

PEMANFAATAN PEMODELAN NEURAL PROPHET DALAM MEMPREDIKSI PARAMETER PM10 (STUDI KASUS DKI JAKARTA)

UTILIZATION OF NEURAL PROPHET MODEL IN PREDICTING PM10 PARAMETERS (CASE STUDY OF DKI JAKARTA)

Muhammad Aulia Zikri^{1*}, Juang Merdeka¹, Agung Hari Saputra¹

¹Sekolah Tinggi Meteorologi Klimatologi dan Geofisika, Tangerang Selatan

*E-mail: auliazikri1809@gmail.com

Naskah masuk: 29 Desember 2023 Naskah diperbaiki: 7 Mei 2024 Naskah diterima: 12 Juli 2024

ABSTRAK

Kualitas udara adalah permasalahan serius di negara berkembang, terutama di DKI Jakarta, yang dipicu oleh jumlah kendaraan bermotor yang semakin meningkat dan aktivitas industri. Penelitian ini menguji keefektifan model Neural Prophet dalam memprediksi konsentrasi PM10 sebagai indikator utama kualitas udara. Data harian dari Stasiun Pemantau Kualitas Udara DKI Jakarta selama periode 2018-2022 digunakan, dengan model dievaluasi. Data awal mengalami pengolahan dengan penyesuaian format tanggal dan penghilangan variabel yang tidak relevan. Model dikonfigurasi dengan *hyperparameter* yang telah ditentukan dan diuji menggunakan teknik *holdout*, dengan membagi data menjadi 95% data latihan dan 5% data uji. Evaluasi model menunjukkan penurunan signifikan dan menunjukkan pembelajaran yang efektif. Data deret waktu menunjukkan fluktuasi tahunan, terutama mencapai puncak dari Juni hingga Oktober. Prediksi model cukup sejalan dengan data aktual, meskipun dengan ketidakpastian pada beberapa titik. Penelitian ini menunjukkan bahwa Neural Prophet dapat memprediksi konsentrasi PM10 dengan akurasi yang memadai, berpotensi sebagai alat untuk manajemen, dan perencanaan kualitas udara di DKI Jakarta.

Kata kunci: Kualitas Udara, Neural Prophet, PM10

ABSTRACT

Air quality is a serious issue in developing country, especially in DKI Jakarta, driven by the increasing number of motor vehicles and industrial activities. This research examines the effectiveness of the Neural Prophet model in predicting PM10 concentrations as the primary air quality indicator. Daily data from DKI Jakarta's Air Quality Monitoring Station for the period 2018-2022 was used, with the model evaluated. Initial data underwent processing involving date format adjustments and the removal of irrelevant variables. The model was configured with predefined hyperparameters and tested using a holdout technique, splitting the data into a 95% training set and a 5% testing set. The model evaluation showed a significant reduction in errors, indicating effective learning. Time series data exhibited annual fluctuations, primarily peaking from June to October. The model's predictions aligned reasonably well with actual data, albeit with uncertainty at some points. This research demonstrates that Neural Prophet can predict PM10 concentrations with adequate accuracy, potentially serving as a tool for air quality management and planning in DKI Jakarta.

Keywords: Air Quality, Neural Prophet, PM10

1. Pendahuluan

Permasalahan kualitas dan pencemaran udara menjadi permasalahan yang sangat penting di negara berkembang [1]. Hal ini dikarenakan dapat menimbulkan banyak dampak buruk bagi kesehatan makhluk hidup, karena dapat menurunkan kesehatan makhluk hidup dan merusak lingkungan [2]. Pencemaran udara yang melewati ambang batas Indeks Standar Pencemar Udara (ISPU) dapat menurunkan kesehatan masyarakat [3]. ISPU merupakan angka yang tidak memiliki satuan yang mengilustrasikan kondisi kualitas udara ambien di suatu lokasi dan didasarkan pada kesehatan manusia, nilai estetika, dan makhluk hidup lainnya [4].

