

PERBANDINGAN PREDIKSI POLUSI UDARA MENGGUNAKAN LSTM DAN BiLSTM

Andre Pratama¹, Asha Sembiring², Junerdi Nababan³,
Muhammad Imam Zarkasyi⁴, Novrizah Rahayu⁵
Universitas Satya Terra Bhinneka, Medan

email: ¹andrepratama@satyaterrabhinneka.ac.id,

²ashasembiring@satyaterrabhinneka.ac.id, ³junerdin@satyaterrabhinneka.ac.id,

⁴zarkasyi@satyaterrabhinneka.ac.id, ⁵novrizarahayu18@gmail.com

Abstract: Air pollution has become a serious problem in densely populated urban areas such as DKI Jakarta. To mitigate its negative impacts, an accurate air pollution prediction system is necessary. This study compares the performance of two deep learning models, Long Short-Term Memory (LSTM) and Bidirectional Long Short-Term Memory (BiLSTM), in predicting PM10 concentration using air quality data from DKI Jakarta between 2016 and 2019. The research process includes data collection and preprocessing, model training, and model evaluation. Both models were tested with various parameters such as the number of hidden neurons, dropout rate, epochs, and batch size. The results consistently show that BiLSTM outperforms LSTM, achieving lower Root Mean Square Error (RMSE) values across 54 testing scenarios. The best BiLSTM configuration, with 64 hidden neurons, 0.2 dropout rate, 50 epochs, and batch size 16, yielded an RMSE of 9.311401. Meanwhile, the best LSTM configuration, with 128 hidden neurons, 0.1 dropout rate, 100 epochs, and batch size 16, produced an RMSE of 9.330554. The advantage of BiLSTM lies in its ability to process data bidirectionally, making it more effective in capturing temporal patterns for air pollution prediction compared to LSTM.

Keywords: air pollution prediction, pollutant, deep learning, LSTM, BiLSTM

Abstrak: Pencemaran udara menjadi masalah serius di wilayah perkotaan padat seperti DKI Jakarta. Untuk mengurangi dampak negatifnya, diperlukan sistem prediksi polusi udara yang akurat. Penelitian ini membandingkan performa dua model *deep learning*, Long Short-Term Memory (LSTM) dan Bidirectional Long Short-Term Memory (BiLSTM), dalam memprediksi konsentrasi PM10 menggunakan data kualitas udara DKI Jakarta tahun 2016-2019. Proses penelitian mencakup pengumpulan dan pra-proses data, pelatihan model, serta evaluasi model. Kedua model diuji dengan berbagai parameter seperti jumlah *hidden neuron*, *dropout rate*, *epoch*, dan *batch size*. Hasil menunjukkan BiLSTM lebih unggul secara konsisten dengan nilai Root Mean Square Error (RMSE) lebih rendah melalui 54 skenario pengujian. Konfigurasi terbaik BiLSTM menggunakan 64 *hidden neuron*, *dropout rate* 0.2, 50 *epoch*, dan *batch size* 16 menghasilkan RMSE 9.311401. Sedangkan konfigurasi LSTM terbaik pada 128 *hidden neuron*, *dropout rate* 0.1, 100 *epoch*, dan *batch size* 16 menghasilkan RMSE 9.330554. Keunggulan BiLSTM terletak pada kemampuannya memproses data dua arah, sehingga lebih efektif dalam menangkap pola temporal untuk prediksi polusi udara dibandingkan LSTM.

