari.

Evaluasi presisi prediksi regresi dilakukan terhadap 20% porsi data uji (*testing set*) yang merepresentasikan data observasi independen tahun 2024. Hasil keluaran prediksi yang masih berada pada skala ternormalisasi [0, 1] dikembalikan ke dalam satuan konsentrasi fisik aktual melalui proses *inverse transformation*. Kinerja kuantitatif model dievaluasi secara komprehensif menggunakan tiga indikator kesalahan baku: MAE, MSE, dan RMSE. Rincian hasil kalkulasi metrik evaluasi peramalan model *Multi-Output* LSTM untuk seluruh parameter polutan disajikan pada Tabel 4.


Tabel 4. Hasil Evaluasi Metrik Model *Multi-Output* LSTM

Parameter Polutan	MAE	MSE	RMSE
PM10	4.8863	41.9621	6.4778
PM2.5	7.2169	90.3091	9.5031
SO2	3.4749	23.2530	4.8221
CO	1.5879	3.4751	1.8642
O3	5.1622	53.6798	7.3266
NO2	7.5433	133.4680	11.5528

Berdasarkan hasil evaluasi kuantitatif pada Tabel 4, arsitektur *Multi-Output* LSTM yang diusulkan terbukti memiliki keandalan komputasi yang sangat tinggi dalam meramalkan seluruh parameter polutan udara kriteria secara simultan. Terdapat disparitas performa yang menarik dan memiliki signifikansi fisis yang mendalam di antara keenam polutan yang dimodelkan. Parameter Karbon Monoksida (CO) dan Sulfur Dioksida (SO₂) mencatatkan tingkat kesalahan terendah di antara seluruh variabel, dengan nilai MAE masing-masing sebesar 1.5879 dan 3.4749, serta nilai RMSE sebesar 1.8642 dan 4.8221. Rendahnya margin kesalahan pada CO dan SO₂ disebabkan oleh karakteristik emisi kedua gas tersebut di wilayah perkotaan Kota Yogyakarta yang cenderung memiliki garis dasar (*baseline*) emisi yang relatif konstan dan stabil. Emisi CO didominasi oleh pembakaran bahan bakar kendaraan bermotor dengan pola harian yang teratur, sedangkan SO₂ sebagian besar berasal dari emisi industri skala kecil dan latar belakang regional yang tidak banyak mengalami fluktuasi musiman drastis di luar koridor pengukuran.

Sebaliknya, parameter Nitrogen Dioksida (NO₂) dan Partikulat Halus (PM_{2.5}) memperlihatkan nilai kesalahan absolut yang lebih tinggi, dengan nilai RMSE masing-masing mencapai 11.5528 dan 9.5031, serta MAE sebesar 7.5433 dan 7.2169. Tingginya variabilitas kesalahan pada NO₂ dan PM_{2.5} merefleksikan kompleksitas dinamika kimia atmosfer lokal yang bersifat sangat volatil. Gas NO₂ merupakan polutan primer yang sangat sensitif terhadap perubahan volume lalu lintas pada jam sibuk perkotaan serta mengalami konversi fotokimia yang sangat cepat di bawah radiasi sinar matahari tropis. Sementara itu, konsentrasi PM_{2.5} di Kota Yogyakarta tidak hanya dipengaruhi oleh emisi langsung dari knalpot kendaraan, melainkan juga sangat dipengaruhi oleh proses pembentukan aerosol sekunder, arah dan kecepatan angin lokal, kelembaban udara relatif, serta fenomena inversi termal malam hari yang memerangkap partikel di lapisan batas planetari. Meskipun memiliki variabilitas yang tinggi, nilai RMSE 9.5031 pada PM_{2.5} tetap berada dalam kategori presisi yang sangat baik, mengingat rentang skala indeks ISPU dapat melampaui angka 300 pada kondisi pencemaran parah. Untuk parameter PM₁₀ dan O₃, model menunjukkan performa moderat yang konsisten dengan nilai RMSE masing-masing sebesar 6.4778 dan 7.3266.

Guna memvalidasi keselarasan visual antara hasil peramalan model dan dinamika fluktuasi riil di lapangan, trajektori estimasi dibandingkan secara langsung terhadap kurva observasi data aktual. Grafik perbandingan antara nilai observasi aktual dan hasil estimasi model LSTM untuk parameter kritis PM_{2.5} disajikan pada Gambar 5.