Di antara banyaknya daerah yang menjadi sorotan karena kualitas udara yang buruk adalah DKI Jakarta. Salah satu penyebab hal ini adalah peningkatan jumlah kendaraan bermotor di DKI Jakarta [5]. Hal ini berkontribusi dalam peningkatan PM_{2.5} dan PM₁₀ [6]. Selain itu, listrik yang dihasilkan dari PLTU berbahan bakar batu bara dan konsumsi BBM, berkontribusi dalam peningkatan polusi udara, khususnya parameter PM_{2.5} dan PM₁₀ [7]. Paparan berbagai parameter ini dapat merugikan kesehatan manusia, khususnya penyakit pernapasan dan kardiovaskular [8].

Parameter kualitas udara PM₁₀ merupakan partikel polutan yang berukuran 10 mikron dan sangat berkaitan dengan kesehatan manusia [9]. Kadar PM₁₀ di udara menjadi parameter utama penyebab penurunan kualitas udara karena PM₁₀ dapat terkoagulasi dengan zat pencemar lainnya [1]. Penurunan dan kenaikan zat pencemar di udara berbanding lurus dengan kadar PM₁₀. Hal ini mengakibatkan konsentrasi yang bertambah seiring pertambahan waktu sehingga daerah penyebaran semakin luas [10].

Neural Prophet adalah suatu paket sumber terbuka yang dirumuskan oleh tim *science data* Facebook untuk memprediksi data berdasarkan model aditif dalam bentuk *time series* dan trend non-linear sesuai dengan musim tahunan, mingguan, harian, dan hari libur [11]. Prophet bekerja paling baik pada *time series* yang memiliki efek musiman yang tinggi dan sangat bagus dalam menggeser tren secara tepat akibat adanya data yang hilang [12]. Permodelan *Neural Prophet* ini membutuhkan data yang sangat banyak untuk diamati dalam interval waktu yang sangat panjang sehingga proses dan hasil estimasi peramalan dapat dilakukan dengan baik dan keakuratan yang

tinggi. Keakuratan pemodelan *Neural Prophet* dalam memodelkan polusi udara secara akurat tanpa menggunakan parameter meteorologi menjadikan pemodelan ini lebih disukai [13]. Namun, hanya sedikit penelitian yang memanfaatkan metode ini dalam pemodelan kualitas udara [14].

Dengan adanya penelitian ini diharapkan mampu menganalisis potensi dan akurasi pemodelan *Neural Prophet* dalam memprediksi indeks PM₁₀ di DKI Jakarta. Selain itu, penelitian ini juga mengidentifikasi perbandingan hasil prediksi dengan data aktual indeks PM₁₀ DKI Jakarta 2018-2022. Penelitian ini juga digunakan untuk mengevaluasi prediksi indeks PM₁₀ DKI Jakarta menggunakan pemodelan *machine learning* dengan metode regresi dan *time series*.

Penggunaan model *Neural Prophet* dalam pengelolaan kualitas udara telah dieksplorasi dalam beberapa penelitian. Cai [15] dan Singh [16] menyoroti kemampuan model tersebut dalam memprediksi kualitas udara, dengan mempertimbangkan efek musiman dan hari libur, serta kinerjanya yang unggul dibandingkan model prakiraan lainnya. Mao [17] semakin menyempurnakan hal ini dengan mengusulkan kerangka pembelajaran mendalam yang mengintegrasikan fitur-fitur temporal dari stasiun pemantauan kualitas udara, sehingga mencapai akurasi tinggi dalam prediksi jangka panjang. Raipure [18] memperluas penerapan model ini pada prakiraan jangka pendek dan spasial, dengan menekankan perannya dalam meningkatkan efisiensi dan akurasi keputusan pengelolaan kualitas udara. Beberapa penelitian ini secara kolektif menunjukkan potensi model *Neural Prophet* dalam sistem pemantauan kualitas udara *realtime*, saran kesehatan masyarakat, dan strategi tanggap darurat selama kualitas udara buruk.

2. Metode Penelitian

Lokasi Penelitian

Penelitian berlokasi di wilayah DKI Jakarta dengan letak astronomis berada pada 5° 10' 00" LS – 6° 22' 21,5" LS dan 106° 41' 12,5" BT – 106° 58' 24,2" BT. Titik lokasi data pengamatan berada di 5 titik Stasiun Pemantau Kualitas Udara (SPKU) DKI Jakarta, yaitu SPKU DKI1 Bundaran HI, SPKU DKI2 Kelapa Gading, SPKU DKI 3 Jagaraksa, SPKU DKI4 Lubang Buaya, SPKU DKI5 Kebon Jeruk. Data pengamatan di masing-masing titik akan dirata-ratakan dan menghasilkan Indeks Standar

Pencemaran Udara (ISPU) DKI Jakarta secara keseluruhan.

