

PREDIKSI INDEKS NITROGEN DIOKSIDA (NO₂) MENGGUNAKAN MODEL NEURALPROPHET STUDI KASUS DKI JAKARTA

Jhon Paul Estomihi Togatorop*, Risang Bayu Firdaush, Yosafat Donni Haryanto

Jurusan Meteorologi, Sekolah Tinggi Meteorologi Klimatologi dan Geofisika

*E-mail korespondensi: jhonpaulestomihitogatorop@gmail.com

ABSTRACT

Nitrogen dioxide gas (NO₂) is one of the air quality parameters that can delay nerve recovery after a stroke. DKI Jakarta as the Capital City of the State of Indonesia continues to experience an increase in population which is marked by an increase in the number of motorized vehicles and infrastructure development. Air quality prediction, especially NO₂, is important as an anticipatory step in detecting air pollution, especially if the measuring instrument is damaged. This study uses standard air pollutant index (ISPU) data as a time series from 2018 – 2021 to predict the NO₂ index in 2022 using the NeuralProphet model. The NeuralProphet model which was designed with parameters of 1000 epochs, learning rate of 0.10, proportion validation of 0.10, and daily frequency produced MAE and RMSE models from the training data of 5.426610 and 7.977689. MAE validation and validation RMSE from the proportion of 0.10 tasting data were 27.762064 and 35.434227. The prediction of the NO₂ index for 365 days resulting from the NeuralProphet model shows that the NO₂ index experiences an increasing trend which is influenced by seasonal events both annually and weekly. Affecting annual seasons, such as national holidays and monsoon rain patterns. The national holidays in question, such as New Year's Day, Lunar New Year's Day, and Christmas Day, trigger an increase in traffic flow. The peak of the NO₂ index occurred in February and December, while the NO₂ index weakened as it entering October.

Keywords: Air Quality, NeuralProphet, NO₂, Prediction.

ABSTRAK

Gas nitrogen dioksida (NO₂) merupakan salah satu parameter kualitas udara yang dapat menunda pemulihan saraf setelah stroke. DKI Jakarta sebagai Ibu Kota Negara Indonesia terus mengalami peningkatan jumlah penduduk yang ditandai dengan peningkatan jumlah kendaraan bermotor dan pembangunan infrastruktur. Prediksi kualitas udara khususnya NO₂ menjadi penting sebagai langkah antisipatif dalam mendeteksi pencemaran udara terutama jika alat ukur mengalami kerusakan. Penelitian ini menggunakan data indeks standar pencemar udara (ISPU) sebagai deret waktu dari tahun 2018 – 2021 untuk memprediksi indeks NO₂ tahun 2022 menggunakan model NeuralProphet. Model NeuralProphet yang dirancang dengan parameter 1000 epochs, learning rate 0.10, proportion validation 0.10, dan frekuensi harian menghasilkan MAE dan RMSE model dari data yang di training sebesar 5.426610 dan 7.977689. MAE validasi dan RMSE validasi dari proporsi 0.10 data tasting sebesar 27.762064 dan 35.434227. Prediksi indeks NO₂ selama 365 hari yang dihasilkan dari model NeuralProphet menunjukkan bahwa indeks NO₂ mengalami tren peningkatan yang dipengaruhi kejadian musiman baik tahunan maupun mingguan. Musim tahunan yang mempengaruhi diantaranya adalah hari libur nasional dan pola hujan monsun. Libur nasional yang dimaksud seperti Tahun Baru, Tahun Baru Imlek, dan Hari Raya Natal dimana memicu meningkatnya arus lalu lintas. Puncak Indeks NO₂ terjadi pada bulan Februari dan Desember, sebaliknya indeks NO₂ melemah ketika memasuki bulan Oktober.

Kata kunci: Kualitas Udara, NeuralProphet, NO₂, Prediksi.

