

PREDIKSI INDEKS STANDAR PENCEMARAN UDARA DI KOTA YOGYAKARTA DENGAN MODEL LONG SHORT-TERM MEMORY DAN GATED RECURRENT UNIT

Shinzi, Valeroy Putra Sientika, Teny Handayani

Teknik Informatika, Universitas Tarumanagara

Letjen S. Parman St No.1, Jakarta, Indonesia

tenyh@fti.untar.ac.id

ABSTRAK

Polusi udara merupakan salah satu permasalahan lingkungan yang berdampak signifikan terhadap kesehatan masyarakat, kualitas hidup, dan stabilitas ekonomi, khususnya di kota-kota besar seperti Kota Yogyakarta. Kurangnya informasi dini mengenai tingkat pencemaran udara menyebabkan kesulitan dalam upaya pencegahan baik untuk masyarakat maupun pemerintah. Penelitian ini bertujuan untuk memprediksi nilai indeks standar pencemaran udara yang berdasar kepada lima jenis polutan udara yaitu PM_{10} , SO_2 , CO , NO_2 , dan O_3 di Kota Yogyakarta. Penelitian ini dilakukan dengan menggunakan dua metode *deep learning* berbasis *Recurrent Neural Network*, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua model dilatih dengan menggunakan data deret waktu dari Tahun 2020 – Tahun 2023, dan dievaluasi menggunakan metrik evaluasi berupa *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), dan *Root Mean Squared Error* (RMSE). Hasil menunjukkan bahwa kedua model mampu memberikan prediksi dengan akurasi yang baik. Model LSTM menghasilkan MAE di bawah 4 dan RMSE di bawah 6 untuk semua polutan, dengan performa terbaik pada prediksi CO . Sementara itu, model GRU menunjukkan nilai MAE antara 1.9 hingga 4, dengan performa terbaik pada prediksi NO_2 . Hasil ini menunjukkan bahwa pendekatan prediktif dengan LSTM dan GRU efektif dalam memberikan informasi dini kualitas udara di Kota Yogyakarta.

Kata kunci : Polusi udara, LSTM, GRU, Peramalan, Prediksi

1. PENDAHULUAN

Polusi udara menjadi salah satu masalah utama yang dihadapi banyak kota besar di dunia saat ini [1] [2]. Polusi udara dapat menyebabkan permasalahan dalam berbagai aspek, baik dalam aspek ekonomi, lingkungan dan terutama dalam aspek kesehatan [3]. Berdasarkan suatu penelitian yang dilakukan di Jakarta, polusi udara terbukti memiliki dampak signifikan dalam menyebabkan penyakit *cardiovascular* dan penyakit pernapasan lainnya, hal ini juga memicu permasalahan dalam aspek ekonomi [4] [5]. Polusi udara pada umumnya terjadi karena aktivitas manusia terutama aktivitas pembakaran bahan bakar untuk kendaraan bermotor dan aktivitas industri [6] [7].

Polusi udara dapat diukur dengan menggunakan indeks standar pencemaran udara (ISPU). ISPU bekerja dengan cara menghitung banyaknya polutan di udara, polutan yang dimaksud berupa PM_{10} , CO , NO_2 , SO_2 , O_3 [8]. Hasil dari perhitungan ISPU dapat digunakan sebagai standar untuk menentukan apakah udara yang ada di suatu tempat berada dalam kadar yang baik atau membahayakan [9]. Informasi yang dihasilkan oleh perhitungan ISPU dapat dimanfaatkan oleh masyarakat untuk mengambil tindakan pencegahan penyakit pernapasan, seperti penggunaan masker dan menghindari aktivitas luar ruangan saat tingkat polusi tinggi. Informasi yang dihasilkan juga dapat bermanfaat bagi pihak pemerintah dalam pengambilan keputusan dan pembuatan peraturan dalam rangka mengurangi kadar polutan [10].

Implementasi dari teknologi dalam bentuk prediksi atau *forecasting* dapat memberikan manfaat

signifikan dalam bentuk pemberian informasi yang lebih dini [11]. Prediksi dapat dilakukan dengan menggunakan model dan arsitektur yang dianggap cocok dengan data historis nilai polutan dalam jangka waktu tertentu di suatu daerah [12]. Penelitian ini dilakukan dengan tujuan untuk memberikan prediksi dan informasi dini tentang tingkat Indeks Standar Pencemaran Udara (ISPU) di salah satu kota di Indonesia, yaitu Kota Yogyakarta.

