

PEMANFAATAN ALGORITMA LONG SHORT-TERM MEMORY UNTUK PERAMALAN KUALITAS UDARA

Utilization of Long Short-Term Memory Algorithms for Air Quality Forecasting

Mochamad Yoga Sutomo¹, Dharu Arseno, S.T., M.T.², Dr. Sofia Naning Hertiana, Ir., M.T.³

¹yogasutomo67@gmail.com, ²alimuayyadi@telkomuniversity.ac.id, ³sofiananing@telkomuniversity.ac.id

Abstrak

Polusi udara merupakan isu kesehatan masyarakat global yang serius, sebagaimana dilaporkan oleh WHO bahwa lebih dari 80% penduduk perkotaan hidup pada kondisi udara yang melebihi ambang batas aman, dengan kontribusi sekitar 4,2 juta kematian setiap tahun akibat paparan udara luar ruang. Di Indonesia, persoalan ini semakin kompleks dengan tingginya jumlah kendaraan bermotor yang pada tahun 2022 tercatat mencapai 142 juta unit, menghasilkan emisi berbahaya seperti CO, NOx, dan SOx. Penelitian ini mengusulkan penerapan model Long Short-Term Memory (LSTM) untuk peramalan Air Quality Index (AQI) jangka pendek. Metodologi meliputi pengumpulan 4.753 data historis AQI wilayah Bojongsoang, Bandung, dari OpenWeather dengan resolusi per jam. Data kemudian diproses melalui normalisasi MinMaxScaler serta rekayasa fitur berbasis waktu dan lag features untuk menangkap pola temporal. Model LSTM dikonfigurasi untuk memprediksi AQI 24 jam ke depan dengan masukan 72 jam sebelumnya. Evaluasi kuantitatif menunjukkan hasil yang memadai, dengan MAE sebesar 8,10, RMSE 13,10, dan MAPE 13,10%, yang setara dengan akurasi prediksi 86,90%. Visualisasi kurva pembelajaran juga memperlihatkan kestabilan model tanpa indikasi overfitting. Temuan ini menegaskan bahwa kombinasi arsitektur LSTM dan rekayasa fitur yang tepat merupakan pendekatan efektif untuk peramalan kualitas udara, dengan potensi pemanfaatan sebagai sistem pendukung keputusan di bidang kesehatan dan lingkungan.

Kata kunci : Long Short-Term Memor, peramalan, Air Quality Index, Recurrent Neural Network

Abstract

Air pollution is a serious global public health issue, as reported by the WHO that more than 80% of urban populations live in conditions where air quality exceeds safe limits, contributing to approximately 4.2 million deaths each year due to exposure to outdoor air. In Indonesia, this issue is further complicated by the high number of motor vehicles, which reached 142 million units in 2022, emitting harmful pollutants such as CO, NOx, and SOx. This study proposes the application of a Long Short-Term Memory (LSTM) model for short-term Air Quality Index (AQI) forecasting. The methodology involves collecting 4,753 historical AQI data points from the Bojongsoang area in Bandung, sourced from OpenWeather with hourly resolution. The data is then processed through MinMaxScaler normalization and time-based feature engineering and lag features to capture temporal patterns. The LSTM model is configured to predict the AQI 24 hours in advance using 72 hours of prior data as input. Quantitative evaluation showed satisfactory results, with an MAE of 8.10, RMSE of 13.10, and MAPE of 13.10%, equivalent to a prediction accuracy of 86.90%. The learning curve visualization also shows model stability without signs of overfitting. These findings confirm that the combination of LSTM architecture and appropriate feature engineering is an effective approach for air quality forecasting, with potential applications as a decision support system in the fields of health and the environment.

Keyword : Long Short-Term Memor, forcaseting, Air Quality Index, Recurrent Neural Network

1. PENDAHULUAN

Polusi udara termasuk salah satu permasalahan utama dalam kesehatan masyarakat. Menurut Organisasi Kesehatan Dunia (WHO), lebih dari 80% penduduk perkotaan yang wilayahnya dipantau kualitas udaranya, hidup dalam kondisi udara yang melampaui ambang batas panduan WHO. Setiap tahun, diperkirakan sekitar 4,2 juta kematian terjadi akibat paparan polusi udara luar ruang[1].