Diterima 17-01-2023 | Disetujui 02-11-2023 | Dipublikasi 30-12-2023

PENDAHULUAN

Ibu kota Republik Indonesia yang dikenal dengan sebutan Daerah Khusus Ibukota Jakarta ini terdiri dari lima komunitas perkotaan dan memiliki jumlah penduduk yang terus bertambah dan tidak diimbangi dengan luas wilayah. Dengan asumsi jumlah penduduk bertambah 1 orang, hal ini akan diikuti oleh peningkatan jumlah kendaraan mekanis sebesar 0,058 unit [1]. Peningkatan jumlah kendaraan yang melintas dapat menyebabkan penyebaran polusi udara yang berpotensi menurunkan mutu udara [2]. Peningkatan jumlah kendaraan sejalan dengan peningkatan jumlah emisi yang diciptakan [3].

Pencemaran udara bisa dijelaskan sebagai situasi iklim di mana konsentrasi zat-zat di atmosfer meningkat secara signifikan, melampaui tingkat normal di sekitarnya, dan berpotensi memengaruhi manusia, makhluk hidup, tumbuhan, dan bahan lainnya [4]. Untuk memahami pencemaran udara, telah dikembangkan indeks standar pencemar udara (ISPU). Menurut Kementerian Lingkungan Hidup (KLH), ISPU adalah suatu nilai tanpa satuan yang mencerminkan kondisi kualitas udara pada suatu wilayah dan waktu tertentu, dengan mempertimbangkan dampaknya terhadap kesehatan manusia, nilai tambah, dan organisme lainnya.

Nitrogen dioksida (NO_2) adalah salah satu parameter penilaian kualitas udara yang, apabila berinteraksi dengan air di atmosfer, mampu membentuk asam nitrat yang berpotensi menyebabkan hujan korosif [6]. NO_2 juga dapat menghambat proses pemulihan kemampuan saraf setelah *stroke* dan meningkatkan risiko terjadinya demensia vaskular (VAD) [7]. Konsentrasi NO_2 cenderung meningkat seiring dengan intensifikasi aktivitas lalu lintas, terutama karena pertumbuhan jumlah kendaraan bermesin [8].

Kendaraan bermotor berkontribusi sebanyak 85% terhadap polusi udara di wilayah metropolitan Indonesia [9]. Polusi dari sektor industri melibatkan kandungan gas karbon monoksida (CO) sebanyak 70,50%, sulfur

oksida (SO_2) sebanyak 0,9%, dan nitrogen dioksida (NO_2) sebanyak 8,9% [10].

Penelitian ini bertujuan untuk memprakirakan indeks NO_2 di DKI Jakarta dengan menggunakan model NeuralProphet. Model ini benar-benar dapat diandalkan dalam pengukuran deret waktu karena mempertimbangkan data tambahan seperti tren, musiman, dan kejadian berulang [11]. Konsekuensi dari prediksi ini dapat digunakan sebagai langkah awal dalam mengidentifikasi kontaminasi udara, terutama jika instrumen monitoring rusak. Model NeuralProphet seharusnya mendapatkan hasil ekspektasi NO_2 yang baik dengan diperolehnya *root mean square error* (RMSE) dan *mean absolute error* (MAE) dari data latih dan validasi yang rendah dan tidak sepenuhnya berbeda.

TINJAUAN PUSTAKA

Peramalan Deret Waktu

Prediksi digunakan untuk mengumpulkan data yang diperlukan dalam proses pengambilan keputusan dalam perencanaan jangka panjang [12]. Menurut Hyndman dan rekan-rekannya, keberhasilan model prediksi sangat tergantung pada tingkat ketersediaan informasi, di mana jika terdapat sejumlah besar informasi yang tidak dapat diakses atau tidak dapat diterapkan, maka pendekatan penilaian subjektif harus diterapkan [12]. Sebaliknya, apabila informasi tersebut dapat diakses dan signifikan, pendekatan kuantitatif sebaiknya digunakan. Salah satu contoh strategi kuantitatif adalah penggunaan deret waktu. Deret waktu menyajikan data matematis mengenai masa lalu dan menyediakan pola yang dapat diidentifikasi serta contoh yang dapat diperhitungkan di masa depan [12]. Deret waktu memiliki elemen-elemen seperti tren, musiman, dan siklus yang dapat diidentifikasi.