Kata kunci: prediksi polusi udara, polutan, *deep learning*, LSTM, BiLSTM

PENDAHULUAN

Polusi udara adalah pencemaran atmosfer sekitar akibat adanya zat kimia,

gas, atau partikel (Almetwally et al., 2020). Polusi udara dapat berdampak pada pertumbuhan tanaman, mempercepat pemanasan global, mengubah ekosistem,

meningkatkan permukaan air laut, serta menyebabkan penipisan lapisan ozon. Dampak tersebut membawa konsekuensi negatif yang signifikan bagi berbagai aspek kehidupan di bumi (Amalia et al., 2022). Selain itu, aktivitas manusia seperti transportasi, rumah tangga, pertanian, dan proses industri semakin memperburuk kondisi udara yang tercemar (Ravindiran et al., 2023). Emisi polutan polimer dari aktivitas manusia telah meningkat di Asia selama 50 tahun terakhir (DESA, 2018). Udara tercemar biasanya mengandung polutan utama seperti Karbon Monoksida (CO), Nitrogen Dioksida (NO₂), partikel-partikel halus (PM_{2.5}, SPM, dan RSPM), Sulfur Dioksida (SO₂), gas-gas rumah kaca, serta Ozon (O₃). Zat-zat ini dapat memicu berbagai gangguan pernapasan, termasuk asma dan kanker paru-paru (Akanksha et al., 2023).

Beberapa kota besar memang menghadapi tantangan serius terkait pencemaran udara (Lu et al., 2021). Sebagai contoh, DKI Jakarta yang telah melampaui 10 juta jiwa, menghadapi tantangan lingkungan yang signifikan, termasuk pencemaran udara yang membutuhkan perhatian serius (Lestari & Mahendra, 2023). Menurut data dari WHO, polusi udara bertanggung jawab atas sekitar 7,6% dari keseluruhan angka kematian di dunia dan menyebabkan lebih dari 7 juta kematian prematur setiap tahunnya akibat berbagai penyakit yang berhubungan dengan polusi udara. Model prediksi polusi yang sangat akurat akan memungkinkan pengambil keputusan dan pihak berwenang untuk mengambil langkah pencegahan dan memberikan respons secara tepat waktu (Mitreska Jovanovska et al., 2023).

Prediksi polusi udara adalah proses memperkirakan tingkat kualitas udara di masa depan (Rahman et al., 2024). Hal ini penting karena pencemaran udara memiliki dampak yang signifikan terhadap kesehatan manusia dan lingkungan. Berdasarkan sebuah penelitian oleh (Lestari & Mahendra, 2023) yang membandingkan dua model

prediksi, yaitu LSTM dan ANN, diperoleh hasil bahwa model LSTM menunjukkan performa yang lebih unggul. LSTM mencatat nilai RMSE sebesar 23,311, MAE sebesar 19,391, dan MAPE sebesar 0,176, sedangkan ANN menghasilkan RMSE 24,673, MAE 21,338, dan MAPE 0,194. Dalam penelitian lain oleh (Raheja & Malik, 2022), dilakukan perbandingan terhadap empat model berbeda, yaitu *Long Short Term Memory* (LSTM), *Support Vector Regressor* (SVR), kombinasi SVR-LSTM, dan *Improved LSTM* (I-LSTM). Penelitian ini menunjukkan bahwa LSTM unggul dalam hal kinerja jika dibandingkan dengan tiga model lainnya, sebagaimana terlihat dari nilai evaluasi menggunakan MAE, RMSE, presisi, *recall*, serta *F1-score*.

Namun, penelitian sebelumnya belum membahas lebih lanjut model LSTM. LSTM memiliki keterbatasan yang hanya memanfaatkan ketergantungan data secara satu arah (*forward*) dan kurang optimal dalam mempertimbangkan ketergantungan data secara dua arah (*backward*) (Chen et al., 2022). Pada penelitian yang dilakukan (Seabe et al., 2023), model *Bidirectional Long Short-Term Memory* (BiLSTM) pun diusulkan dan dibandingkan dengan model LSTM dan *Gate Recurrent Unit* (GRU) untuk memprediksi harga *cryptocurrency*. Dari penelitian tersebut diperoleh hasil bahwa model BiLSTM memiliki nilai RMSE dan MAPE paling akurat.