Untuk melakukan prediksi tingkat polusi udara, Penelitian ini memanfaatkan pendekatan pembelajaran mesin berbasis *deep learning*, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua model ini dipilih karena memiliki kemampuan yang baik dalam mengolah data deret waktu (*time-series*) serta mampu menangkap pola dan ketergantungan jangka pendek maupun jangka panjang antar data secara efektif [13][14].

2. TINJAUAN PUSTAKA

2.1. Indeks Standar Pencemaran Udara (ISPU)

Indeks Standar Pencemaran Udara (ISPU) merupakan indikator yang memberikan informasi mengenai tingkat kualitas udara di suatu wilayah [8]. Secara umum, ISPU terdiri dari beberapa polutan udara seperti PM_{10} , CO , NO_2 , SO_2 , dan O_3 .

2.2. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu arsitektur *Recurrent Neural Network* (RNN) yang dirancang khusus untuk menangani masalah yang terkait dengan aliran data panjang, salah satunya adalah implementasi pada data deret waktu [15].

Kelebihan utama dari LSTM adalah pada kemampuan arsitektur ini dalam mengingat informasi dalam jangka panjang, dimana hal ini sering tidak ada pada arsitektur RNN tradisional [16]. LSTM menggunakan unit memori yang dikenal dengan *cell state* yang mengalir di sepanjang rantai dengan beberapa gerbang untuk mengatur aliran informasi [16].

Terdapat tiga gerbang utama pada LSTM yaitu, *input gate*, *forget gate*, dan *output gate* [17]. *Input gate* menentukan berapa banyak informasi baru yang disimpan dalam *cell state*, *forget gate* berfungsi untuk menentukan banyaknya informasi lama yang harus dihapus dari *cell state*, dan *output gate* yang mengatur bagaimana *cell state* akan menghasilkan *output* berdasarkan input. *Input gate*, *forget gate*, dan *output gate* dapat dirumuskan sesuai dengan urutan Rumus 1-3 [18]. *Cell state* memiliki digunakan untuk menyimpan dan memodifikasi informasi dari waktu ke waktu sesuai dengan Rumus 4, pada LSTM juga terdapat calon nilai yang dapat dimasukkan ke dalam *cell state* sesuai dengan Rumus 5. LSTM dapat menghasilkan *output* sesuai dengan *cell state* yang dimodifikasi dan diatur oleh *output gate* sesuai dengan Rumus 6.

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \quad (1)$$

$$i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh \tanh (W h_{t-1} + U x_t + b) \quad (3)$$

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \quad (4)$$

$$h^{(t)} = \sigma_t \circ \tanh \tanh (c_t) \quad (5)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (6)$$

2.3. Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan arsitektur lain yang berdasar dari Recurrent Neural Network (RNN), GRU dirancang untuk mengatasi masalah pengolahan data yang memiliki urutan yang panjang. GRU lebih sederhana dari LSTM, tetapi pemakaian dari GRU dapat menghasilkan hasil yang lebih baik dari LSTM [19] [20] [21]. GRU bekerja dengan menggabungkan konsep *input gate* dan *forget gate* menjadi satu unit yang disebut sebagai *reset gate* yang dirumuskan pada rumus 7 dan menggunakan *update gate* untuk mengatur aliran informasi, *update gate* dapat dirumuskan sesuai dengan rumus 8 [22]. GRU juga memiliki kandidat atau calon nilai yang dapat diperbarui sesuai dengan rumus 9. GRU menggabungkan informasi dari *update gate* dengan informasi dari kandidat nilai untuk menghasilkan *hidden state* baru, *hidden state* dapat dirumuskan sesuai dengan rumus 10. Hal-hal tersebut membuat arsitektur GRU lebih sederhana dari LSTM [20] [23].