1. Pola muncul ketika terjadi kenaikan atau penurunan data dalam suatu rangkaian waktu yang berlangsung terus-menerus.
2. Musiman terjadi ketika rangkaian periode dipengaruhi oleh faktor-faktor sesekali

seperti tujuh hari, bulan, atau tahun. Musiman terjadi ketika informasi menunjukkan poin tinggi dan poin rendah dibandingkan dengan pengulangan yang layak.

- Peristiwa berulang umumnya diinduksi oleh perubahan kondisi keuangan dan seringkali terkait dengan perputaran bisnis. Siklus biasanya timbul sebagai akibat dari fluktuasi variabel yang menjadi fokus pertanyaan.

NeuralProphet

Model NeuralProphet memiliki kesamaan yang signifikan dengan model Facebook Prophet, mampu menghadapi permasalahan dengan kemampuan prediksi [13]. Model ini dibuat untuk mengatasi kelemahan Facebook Prophet seperti terjemahan dan desain. NeuralProphet memberikan ekstensibilitas yang lebih besar, misalnya pembedaan terprogram dengan PyTorch sebagai backend. NeuralProphet dibuat dalam suatu struktur yang terukur, dengan tujuan agar dalam penarikannya dapat diperbesar dengan baik untuk menambahkan beberapa bagian baru [14].

Dalam penelitian yang dilakukan oleh Triebe dan rekan-rekannya, konsep utama dari model NeuralProphet adalah komposisi yang bersifat partikular, di mana setiap modul akan disisipkan ke dalam bagian tambahan yang selanjutnya digunakan untuk melakukan prediksi [14]. Beberapa bagian dapat dirancang untuk diskalakan berdasarkan pola, sehingga menghasilkan dampak multiplikatif [13]. Setiap modul memiliki umpan balik dan siklus modelnya sendiri. Namun, seluruh modul harus menghasilkan jumlah kemajuan yang diwakili oleh h , yang akan diprediksi di masa mendatang. Hal ini terlepas dari nilai yang diantisipasi $y^*_t, \dots, y^*_{(t+h-1)}$ untuk nilai masa depan $y^*_t, \dots, y^*_{(t+h-1)}$. Jika model tersebut hanya bergantung pada waktu, jumlah estimasi yang tidak teratur dapat dilakukan. Campuran yang menyertainya sebanding dengan ramalan satu langkah ke depan dengan $h=1$ (lihat kondisi 1).

$$\hat{y}_t = T(t) + S(t) + E(t) + F(t) + A(t) + L(t) \quad (1)$$

Keterangan:

$T(t)$: Fungsi pola dalam deret waktu.

$S(t)$: Fungsi musiman dalam waktu t .

$E(t)$: Fungsi *event* dan hari libur pada saat t .

$F(t)$: Fungsi regresi pada waktu t untuk faktor eksogen yang telah diketahui sebelumnya.

$A(t)$: Fungsi autoregresi pada waktu t dengan mempertimbangkan informasi dari masa lalu.

$L(t)$: Fungsi regresi pada waktu t untuk menggambarkan pengaruh tertunda dari faktor eksogen.

\hat{y}_t : Hasil prediksi.

Semua komponen modul dapat dirancang dan disatukan untuk membentuk model. Jika tidak semua modul digunakan, batas statis akan diterapkan sebagai elemen dari pola. Secara alamiah, yang pertama kali dibentuk hanyalah model untuk pola dan komponen musiman [14].

Root Mean Square Error

Root mean square error (RMSE) merupakan suatu jenis kesalahan yang tergantung pada skala dan tidak dapat dibandingkan secara langsung antar skala yang berbeda. Untuk mengatasi hal ini, perbaikan RMSE melibatkan pembuatan akar kuadrat dari perbedaan antara nilai yang diharapkan dan nilai sebenarnya, membentuk dasar yang bersifat umum untuk kualitas yang diantisipasi dan kualitas sebenarnya (lihat kondisi 2) [13].

