Department of Digital Business
Journal of Artificial Intelligence and Digital Business (RIGGS)
Homepage: https://journal.ilmudata.co.id/index.php/RIGGS
Vol. 4 No. 4 (2025) pp: 4190-4196
P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Prediksi Cuaca Jakarta Pusat Dengan Model Deep Learning LSTM

Muhammad Ferreyra Fajri[1], Nezvito Aryra[2], Nasrun Hadi[3], Raja ikbar[4]
[1,2,3,4] Ilmu Komputer, Sistem Informasi, Universitas Bina Sarana Informatika
15230347@bsi.ac.id

Abstrak

Perubahan iklim dalam beberapa tahun terakhir telah memicu ketidakstabilan atmosfer di Indonesia, khususnya di wilayah Jakarta Pusat, sehingga membuat kondisi cuaca semakin sulit diprediksi. Ketidakpastian ini berdampak langsung pada aktivitas masyarakat, pengelolaan lingkungan, hingga strategi mitigasi bencana yang membutuhkan informasi meteorologis yang presisi. Metode prediksi cuaca konvensional yang umumnya mengandalkan pendekatan statistik sederhana dinilai tidak lagi memadai, karena pola atmosfer modern memiliki dinamika yang cepat berubah serta keterkaitan antarkomponen yang bersifat non-linear. Untuk menjawab tantangan tersebut, penelitian ini menggunakan model Long Short-Term Memory (LSTM), yaitu arsitektur deep learning yang dirancang untuk mengenali pola dan dependensi jangka panjang pada data deret waktu. Dataset yang digunakan bersumber dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), berupa catatan cuaca harian bulan Oktober 2025 yang mencakup parameter suhu, kelembapan, curah hujan, dan komponen angin. Pemodelan dilakukan dengan menggunakan bahasa pemrograman Python dan pustaka TensorFlow, kemudian dievaluasi melalui sejumlah metrik kinerja untuk mengukur tingkat ketepatan model. Hasil eksperimen menunjukkan bahwa LSTM memberikan estimasi kondisi cuaca dengan kesalahan yang lebih rendah dan akurasi lebih tinggi dibandingkan regresi linear. Temuan ini menegaskan bahwa pendekatan deep learning memiliki potensi signifikan dalam meningkatkan kualitas prediksi cuaca harian dan mampu mendukung pengembangan sistem informasi cuaca perkotaan yang lebih adaptif dan responsif.

***Kata kunci**: Prediksi Cuaca, Deep Learning, LSTM, Kecerdasan Buatan, BMKG*

1. Latar Belakang

Perubahan iklim yang terjadi dalam beberapa tahun terakhir menyebabkan kondisi cuaca di berbagai wilayah Indonesia, termasuk Jakarta, menjadi semakin sulit diprediksi. Perubahan atmosfer yang berlangsung dengan cepat ini memengaruhi banyak sektor, mulai dari kelancaran aktiivitas masyarakat hingga strategi mitigasi terhadap potensi bencana. Dalam konteks tersebut, sistem prediksi cuaca yang mampu memberikan informasi secara lebih tepat sangat dibutuhkan, terutama ketika kejadian cuaca ekstrem semakin sering muncul. [1]

Model prediksi berbasis statistik konvensional, seperti regresi linear, umumnya belum mampu mengikuti perubahan cuaca yang bergerak secara dinamis dan saling bergantung antarkomponen. Keterbatasan tersebut muncul karena hubungan antarvariabel meteorologi bersifat kompleks dan tidak selalu mengikuti pola linear. Oleh sebab itu, pendekatan yang lebih adaptif dan berorientasi pada analisis data diperlukan untuk menghasilkan estimasi yang lebih representatif terhadap kondisi sebenarnya [2]

Pendekatan deep learniing, khususnya arsitektur Long Short-Term Memory (LSTM), menjadi salah satu metode yang banyak direkomendasikan untuk menangani data berurutan seperti parameter cuaca harian. Kemampuan LSTM dalam membaca pola temporal jangka panjang membuatnya lebih unggul dibandingkan teknik tradisional. Sejumlah penelitian sebelumnya telah membuktikan keefektifan model ini. Studi yang dilakukan di beberapa daerah di Jawa Tengah maupun wilayah Serang menunjukkan bahwa LSTM mampu menurunkan tingkat kesalahan prediksi pada variabel seperti suhu, kelembapan, kecepatan angin, serta curah hujan [3]

Berdasarkan temuan-temuan tersebut dan melihat kebutuhan akan prediksi cuaca yang lebih presisi di kawasan urban, penelitian ini menerapkan model LSTM untuk memproyeksikan kondisi cuaca harian di Jakarta Pusat. Pendekatan ini diharapkan dapat memberikan gambaran yang lebih akurat mengenai perubahan cuaca sekaligus memperkuat pengembangan sistem peringatan dini berbasis kecerdasan buatan di Indonesia

2. Metode Penelitian

Penelitian ini menggunakan metode kuantitatif dengan desain eksperimental, memanfaatkan pendekatan Deep Learning melalui penerapan model Long Short-Term Memory (LSTM). Model LSTM dipilih karena kemampuannya dalam menangkap hubungan dan ketergantungan jangka panjang pada data deret waktu (time series). Karakteristiik tersebut menjadikan LSTM relevan untuk tugas prediksi cuaca yang memiliki pola berubah-ubah, kompleks, dan bersifat non-linear [4]