Menurut data Badan Pusat Statistik (BPS), jumlah kendaraan bermotor di Indonesia pada tahun 2022 mencapai sekitar 142 juta unit, dengan 22 juta di antaranya berada di wilayah Jakarta. Setiap kendaraan menghasilkan emisi gas buang yang mengandung polutan berbahaya, antara lain karbon monoksida (CO), hidrokarbon, oksida nitrogen (NOx), sulfur oksida (SOx), serta partikulat debu termasuk timbal (Pb)[2].

Penelitian ini menekankan pada penggunaan model Long Short-Term Memory (LSTM), yang merupakan pengembangan dari recurrent neural networks (RNN) sebagai pendekatan utama dalam prediksi kualitas udara[3]. LSTM dipilih karena kemampuannya dalam mempelajari pola jangka panjang pada data runtut waktu serta

mengatasi permasalahan *vanishing gradient* yang sering terjadi pada RNN konvensional. Dataset yang digunakan mencakup parameter lingkungan seperti PM2.5, PM10, O₃, CO, NO₂, NH₃, suhu, kelembapan, curah hujan, arah angin dan kecepatan angin.

2. TINJAUAN PUSTAKA

2.1 Indeks Standar Pencemaran Udara (ISPU)

Indeks Standar Pencemar Udara (ISPU) merupakan indikator yang digunakan untuk menilai tingkat pencemaran udara di suatu daerah serta memberikan gambaran risiko kesehatan yang mungkin ditimbulkan. Perhitungan ISPU didasarkan pada konsentrasi polutan utama, seperti partikulat (PM10 dan PM2.5), ozon (O₃), nitrogen dioksida (NO₂), dan sulfur dioksida (SO₂). Nilai ISPU berada pada rentang 0 hingga 500, dengan nilai yang lebih tinggi menunjukkan kualitas udara yang semakin buruk dan berpotensi berbahaya bagi kesehatan manusia. Pengukuran indeks ini dilakukan secara berkala oleh instansi terkait di bidang lingkungan dan kesehatan[4].

2.1.1 Ambang Batas ISPU

Tabel 2.1 Ambang Batas ISPU

Kategori	Status Warna	Angka rentang
Baik	Hijau	1 – 50
Sedang	Biru	51 - 100
Tidak Sehat	Kuning	101 – 200
Sangat Tidak Sehat	Merah	201 – 300
Berbahaya	Hitam	≥ 301

Tabel ini memberikan pedoman bagi masyarakat dan pemerintah untuk menilai tingkat pencemaran udara berdasarkan angka ISPU, serta menentukan tindakan mitigasi kesehatan sesuai kategori warna dan ambang batasnya.

2.2 Air Quality Index (AQI)

AQI adalah konsep serupa yang digunakan secara global untuk menilai tingkat kualitas udara. AQI memiliki skala nilai 0 hingga 500, dengan prinsip semakin tinggi nilai indeks maka semakin buruk kualitas udara serta semakin besar dampaknya terhadap kesehatan. AQI dirancang agar masyarakat umum dapat memahami data polusi tanpa harus membaca konsentrasi polutan mentah yang bersifat teknis[4]. Meskipun berbeda istilah, ISPU di Indonesia dan AQI di tingkat internasional memiliki kesamaan konsep dan fungsi, yaitu menyajikan informasi kualitas udara dalam bentuk sederhana yang mudah dipahami. Standarisasi ini penting untuk memudahkan komunikasi data lingkungan, meningkatkan kesadaran publik, serta mendukung langkah-langkah mitigasi kesehatan masyarakat[5].