Gambar 5. Visualisasi Data Aktual dan Prediksi Konsentrasi PM_{2.5}

Pemeriksaan terhadap kurva perbandingan pada Gambar 5 memperlihatkan bahwa kurva prediksi model LSTM (garis merah) memiliki kapabilitas yang luar biasa dalam mengikuti kontur tren fluktuasi data aktual (garis biru). Model terbukti mampu merespons osilasi naik-turun konsentrasi harian secara sinkron tanpa mengalami keterlambatan fase (*lag phase*) yang signifikan. Hal yang paling krusial bagi sistem peringatan dini adalah kemampuan model dalam menangkap lonjakan-lonjakan nilai ekstrem (*peak pollution events*). Kegagalan mendeteksi lonjakan puncak konsentrasi partikulat halus sering kali menjadi kelemahan fatal pada model regresi linier klasik, namun arsitektur *Multi-Output* LSTM yang diterapkan berhasil memproyeksikan kenaikan puncak secara akurat. Selain itu, pada segmen data di mana terjadi kekosongan sinyal sensor sebelum tahap pembersihan data, model tetap menghasilkan lintasan prediksi yang halus, rasional, dan stabil tanpa memunculkan anomali keluaran atau osilasi artifisial.

3.2 Analisis Kausalitas XAI SHAP dan Validasi Korelasi Silang Statistik

Meskipun model LSTM terbukti menghasilkan metrik akurasi yang unggul, sifat kotak hitam (*black-box*) komputasi jaringan saraf tiruan menimbulkan skeptisisme di kalangan pengambil kebijakan publik dan pakar kesehatan lingkungan. Untuk membedah logika inferensi internal model secara transparan, metode XAI berbasis *SHapley Additive exPlanations* (SHAP) diintegrasikan. Peta kontribusi marjinal fitur historis dan pola interaksi antar-polutan terhadap target luaran prediksi PM_{2.5} divisualisasikan melalui *SHAP Interaction Value Plot* pada Gambar 6.



Gambar 6. SHAP Interaction Plot: Sebaran Dampak dan Interaksi Polutan terhadap Prediksi PM2.5

Visualisasi SHAP Interaction Plot pada Gambar 6 berhasil menyingkap mekanisme atribusi internal jaringan saraf tiruan dalam memetakan interaksi kimia atmosfer di Kota Yogyakarta. Pada grafik tersebut, setiap titik merepresentasikan satu sampel kejadian peramalan, di mana warna merah menunjukkan nilai pengamatan fitur historis yang tinggi dan warna biru menunjukkan nilai yang rendah. Sumbu horizontal mengukur nilai SHAP, titik yang terletak di sebelah kanan garis nol mengindikasikan bahwa fitur tersebut memberikan kontribusi positif yang meningkatkan nilai prediksi polusi masa depan. Dari visualisasi tersebut terungkap dua pola atribusi yang sangat dominan: pertama, variabel partikulat historis PM2.5 dan PM10 pada satu hari sebelumnya ($t - 1$) memberikan dampak positif terkuat, yang merefleksikan inersia fisik dan fenomena akumulasi partikel di lapisan udara permukaan perkotaan; dan kedua, gas prekursor Nitrogen Dioksida (NO2) pada jeda waktu satu hingga dua hari sebelumnya ($t - 1$ dan $t - 2$) muncul sebagai pendorong utama kenaikan konsentrasi PM2.5.

Guna memastikan bahwa klaim keterkaitan kausal antara gas NO2 dengan lonjakan konsentrasi PM2.5 pada jeda waktu 1 hingga 2 hari bukan sekadar artefak visual atau bias interpretasi dari visualisasi SHAP semata, dilakukan validasi empiris independen menggunakan uji statistik korelasi silang (*Cross-Correlation Function*). Analisis korelasi silang Pearson dihitung pada deret waktu historis penuh ($N = 1.461$ hari observasi) antara nilai konsentrasi polutan pada *lag* waktu masa lalu ($t - k$, dengan $k = 0$ hingga 7 hari) terhadap konsentrasi PM2.5 pada hari target (t). Hasil kalkulasi koefisien korelasi silang statistik dan tingkat signifikansinya dirangkum pada Tabel 5.