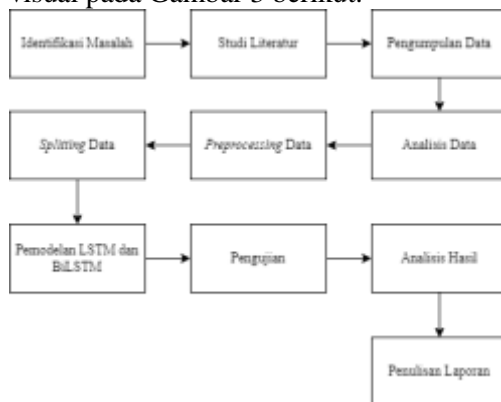
Penelitian ini akan menguji dan membandingkan performa model LSTM dan BiLSTM dalam melakukan prediksi polusi udara. LSTM dirancang khusus untuk menghindari *long-term dependencies*, sekaligus mengatasi masalah *vanishing gradient* dengan mekanisme tambahan untuk mengatur informasi, sehingga informasi tersebut dapat tetap dipertahankan dalam jangka waktu yang lama (Hua, 2020). Sementara *Bidirectional LSTM* menggunakan kombinasi dari *forward LSTM* dan *backward LSTM* untuk melakukan

prediksi, sehingga memungkinkan model untuk mendapatkan data historis dan masa depan secara menyeluruh untuk analisis agar hasil prediksinya menjadi lebih akurat (Seabe et al., 2023).

Dengan membandingkan model LSTM dan BiLSTM, penelitian ini diharapkan dapat memberikan wawasan yang lebih mendalam mengenai model yang lebih unggul dalam melakukan prediksi polusi udara. Dengan demikian, penelitian ini tidak hanya berkontribusi pada ranah akademik dan teknologi, tetapi juga memiliki potensi yang signifikan dalam membantu para pemangku kepentingan dalam mengambil langkah preventif lebih cepat berdasarkan data untuk mengurangi polusi udara di wilayah tertentu.

METODE

Metode penelitian ini mencakup beberapa tahapan yang disajikan secara visual pada Gambar 3 berikut.



Gambar 1 Workflow Penelitian

1. **Identifikasi Masalah**
Tahapan awal yang dilakukan adalah pengenalan dan perumusan masalah yang ingin diselesaikan, yaitu menentukan model yang optimal untuk prediksi polusi udara.
2. **Studi Literatur**
Tahap ini mencakup proses pencarian informasi yang dapat diperoleh melalui artikel ilmiah, jurnal, buku dan sumber-sumber lain untuk memahami latar belakang masalah, metode yang sudah ada,


dan pendekatan terbaik untuk menyelesaikan masalah.

3. **Pengumpulan Data**
Pada tahap ini, data historis polusi udara di wilayah DKI Jakarta dikumpulkan sebagai bahan utama dalam penelitian.
4. **Analisis Data**
Setelah pengumpulan data, tahapan berikutnya yaitu melakukan analisis data untuk memilih fitur/atribut yang akan digunakan.
5. **Preprocessing Data**
Pada tahapan ini dilakukan pemrosesan awal terhadap data seperti cek *missing value* dan *normalization*.
6. **Splitting Data**
Pada tahapan ini dilakukan pembagian dataset menjadi 2 bagian, yaitu 80% dialokasikan untuk keperluan pelatihan dan 20% untuk keperluan pengujian.
7. **Pemodelan LSTM dan BiLSTM**
Pada tahapan ini, dilakukan perancangan dan pelatihan model LSTM dan BiLSTM untuk prediksi polusi udara.
8. **Pengujian**
Tahapan berikutnya adalah melakukan pengujian terhadap model LSTM dan BiLSTM untuk mengukur keefektifannya dalam prediksi polusi udara.
9. **Analisis Hasil**
Pada tahapan ini, hasil dari pengujian sebelumnya akan dianalisis untuk menentukan model yang lebih efektif dalam prediksi polusi udara.
10. **Penulisan Laporan**
Tahapan terakhir yaitu menulis laporan penelitian. Penulisan laporan penelitian dilakukan sebagai bentuk tanggung jawab dari penelitian yang telah dilakukan.