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (7)$$

$$u_t = \sigma(W_u h_t + U_u x_{t-1} + b_u) \quad (8)$$

$$c_t = \tanh \tanh (W x_t + U (r_t \odot h_{t-1}) + b) \quad (9)$$

$$h_t = u_t \odot h_{t-1} + (1 - u_t) \odot c_t \quad (10)$$

2.4. Evaluation Metrics

Evaluation metrics atau metrik evaluasi merupakan ukuran yang digunakan untuk menilai seberapa baik kinerja suatu model dalam melakukan prediksi [24]. Metrik evaluasi yang digunakan pada penelitian ini adalah Mean Absolute Error (MAE), Mean Squared Error (MSE), dan RMSE (Root Mean Squared Error). MAE menghitung rata – rata dari selisih antara prediksi dari model suatu arsitektur dengan nilai sebenarnya secara absolut, MAE memiliki jangkauan nilai antara 0 sampai ∞ , dimana semakin mendekati 0 model berarti memiliki akurasi yang baik [25], MAE dirumuskan pada Rumus 11. MSE menghitung rata – rata dari kuadrat selisih antara prediksi model dan nilai sebenarnya dan memberikan bobot lebih besar kepada kesalahan prediksi, sedangkan RMSE adalah akar kuadrat dari MSE dimana pada hal ini memberikan ukuran kesalahan yang lebih mudah diinterpretasikan, perumusan dari MSE dan RMSE dapat dilihat pada Rumus 12-13 [26].

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (11)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (12)$$


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (13)$$

2.5. Penelitian Terdahulu

Penelitian ini memiliki kesamaan dengan penelitian prediksi kualitas udara di Jakarta yang telah dilakukan sebelumnya [27], terutama dalam penggunaan model LSTM untuk melakukan *forecasting*. Kedua penelitian bertujuan untuk melakukan prediksi terhadap nilai besaran polutan-polutan di salah satu kota di Indonesia. Namun, terdapat beberapa perbedaan signifikan, Penelitian sebelumnya hanya berfokus pada prediksi nilai PM_{2.5} dengan membandingkan dua metode, yaitu LSTM dan *Artificial Neural Network* (ANN), serta menggunakan data selama satu tahun dari DKI Jakarta. Sementara itu, penelitian ini mencakup lima jenis polutan (PM₁₀, SO₂, CO, NO₂, dan O₃) dan menggunakan dua model deep learning yang berbasis *Recurrent Neural Network*, yaitu LSTM dan GRU, yang kemudian dievaluasi dan dibandingkan performanya secara lebih menyeluruh.

3. METODE PENELITIAN

Gambar 1 menunjukkan alur penelitian yang menggambarkan tahapan-tahapan yang dilakukan dalam penelitian ini. Setiap langkah dalam alur tersebut dilakukan untuk memastikan proses analisis data deret waktu berjalan secara terstruktur, mulai dari tahap awal pengumpulan data hingga tahap akhir evaluasi dan interpretasi hasil prediksi.



Gambar 1. Diagram alir

3.1. Pengumpulan Data

Data yang digunakan pada penelitian ini diperoleh dari situs resmi Dinas Lingkungan Hidup Kota Yogyakarta yang dapat diakses dari tautan berikut: <https://lingkunganhidup.jogjakota.go.id>. Data yang diperoleh merupakan data historis 5 polutan udara di Kota Yogyakarta selama 4 Tahun yaitu dari Januari 2020 – 31 Desember 2023. Polutan-polutan yang diamati berupa PM₁₀, SO₂, CO, O₃, dan NO₂.

3.2. Pra Pemrosesan Data

Pada tahap ini, data dibersihkan dengan melakukan pengisian nilai yang hilang (*missing value*) dengan menggunakan metode interpolasi linear [28]. Selanjutnya dilakukan normalisasi data ke rentang

[0,1] menggunakan *Min-Max Scaling*, kemudian melakukan penghapusan outlier, serta transformasi data deret waktu (*time-series*) ke dalam bentuk *supervise*.

3.3. Pelatihan Model

Penelitian dilakukan dengan menggunakan dua jenis arsitektur model, yaitu LSTM dan GRU. Kedua model dilatih menggunakan parameter yang sudah divariasikan. Setiap arsitektur diatur dengan komposisi data latih 80% dan data uji 20%, penelitian juga dilakukan dengan variasi lapisan unit arsitektur yaitu lapisan unit 32, 16, 8 atau lapisan unit 64, 32, 16, pemilihan *time-step* dilakukan dengan 3 atau 5 *step*, jumlah *epoch* di antara 25 dan 50, serta *batch size* diantara 32 atau 64 pada model LSTM dan GRU.