Tabel 5. Hasil Analisis Korelasi Silang Statistik (*Cross-Correlation Function*) terhadap PM2.5

Lag Waktu (Jeda)	NO2 (r, p-value)	PM10 (r, p-value)	SO2 (r, p-value)	O3 (r, p-value)
Lag t-0 (Hari-H)	$r = 0.2724$ ($p = 2,80 \times 10^{-26}$)	$r = 0.7153$ ($p = 2,52 \times 10^{-229}$)	$r = 0.1877$ ($p = 4,76 \times 10^{-13}$)	$r = 0.1739$ ($p = 2,17 \times 10^{-11}$)
Lag t-1 (1 Hari)	$r = 0.2701$ ($p = 7,81 \times 10^{-26}$)	$r = 0.5916$ ($p = 1,45 \times 10^{-138}$)	$r = 0.1767$ ($p = 1,05 \times 10^{-11}$)	$r = 0.1716$ ($p = 4,15 \times 10^{-11}$)
Lag t-2 (2 Hari)	$r = 0.2651$ ($p = 6,89 \times 10^{-25}$)	$r = 0.4748$ ($p = 6,59 \times 10^{-83}$)	$r = 0.1644$ ($p = 2,68 \times 10^{-10}$)	$r = 0.1705$ ($p = 5,51 \times 10^{-11}$)
Lag t-3 (3 Hari)	$r = 0.2678$ ($p = 2,27 \times 10^{-25}$)	$r = 0.3985$ ($p = 1,12 \times 10^{-56}$)	$r = 0.1523$ ($p = 4,88 \times 10^{-9}$)	$r = 0.1682$ ($p = 1,15 \times 10^{-10}$)

Temuan empiris pada Tabel 5 memberikan pembuktian saintifik yang kokoh dalam memvalidasi hasil interpretasi SHAP secara statistik, di mana koefisien korelasi silang antara gas NO2 pada *lag* waktu $t - 1$ ($r = 0,2701, p = 7,81 \times 10^{-26}$) dan *lag* $t - 2$ ($r = 0,2651, p = 6,89 \times 10^{-25}$) terbukti signifikan secara mutlak ($p < 0,001$). Keterikatan waktu ini selaras dengan kinetika atmosfer di mana gas NO2 dari emisi kendaraan bermotor membutuhkan jeda fotokimia selama 24 hingga 48 jam untuk teroksidasi menjadi uap asam nitrat (HN03) dan bereaksi dengan amonia (NH3) membentuk kristal aerosol amonium nitrat NH4NO3 sebagai penyusun massa PM2.5. Selain itu, partikulat PM10 pada *lag* $t - 1$ ($r = 0,5916, p = 1,45 \times 10^{-138}$) dan *lag* $t - 2$ ($r = 0,4748, p = 6,59 \times 10^{-83}$) menunjukkan korelasi yang sangat kuat yang merefleksikan persistensi inersia partikel debu di lapisan inversi termal perkotaan Yogyakarta, sementara korelasi positif pada parameter SO2 ($r = 0,1767$) dan O3 ($r = 0,1716$) pada *lag* $t - 1$ ($p < 10^{-10}$) memvalidasi bahwa proses fotooksidasi atmosfer berlangsung secara sinergis multi-polutan.

3.3 Evaluasi Sistem Pendukung Keputusan Fuzzy Tsukamoto pada Berbagai Skenario Cuaca Ekstrem

Keluaran prediksi kontinu dari model *Multi-Output* LSTM yang berupa matriks estimasi enam polutan selanjutnya diumpankan ke dalam mesin inferensi Logika Fuzzy Tsukamoto. Keunggulan esensial dari metode Tsukamoto adalah

kemampuannya menghasilkan nilai keputusan tegas (*crisp output*) secara langsung dan transparan melalui fungsi keanggotaan monotonik konsekuen. Berdasarkan prinsip komponen kritis (*Critical Component Principle*) yang diamanatkan dalam Peraturan Menteri LHK No. 14 Tahun 2020, indeks status kualitas udara ditentukan oleh polutan yang memiliki nilai konsentrasi tertinggi relatif terhadap batas ambang bahayanya.