Long Short Term Memory

LSTM adalah model khusus yang dapat menghindari *long-term dependencies*, sekaligus mengatasi masalah *vanishing gradient* dengan mekanisme tambahan untuk mengatur

informasi, sehingga informasi tersebut dapat tetap dipertahankan dalam jangka waktu yang lama (Seabe et al., 2023). LSTM memanfaatkan mekanisme pengendali berupa beberapa gerbang, yaitu gerbang pelupa (*forget gate*), gerbang input (*input gate*), status sel (*cell state*), dan gerbang output (*output gate*) (Dhake et al., 2023). Model jaringan LSTM memiliki fungsi memori yang dapat dilihat pada Gambar 1.



Gambar 2 Model Jaringan Long Short Term Memory

Dimana x_t merupakan masukan/input dari node saat ini, C_t mewakili vektor nilai kandidat di proses perhitungan, σ mewakili fungsi aktivasi sigmoid *feedforward* dari lapisan jaringan, dan \tanh mewakili fungsi aktivasi dari lapisan jaringan *feedforward*. Adapun langkah-langkah algoritma LSTM sebagai berikut (Pratama, 2024) :

1. Hitung *input gate* menggunakan persamaan:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1)$$
2. Hitung waktu kalkulasi t pada saat memasukkan kandidat nilai *cell state* \tilde{C}_t menggunakan persamaan:

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2)$$
3. Hitung fungsi aktivasi *forget gate* menggunakan persamaan:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$
4. Berdasarkan kalkulasi di atas, diperoleh nilai perubahan *cell state* pada waktu t dan dirumuskan dengan:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$
5. Nilai *output gate* diperoleh dengan persamaan :

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (5)$$


6. Lapisan *hidden layer* berikutnya dapat diperoleh dengan persamaan:

$$h_t = o_t * \tanh(C_t) \quad (6)$$

dimana W_f , W_i , W_c , dan W_o mewakili *weight matrices* dan b_f , b_i , b_c , dan b_o mewakili *bias terms* dari setiap *gate*.

Bidirectional Long Short Term Memory (LSTM)

Bidirectional Long Short Term Memory (BiLSTM) adalah struktur deformasi dari LSTM yang memiliki lapisan *forward LSTM* maju dan *backward LSTM*. Dengan memanfaatkan konsep sebelum dan sesudahnya saat memahami konteks, BiLSTM dapat mempertimbangkan *future information* dan *past information* dari data yang ada secara bersamaan (Peng et al., 2021). BiLSTM menerima data yang telah melalui tahap pra-pemrosesan sebagai input, kemudian diproses melalui lapisan LSTM maju (*forward*) dan mundur (*backward*), dilanjutkan ke lapisan *fully connected* untuk menghasilkan output prediksi, sebagaimana digambarkan pada Gambar 2 (Pratama, 2024).



Gambar 3 Model Jaringan Bidirectional Long Short Term Memory

Adapun langkah-langkah dari algoritma BiLSTM sebagai berikut (Pratama, 2024) :

1. Hitung masukan ke lapisan tersembunyi *forward layer* dengan persamaan :

$$\vec{h}_t = f(w_1 x_t + w_2 h_{t-1}) \quad (7)$$
2. Hitung lapisan tersembunyi *backward layer* dengan persamaan :

$$\overleftarrow{h}_t = f(w_3 x_t + w_5 h_{t+1}) \quad (8)$$

3. Hitung lapisan *output* dengan menggabungkan keluaran dari *forward layer* dan *backward layer* seperti pada persamaan berikut :

$$o_t = g(w_4 \overrightarrow{h_t} + w_6 \overleftarrow{h_t}) \quad (9)$$

dimana f merupakan fungsi aktivasi dan g merupakan *optimizer* yang digunakan.