3.4. Evaluasi Model


Model yang sudah dilatih, dievaluasi dengan menggunakan tiga metrik utama, yaitu Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE). Evaluasi dilakukan terhadap data uji (*test-set*) untuk mengukur kemampuan prediksi model terhadap data baru.

3.5. Analisis Hasil

Pada tahap ini, model yang telah dilatih digunakan untuk menghasilkan nilai prediksi terhadap lima jenis polutan. Hasil prediksi tersebut kemudian dianalisis dan digunakan untuk mengevaluasi performa masing-masing model. Evaluasi dilakukan untuk menentukan model mana yang memiliki kinerja terbaik dalam memprediksi polutan.

4. HASIL DAN PEMBAHASAN

Hasil dari pelatihan model LSTM dan GRU menunjukkan perbedaan performa dalam memprediksi polutan udara di Kota Yogyakarta.



Gambar 2. Rata-rata ISPU di Kota Yogyakarta pada triwulan dan bulan dari Tahun 2020 – 2023

Berdasarkan data yang diperoleh dan dapat dilihat pada Gambar 2, nilai PM₁₀ dan SO₂ cenderung memiliki nilai rata – rata yang cukup stabil di sepanjang Tahun. Untuk polutan CO terdapat tren penurunan nilai seiring mendekati Tahun 2023. Polutan O₃ dapat dilihat mengalami sempat mengalami


penurunan yang signifikan pada triwulan pertama sampai triwulan ketiga Tahun 2022 tetapi mulai mengalami kenaikan seiring mendekati akhir Tahun. Polutan NO₃ terlihat memiliki tren penurunan nilai pada bulan September – November, NO₃ juga sempat mengalami kenaikan nilai yang drastis pada triwulan

pertama dan kedua Tahun 2023, namun dapat diperhatikan bahwa ledakan tersebut sudah cenderung mengalami penurunan mendekati Tahun 2023. Bulan

Juni dan Desember menjadi bulan memiliki rata – rata nilai polutan terbesar diantara bulan lainnya.

Tabel 1. Konfigurasi terbaik dan hasil model LSTM

Polutan	Lapisan Unit	Time Step	Epoch	Batch Size	MAE	MSE	RMSE
PM ₁₀	64, 32, 16	3	50	32	3.9648	32.2262	5.6768
SO ₂	64, 32, 16	5	25	32	2.8768	26.3258	5.1309
CO	64, 32, 16	3	25	32	1.785	6.19	2.488
O ₃	64, 32, 16	3	50	64	2.4347	15.4028	3.9426
NO ₂	64, 32, 16	3	50	32	1.8738	11.8551	3.4431




Gambar 3. Hasil prediksi polutan dengan LSTM

Penelitian dengan *Long Short-Term Memory* dilakukan dengan fungsi aktivasi *sigmoid* dengan tambahan *adam optimizer*. Sesuai dengan tabel 1, nilai prediksi dari masing – masing polutan memiliki nilai yang cukup baik, hal ini dapat dilihat dari visualisasi dari Gambar 3, dan juga dari nilai metrik evaluasi yang memiliki nilai cukup ideal dimana semua polutan memiliki nilai MAE dibawah 4 dan nilai RMSE dibawah 6. Semua polutan memperoleh hasil terbaik

pada saat dijalankan pada lapisan unit 64, 32, dan 16. Polutan PM₁₀, O₃, dan NO₂ memperoleh hasil terbaik pada saat dijalankan dengan *time-step* 3 di 50 *epochs*, Polutan SO₂ memperoleh hasil terbaik pada saat dijalankan di *time-step* 3 pada 25 *epochs*, Polutan CO memiliki nilai akurasi tertinggi pada model LSTM yaitu MAE dengan nilai 1.785 pada saat dijalankan pada *time-step* 3 pada 25 *epochs*.