2.3 Peramalan

Peramalan (forecasting) merupakan seni sekaligus ilmu dalam memprediksi suatu peristiwa di masa mendatang dengan memanfaatkan data historis dan memproyeksikannya melalui model yang terstruktur. Selain berbasis data, peramalan juga dapat mengandung unsur subjektif atau intuisi, bahkan berupa kombinasi antara pendekatan sistematis dengan penilaian praktis seorang manajer. Inti dari peramalan adalah mengidentifikasi pola pada data masa lalu untuk kemudian digunakan dalam memperkirakan kejadian di masa depan serta sebagai dasar dalam pengambilan kebijakan[6]. Tujuan utama peramalan adalah meminimalkan tingkat kesalahan dalam prediksi. Meskipun tidak dapat memberikan kepastian mutlak mengenai apa yang akan terjadi, peramalan berupaya menghasilkan estimasi yang sedekat mungkin dengan kondisi sebenarnya di masa depan.


2.4 Artificial Neural Network (RNN)

ANN merupakan algoritma komputasi yang digunakan untuk memodelkan data. Konsepnya terinspirasi dari cara kerja sistem saraf biologis, sehingga dinamakan demikian. ANN terdiri atas sekumpulan unit pemrosesan yang disebut neuron, yang saling terhubung dan bekerja secara terkoordinasi untuk menyelesaikan permasalahan yang kompleks. Pendekatan ini sangat bermanfaat ketika pola atau tren dalam data sulit diidentifikasi dengan metode konvensional[7].

Meskipun ANN mampu memodelkan sistem nonlinier, berbagai arsitektur lanjutan telah dikembangkan,

seperti *feed-forward*, *Recurrent Neural Networks* (RNN), dan LSTM. RNN, yang merupakan perluasan dari *feed-forward network*, dirancang untuk menangani masukan berupa urutan dengan panjang bervariasi. Di antara varian RNN, LSTM memiliki keunggulan dalam mempelajari pola jangka panjang pada data sekuensial serta mempertahankan informasi dalam periode yang lebih lama[8].

2.5 Long Short-Term Memory (LSTM)



Gambar 2.1 Arsitektur LSTM

LSTM merupakan varian dari RNN yang dikembangkan untuk mengatasi permasalahan exploding maupun vanishing gradient yang sering terjadi ketika jaringan mempelajari ketergantungan jangka panjang. LSTM memiliki mekanisme khusus berupa sel memori dengan gates yang mengatur aliran informasi masuk dan keluar. Struktur ini memungkinkan jaringan mempertahankan informasi dalam periode waktu lebih panjang dibandingkan dengan RNN konvensional, sekaligus menjaga stabilitas pembelajaran pada data sekuensial yang kompleks[2].

2.6 Metrik Evaluasi

Dalam penelitian kuantitatif, evaluasi kinerja model prediksi umumnya dilakukan dengan menggunakan metrik error yang mampu menggambarkan tingkat perbedaan antara nilai aktual dan nilai hasil prediksi. Pada persamaan berikut, X_i merepresentasikan nilai prediksi ke- i , sedangkan Y_i menunjukkan nilai aktual ke- i . Metode regresi berfungsi untuk memperkirakan nilai X_i yang sesuai dengan Y_i pada dataset acuan atau *ground truth*.

2.6.1 Mean Absolute Error (MAE)

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i|$$

MAE dapat digunakan apabila keberadaan outlier dianggap sebagai data yang rusak atau tidak relevan. Metode ini tidak memberikan penalti berlebihan terhadap outlier pada data pelatihan, sehingga menghasilkan ukuran performa yang bersifat umum dan terikat dalam batas tertentu. Namun, apabila pada data uji terdapat banyak outlier, kinerja model cenderung menurun dan hasil prediksinya menjadi kurang optimal[9].