Evaluasi Model

Untuk meninjau keefektifan dan sejauh mana performa model yang digunakan dalam prediksi, digunakan metrik evaluasi *Root Mean Square Error* (RMSE) yang mengukur selisih antara nilai yang diprediksi dan nilai aktual, yang dirumuskan sebagai berikut (Dhake et al., 2023; Lestari & Mahendra, 2023) :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

di mana n menyatakan jumlah data, y_i menyatakan nilai data asli pada waktu ke- i , dan \hat{y}_i menyatakan nilai data hasil prediksi pada waktu ke- i .

HASIL DAN PEMBAHASAN

Pengumpulan dan Analisis Data

Penelitian ini menggunakan dataset sekunder yang diperoleh melalui situs Satu Data Jakarta. Dataset yang digunakan merupakan data historis Indeks Standar Pencemar Udara (ISPU) di Provinsi DKI Jakarta pada periode Januari 2016 hingga 31 Desember 2019 yang bisa diakses melalui <https://satudata.jakarta.go.id>.

Data historis tersebut memiliki beberapa atribut seperti *periode_data*, *tanggal*, *stasiun*, *pm10*, *so2*, *co*, *o3*, *no2*, *max*, *critical* dan *kategori*.

Atribut yang akan digunakan dalam pelatihan dan prediksi hanya *pm10*, *so2*, *co*, *o3*, *no2*, sehingga apabila data *pm10*, *so2*, *co*, *o3*, *no2* memiliki *stasiun* pemantauan yang berbeda pada *tanggal* yang sama, nilainya akan dikombinasikan dengan mencari rata-rata nilai pada setiap konsentrasi polusi udara.

Target prediksi dalam penelitian ini adalah konsentrasi polutan PM10 (*pm10*)

yang berkorelasi positif terhadap semua atribut. Analisis korelasi diperlukan untuk mengidentifikasi atribut yang paling relevan dalam memprediksi target (PM10), karena tidak semua fitur dalam dataset memberikan kontribusi signifikan. Pemilihan fitur yang tepat dapat meningkatkan efektivitas dan efisiensi dalam pelatihan model (Lestari & Mahendra, 2023). Hasil perhitungan nilai koefisien korelasi pada data historis polusi udara yang digunakan disajikan pada Tabel 1 berikut.

Tabel 1. Nilai Koefisien Korelasi Data

	<i>pm10</i>	<i>so2</i>	<i>co</i>	<i>o3</i>	<i>no2</i>
<i>pm10</i>	1.00	0.19	0.30	0.61	0.57
<i>so2</i>	0.19	1.00	- 0.08	0.31	0.26
<i>co</i>	0.30	- 0.08	1.00	0.05	0.28
<i>o3</i>	0.61	0.31	0.05	1.00	0.67
<i>no2</i>	0.57	0.26	0.28	0.67	1.00

Data Preprocessing

Tahap berikutnya adalah *preprocessing* data untuk memastikan data bersih dan siap digunakan dalam pelatihan model.

Langkah pertama adalah pengecekan *missing value* pada atribut PM10, SO2, CO, O3, dan NO2. Jika ditemukan nilai kosong, maka diisi dengan rata-rata masing-masing atribut untuk menjaga kestabilan distribusi data tanpa menghilangkan sampel. Selanjutnya, dilakukan normalisasi menggunakan metode *min-max normalization* agar seluruh atribut berada pada skala yang sama. Hal ini penting karena setiap atribut memiliki satuan dan rentang nilai yang berbeda.

Data Splitting

Setelah melalui tahap *preprocessing*, data dibagi menjadi 2 bagian, yaitu 80% dari keseluruhan data dialokasikan untuk data latih dan 20% dialokasikan untuk data uji. Pembagian ini bertujuan agar model dapat belajar dari pola historis data dan diuji

kemampuannya pada data yang belum pernah dipelajari.

Data historis polusi udara yang digunakan berbentuk deret waktu (*time series*). Oleh karena itu, aspek penting lainnya yang harus diperhatikan adalah jumlah data historis yang digunakan untuk memprediksi nilai di masa depan, yang dikenal dengan istilah *time step (loopback)*. Dalam penelitian ini digunakan *time step* sebesar 1, artinya model menggunakan satu data sebelumnya untuk memprediksi data pada hari berikutnya.