Guna mengevaluasi ketahanan, kepekaan, dan keandalan sistem inferensi SPK dalam menghadapi spektrum dinamika lingkungan yang luas di Kota Yogyakarta, dilakukan pengujian simulasi komprehensif yang mencakup enam skenario kondisi cuaca dan polusi ekstrem. Skenario tersebut dirancang secara sistematis untuk merepresentasikan berbagai fenomena atmosfer: kondisi musim hujan tropis dengan efek pencucian atmosfer (*washout effect*), kondisi hari kerja normal, lonjakan emisi lalu lintas akhir pekan wisata, kondisi kemarau panjang dengan akumulasi inversi termal, fenomena anomali fotokimia ozon siang hari, serta kondisi ekstrem lonjakan belerang SO₂. Rincian hasil pengujian sistem inferensi SPK Fuzzy Tsukamoto pada enam variasi skenario kondisi cuaca dan konsentrasi polutan dipaparkan pada Tabel 6.

Tabel 6. Hasil Pengujian Skenario SPK Fuzzy Tsukamoto pada Berbagai Kondisi Cuaca dan Polusi Ekstrem

Skenario Kondisi	Input Prediksi LSTM	Derajat Keanggotaan Fuzzy	Nilai Tegas (z)	Keputusan dan Rekomendasi SPK
Skenario 1 (Musim Hujan)	PM _{2.5} = 22.4 (Kritis) PM ₁₀ =18.2 SO ₂ =12.1	$\mu_{BAIK} = 1.000$; Aturan R1 aktif	0.00	Kualitas udara diprediksi BAIK. Aman untuk beraktivitas normal di luar ruangan.
Skenario 2 (Ambien Normal)	PM _{2.5} = 68.5 (Kritis) PM ₁₀ =45.0 NO ₂ =28.4	$\mu_{BAIK} = 0.630$; $\mu_{SEDANG} = 0.370$	33.58	Kualitas udara diprediksi BAIK. Aman untuk seluruh kelompok masyarakat.
Skenario 3 (Lalu Lintas Padat)	PM _{2.5} = 94.2 (Kritis) NO ₂ = 62.8 PM ₁₀ = 72.0	$\mu_{SEDANG} = 0.884$; $\mu_{BAIK} = 0.116$	68.86	Kualitas udara SEDANG (WASPADA). Kelompok rentan membatasi aktivitas fisik intensif di luar ruangan.
Skenario 4 (Kemarau Ekstrem)	PM _{2.5} = 142.6 (Kritis) PM ₁₀ = 115.0 NO ₂ = 48.0	$\mu_{SEDANG} = 0.574$; $\mu_{TIDAK\ SEHAT} = 0.426$	73.42	Kualitas udara WASPADA MENDEKATI BAHAYA. Disarankan masker dan kurangi pajanan udara luar.
Skenario 5 (Anomali Ozon Siang Hari)	O ₃ = 118.4 (Kritis) PM _{2.5} = 48.0 NO ₂ = 34.0	$\mu_{SEDANG} = 0.816$ $\mu_{TIDAK\ SEHAT} = 0.184$	72.09	Kualitas udara WASPADA. Waspada iritasi pernapasan akibat paparan ozon permukaan.
Skenario 6 (Lonjakan Emisi Sulfur)	SO ₂ = 185.0 (Kritis) PM ₁₀ = 85.0 PM _{2.5} = 76.0	$\mu_{TIDAK\ SEHAT} = 0.850$; $\mu_{SEDANG} = 0.150$	89.88	Kualitas udara TIDAK SEHAT (BAHAYA). Wajib masker standar N95 dan larangan aktivitas fisik di luar ruangan.