Tabel 2. Konfigurasi terbaik dan hasil model GRU

Polutan	Lapisan Unit	Time Step	Epoch	Batch Size	MAE	MSE	RMSE
PM ₁₀	64, 32, 16	5	50	32	4.0288	34.2549	5.8258
SO ₂	64, 32, 16	5	25	32	1.9595	6.5891	2.5669
CO	64, 32, 16	3	50	64	1.7943	5.6619	2.3795
O ₃	64, 32, 16	3	50	32	2.1767	13.3579	3.6548
NO ₂	64, 32, 16	5	50	32	1.5061	9.1744	3.0289



Gambar 4. Hasil prediksi polutan dengan GRU

Penelitian dengan Gated Recurrent Unit dilakukan dengan fungsi aktivasi *sigmoid* dengan tambahan *Adam Optimizer*. Sesuai dengan tabel 2, nilai prediksi dari masing – masing polutan memiliki nilai yang cukup baik, hal ini dapat dilihat dari visualisasi dari Gambar 3, dan juga dari nilai metrik evaluasi yang memiliki nilai cukup ideal dimana semua polutan memiliki nilai MAE yang berada dalam 1.9 - 4 dan nilai RMSE yang berada diantara 2.3 – 5.8. GRU memiliki kemiripan seperti LSTM dimana semua polutan memperoleh hasil terbaik pada saat dijalankan pada lapisan unit 64, 32, dan 16. Polutan PM₁₀, SO₂, dan NO₂ memperoleh hasil terbaik pada saat dijalankan dengan *time-step* 5 dan *batch size* 32 pada 50 *epochs*.

5. KESIMPULAN DAN SARAN

Penerapan Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi tingkat ISPU di Kota Yogyakarta berhasil memberikan hasil yang akurat. Berdasarkan data historis lima polutan utama (PM₁₀, SO₂, CO, O₃, NO₂) dari Januari 2020 hingga Desember 2023, kedua model menunjukkan performa yang baik. Model LSTM menghasilkan nilai MAE di bawah 4 dan RMSE di bawah 6 untuk semua polutan, dengan hasil terbaik untuk CO yang memiliki MAE sebesar 1.785. Sementara itu, model GRU menunjukkan nilai MAE antara 1.9 hingga 4 dan RMSE antara 2.3 hingga 5.8, dengan hasil terbaik untuk NO₂ dengan MAE sebesar 1.5061. Untuk pengembangan selanjutnya, penelitian dapat melibatkan data tambahan berupa data kondisi

cuaca lingkungan sekitar untuk mengetahui korelasi dari kondisi cuaca terhadap tingkat polutan. Selain itu, teknik optimisasi lain seperti *hyperparameter tuning* dapat digunakan untuk meningkatkan performa model.

DAFTAR PUSTAKA

- [1] F. D. S. Júnior, F. R. d. Moura and R. B. de Lima, "Air pollution-A look beyond big cities," *Integrated Environmental Assessment and Management*, vol. 19, pp. 295-297, 2023.
- [2] E. S. Manangahttps, E. Lopez and A. Diop, "The impact of the air pollution on health in New York City," *Journal of Public Health Research*, vol. 12, no. 4, 2023.
- [3] Z. Fang, P.-Y. Wu and Y.-N. Lin, "Air Pollution's Impact on the Economic, Social, Medical, and Industrial Injury Environments in China," *Healthcare*, vol. 9, no. 3, 2021.
- [4] G. Syuhada, A. Akbar and D. Hardiawan, "Impacts of Air Pollution on Health and Cost of Illness in Jakarta, Indonesia," *International Journal of Environmental Research and Public Health*, 2023.
- [5] R. A. Montone, R. Rinaldi and A. Bonanni, "Impact of air pollution on ischemic heart disease: Evidence, mechanisms, clinical perspectives," *Atherosclerosis*, vol. 366, pp. 22-31, 2023.
- [6] G. Yang, Y. Zhang and X. Li, "Impact of gasoline upgrade policy on particulate matter pollution in China," *Journal of Cleaner Production*, vol. 262, 2020.