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

Keterangan:

n : Banyaknya data

y_i : Nilai asli

\hat{y}_i : Nilai perkiraan

Mean Absolute Error

Mean absolute error (MAE) digunakan untuk menghitung nilai rata-rata antara nilai aktual dalam seri waktu dan nilai yang diprediksi. MAE dikenal karena kesalahannya berskala, di mana evaluasi kesalahan tergantung pada nilai skala dan tidak dapat dibandingkan secara langsung antar skala yang berbeda. Untuk mengatasi ini, penyesuaian MAE melibatkan normalisasi nilai terhadap nilai yang diprediksi, dan setelah itu, menghilangkan nilai absolut dari kualitas negatif. Selanjutnya, jumlahkan semua nilai tersebut dan bagi dengan jumlah total observasi n (lihat kondisi 3) [13].

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (3)$$

Keterangan:

n : Banyaknya data

y_i : Nilai asli

\hat{y}_i : Nilai prediksi

METODE PENELITIAN

Gambaran Umum

Metode penelitian bermanfaat untuk menjelaskan langkah-langkah yang akan diambil dalam mengumpulkan dan menjelajahi informasi. Berikut adalah prosedur untuk menyusun daftar ekspektasi terkait NO_2 dengan memanfaatkan model NeuralProphet:

Tinjauan Literatur

Tinjauan literatur dilakukan untuk mengeksplorasi faktor-faktor yang mendukung penyelesaian masalah penelitian ini. Ini mencakup pemahaman tentang NeuralProphet, indeks standar pencemar udara (ISPU), RMSE, dan MAE.

Analisis

Tahapan ini dilakukan untuk membedah persyaratan yang akan digunakan sebelum membuat model prediksi, seperti pengumpulan

informasi dan rencana model. Model rencana dibuat dengan menggunakan *flowchart*.

Eksekusi Model

Interaksi pelaksanaan selesai setelah siklus pemeriksaan selesai. Konsekuensi dari rencana tersebut dijadikan sebuah program. Berikut ini adalah keseluruhan eksekusi NeuralProphet:

- (a) Penelaahan informasi diselesaikan sebelum menyiapkan model train, misalnya, mengubah tanda dan selanjutnya mencocokkan desain tanggal.
- (b) Pemisahan data dilakukan untuk membagi antara data latih dan data uji.
- (c) Model dibuat dengan melatihnya menggunakan data latih.
- (d) Model melakukan prediksi dengan membandingkan hasil prediksinya dengan data uji.

Uji dan Evaluasi


Setelah proses implementasi selesai, perlu diuji apakah model NeuralProphet memenuhi standar kesalahan yang diterima. Proses pengujian melibatkan pengukuran RMSE dan MAE untuk setiap model.

Pencatatan Data

Dataset yang digunakan berasal dari sumber yang tersedia di (data.jakarta.go.id). Pengumpulan data diselesaikan melalui proses *scrapping*, yang merupakan metode umum untuk mengambil informasi dan data secara langsung dari suatu situs web. Dataset ini merupakan data ISPU yang diukur melalui lima stasiun pemantau kualitas udara di Provinsi DKI Jakarta selama periode tahun 2018 – 2021.


Pembuatan Model

Model dibuat dengan mengilustrasikan alur kerja menggunakan *flowchart*. Diagram alur yang digambarkan berisi cara paling umum untuk memahami data, demonstrasi NeuralProphet, dan penilaian model. Berikut proses kerja modelnya.



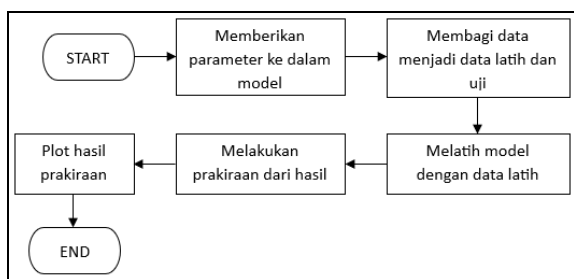
Gambar 1. Flowchart prediksi indeks NO₂.

Gambar 1 menjelaskan rencana model NeuralProphet. Interaksi utamanya adalah membaca informasi, hal ini diharapkan dapat menjamin bahwa informasi yang ditangani mengikuti format, khususnya tanggal (datetime64[ns]) dan indeks NO₂ (float64). Kemudian pada saat itu dilakukan demonstrasi NeuralProphet yang terakhir menilai ekspektasi NeuralProphet menggunakan RMSE dan MAE.



Gambar 2. Flowchart pembacaan data.