2.6.2 Root Mean Squared Error (RMSE)

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2}$$

RMSE mengambil akar dari nilai MSE sehingga menghasilkan ukuran kesalahan dengan satuan yang sama seperti data asli, menjadikannya lebih mudah untuk diinterpretasikan. Sama seperti *Mean Squared Error* (MSE), nilai RMSE terbaik adalah 0, sedangkan nilai yang lebih besar menunjukkan tingkat kesalahan prediksi yang lebih tinggi. Karena RMSE secara monoton berhubungan dengan MSE melalui operasi akar kuadrat, maka pemeringkatan model regresi berdasarkan MSE akan identik dengan pemeringkatan model berdasarkan RMSE. Dengan demikian, RMSE dapat dipandang sebagai bentuk terukur dari MSE yang lebih intuitif, sekaligus memberikan informasi yang sensitif terhadap kesalahan besar dalam prediksi[9].

2.6.3 Mean Absolute Percentage Error (MAPE)

$$\text{MAPE} = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right|$$


MAPE merupakan salah satu metrik evaluasi pada model regresi yang memiliki interpretasi intuitif dalam bentuk kesalahan relatif. Karena sifat definisinya, MAPE lebih disarankan digunakan pada kasus di mana sensitivitas terhadap variasi relatif lebih penting dibandingkan variasi absolut. Namun demikian, metrik ini juga memiliki keterbatasan, terutama hanya dapat diterapkan pada data dengan nilai positif serta cenderung bias terhadap prediksi bernilai rendah. Hal ini membuat MAPE kurang tepat digunakan pada model prediktif yang berpotensi menghasilkan kesalahan besar[9].

3. METODOLOGI

3.1 Pengumpulan Data

Dataset yang digunakan pada penelitian ini tersedia dalam format CSV dengan atribut utama berupa penanda waktu (dt) dan nilai target AQI. Data diperoleh dari platform OpenWeather dengan lokasi pengamatan di Bojongsoang, Bandung. Secara keseluruhan, dataset terdiri atas 4.753 entri data kualitas udara dengan resolusi per jam, yang tercatat sejak 16 November 2024 hingga 12 Juni 2025.

3.2 Perancangan Pipeline



Gambar 3.1 Diagram alir pipeline


Diagram alir sistem ditunjukkan pada Gambar 3.1, yang menjelaskan alur pemrosesan data hingga evaluasi

hasil prediksi. Proses penelitian terdiri dari delapan langkah utama:

1. Dataset diperoleh dari layanan OpenWeather dengan titik lokasi di Bojongsoang, Bandung, dan disimpan dalam format CSV.
2. Tahap praproses dilakukan dengan menetapkan kolom waktu (dt) sebagai indeks utama. Selain itu, ditambahkan fitur berbasis waktu menggunakan transformasi sinus dan cosinus untuk merepresentasikan jam serta hari. Fitur *lag* (aqi_lag1 hingga aqi_lag5) juga dibuat guna menangkap ketergantungan nilai historis AQI. Selanjutnya, data dinormalisasi dengan metode *MinMaxScaler* agar seluruh variabel berada dalam rentang [0,1].
3. Dataset diubah ke dalam format sekuensial dengan skema masukan sepanjang 72 jam (tiga hari sebelumnya) dan keluaran sepanjang 24 jam (prediksi satu hari berikutnya).
4. Data dibagi menjadi dua subset, yaitu 80% untuk pelatihan (*training set*) dan 20% untuk pengujian (*testing set*).
5. Arsitektur model menggunakan *Long Short-Term Memory* (LSTM) dengan susunan sebagai berikut:
 - LSTM layer berisi 128 unit dengan *return_sequences=True*.
 - Dropout sebesar 0,2.
 - LSTM layer berisi 64 unit.
 - Dense layer dengan 64 unit dan fungsi aktivasi ReLU.
 - Dense layer keluaran berisi 24 unit untuk menghasilkan prediksi 24 jam ke depan.
6. Model dilatih menggunakan optimizer Adam dengan *learning rate* 0,001 serta *loss function* berupa *Mean Squared Error* (MSE). Selain itu, digunakan *callback* ModelCheckpoint untuk menyimpan bobot terbaik selama proses pelatihan.
7. Kinerja model diuji dengan data pengujian menggunakan beberapa metrik evaluasi, yaitu:
 - *Mean Absolute Error* (MAE)
 - *Root Mean Square Error* (RMSE)
 - *Mean Absolute Percentage Error* (MAPE)
8. Model yang telah terlatih disimpan dalam format *SavedModel*, sedangkan objek normalisasi (*scaler_x.pkl* dan *scaler_y.pkl*) turut diekspor untuk mendukung implementasi prediksi di tahap selanjutnya.