Data Penelitian

Dalam penelitian ini, digunakan data SPKU dari Dinas Lingkungan Hidup DKI Jakarta tahun 2018-2022 dengan temporal harian yang diakses dari <https://data.jakarta.go.id/> dan <https://katalog.data.go.id/>. Data diunduh dalam format csv dan diolah dalam *Microsoft Excel* dengan menyesuaikan format penulisan tanggal *yyyy-mm-dd* sehingga dapat dijalankan di dalam model. Selain itu, yang tidak digunakan seperti SO₂, CO, O₃, nilai *max*, nilai kritis, kategori, dan lokasi SPKU dihilangkan sehingga tersisa tanggal dan nilai indeks PM₁₀.

Teknik Pengolahan Data

Preprocessing Data

Pada tahap ini, data yang telah ada digabung dalam *sheet* yang sama dan disesuaikan format penanggalannya dengan format yang diinginkan model. Setelah itu data yang tidak diperlukan dalam pemodelan dihapus, yaitu nilai *max*, nilai kritis, kategori, dan lokasi SPKU. Data ini kemudian dibaca dalam bentuk *data frame* dengan menggunakan *library python pandas tools*. Untuk menampilkan dataset ini, digunakan perintah *df.head()*. Selanjutnya, dataset akan ditransformasikan dalam bentuk tabel yang memuat data yang akan diprediksi setiap masing-masing kelompok yang terdiri dari komponen *ds* yang mewakili waktu kejadian dan waktu yang diprediksi dan komponen *y* mewakili nilai *time series* parameter kualitas udara (PM₁₀) yang akan diprediksi.

Eksekusi Model

Pada tahap ini, akan dilakukan pengujian nilai *hyperparameter* seperti *horizon value*, *lag number*, *hidden layer*, *seasonality*, *forecast total*, dan sebagainya. Pengujian ini sangat perlu dilakukan karena akan mempengaruhi nilai prediksi yang akan dihasilkan [19]. Nilai *hyperparameter* ini akan terus dimodifikasi untuk mendapatkan nilai prediksi terbaik yang dinilai dari nilai error dan pola grafik yang dihasilkan dari proses evaluasi model. Di bawah ini adalah nilai *hyperparameter* pemodelan Neural Prophet yang digunakan dalam penelitian ini.

Tabel 1. Konfigurasi nilai hyperparameter

No	Hyperparameter	Nilai
1	<i>n_changepts</i>	10
2	<i>n_lags</i>	10
3	<i>n_forecasts</i>	10

4	<i>quantiles</i>	(0.05; 0.95)
5	<i>yearly_seasonality</i>	True
6	<i>weekly_seasonality</i>	True
7	<i>daily_seasonality</i>	True
8	<i>ar_reg</i>	1
9	<i>ar_layer</i>	(32, 32, 32, 32)
10	<i>learning_rate</i>	0.001
11	<i>growth</i>	off
12	<i>epochs</i>	200
13	<i>drop_missing</i>	true

Setelah ini, data akan dibagi menjadi 2 bagian, yang dikenal dengan teknik *holdout*. Teknik ini bertujuan membagi dataset menjadi 2 sub dataset, yaitu *training set* dan *testing set*. Kedua sub dataset ini akan dibagi sebesar 95% *training set* dan 5% *testing set* [20].

Evaluasi Model

Untuk melihat keakuratan pemodelan *Neural Prophet*, dilakukan analisis nilai eror. Pada penelitian ini, perhitungan RMSE (*Root Mean Squared Error*) dan MAE (*Mean Absolute Error*) digunakan untuk mengevaluasi model. Hal ini dilakukan untuk melihat apakah pemodelan Neural Prophet telah memenuhi ambang batas kesalahan yang diterima [21].

