

Analisis Perbandingan Gradient Boosting, LSTM, Dan Autoformer Dalam Forecasting Kualitas Udara Sebagai Indikator Dampak Perubahan Iklim Di Kota Palangkaraya

Novera Kristianti ^{a,1,*} Widiatry ^{b,2}

Program Studi Teknik Informatika, Fakultas Teknik, Universitas Palangka Raya, Indonesia

* corresponding author

ARTICLE INFO

Keywords

air quality forecasting, LSTM, XGBoost, Autoformer, PM2.5, ISPU

ABSTRACT

Forest and peatland fires cause sharp fluctuations in Palangkaraya's air quality. This study compares XGBoost, Long Short-Term Memory (LSTM), and Autoformer for one-day-ahead forecasting of daily PM2.5, CO, O3, and SO2 concentrations. A total of 950 daily observations from September 2023 to May 2026 were obtained from the Air Quality Open Data Platform and processed using backward filling, logarithmic transformation, differencing, temporal feature engineering, and a seven-day sliding window. Performance was evaluated using MAE, RMSE, and R2. LSTM was the most consistent model, attaining R2 values of 0.609 for PM2.5, 0.925 for O3, and 0.785 for SO2, while XGBoost performed best for CO with an R2 of 0.961. Autoformer was less effective for most pollutants because of the limited dataset and short sequence. LSTM was subsequently implemented in a web system to produce H+1 forecasts and ISPU categories.


1. Pendahuluan

Kualitas udara berpengaruh langsung terhadap kesehatan masyarakat dan kelestarian lingkungan. Di Kota Palangkaraya, kebakaran hutan dan lahan gambut yang berulang menimbulkan lonjakan polutan, terutama PM2.5, sehingga pola deret waktunya tidak stabil. Pemantauan saja belum cukup; prediksi jangka pendek dibutuhkan untuk mendukung mitigasi, peringatan dini, dan pengambilan keputusan [1], [2].

Pendekatan yang dibandingkan mewakili tiga karakter pemodelan. XGBoost mempelajari hubungan nonlinier dari fitur tabular [3], LSTM menangkap dependensi temporal melalui mekanisme memori [4], sedangkan Autoformer menguraikan tren dan musiman melalui auto-correlation [5]. Penelitian terdahulu banyak menilai model secara terpisah, sedangkan perbandingan langsung ketiganya pada empat polutan utama di Palangkaraya masih terbatas.

Penelitian bertujuan: (1) membangun model prediksi H+1 untuk PM2.5, CO, O3, dan SO2; (2) membandingkan akurasi XGBoost, LSTM, dan Autoformer menggunakan MAE, RMSE, serta R2; dan (3) menerapkan model terpilih pada sistem prediksi berbasis web yang menyajikan kategori Indeks Standar Pencemar Udara (ISPU).

2. Metode Penelitian



Gambar 1. Metodologi Penelitian

Data dan rancangan evaluasi. Data harian berasal dari Air Quality Open Data Platform (AQICN), mencakup 950 tanggal pada September 2023-Mei 2026. Variabel target adalah median harian PM2.5, CO, O3, dan SO2. Median dipilih karena lebih tahan terhadap penciran daripada rerata. Pembagian data dilakukan secara kronologis agar informasi masa depan tidak masuk ke data pelatihan.

Prapemrosesan. Atribut yang tidak relevan dihapus, format tanggal diseragamkan, dan keempat seri digabungkan berdasarkan tanggal. Nilai hilang ditangani dengan backward fill; proporsinya adalah 3,05% (PM2.5), 16,32% (CO), 16,84% (O3), dan 20,95% (SO2). Transformasi logaritmik mengurangi kemencengan, sedangkan differencing membantu menstabilkan perubahan antartanggal [6], [7].

Rekayasa fitur dan sekuens. Fitur meliputi lag historis, moving average, volatilitas, tren, spike detection, dan fire flag. Observasi kemudian dibentuk menjadi sekuens sliding window tujuh hari untuk memprediksi hari kedelapan. Fitur tersebut juga mengubah informasi temporal menjadi representasi tabular yang dapat dipelajari XGBoost [8].

Pemodelan. XGBoost dibangun sebagai ensemble pohon keputusan berurutan. Model LSTM menggunakan arsitektur bidirectional dan Huber loss agar lebih robust terhadap lonjakan ekstrem. Autoformer menggunakan dekomposisi seri dan mekanisme auto-correlation untuk mempelajari tren serta periodisitas. Semua hasil prediksi direkonstruksi dari delta dan dikembalikan dari skala logaritmik ke satuan asli.

Evaluasi. MAE menyatakan rata-rata galat absolut, RMSE memberi penalti lebih besar pada galat ekstrem, dan R2 menunjukkan proporsi variasi target yang dijelaskan model [9], [10]. Model terbaik dipilih berdasarkan galat rendah, R2 tinggi, dan konsistensi lintas polutan.