Pemodelan LSTM dan BiLSTM

Dalam penelitian ini, model LSTM dan BiLSTM akan digunakan untuk melakukan prediksi polusi udara. Masing-masing model akan dibangun dengan dua *hidden layer*. Untuk mengurangi risiko *overfitting*, diterapkan mekanisme *dropout* pada setiap *hidden layer*. Proses pelatihan model dilakukan dengan menggunakan algoritma Nadam (*Nesterov-accelerated Adaptive Moment Estimation*) guna mengoptimalkan pembaruan gradien secara efisien.

Model LSTM dan BiLSTM akan diuji dengan berbagai konfigurasi parameter, antara lain jumlah *hidden neuron* sebanyak 32, 64, dan 128 pada setiap *hidden layer*, serta nilai *dropout rate* sebesar 0.1, 0.2, dan 0.3.

Selain itu, parameter lain yang divariasikan mencakup jumlah *epoch* sebanyak 50 dan 100, serta *batch size* sebesar 16, 32, dan 64. Pengujian terhadap kombinasi berbagai parameter ini bertujuan untuk mengevaluasi performa model dan menentukan konfigurasi terbaik dalam memprediksi polusi udara.

Pengujian dan Evaluasi Hasil

Penelitian ini menguji berbagai parameter dan mengevaluasi performa model berdasarkan hasil akhir yang diperoleh.

Performa model LSTM dan BiLSTM dalam melakukan prediksi polusi udara disajikan pada Tabel 2 (untuk 32 *hidden*

neuron dan variasi parameter lain), Tabel 3 (untuk 64 *hidden neuron* dan variasi parameter lain), dan Tabel 4 (untuk 128 *hidden neuron* dan variasi parameter lain).

Tabel 2 Performa Model LSTM dan BiLSTM dengan 32 *hidden neuron*

Hidden Neuron	Dropout Rate	Epoch	Batch Size	LSTM	BiLSTM
				RMSE	RMS E
32	0.1	50	16	9.4798	9.3563
			32	9.7036	9.5534
			64	10.0943	9.8117
		100	16	9.3741	9.3470
			32	9.5900	9.3977
			64	9.6167	9.4836
	0.2	50	16	9.4486	9.3353
			32	9.8321	9.5696
			64	10.0583	9.8218
		100	16	9.4063	9.3671
			32	9.4583	9.4747
			64	9.7012	9.5814
0.3	50	16	9.5805	9.4026	
		32	9.8610	9.5434	
		64	10.1535	9.8682	
	100	16	9.4085	9.3789	
		32	9.5134	9.5293	
		64	9.8840	9.6140	

Tabel 3 Performa Model LSTM dan BiLSTM dengan 64 hidden neuron

Hidden Neuron	Dropout Rate	Epoch	Batch Size	LSTM	BiLSTM
				RMS E	RMSE
64	0.1	50	16	9.3494	9.3315
			32	9.5562	9.4336
			64	9.8481	9.6519
		100	16	9.3354	9.3434
			32	9.5035	9.3346
			64	9.5237	9.4401
	0.2	50	16	9.4446	9.3114
			32	9.6434	9.4242
			64	9.8440	9.6426
		100	16	9.3661	9.3349
			32	9.4494	9.4047
			64	9.5608	9.4091
0.3	50	16	9.4088	9.3886	
		32	9.6507	9.6768	
		64	9.9693	9.6925	
	100	16	9.4207	9.3806	
		32	9.4710	9.4501	
		64	9.5688	9.4389	

		0	32	9.4544	9.3489
			64	9.4956	9.4198

Berdasarkan hasil pengujian dan evaluasi yang ditampilkan pada Tabel 2, Tabel 3, dan Tabel 4, model BiLSTM secara konsisten menunjukkan performa yang lebih baik dibandingkan model LSTM dalam melakukan prediksi tingkat polusi udara, yang diukur berdasarkan nilai *Root Mean Square Error* (RMSE).