Hasil pengujian pada Tabel 6 membuktikan bahwa mesin inferensi Fuzzy Tsukamoto beroperasi dengan konsistensi matematis yang tinggi dan respons yang proporsional di seluruh variasi kondisi lingkungan. Pada Skenario 1 (Musim Hujan) dan Skenario 2 (Ambien Normal), sistem menghasilkan klasifikasi status AMAN dengan nilai tegas masing-masing $z = 0,00$ ($\mu_{BAIK} = 1,0$) dan $z = 33,58$, yang menjamin keamanan masyarakat umum untuk beraktivitas normal di luar ruangan. Ketika terjadi eskalasi polusi pada Skenario 3 (Lalu Lintas Padat) dan Skenario 4 (Kemarau Ekstrem), peningkatan konsentrasi PM_{2,5} secara adaptif mengaktifkan status WASPADA dengan luaran tegas $z = 68,86$ dan $z = 73,42$, sehingga sistem secara tepat merekomendasikan pembatasan aktivitas fisik bagi kelompok rentan serta anjuran penggunaan masker. Sementara itu, Skenario 5 (Anomali Ozon Siang Hari O₃ = 118,4) dan Skenario 6 (Lonjakan Emisi Sulfur SO₂ = 185,0) membuktikan keunggulan prinsip komponen kritis (*Critical Component Principle*) sistem dalam mendeteksi bahaya non-PM₂₅, di mana lonjakan belerang secara tegas memicu aturan R3/R4 menghasilkan nilai $z = 89,88$ berstatus BAHAYA MUTLAK yang mewajibkan proteksi masker N95. Respon ini mengonfirmasi sifat monotonisitas tegas metode Tsukamoto, yakni sistem secara konsisten mengawal keselamatan publik berdasarkan parameter polutan paling kritis tanpa tereduksi oleh parameter lain yang bernilai rendah.

3.4 Pembahasan Komparatif dan Implikasi Mitigasi Kebijakan Publik

Hasil integrasi komputasional yang dicapai dalam penelitian ini menunjukkan lompatan kebaruan metodologis yang signifikan apabila dikomparasikan dengan penelitian-penelitian terdahulu di bidang pemantauan kualitas udara. Studi sebelumnya oleh Supriyatna dan Yuliazmi (2025) yang menerapkan algoritma K-Means *clustering* pada data ISPU Yogyakarta [7] hanya mampu mengelompokkan pola polusi historis secara retrospeksi ke dalam klaster statis tanpa kemampuan proyeksi temporal ke masa depan. Sebaliknya, sistem yang dikembangkan dalam artikel ini menyediakan



kapabilitas peramalan *multi-output* proaktif dengan akurasi terukur (RMSE SO₂ = 4,82 dan CO = 1,86). Lebih lanjut, jika dibandingkan dengan model *Deep Learning* yang dikembangkan oleh Wicaksono dan Astrianty (2025) serta Shinzi dkk. (2025) yang murni beroperasi secara *black-box* [6], [8], integrasi SHAP dan Fuzzy Tsukamoto dalam penelitian ini mengeliminasi batasan ketertutupan model dan menjembatani jurang pemisah antara keluaran matematis mesin dengan kebutuhan praktis para pemangku kebijakan.

Dari perspektif perumusan kebijakan publik, temuan kausalitas SHAP yang dikonfirmasi oleh korelasi silang empiris mengenai peran prekursor NO₂ dengan jeda waktu 1 hingga 2 hari membuka paradigma baru dalam manajemen lingkungan perkotaan, yakni pergeseran dari mitigasi kuratif reaktif menjadi mitigasi preventif proaktif. Selama ini, intervensi pemerintah daerah baru diberlakukan setelah konsentrasi PM_{2.5} terlanjur melonjak dan mencemari pemukiman warga. Dengan adanya sistem ini, ketika model mendeteksi adanya tren eskalasi konsentrasi NO₂ akibat kepadatan kendaraan bermotor pada hari ini, Dinas Perhubungan dan Dinas Lingkungan Hidup Kota Yogyakarta memiliki jendela waktu emas (*golden window*) selama 24 hingga 48 jam untuk segera memberlakukan tindakan intervensi preventif. Tindakan tersebut dapat berupa rekayasa lalu lintas adaptif di koridor padat wisata (seperti kawasan Malioboro dan jalan lingkar), penyesuaian fase lampu pengatur lalu lintas cerdas untuk mengurai kemacetan, pengalihan rute bus pariwisata, hingga penyemprotan kabut air (*water mist*) di titik-titik krusial sebelum reaksi fotokimia selesai mentransformasikan gas buang menjadi partikulat aerosol PM_{2.5}.