Gambar 2 menjelaskan proses kerja untuk memahami informasi. Yang pertama mengambil informasi dari (data.jakarta.go.id) dengan menggunakan metode *scrapping* tahun 2018 – 2021. Data tanggal diubah menjadi *ds* dan data indeks NO₂ diubah menjadi *y*. Terakhir adalah menambah efek *holidays*, yaitu hari libur nasional.



Gambar 3. Flowchart model NeuralProphet.

Ilustrasi pada Gambar 3 menggambarkan langkah-langkah operasional model NeuralProphet. Dimulai dengan menetapkan parameter awal ke dalam NeuralProphet, yaitu *seasonality*, *epochs*, *learning_rate*, *frequency*, dan *validation proportion*. Lalu memisahkan

dataset menjadi data latih dan data uji agar model tersebut dapat dilatih berdasarkan parameter yang diinput dimana saah satunya adalah *frequency daily* (harian). Kemudian melakukan *plot* hasil prediksi, tren, dan musiman.




Gambar 4. Flowchart evaluasi model.

Gambar 4 menjelaskan algoritma dari penilaian model. Evaluasi model menggunakan RMSE dan MAE.

HASIL DAN PEMBAHASAN

Deret Waktu Indeks NO₂ DKI Jakarta Tahun 2018 – 2021

Dataset indeks NO₂ yang telah digabungkan menjadi kumpulan data deret waktu di-*plot* dalam bentuk grafik (lihat Gambar 5). Sebelum di-*plot*, data tersebut diubah ke dalam format *ds* (tanggal) dan *y* (indeks NO₂). Secara *time series*, indeks NO₂ mengalami peningkatan pada Oktober 2020 hingga akhir tahun 2021, hal ini dipengaruhi oleh kondisi pasca Covid-19 yang mulai memasuki keadaan normal baru.



Gambar 5. Time series indeks NO₂ Tahun 2018 – 2021 di DKI Jakarta.

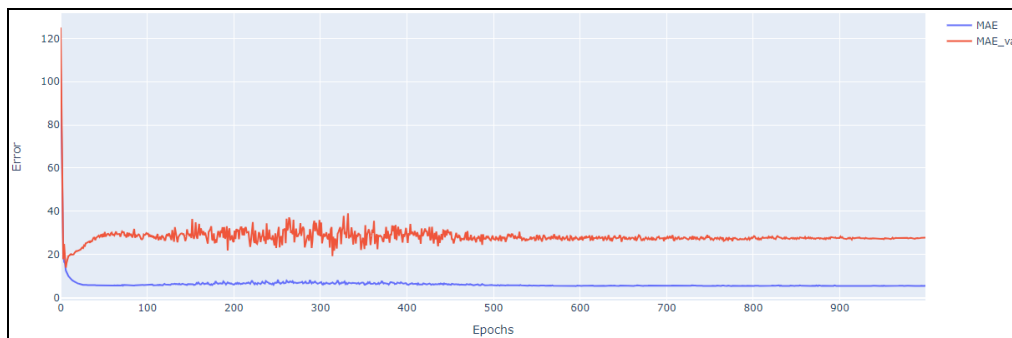
Training dan Testing Model NeuralProphet

Datasets yang telah berformat *ds* dan yselanjutnya digunakan untuk *training* dan *testing* model NeuralProphet. *Training* model dilakukan dengan frekuensi harian dimana proporsi data untuk *testing* sebesar 0.10 dan model dilatih sebanyak 1000 *epochs* dengan *learning_rate* 0.10. Untuk menguji sebearapa akurat *training* dan *testing* dilakukan uji akurasi MAE dan RMSE (lihat Gambar 6, 7, dan 8). Nilai MAE dan RMSE saat model di *training*


hingga 1000 *epoch* adalah 5.426610 dan 7.977689, sedangkan nilai MAE dan RMSE saat dilakukan *testing/validasi* dari data yang sebelumnya tidak dikenal dengan proporsi 10% (*value_p* = 0,1) adalah 27.762064 dan 35.434227. Perbandingan antara MAE vs MAE validasi dan RMSE dan RMSE validasi dapat dilihat pada Gambar 7 dan 8 di mana nilai MAE validasi dan RMSE validasi terletak di atas MAE dan RMSE. Hal ini cukup wajar dikarenakan jumlah dataset yang digunakan terbatas.