3. Hasil dan Pembahasan

A. 3.1 Karakteristik Data

PM2.5 memiliki rentang paling ekstrem (0,10-402,58) dengan rata-rata 18,33, terutama akibat lonjakan pada awal Oktober 2023. SO2 mencapai 262,14 dan memiliki nilai hilang terbanyak. O3 memperlihatkan struktur temporal lebih teratur, sedangkan CO paling stabil. Perbedaan ini memengaruhi kemampuan masing-masing model dalam mempelajari pola.

B. 3.2 Perbandingan Kinerja Model

Model	Polutan	MAE	RMSE	R2
XGBoost	PM2.5	5,11	7,76	0,546
XGBoost	CO	0,11	0,18	0,961

XGBoost	O3	12,14	20,59	0,904
XGBoost	SO2	3,03	5,55	0,750
LSTM	PM2.5	4,70	7,21	0,609
LSTM	CO	0,11	0,19	0,958
LSTM	O3	9,21	18,15	0,925
LSTM	SO2	2,56	5,15	0,785
Autoformer	PM2.5	5,61	8,75	0,423
Autoformer	CO	0,12	0,19	0,956
Autoformer	O3	10,40	19,36	0,915
Autoformer	SO2	3,29	6,37	0,670

Tabel 1. Hasil evaluasi ketiga model pada data uji


LSTM memberi hasil terbaik pada PM2.5, O3, dan SO2. Keunggulan ini berkaitan dengan kemampuannya mempertahankan informasi historis yang relevan melalui memory cell dan memproses konteks temporal dua arah. Huber loss turut menjaga kestabilan pelatihan saat data mengandung pencilan. Namun, seluruh model masih memperlihatkan smoothing effect sehingga puncak PM2.5 yang mendadak cenderung diremehkan.

XGBoost unggul pada CO ($R^2=0,961$). Pola CO yang stabil dan gradual sesuai dengan model boosting, terlebih setelah pola waktu direpresentasikan sebagai lag, moving average, volatilitas, spike, dan fire flag. Temuan ini menunjukkan bahwa pada dataset terbatas, rekayasa fitur yang tepat dapat membuat model berbasis pohon menandingi deep learning.


Autoformer tidak menjadi model terbaik. Arsitektur ini dirancang untuk peramalan jangka panjang dan sekuens yang lebih panjang, sedangkan penelitian menggunakan one-step forecasting dengan window tujuh hari dan sekitar 929 sampel valid setelah pembentukan sekuens. Mekanisme auto-correlation masih kompetitif pada O3 yang lebih periodik, tetapi kurang efektif pada lonjakan episodik PM2.5 dan SO2.

C. 3.3 Implementasi Sistem dan Pengujian


LSTM dipilih sebagai model utama sistem karena paling konsisten. Sistem web menyediakan tiga fungsi: prediksi H+1 beserta kategori ISPU dan polutan dominan; grafik aktual versus prediksi untuk memilih model dan parameter; serta simulasi interaktif berdasarkan input PM2.5, CO, O3, dan SO2. Konversi ISPU mengikuti ketentuan nasional [11].




Gambar 2. Grafik Time Series PM2.5 Kota Palangkaraya Periode September 2023
– Mei 2026



Gambar 3 Grafik Time Series CO Kota Palangkaraya Periode September 2023 – Mei 2026



Gambar 4 Grafik Time Series O₃ Kota Palangkaraya Periode September 2023 – Mei 2026



Gambar 5 Grafik Time Series SO₂ Kota Palangkaraya Periode September 2023 – Mei 2026

Berdasarkan hasil observasi awal, *dataset* kualitas udara menunjukkan karakteristik *time series* dengan pola perubahan nilai yang fluktuatif pada masing-masing parameter polutan. PM_{2.5} mencatat nilai tertinggi hingga 402.58 µg/m³ jauh melampaui rata-rata hariannya dengan lonjakan ekstrem yang terkonsentrasi pada periode awal Oktober 2023, yang diduga berkaitan dengan kejadian kebakaran lahan gambut di wilayah Palangkaraya. Parameter SO₂ juga menunjukkan lonjakan signifikan pada periode yang sama, mencapai nilai maksimum 262.14 µg/m³, mengindikasikan adanya sumber polutan yang saling berkaitan antar parameter. Sementara itu, CO

menunjukkan pola perubahan yang relatif lebih konsisten dibandingkan parameter lainnya, meskipun tetap ditemukan nilai ekstrem pada beberapa periode pengamatan.

Keberadaan nilai ekstrem yang cukup besar pada seluruh parameter mengindikasikan bahwa distribusi data bersifat tidak simetris dan rentan terhadap pengaruh *outlier*. Dalam kondisi distribusi yang miring (*skewed*), penggunaan rata-rata (*mean*) sebagai nilai representatif harian dapat terdistorsi secara signifikan oleh nilai-nilai ekstrem tersebut. Oleh karena itu, nilai median dipilih sebagai representasi nilai harian pada masing-masing parameter, karena median bersifat *robust* terhadap *outlier* dan lebih mencerminkan kondisi kualitas udara yang sesungguhnya pada setiap hari pengamatan. Pendekatan ini sejalan dengan struktur data yang tersedia, di mana setiap entri harian telah dilengkapi dengan informasi median hasil pengukuran sepanjang hari.