RMSE merupakan penjumlahan dari kesalahan kuadrat atau selisih nilai aktual dengan nilai *forecast* yang telah ditentukan [22]. Dengan formula:

$$RMSE = \sqrt{\frac{(y' - y)^2}{n}}$$

n = jumlah data
y' = nilai data forecast
y = nilai data aktual

MAE merupakan rata-rata selisih mutlak nilai *forecast* dan nilai actual [22]. MAE memberikan nilai pengukuran seberapa besar kesalahan nilai peramalan dalam satuan yang sama dengan variabel yang diukur. Dengan formula:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x|$$


n = jumlah data
x_i = nilai data aktual
x = nilai data forecast

3. Hasil dan Pembahasan

Time Series Indeks PM₁₀ DKI Jakarta Tahun 2018-2022

Data indeks PM10 yang telah digabung dan disesuaikan format penanggalannya di-*plot* dalam bentuk grafik *time series*. Sebelum di-*run* dalam bentuk grafik, data PM10 diubah menjadi

format *ds* untuk tanggal dan *y* untuk indeks PM10. Selanjutnya baru dibuatkan *time series* dengan fungsi *matplotlib*.



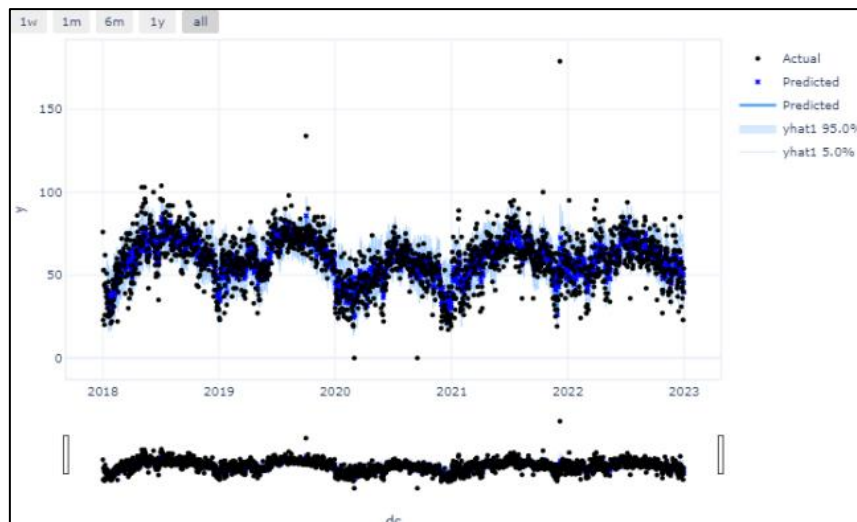
Gambar 1. Time series nilai PM10 DKI Jakarta 2018-2022

sumber: data diolah

Grafik *time series* pada gambar 1 menunjukkan PM10 berfluktuasi dari waktu ke waktu tanpa adanya tren jangka panjang dan nilai yang konsisten mengalami kenaikan dan penurunan selama 2018-2022. Selain itu, ada pola perulangan setiap tahun yang terjadi bulan Juni hingga Oktober setiap tahunnya. Selain itu terdapat anomali peningkatan ekstrem kemudian turun kembali. Di sisi lain, data yang disajikan menunjukkan banyaknya volatilitas yang ditunjukkan oleh penyebaran vertikal titik data. Hal ini mungkin disebabkan oleh variasi cuaca harian dan faktor jangka pendek lainnya seperti suhu, curah hujan, jumlah kendaraan yang menghasilkan emisi, dan sebagainya[23].

Eksekusi Teknik Holdout Pemodelan Neural Prophet

Data yang telah disesuaikan format dan penamaan selanjutnya akan dibagi menjadi data *training* dan data *testing* yang dikenal dengan teknik *holdout*. Pemodelan data training dilakukan dengan proporsi data testing sebesar 0.05 dan data training 0.95. Pemodelan diatur mempelajari data sebanyak 200 *epoch* dengan laju pembelajaran (*learning_rate*) sebesar 0.001.