	MAE_val	RMSE_val	Loss_val	RegLoss_val	epoch	MAE	RMSE	Loss	RegLoss
0	125.060806	140.634964	1.936299	0.0	0	106.741211	128.284210	1.291211	0.0
1	88.369408	93.009949	1.322823	0.0	1	70.772522	82.642700	0.819454	0.0
2	45.184895	46.385674	0.603082	0.0	2	43.010639	48.585693	0.447237	0.0
3	17.758545	21.040117	0.171275	0.0	3	20.358318	25.150986	0.168799	0.0
4	24.887346	29.903927	0.282606	0.0	4	16.567318	21.581352	0.138375	0.0
...
995	27.673189	35.314503	0.329165	0.0	995	5.407756	7.902212	0.022271	0.0
996	27.698721	35.351849	0.329538	0.0	996	5.353745	7.743641	0.022102	0.0
997	27.568144	35.182060	0.327464	0.0	997	5.454650	8.018410	0.022766	0.0
998	27.526150	35.137211	0.326882	0.0	998	5.555616	8.104799	0.023716	0.0
999	27.762064	35.434227	0.330625	0.0	999	5.426610	7.977689	0.022841	0.0

Gambar 6. Metrics model NeuralProphet hasil *training* dan *testing* data.




Gambar 7. Grafik MAE *training* (biru) vs MAE *testing* (merah).




Gambar 8. Grafik RMSE *training* (biru) vs RMSE *testing* (merah).

Prediksi Indeks NO₂ Tahun 2022

Model NeuralProphet yang telah dilakukan *training* dan *testing* kemudian dilakukan prediksi dengan periode 365 hari (= 1 tahun) dengan mempertimbangkan MAE, RMSE, MAE validasi, dan RMSE validasi. Data prediksi disajikan dalam bentuk grafik deret waktu yang disajikan dalam Gambar 9. Bentuk atau pola grafik tersebut serupa dengan pola *yearly seasonality* (lihat Gambar 11) di mana indeks NO₂ mengalami dua puncak sekitar bulan Februari dan Desember. Hal ini berkaitan dengan adanya peristiwa khusus yang terjadi setiap tahunnya pada bulan tersebut yang memicu peningkatan aktivitas lalu lintas seperti, Tahun Baru, Tahun Baru Imlek, Isra Mikraj Nabi Muhammad, Hari Ibu, dan Hari Raya Natal. Di samping itu juga, DKI Jakarta memiliki tipe hujan monsun dimana memiliki satu puncak musim hujan pada bulan Desember, Januari, dan Februari untuk tiap tahunnya. Selain memiliki puncak, indeks NO₂ juga diprediksi memiliki lembah pada bulan Maret dan Oktober.




Gambar 9. Grafik prediksi indeks NO₂ DKI Jakarta Tahun 2022.




Gambar 10. Grafik *weekly seasonality* dari komponen prediksi.

Model NeuralProphet memprediksi musim mingguan terlihat pada Gambar 10 dimana tiap minggunya dalam periode satu tahun diproyeksikan terus mengalami peningkatan. Tren peningkatan juga disajikan dalam Gambar 12 dimana indeks NO₂ diproyeksikan akan mengalami peningkatan sekitar 90 – 130 satuan ISPU pada tahun 2022.



Gambar 11. Grafik *yearly seasonality* dari komponen prediksi.



Gambar 12. Grafik tren dari komponen prediksi.