Berdasarkan pengujian dengan konfigurasi jumlah *hidden neuron* sebanyak 32, model BiLSTM menghasilkan nilai RMSE yang lebih baik pada 16 dari 18 kombinasi parameter yang diuji, yang mencakup variasi *dropout rate*, jumlah *epoch*, dan *batch size*. Hasil serupa juga diperoleh pada konfigurasi *hidden neuron* sebanyak 64, model BiLSTM kembali menunjukkan keunggulan dalam 16 dari 18 pengujian. Sementara itu, pada konfigurasi dengan 128 *hidden neuron*, model BiLSTM tetap unggul dengan menghasilkan nilai RMSE yang lebih baik pada 15 dari 18 pengujian.

Secara keseluruhan, hasil ini mengindikasikan bahwa model BiLSTM lebih mampu menangkap pola data *time series* secara lebih efektif dibandingkan LSTM. Kemampuan BiLSTM dalam memproses informasi secara dua arah memberikan kontribusi yang signifikan terhadap peningkatan akurasi prediksi dan lebih baik dalam menangani kompleksitas data polusi udara.

SIMPULAN

Berdasarkan hasil penelitian mengenai perbandingan prediksi polusi udara menggunakan model LSTM dan BiLSTM, dapat ditarik kesimpulan bahwa BiLSTM memiliki performa prediksi yang lebih unggul dibandingkan LSTM. Hal ini dibuktikan oleh nilai RMSE yang konsisten lebih rendah pada sebagian besar kombinasi parameter saat pengujian. Konfigurasi optimal ditemukan pada model BiLSTM dengan

Tabel 4 Performa Model LSTM dan BiLSTM dengan 128 hidden neuron

Hidden Neuron	Dropout Rate	Epoch	Batch Size	LSTM	BiLSTM
				RMS E	RMSE
128	0.1	50	16	9.3421	9.3595
			32	9.4412	9.3776
			64	9.6679	9.5876
		100	16	9.3306	9.3590
			32	9.3417	9.3369
			64	9.4426	9.4130
	0.2	50	16	9.3555	9.3453
			32	9.4623	9.3997
			64	9.6965	9.5800
		100	16	9.3349	9.3634
			32	9.3809	9.3251
			64	9.4364	9.3699
0.3	50	16	9.3652	9.3512	
		32	9.5446	9.3842	
	100	64	9.7101	9.6149	
		16	9.3518	9.3489	

jumlah *hidden neuron* sebanyak 64, *dropout rate* sebesar 0.2, *epoch* 50, dan *batch size* 16, yang menghasilkan nilai RMSE terendah sebesar 9.311401. Sebagai perbandingan, model LSTM mencapai performa terbaiknya pada konfigurasi 128 *hidden neuron*, *dropout rate* 0.1, *epoch* 100, dan *batch size* 16, dengan nilai RMSE sebesar 9.330554.

Untuk pengembangan penelitian di masa mendatang, disarankan untuk

menambahkan proses optimasi dalam penentuan nilai parameter model untuk memperoleh kombinasi parameter yang memberikan hasil prediksi terbaik. Selain itu, integrasi variabel eksternal seperti curah hujan juga dapat dipertimbangkan untuk melihat pengaruhnya terhadap tingkat polusi udara, sehingga dapat meningkatkan akurasi prediksi secara keseluruhan.