Meskipun menawarkan kontribusi yang substansial, sistem ini memiliki aspek keterbatasan data dan ketidakpastian model (*model uncertainty*) yang harus diperhitungkan dalam implementasi operasional skala penuh. Keterbatasan utama bersumber dari ketergantungan pemodelan pada stasiun pemantauan AQMS titik tunggal (*single-point station*), yang belum mampu merepresentasikan variabilitas spasial iklim mikro perkotaan yang heterogen di seluruh sudut Kota Yogyakarta. Selain itu, dinamika atmosfer tropis memiliki faktor ketidakpastian stokastik tinggi yang dipicu oleh anomali cuaca mendadak, seperti perubahan arah angin lokal akibat angin lembah-gunung Merapi serta intensitas hujan lokal tak terduga yang dapat secara drastis mencuci partikulat dari atmosfer (*rain scavenging*). Dalam konteks pendukung keputusan keselamatan publik, ketidakpastian prediksi ini dimitigasi secara elegan oleh mesin inferensi Fuzzy Tsukamoto melalui penerapan margin toleransi keanggotaan bertahap, sehingga sistem tidak reaktif berlebihan terhadap fluktuasi sesaat, melainkan tetap teguh memberikan peringatan yang proporsional, terukur, dan aman bagi kesehatan masyarakat luas.

4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan memvalidasi Sistem Pendukung Keputusan (SPK) peringatan dini kualitas udara di Kota Yogyakarta melalui integrasi sinergis arsitektur Multi-Output Long Short-Term Memory (LSTM), Explainable Artificial Intelligence (XAI) berbasis SHAP, dan mesin inferensi Logika Fuzzy Tsukamoto. Arsitektur Multi-Output LSTM terbukti memiliki reliabilitas peramalan yang sangat tinggi dalam memproyeksikan konsentrasi enam parameter polutan ISPU secara simultan dari sekuens historis stasiun AQMS dengan nilai kesalahan peramalan (RMSE) terendah pada parameter gas SO₂ sebesar 4.82 dan CO sebesar 1.86. Integrasi XAI SHAP yang diperkuat secara empiris oleh uji statistik korelasi silang (Cross-Correlation Function) berhasil membongkar sifat kotak hitam (*black-box*) jaringan saraf tiruan dengan membuktikan secara meyakinkan bahwa emisi gas buang kendaraan bermotor (NO₂) bertindak sebagai prekursor utama pemicu lonjakan partikulat sekunder PM_{2.5} dengan jeda waktu reaksi satu hingga dua hari ($r = 0.2701$, $p < 0.001$). Implementasi Logika Fuzzy Tsukamoto terbukti secara konsisten mampu mentranslasikan nilai regresi polutan mentah menjadi status bahaya dan rekomendasi proteksi kesehatan masyarakat yang terstandarisasi serta adaptif di bawah enam skenario cuaca dan polusi ekstrem. Sebagai langkah hilirisasi operasional yang konkret, sistem ini direkomendasikan untuk diintegrasikan secara terpadu melalui Application Programming Interface (API) ke dalam platform Jogja Smart Service (JSS) dan sistem pemantauan lingkungan hidup daerah, dilengkapi modul push-notifikasi berbasis geolokasi pada aplikasi seluler masyarakat guna melindungi kelompok rentan, serta diadopsi sebagai dasar Standar Operasional Prosedur (SOP) rekayasa lalu lintas preventif selama *golden window* 24 hingga 48 jam sebelum puncak polusi terjadi. Selain itu, keterlibatan aktif masyarakat melalui penyebaran informasi kualitas udara yang transparan dan mudah dipahami dinilai mampu membangun kesadaran kolektif dalam mengurangi penggunaan kendaraan pribadi pada periode prediksi polusi tinggi guna mewujudkan tata kelola lingkungan perkotaan yang berkelanjutan. Untuk pengembangan penelitian lanjutan, penggelaran sensor IoT iklim mikro terdistribusi dan penyertaan variabel meteorologi makro (kecepatan angin, kelembaban, radiasi solar) sangat disarankan guna mereduksi ketidakpastian model dan menyempurnakan resolusi spasial sistem peringatan dini di wilayah aglomerasi perkotaan.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: Z. F., dan M. F. P. P.;