Gambar 2. Grafik nilai aktual, nilai *forecast*, dan nilai residu
sumber: data diolah

Grafik pada gambar 2 menginterpretasikan nilai aktual dan nilai *forecast* hasil pembelajaran yang dilakukan oleh model. Titik hitam menunjukkan data aktual, titik biru menunjukkan nilai prediksi berdasarkan pola historis data. Area biru muda di sekitar garis prediksi menunjukkan interval prediksi. Ini menunjukkan tingkat keakuratan model terhadap nilai prediksinya. Garis atas menunjukkan akurasi data training (0.95) dan garis bawah mewakili batas bawah dari keakuratan data testing (0.05). Pada gambar 2 diamati model dapat melakukan prediksi dengan cukup baik dalam penyesuaian dengan data aktual, meskipun ada beberapa titik prediksi yang tidak selaras dengan nilai aktualnya. Selain itu, interval kepercayaan yang lebar pada beberapa bagian menunjukkan ketidakpastian.

yang lebih tinggi dalam prediksi model. Pada grafik kedua, residu tidak menunjukkan pola yang sistematis yang dapat dijelaskan bahwa model telah menangkap sebagian besar pola dalam data.

Evaluasi Model

Grafik pada gambar 3, RMSE ditunjukkan oleh garis biru sedangkan MAE ditunjukkan oleh garis merah. Nilai RMSE awalnya tinggi namun menurun dengan cepat dalam beberapa *epochs* pertama. Hal ini mengindikasikan model dapat mempelajari karakteristik data dengan cepat. Nilai MAE juga menunjukkan adanya penurunan serupa namun dengan laju yang sedikit lambat.

Kedua metrik ini menunjukkan penurunan signifikan di awal *training model*. Hal ini menunjukkan bahwa model mampu belajar


dengan baik dari kesalahannya dan meningkatkan ketepatan nilai prediksi. Setelah penurunan hingga *epochs* 20, kedua metrik mendekati konvergensi dan menunjukkan perubahan yang lebih sedikit terhadap peningkatan *epochs*. Hal ini menunjukkan mode mulai mencapai batas kemampuannya dalam mempelajari data. Pada *epochs* >160, kedua garis mendekati satu sama lain dan relatif datar. Hal ini menunjukkan model telah mencapai kondisi maksimal dalam mempelajari data dan tidak mampu lagi menghasilkan perbaikan yang berarti dalam performa model.

Sejumlah penelitian sebelumnya mendukung hasil penelitian ini. Rahman, 2015 menjelaskan bahwa model (*Artificial Neural Network*) ANN mengungguli ARIMA dan FTS dalam memprediksi indeks pencemaran udara [24]. Hal ini dikarenakan prediksi yang dihasilkan oleh ANN menghasilkan nilai yang konsisten dan kealahan peramalan terkecil dibandingkan model lainnya. Kunnathettu (2020) melakukan penelitian yang membandingkan efektivitas berbagai teknik pembelajaran mesin dalam memprediksi kualitas udara, dengan fokus pada tingkat PM2.5. Studi ini menemukan bahwa model *Regresi Logistik* dan *Support Vector Machine*, jika disesuaikan dengan hyperparameter, mengungguli teknik lainnya, dengan mencapai akurasi masing-masing sebesar 88,12% dan 87,56%. Hal ini menunjukkan bahwa model ini mungkin berguna dalam prediksi kualitas udara [25].

Penggunaan model *Neural Prophet* dalam prediksi *time series* lebih disukai karena kemampuannya menangani ketergantungan jangka panjang dan mengurangi efek memori jangka pendek, seperti yang ditunjukkan dalam

penelitian oleh Fang [26] dan Junior [27]. Selain itu, kesederhanaan model dan kecepatan penerapannya, serta kemampuannya menangkap tren dan musim, menjadikannya pilihan populer. Performa model ini semakin ditingkatkan bila dikombinasikan dengan teknik

lain, seperti model BiLSTM, seperti yang ditunjukkan dalam studi oleh Wang [28]. Faktor-faktor ini secara kolektif berkontribusi terhadap meluasnya penggunaan model Neural Prophet dalam prediksi deret waktu



Gambar 3. Grafik RMSE dan MAE hasil evaluasi model
Sumber: data diolah

4. Kesimpulan

Dari hasil penelitian di atas, model Neural Prophet yang diatur pengulangan pembelajaran data sebesar 200 *epochs* dan laju pembelajaran 0.001 menghasilkan nilai MAE dan RMSE yang relatif kecil dan dapat memanfaatkan model memprediksi parameter PM10 DKI Jakarta di tahun berikutnya. Selain itu, grafik time series Konsentrasi PM10 DKI Jakarta 2018-2022 mengalami fluktuasi setiap tahunnya dengan 1 puncak nilai yang terjadi di bulan Juni Hingga Oktober. Saat mengeksekusi teknik holdout terhadap model, Neural Prophet telah mampu menghasilkan prediksi cukup baik dalam penyesuaian dengan data aktual, walaupun ada beberapa titik prediksi yang tidak selaras dengan nilai aktualnya. Hasil evaluasi model terhadap pemodelan Neural Prophet ini dinilai sudah tepat dalam memprediksi konsentrasi PM10 di DKI Jakarta dengan beberapa penyesuaian yang dilakukan terhadap model.