4. HASIL DAN PEMBAHASAN

4.1 Model Learning Curve



Gambar 4.1 Grafik model *learning curve*

Gambar tersebut menampilkan kurva loss pada data pelatihan dan validasi selama proses pelatihan model LSTM. Pada fase awal epoch, nilai loss relatif tinggi, namun secara bertahap menurun hingga stabil di sekitar epoch ke-20. Baik training loss maupun validation loss menunjukkan pola yang serupa dengan selisih yang sangat kecil, sehingga dapat disimpulkan bahwa model tidak mengalami gejala overfitting. Penurunan tajam pada awal pelatihan mengindikasikan bahwa model mampu dengan cepat mengenali pola dari data. Selanjutnya, pada epoch ke-30 hingga ke-40, nilai loss tetap berada pada tingkat yang sangat rendah ($<0,002$) dan stabil, menandakan bahwa model telah mencapai titik konvergensi.


Secara keseluruhan, kurva pembelajaran ini memperlihatkan bahwa arsitektur LSTM yang digunakan efektif dalam mempelajari dinamika temporal data kualitas udara, sekaligus menjaga keseimbangan antara akurasi pelatihan dan kemampuan generalisasi pada data validasi.

4.2 Kinerja Model


Tabel 4.1 Evaluasi Metrik Model LSTM

Metrik	Nilai
MAE	8.10
RMSE	13.10
MAPE (%)	13.10


Nilai MAE sebesar 8,10 mengindikasikan bahwa rata-rata kesalahan absolut prediksi AQI berada pada kisaran $\pm 8,10$ poin. Besaran kesalahan ini masih dianggap wajar untuk kebutuhan peramalan kualitas udara jangka pendek. Selain itu, RMSE dengan nilai 13,10 memperlihatkan bahwa deviasi rata-rata kesalahan prediksi tetap terkendali meskipun terdapat outlier atau fluktuasi signifikan pada nilai AQI. Sementara itu, MAPE sebesar 13,10% menunjukkan tingkat kesalahan relatif yang cukup rendah, sehingga akurasi prediksi mencapai sekitar 86,90%. Dengan hasil tersebut, model dapat dinyatakan layak digunakan dalam menghasilkan proyeksi kualitas udara. Keberhasilan model dalam menangkap pola temporal kompleks dari data AQI menunjukkan bahwa kombinasi arsitektur LSTM dan rekayasa fitur yang cermat merupakan pendekatan yang efektif.