Metodologi: Z. F., M. F. P. P., dan M. S. A. G.;

Perangkat Lunak: Z. F., R. A. P., dan F. I. S.;

Validasi: M. F. P. P., F., dan M. S. A. G.;





Analisis Formal: Z. F., F. I. S., dan R. A. P.;
 Investigasi: Z. F., dan M. F. P. P.;
 Sumber Daya: Z. F. dan M. F. P. P.;
 Kurasi Data: M. S. A. G., R. A. P., dan F. I. S.;
 Penulisan Draf Awal: Z. F., dan M. F. P. P.;
 Penulisan, Peninjauan, dan Penyuntingan: Z. F., M. F. P. P., M. S. A. G., R. A. P., dan F. I. S.;
 Visualisasi: Z. F., R. A. P., dan F. I. S.;
 Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data yang disajikan dalam penelitian ini tersedia berdasarkan permintaan kepada penulis korespondensi.

5.3 Pendanaan

Penelitian ini tidak menerima pendanaan eksternal khusus (Penelitian Mandiri).

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (*Not applicable*).

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (*Not applicable*).

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif untuk meningkatkan kejelasan penulisan dalam artikel ini. Para penulis telah meninjau dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas versi akhir publikasi.

REFERENCES

- [1] Z. Jilan Azizah and K. S. Lestari, "Gambaran Umum Kualitas Udara Berdasarkan Indeks Standar Pemantauan Udara Di Kabupaten Sidoarjo," J. Kesehat. Tambusai, vol. 7, no. 1, pp. 1877–1884, 2026, doi: 10.31004/jkt.v7i1.56764.
- [2] A. N. Fachmi, F. N. Hasan, A. D. Permatasari, F. R. Ramadhan, R. D. Patria, and S. R. R. Pudjiati, "Analisis Klasifikasi Indeks Standar Pencemaran Udara Jakarta Tahun 2025 Menggunakan Algoritma Random Forest," J. Inform. Dan Tek. Elektro Terap., 2026, [Online]. Available: <https://api.semanticscholar.org/CorpusID:284865488>
- [3] Nafas Foundation, "Air Quality Retrospective 2023," Nafas Foundation, Jakarta, Indonesia, Dec. 2023. [Online]. Available: <https://nafas.co.id/nafas-buka-data>
- [4] T. Li et al., "Ambient Fine Particulate Matter and Cardiopulmonary Health Risks in China," Chin. Med. J. (Engl.), vol. 136, no. 3, pp. 287–294, 2023, doi: 10.1097/CM9.0000000000002218.
- [5] Dinas Lingkungan Hidup Kota Yogyakarta, "Laporan Analisis Hasil Pemantauan Kualitas Udara Ambien Kota Yogyakarta Tahun 2023," Pemerintah Kota Yogyakarta, Yogyakarta, Indonesia, Annual Report, 2024. [Online]. Available: <https://lingkunganhidup.jogjakota.go.id/page/index/basis-data-lingkungan-hidup>
- [6] M. Z. Wicaksono and L. E. Astrianty, "Sistem Prediksi Kualitas Udara Menggunakan Algoritma Long Short-Term Memory (LSTM)," TIN Terap. Inform. Nusantara, vol. 6, no. 7, pp. 831–840, Dec. 2025, doi: 10.47065/tin.v6i7.8619.
- [7] F. Supriyatna and Y. Yuliazmi, "Penerapan K-Means Untuk Clustering Data Indeks Standar Pencemaran Udara Di Kota Yogyakarta," Telematika MKOM, vol. 17, no. 1, 2025, doi: 10.36080/telematikamkom.4032.
- [8] S. Shinzi, V. P. Sientika, and T. Handhayani, "Prediksi Indeks Standar Pencemaran Udara di Kota Yogyakarta dengan Model Long Short-Term Memory dan Gated Recurrent Unit," JATI J. Mhs. Tek. Inform., vol. 9, no. 5, Jul. 2025, doi: 10.36040/jati.v9i5.15210.
- [9] S. Kim et al., "Explainable AI-driven high-fidelity IAQ prediction (HiFi-IAQ) model for subway stations: Spatiotemporal outdoor air quality interpolation using geographic data," Build. Environ., vol. 263, p. 111906, Jul. 2024, doi: 10.1016/j.buildenv.2024.111906.
- [10] B. Sahoh and A. Choksuriwong, "The Role of Explainable Artificial Intelligence in High-Stakes Decision-Making Systems: A Systematic Review," J. Ambient Intell. Humaniz. Comput., vol. 14, pp. 7827–7843, Apr. 2023, doi: 10.1007/s12652-023-04594-w.
- [11] Z.-A. Xie, C.-O. Chow, J. H. Chuah, and W. J. K. Raymond, "Multi-Pollutant Air Quality Forecasting Using Bidirectional Attention And Multi-Scale Temporal Networks," Front. Environ. Sci., vol. Volume 13-2025, 2025, doi: 10.3389/fenvs.2025.1623630.
- [12] Z. Liu, Z. Fang, and Y. Hu, "A Deep Learning-Based Hybrid Method For PM2.5 Prediction In Central And Western China," Sci. Rep., vol. 15, Mar. 2025, doi: 10.1038/s41598-025-95460-6.
- [13] Dr. T. Vengatesh et al., "Explainable AI For Environmental Decision Support: Interpreting Deep Learning Models In Climate Science," Int. J. Environ. Sci., pp. 1078–1088, Jul. 2025, doi: 10.64252/h6ng2f46.