Hasil penelitian ini bermanfaat untuk memprediksi kualitas udara DKI Jakarta ke depannya dengan metode yang telah diterapkan dalam penelitian ini. Penggunaan model dengan data aktual yang bagus dapat memberikan nilai prediksi yang akurat di masa yang datang.

Ucapan Terima Kasih

Ucapan terima kasih kepada pembina dan program studi Meteorologi Sekolah Tinggi Meteorologi Klimatologi dan Geofisika yang telah mendukung pelaksanaan dan

penyelesaian penelitian ini. Selanjutnya kepada Dinas Lingkungan Hidup DKI Jakarta yang telah selaku pengamat, pengelola, dan penyedia data informasi ISPU yang dapat digunakan dalam penelitian ini. Kemudian, ucapan terima kasih kepada teman-teman yang telah mendukung dan menyukseskan pelaksanaan penelitian dan penulisan paper ini.

Daftar Pustaka

- [1] Anggraeni, S. H. D. A., Darundiati, Y. H., & Joko, T. (2021). Analisis Konsentrasi PM10 Hasil Pengukuran Stasiun BMKG Kemayoran di Jakarta Pusat Pada Masa Pandemi COVID-19. *Media Kesehatan Masyarakat Indonesia*, 20(1), 63-69.
- [2] Yoo, E., Pu, Q., Eum, Y., & Jiang, X. (2021). The impact of individual mobility on long-term exposure to ambient PM2.5: Assessing effect modification by travel patterns and spatial variability of PM2.5. *International Journal of Environmental Research and Public Health*, 18(4), 2194.
- [3] Septiyana, D., Sukmono, A., & Yusuf, M. A. (2023). Pemantauan Kualitas Udara ISPU (PM10, SO2, NO2) Menggunakan Citra Landsat 8 dan 9 untuk Kecamatan Mijen Selama Pandemi Covid-19. *Jurnal Geodesi Undip*, 12(3), 271-280.
- [4] Umri, S. S. A. (2021). Analisis Dan Komparasi Algoritma Klasifikasi Dalam Indeks Pencemaran Udara Di DKI Jakarta. *JIKO (Jurnal Informatika dan Komputer)*, 4(2), 98-104.
- [5] Irwan, Z. D. (2005). Tantangan Lingkungan & Lansekap Hutan Kota.
- [6] Idiawati, N., & Siregar, S. (2021). Impact of COVID-19 Event on Air Pollutants of PM2.5 and PM10 in Jakarta, Indonesia. *Journal of Southwest Jiaotong University*, 56(4).
- [7] Haryanto, B. (2018). Climate change and urban air pollution health impacts in Indonesia. In *Climate Change and Air Pollution: The Impact on Human Health in Developed and Developing Countries* (pp. 215-239).
- [8] Reid, C. E., et al. (2016). Differential respiratory health effects from the 2008 northern California wildfires: A spatiotemporal approach. *Environmental Research*, 150, 227-235.