DAFTAR PUSTAKA

- Akanksha, A., Maurya, N., Jain, M., & Arya, S. (2023). Prediction And Analysis of Air Pollution Using Machine Learning Algorithms. *2023 3rd International Conference on Intelligent Technologies (CONIT)*, 1–6. <https://doi.org/10.1109/CONIT59222.2023.10205615>
- Almetwally, A. A., Bin-Jumah, M., & Allam, A. A. (2020). Ambient air pollution and its influence on human health and welfare: an overview. *Environmental Science and Pollution Research International*, 27(20), 24815–24830. <https://doi.org/10.1007/s11356-020-09042-2>
- Amalia, A. P., Zaidiah, A., & Isnainiyah, I. N. (2022). Prediksi Kualitas Udara Menggunakan Algoritma K-Nearest Neighbor. *JIPi (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*. <https://api.semanticscholar.org/CorpusID:251416679>
- Chen, K., Purba, R., & Halim, A. (2022). Stock Price Prediction Using XCEEMDAN-Bidirectional LSTM - Spline. *Indonesian Journal of Artificial Intelligence and Data Mining*, 5(1), 1. <https://doi.org/10.24014/ijaidm.v5i1.14424>
- DESA, U. N. (2018). *2018 Revision of World Urbanization Prospects*. United Nations News. <https://www.un.org/zh/desa/2018-revision-world-urbanization-prospects>
- Dhake, H., Kashyap, Y., & Kosmopoulos, P. (2023). Algorithms for Hyperparameter Tuning of LSTMs for Time Series Forecasting. *Remote Sensing*, 15(8). <https://doi.org/10.3390/rs15082076>
- Hua, Y. (2020). Bitcoin price prediction using ARIMA and LSTM. *E3S Web of Conferences*. <https://api.semanticscholar.org/CorpusID:234616966>
- Lestari, I., & Mahendra, I. (2023). Prediksi Kualitas Udara dengan Menggunakan Metode Long Short-Term Memory dan Artificial Neural Network. *Jurnal Sistem Dan Informatika (JSI)*, 17, 121–129. <https://doi.org/10.30864/jsi.v17i2.565>
- Lu, J., Li, B., Li, H., & Al-Barakani, A. (2021). Expansion of city scale, traffic modes, traffic congestion, and air pollution. *Cities*, 108, 102974. <https://doi.org/https://doi.org/10.1016/j.cities.2020.102974>
- Mitreska Jovanovska, E., Batz, V., Lameski, P., Zdravevski, E., Herzog, M. A., & Trajkovik, V. (2023). Methods for Urban Air Pollution Measurement and Forecasting: Challenges, Opportunities, and Solutions. *Atmosphere*, 14(9). <https://doi.org/10.3390/atmos14091441>

- Peng, T., Zhang, C., Zhou, J., & Nazir, M. S. (2021). An integrated framework of Bi-directional long-short term memory (BiLSTM) based on sine cosine algorithm for hourly solar radiation forecasting. *Energy*, *221*, 119887. <https://doi.org/https://doi.org/10.1016/j.energy.2021.119887>
- Pratama, A. (2024). Bitcoin Cryptocurrency Price Prediction Using IFA-BiLSTM. *2024 2nd International Conference on Technology Innovation and Its Applications (ICTIIA)*, 1–6. <https://doi.org/10.1109/ICTIIA61827.2024.10761776>
- Raheja, S., & Malik, S. (2022). Prediction of Air Quality Using LSTM Recurrent Neural Network. *International Journal of Software Innovation*, *10*, 1–16. <https://doi.org/10.4018/IJSI.297982>
- Rahman, M. M., Nayeem, M. E. H., Ahmed, M. S., Tanha, K. A., Sakib, M. S. A., Uddin, K. M. M., & Babu, H. M. H. (2024). AirNet: predictive machine learning model for air quality forecasting using web interface. *Environmental Systems Research*, *13*(1), 44. <https://doi.org/10.1186/s40068-024-00378-z>
- Ravindiran, G., Hayder, G., Kanagarathinam, K., Alagumalai, A., & Sonne, C. (2023). Air quality prediction by machine learning models: A predictive study on the indian coastal city of Visakhapatnam. *Chemosphere*, *338*, 139518. <https://doi.org/https://doi.org/10.1016/j.chemosphere.2023.139518>
- Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach. *Fractal and Fractional*, *7*(2). <https://doi.org/10.3390/fractalfract7020203>