Tabel 2. Ringkasan pengujian black-box sistem

Fitur	Keluaran yang diuji	Hasil
Prediksi H+1	Nilai, kategori ISPU, dominan, confidence	Berhasil
Aktual vs prediksi	Grafik sesuai model dan polutan	Berhasil
Simulasi interaktif	Output berubah sesuai masukan	Berhasil

Seluruh skenario black-box berhasil. Sistem menerima masukan, memproses data, menampilkan prediksi dan kategori ISPU, menyajikan grafik perbandingan, serta menghasilkan keluaran simulasi tanpa kesalahan fungsional. Pengujian ini memastikan fungsi sesuai spesifikasi, tetapi belum menggantikan evaluasi kegunaan, keamanan, dan performa pada penggunaan nyata [12].

4. Kesimpulan

Ketiga model berhasil digunakan untuk prediksi kualitas udara H+1 di Palangkaraya. LSTM paling konsisten dengan R² 0,609 pada PM_{2.5}, 0,925 pada O₃, dan 0,785 pada SO₂, sedangkan XGBoost terbaik pada CO dengan R² 0,961. Autoformer mengikuti pola umum, tetapi belum optimal karena jumlah data dan panjang sekuens terbatas. Hasil menegaskan bahwa pemilihan model harus mempertimbangkan karakter polutan, skala data, dan rancangan horizon prediksi.

5. Saran

Model LSTM telah diintegrasikan ke sistem web yang menyajikan prediksi, kategori ISPU, polutan dominan, tingkat keyakinan, grafik aktual-prediksi, dan simulasi interaktif. Pengembangan berikutnya perlu menambahkan cuaca, arah angin, kelembapan, dan curah hujan; melakukan tuning atau pemodelan hibrida; mengintegrasikan API real-time; serta menambah peringatan dini dan visualisasi spasial.

Daftar Pustaka

- [1] World Health Organization, WHO Global Air Quality Guidelines, Geneva: WHO, 2021.
- [2] H. J. J. Hilly et al., 'Review of scientific research on air quality and environmental health risk and impact for PICTS,' Science of the Total Environment, vol. 942, 2024, doi:10.1016/j.scitotenv.2024.173628.
- [3] T. Chen and C. Guestrin, 'XGBoost: A scalable tree boosting system,' Proc. KDD, 2016, doi:10.1145/2939672.2939785.

- [4] A. Khumaidi, R. Raafi, and I. P. Solihin, 'Pengujian algoritma Long Short Term Memory untuk prediksi kualitas udara dan suhu Kota Bandung,' *Jurnal Telematika*, vol. 15, no. 1, 2020.
- [5] H. Wu, J. Xu, J. Wang, and M. Long, 'Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting,' *NeurIPS*, 2021/2022, arXiv:2106.13008.
- [6] H. Hua et al., 'The impact of data imputation on air quality prediction problem,' *PLoS ONE*, vol. 19, no. 9, 2024, doi:10.1371/journal.pone.0306303.
- [7] R. M. West, 'Best practice in statistics: The use of log transformation,' *Annals of Clinical Biochemistry*, vol. 59, no. 3, pp. 162-165, 2022.
- [8] J. Leites, V. Cerqueira, and C. Soares, 'Lag selection for univariate time series forecasting using deep learning: An empirical study,' arXiv:2405.11237, 2024.
- [9] T. Chai and R. R. Draxler, 'Root mean square error (RMSE) or mean absolute error (MAE)?' *Geoscientific Model Development*, vol. 7, pp. 1247-1250, 2014.
- [10] D. Chicco, M. J. Warrens, and G. Jurman, 'The coefficient of determination R-squared is more informative ... in regression analysis evaluation,' *PeerJ Computer Science*, vol. 7, 2021, doi:10.7717/PEERJ-CS.623.
- [11] Kementerian Lingkungan Hidup dan Kehutanan RI, Peraturan Menteri LHK Nomor 14 Tahun 2020 tentang Indeks Standar Pencemar Udara, 2020.
- [12] T. S. Jaya, 'Pengujian aplikasi dengan metode black-box testing boundary value analysis,' *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 3, no. 2, 2018.
- [13] M. R. Muhaimin, D. M. Karina, and A. B. Krisna, 'Prediksi kualitas udara Malang menggunakan metode Gradient Boosting Regression,' *Digital Transformation Technology*, vol. 4, no. 2, pp. 937-942, 2024.
- [14] B. Lim and S. Zohren, 'Time-series forecasting with deep learning: A survey,' *Philosophical Transactions A*, 2021, doi:10.1098/rsta.2020.0209.
- [15] M. Z. Wicaksono and L. E. Astrianty, 'Sistem prediksi kualitas udara menggunakan algoritma LSTM,' vol. 6, no. 7, pp. 831-840, 2025, doi:10.47065/tin.v6i7.8619.