- [9] Najmi, A., & Tonis, M. (2021). Studi Kualitatif PM10 dan PM2.5 dengan Keluhan Subjektif ISPA di SDN 55 Pekanbaru. *Journal of STIKes Awal Bros Pekanbaru*, 2(2), 1-10.
- [10] Susanto, J. P. (2005). Kualitas Udara Beberapa Kota Di Asia (Monitoring Kandungan SO₂ Udara Ambien dengan Passive Sampler). *Jurnal Teknologi Lingkungan*, 6(1).
- [11] Jange, B. (2021). Prediksi Harga Saham Bank BCA Menggunakan Prophet. *Journal of Trends Economics and Accounting Research*, 2(1), 1-5.
- [12] Ye, Z. (2019). Air pollutants prediction in Shenzhen based on ARIMA and Prophet method. In *E3S Web of Conferences* (Vol. 136, p. 05001). EDP Sciences.
- [13] Shen, J., Valagolam, D., & McCalla, S. (2020). Prophet forecasting model: A machine learning approach to predict the concentration of air pollutants (PM_{2.5}, PM₁₀, O₃, NO₂, SO₂, CO) in Seoul, South Korea. *PeerJ*, 8, e9961.
- [14] Samal, K. K. R., Babu, K. S., Das, S. K., & Acharaya, A. (2019). Time series based air pollution forecasting using SARIMA and Prophet model. In *Proceedings of the 2019 International Conference on Information Technology and Computer Communications* (pp. 80-85).
- [15] Cai, F. (2023). The Prediction of the Air Quality based on the Prophet Algorithm. *Highlights in Science, Engineering and Technology*, 39, 1056-1060.
- [16] Singh, A. (2019). Air Pollution Forecasting and Performance Evaluation Using Advanced Time Series and Deep Learning Approach for Gurgaon (Ph.D. dissertation). National College of Ireland, Dublin.
- [17] Mao, W., Wang, W., Jiao, L., Zhao, S., & Liu, A. (2021). Modeling air quality prediction using a deep learning approach: Method optimization and evaluation. *Sustainable Cities and Society*, 65, 102567.
- [18] Raipure, S. (2018). Monitoring and Prediction of Air Quality using Neural Network. *International Journal of Advanced Research in Computer Science and Software Engineering*.
- [19] Sihombing, C., Saputra, A. H., Sari, F. P., & Mulya, A. (2022). Prediksi Curah Hujan di Wilayah DKI Jakarta dengan Model NeuralProphet. *Jurnal Aplikasi Meteorologi*, 1(2).
- [20] Rahayu, D. S., Nursafika, N., Afifah, J., & Intan, S. (2023). Klasifikasi Penyakit Diabetes Melitus Menggunakan Algoritma C4.5, Support Vector Machine (SVM) dan Regresi Linear: Classification Diabetes Mellitus Using C4.5 Algorithm, Support Vector Machine (SVM) and Linear Regression. In *SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat* (pp. 56-63).
- [21] Togatorop, J. P. E., Firdaush, R. B., & Haryanto, Y. D. (2021). Prediksi Indeks Nitrogen Dioksida (NO₂) Menggunakan Model NeuralProphet Studi Kasus DKI Jakarta. *Indonesian Physics Communication*, 20(3), 215-222.
- [22] Ardiansyah, D. (2023). Perbandingan Model Prediksi Radiasi Matahari Berbasis Mesin Pembelajaran Pada Stasiun Meteorologi Fatmawati Soekarno Bengkulu. *Megasains*, 14(1).
- [23] Nofendri, Y. (2018). Pengaruh Penambahan Oksigenat Pada Solar Terhadap Emisi Gas Buang Mesin Diesel. *Jurnal Kajian Teknik Mesin*, 3(1), 30-39.
- [24] Rahman, N. H. A., Lee, M. H., Suhartono, & Latif, M. T. (2015). Artificial neural networks and fuzzy time series forecasting: An application to air quality. *Quality & Quantity*, 49, 2633-2647.
- [25] Kunnathettu, A. J., & Varma, S. L. (2020). Comparative Analysis of Neural Network and Machine Learning Techniques for Air Quality Prediction. In *2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)* (pp. 724-729). IEEE.
- [26] Fang, W.-X., Lan, P.-C., Lin, W.-R., Chang, H.-C., Chang, H.-Y., & Wang, Y.-H. (2019). Combine Facebook Prophet and LSTM with BPNN forecasting financial markets: The Morgan Taiwan index. In *2019 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)* (pp. 1-2). IEEE.
- [27] Junior, C., Gusmão, P., Moreira, J., & Tome, A. M. M. (2021). Time Series Forecasting in Retail Sales Using LSTM and Prophet. In *Handbook of Research on Applied Data Science and Artificial Intelligence in Business and Industry* (pp. 241-262). IGI Global.
- [28] Wang, Z., & Gu, X. (2023). A Time Series Prediction Algorithm Based on BiLSTM and Prophet Hybrid Model. In *2023 4th International Conference on Computer Engineering and Application (ICCEA)* (pp. 128-132). IEEE.