KESIMPULAN

Model NeuralProphet yang dirancang dengan parameter 1000 *epochs*, *learning rate* 0.10, *proportion validation* 0.10, dan frekuensi harian menghasilkan MAE dan RMSE model dari data yang di *training* sebesar 5.426610 dan 7.977689. Dari proporsi 0.10 *datasets* dilakukan *testing* yang menghasilkan MAE validasi dan RMSE validasi sebesar 27.762064 dan 35.434227. Prediksi indeks NO₂ selama 365 hari yang dihasilkan dari model NeuralProphet menunjukkan bahwa indeks NO₂ mengalami tren peningkatan yang dipengaruhi kejadian musiman baik tahunan maupun mingguan. Musim tahunan yang mempengaruhi indeks NO₂ diantaranya hari libur nasional dan


pola hujan monsun di wilayah DKI Jakarta. Libur nasional yang dimaksud diantaranya Tahun Baru, Tahun Baru Imlek, dan Hari Raya Natal dimana memicu meningkatnya arus lalu lintas. Puncak Indeks NO₂ terjadi pada bulan Februari dan Desember, sebaliknya lembah indeks NO₂ berada pada bulan Oktober.

UCAPAN TERIMAKASIH

Penulis ingin menyampaikan rasa terima kasih kepada Pemerintah Provinsi DKI Jakarta, terutama kepada Dinas Komunikasi, Informatika, dan Statistik, yang telah memberikan dukungan berupa data indeks standar pencemar udara (ISPU) dengan akses terbuka melalui situs data.jakarta.go.id. Juga, terima kasih kepada semua pihak yang tidak dapat disebutkan satu per satu atas dukungan moral yang diberikan.

REFERENSI

1. Putra, W. (2022). Pengaruh Jumlah Penduduk dan Panjang Jalan terhadap Pertumbuhan Ekonomi melalui Pertambahan Jumlah Kendaraan. *Prosiding Seminar Nasional Seminar Akademik Tahunan Ilmu Ekonomi dan Studi Pembangunan*, **5**, 170–179.
2. Putranto, L. S. (2008). *Rekayasa Lalu Lintas*. Jakarta: PT. Macanan Jaya Cemerlang.
3. Rohidin. (2011). *Emisi Gas Buang Kendaraan*. Diakses pada tanggal 19 November 2023, URL: <http://viarohidinthea.blogspot.com/2011/05/emisi-gasbuang.html>.
4. Seinfeld, J. H. (1986). *Atmospheric Chemistry of Air Pollution*. New York: John Wiley & Sons, Inc.
5. Indonesia, P. R. (1999). Peraturan Pemerintah No. 41 Tahun 1999 Tentang Pengendalian Pencemaran Udara. *Lembaran Negara RI Tahun*, **86**.
6. Alfiah, T. (2009). *Oksida-Oksida Nitrogen*. Surabaya: Institut Teknologi Adhi Tama.
7. Li, H., & Xin, X. (2013). Nitrogen dioxide (NO₂) pollution as a potential risk factor for developing vascular dementia and its synaptic mechanisms. *Chemosphere*, **92**(1), 52–58.
8. Kiswandono, A. A. (2017). Kajian Indeks Standar Polusi Udara (ISPU) Nitrogen Dioksida (NO₂) Di Tiga Lokasi Kota Bandar Lampung. *Analit: Analytical and Environmental Chemistry*, **2**(1), 42–51.
9. Ruslinda, Y., Gunawan, H., Goembira, F., & Wulandari, S. (2016). Pengaruh jumlah kendaraan berbahan bakar bensin terhadap konsentrasi timbal (Pb) di udara ambien jalan raya kota Padang. *Seminar Nasional Sains dan Teknologi Lingkungan II*, **2541**, 3880.
10. Sugiarti, G. P. U. (2009). Pengaruhnya Bagi Kesehatan Manusia. *Jurnal Chemica*, **10**, 50–58.
11. Mavuduru, A. (2020). How to use Facebook's NeuralProphet and why it's so powerful. Diakses pada 07 Januari 2023, URL: <https://towardsdatascience.com/how-to-use-facebooks-neuralprophet-and-why-it-s-so-powerful-136652d2da8b>.
12. Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. Otexts.
13. Wijaya, E. Y. (2022). *Implementasi Model Neural Prophet untuk Memprediksi Kasus Covid-19 di Indonesia*. Disertasi Informatika, Universitas Multimedia Nusantara.
14. Triebe, O., Hewamalage, H., Pilyugina, P., Laptev, N., Bergmeir, C., & Rajagopal, R. (2021). Neuralprophet: Explainable forecasting at scale. arXiv preprint arXiv:2111.15397.



Artikel ini menggunakan lisensi [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)