Gambar 4.2 Grafik perbandingan nilai AQI aktual dan prediksi pada 5 Mei 2025



Gambar 4.3 Grafik perbandingan nilai AQI aktual dan prediksi pada 19 Mei 2025



Gambar 4.4 Grafik perbandingan nilai AQI aktual dan prediksi pada 5 Juni 2025

Hasil visualisasi berupa grafik perbandingan antara data aktual dan hasil prediksi AQI pada dataset pengujian memperlihatkan performa model yang baik. Kurva prediksi tampak mengikuti pola data aktual dengan kedekatan yang tinggi, termasuk pada periode dengan variasi tajam maupun lonjakan nilai. Temuan ini menunjukkan bahwa LSTM tidak hanya melakukan *memorization* terhadap data pelatihan, melainkan mampu menangkap pola temporal yang kompleks dalam data kualitas udara. Dengan demikian, model ini berpotensi dimanfaatkan sebagai alat bantu prediksi jangka pendek untuk mendukung pengambilan keputusan di bidang kesehatan dan lingkungan.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Hasil penelitian ini menunjukkan bahwa algoritma *Long Short-Term Memory* (LSTM) merupakan metode yang efektif dan andal dalam melakukan peramalan *Air Quality Index* (AQI) jangka pendek. Capaian tersebut diperoleh melalui metodologi yang komprehensif, mencakup tahap praproses data yang sistematis serta rekayasa fitur yang cermat sehingga model mampu mengenali pola temporal yang kompleks. Evaluasi model memperlihatkan performa yang baik dengan nilai MAE sebesar 8,10, RMSE sebesar 13,10, serta MAPE 13,10% atau setara dengan akurasi prediksi 86,90%. Secara kualitatif, visualisasi perbandingan antara data aktual dan hasil prediksi memperlihatkan kesesuaian pola yang erat, termasuk pada periode dengan fluktuasi tajam. Dengan demikian, penelitian ini menghasilkan model prediksi yang berpotensi besar untuk dimanfaatkan sebagai sistem pendukung keputusan di bidang kesehatan dan lingkungan.

5.2. Saran

Berdasarkan temuan penelitian, berikut adalah beberapa saran untuk pengembangan dan penelitian di masa depan:

1. Penelitian berikutnya dapat diarahkan pada perbandingan sistematis dengan model peramalan lain, seperti Gated Recurrent Unit (GRU), Bidirectional LSTM, maupun pendekatan statistik tradisional seperti ARIMA, guna menentukan arsitektur yang paling optimal.
2. Selain itu, perlu dilakukan studi lanjutan mengenai optimasi hyperparameter—misalnya jumlah unit pada lapisan LSTM, learning rate, atau tingkat dropout—untuk meningkatkan akurasi dan stabilitas model.
3. menyoediki dampak dari teknik praproses data, seperti penggunaan metode normalisasi alternatif selain MinMaxScaler atau penerapan strategi penanganan outlier yang lebih canggih, untuk menilai sejauh mana hal tersebut dapat meningkatkan performa prediksi.

DAFTAR PUSTAKA

- [1] T. Cassard, G. Jauvion, and D. Lissmyr, "High-Resolution Air Quality Prediction Using Low-Cost Sensors," 2020, [Online]. Available: <http://arxiv.org/abs/2006.12092>
- [2] A. Z. H. Ramadhan, B. Rahayudi, and D. E. Ratnawati, "Prediksi Polusi Udara Di Dki Jakarta Dengan Menggunakan Metode Long-Short Term Memory (Lstm)," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 1, pp. 1–8, 2017, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [3] Y. Karyadi, "Prediksi Kualitas Udara Dengan Metoda LSTM, Bidirectional LSTM, dan GRU," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 9, no. 1, pp. 671–684, 2022, doi: 10.35957/jatisi.v9i1.1588.
- [4] 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, p. 190, 2023, doi:

10.26418/coding.v1i12.58704.

[5] Yoga Dwi Prasetyo, Fitria Nur Rahmadani, Mohammad Idhom, and Trimono, "Prediction of the Air Quality Index in DKI Jakarta Province Using the CatBoost Method," *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 3, pp. 2101–2105, 2025, doi: 10.59934/jaiea.v4i3.1103.

[6] Y. Utami, D. Vinsensia, and E. Panggabean, "Forecasting Exponential Smoothing untuk Menentukan Jumlah Produksi," *J. Ilmu Komput. dan Sist. Inf.*, vol. 7, no. 1, pp. 154–160, 2024, doi: 10.55338/jikomsi.v7i1.2853.

[7] A. Maher G. M. *et al.*, "Artificial Neural Networks Based Optimization Techniques: A Review," no. M1, 2021.

[8] P. Wongburi and J. K. Park, "Prediction of Wastewater Treatment Plant Effluent Water Quality Using Recurrent Neural Network (RNN) Models," *Water (Switzerland)*, vol. 15, no. 19, pp. 1–16, 2023, doi: 10.3390/w15193325.

[9] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.