- [7] R. Z. Akbar, "Air Pollution Levels of Motorized Vehicles in the South Parking Area of Yogyakarta Muhammadiyah University," *Media Ilmiah Teknik Lingkungan (MITL)*, vol. 8, no. 1, pp. 25-33, 2023.
- [8] M. Imam, S. Adam and S. Dev, "Air quality monitoring using statistical learning models for sustainable environment," *Intelligent Systems with Applications*, vol. 22, 2024.
- [9] A. M. Graham, K. J. Pringle and R. J. Pope, "Impact of the 2019/2020 Australian Megafires on Air Quality and Health," *GeoHealth*, vol. 5, no. 10, 2021.
- [10] M. Amann, G. Kiesewetter and W. Schöpp, "Reducing global air pollution: the scope for further policy interventions," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 378, no. 2183, 2020.
- [11] F. Petropoulos, D. Apiletti and V. Assimakopoulos, "Forecasting: theory and practice," *International Journal of Forecasting*, vol. 38, no. 3, pp. 705-871, 2022.
- [12] P. Lara-Benitez, M. Carranza-Garcia and J. C. Riquelme, "An Experimental Review on Deep Learning Architectures For Time Series Forecasting," *International Journal of Neural Systems*, vol. 31, no. 3, 2021.
- [13] Y. Kong, Z. Wang dan T. Zhou, "Unlocking the Power of LSTM for Long Term Time Series Forecasting," dalam *Annual AAAI Conference*, 2024.
- [14] M. Diqi, A. Wakhid dan I. W. Ordiyasa, "Harnessing the Power of Stacked GRU for Accurate Weather Predictions," *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 6, no. 2, pp. 208-219, 2023.
- [15] B. Lindemann, T. Müller and H. Vietz, "A survey on long short-term memory networks for time series prediction," *Procedia CIRP*, vol. 99, pp. 650-655, 2021.
- [16] G. V. Houdt, C. Mosquera and G. Nápoles, "A review on the long short-term memory model," *Artificial Intelligence Review*, vol. 53, pp. 5929-5955, 2020.
- [17] N. Absar, M. N. Uddin and M. U. Khandaker, "The efficacy of deep learning-based LSTM model in forecasting the outbreak of contagious diseases," *Infectious Disease Modelling*, vol. 7, no. 1, pp. 170-183, 2022.
- [18] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network," *Physica D: Nonlinear Phenomena*, vol. 404, 2020.
- [19] A. M. Ozbayoglu, M. U. Gudelek and O. B. Sezer, "Deep learning for financial applications: A survey," *Applied Soft Computing*, vol. 93, 2020.
- [20] R. Cahuantzi, C. Xinye and G. Stefan, "A Comparison of LSTM and GRU Networks for Learning Symbolic Sequences," *Intelligent Computing*, vol. 2, 2023.
- [21] R. Achmad, Y. Tokoro and J. Haurissa, "Recurrent Neural Network-Gated Recurrent Unit for Indonesia-Sentani Papua Machine Translation," *Journal of Information Systems and Informatics*, vol. 5, no. 4, pp. 1450-1460, 2023.
- [22] U. I. Arfianti, D. C. R. Novitasari and N. Widodo, "Sunspot Number Prediction Using Gated Recurrent Unit," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 15, no. 2, pp. 141-152, 2021.
- [23] T. Doleck, D. J. Lemay and R. B. Basnet, "Predictive analytics in education: a comparison of deep learning frameworks," vol. 25, pp. 1951-1963, 2020.
- [24] A. Neupane, N. Raj and R. Deo, "Development of data-driven models for wind speed forecasting in Australia," 2021, pp. 143-190.
- [25] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," *Geoscientific Model Development*, vol. 15, no. 14, pp. 5842-5847, 2022.
- [26] E. K. Hendarwati, P. Lepong and Suyitno, "Pemilihan Semivariogram Terbaik Berdasarkan Root Mean Square Error (Rmse) Pada Data Spasial Eksplorasi Emas Awak Mas," *Jurnal Geosains Kutai Basin*, vol. 6, no. 1, 2023.
- [27] I. G. A. N. Lestari dan I. N. D. A. Mahendra, "Prediksi Kualitas Udara dengan Menggunakan Metode Long Short-Term Memory dan Artificial Neural Network," *Jurnal Sistem dan Informatika (JSI)*, pp. 121-129, 2023.
- [28] D. M. Larson, W. Bungula and A. Lee, "Reconstructing missing data by comparing interpolation techniques: Applications for long-term water quality data," *Limnology and Oceanography: Methods*, vol. 21, no. 7, pp. 435-449, 2021.