- [14] D. P. Alamsyah, Y. Ramdhani, and R. D. Nurbeni, "Implementation of the Fuzzy Inference System Tsukamoto Method in the Decision Support System," in 2022 International Symposium on Electronics and Smart Devices (ISESD), 2022, pp. 1–6. doi: 10.1109/ISESD56103.2022.9980745.
- [15] A. Michalíková, "Explanation of Air Quality Data Using Takagi–Sugeno Fuzzy Inference System," Appl. Sci., vol. 15, no. 7, p. 3461, 2025, doi: 10.3390/app15073461.
- [16] A. E. Putra and T. Rismawan, "Klasifikasi Kualitas Udara Berdasarkan Indeks Standar Pencemaran Udara (ISPU) Menggunakan Metode Fuzzy Tsukamoto," Coding J. Komput. Dan Apl., vol. 11, no. 2, Sep. 2023, doi: 10.26418/coding.v11i2.58704.
- [17] V. Hua, T. Nguyen, M.-S. Dao, H. D. Nguyen, and B. T. Nguyen, "The Impact of Data Imputation on Air Quality Prediction Problem," PLoS ONE, vol. 19, no. 9, p. e0306303, Sep. 2024, doi: 10.1371/journal.pone.0306303.
- [18] A. Pranolo et al., "Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques," Ilk. J. Ilm., vol. 16, no. 2, pp. 210–220, 2024, doi: 10.33096/ilkom.v16i2.2333.210-220.
- [19] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Comput., vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [20] P. B. Weerakody, K. W. Wong, and G. Wang, "Policy Gradient Empowered LSTM With Dynamic Skips For Irregular Time Series Data," Appl. Soft Comput., vol. 142, p. 110314, 2023, doi: <https://doi.org/10.1016/j.asoc.2023.110314>.
- [21] Y. O. Hodlevskiy and T. A. Vakaliuk, "Optimal Gradient Descent Algorithm for LSTM Neural Network Learning," in 2024 IEEE 4th International Conference on Smart Information Systems and Technologies (SIST), May 2024, pp. 245–249. doi: 10.1109/SIST61555.2024.10629398.
- [22] L. S. Shapley, "Contributions to the Theory of Games, Volume II," H. W. Kuhn and A. W. Tucker, Eds., Princeton University Press, 1953, pp. 307–318. doi: 10.1515/9781400881970-018.
- [23] S. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions." 2017. [Online]. Available: <https://arxiv.org/abs/1705.07874>
- [24] Mushliha and Nisrinah, "Evaluation of ARIMA, ARIMA-LSTM, LSTM, and CNN-LSTM Models for Daily Air Quality Index Forecasting in Jakarta," J. IDEALIS, vol. 9, no. 2, pp. 214–223, Jul. 2026, doi: 10.36080/idealism.v9i2.3799.