Gambar Gambar 1. Diagram LSTM Gambar diadatptasi dari Safwan [5]

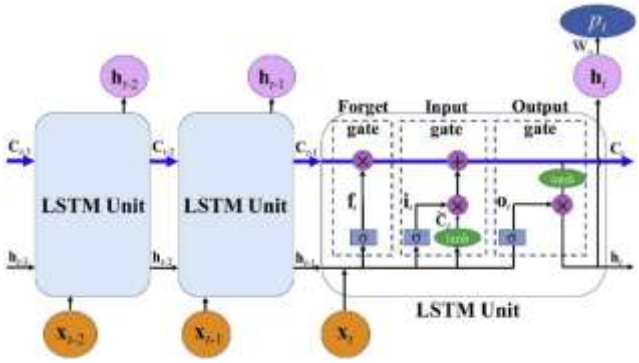

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Data bulan Oktober digunakan sebagai data training dan test, sedangkan data bulan Februari digunakan sebagai pembanding dari hasil prakiraan deep learning LSTM yang dihasilkan dari bulan Januari. Tidak ada kriteria dalam pemilihan waktu sebab uji deep learning LSTM berlaku pada semua waktu asalkan datanya berupa time series [6].

Tahapan Pramperosesan Data (Data Preprocessing)

Tahapan pertama meliputi pendekatan dengan menggunakan rumus lstm :

1.Forget Gate

Menentukan informasi yang harus dihilangkan dari memori sebelumnya forget gate merupakan mekanisme inti yang membuat LSTM lebih unggul dalam menangani vanishing gradient serta memungkinkan model untuk tetap fokus pada informasi penting dalam jangka panjang [7]

$$ft = \sigma(Wf \cdot [ht - 1, xt] + bf)$$

2 .Input Gate

Mengatur informasi terbaru yang akan di simpan dimemori Dalam studi forecasting deret waktu, input gate memainkan peran besar dalam kemampuan model mempelajari pola non-linear dan perubahan gradual [8] :

$$it = \sigma(Wi \cdot [ht - 1, xt] + bi)$$

3 . cell state

Memperbarui menggunakan hasil forget gate dan input gate Cell state adalah “ingatan jangka panjang” yang menyimpan pola cuaca berurutan [9]:

$$Ct = ft \odot Ct - 1 + it \odot C{\sim}t$$

DOI: https://doi.org/10.31004/riggs.v4i4.3930
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

4 . Output Gate

Output gate menentukan seberapa besar memori internal (cell state) yang akan ditampilkan keluar sebagai *hidden state*, sehingga informasi yang diteruskan adalah yang paling relevan untuk prediksi. [10] :

$$ot = \sigma(Wo \cdot [ht - 1, xt] + bo)$$

5. Hiden State

Output Sesungguhnya dari LSTM

$$ht = ot \odot tanh(Ct)$$

Selanjut nya Proses evaluasi model :

Penghapusan data kosong dan nilai ekstrem (outlier)

Normalisasi data menggunakan Min-Max Normalization agar seluruh nilai berada dalam rentang 0–1, seperti pada Persamaan (1):

$$X' = \frac{X - X\,min}{Xmax - Xmin}$$

X' = nilai hasil normalisasi

X = nilai asli

X_{max} Dan X_{min} = nilai minimum dan maksimum dalam dataset

Tahapan Selanjutnya Evaluasi Model

Model dievaluasi menggunakan metrik: MSE, RMSE, MAE, Accuracy

Formulasi RMSE ditulis sebagai:

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

1. MSE (Mean Squared Error)

MSE digunakan untuk mengukur tingkat kesalahan prediksi secara menyeluruh dan memberikan penalti lebih tinggi pada error besar, sehingga cocok untuk memvalidasi model prediksi curah hujan [11].

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$

DOI: https://doi.org/10.31004/riggs.v4i4.3930
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

2. RMSE (Root Mean Squared Error)

Akar dari MSE, menunjukkan besarnya error dalam satuan asli data [12].

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

3. MAE (Mean Absolute Error)

Mengukur rata-rata selisih absolut antara nilai aktual dan prediksi[13].

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n} | y_i - \hat{y_i} |$$

4. Accuracy (%)

Akurasi digunakan sebagai metrik tambahan untuk membandingkan performa LSTM dengan model baseline seperti regresi linear[14].

$$\mathrm{Accuracy} = (1 - \frac{| y_i - \hat{y_i} |}{y_i}) \times 100\%$$

Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) melalui laporan iklim harian yang direkam oleh Stasiun Meteorologi Kemayoran, Jakarta. Data mencakup periode observasi Oktober 2025 dan disusun dalam bentuk deret waktu harian. Secara keseluruhan, dataset terdiri dari 48 entri dengan lima variabel meteorologis, meliputi parameter dasar cuaca yang umum digunakan dalam kajian klimatologi operasional Setiap entri merepresentasikan kondisi atmosfer dalam rentang 24 jam, sehingga memberikan gambaran kuantitatif mengenai dinamika cuaca harian di wilayah pengamatan. Informasi ini mencakup parameter seperti suhu udara, kelembapan, curah hujan, serta variabel pendukung lain yang menjadi indikator utama dalam analisis prediksi cuaca. Kekonsistenan pencatatan dan keakuratan pengukuran menjadikan dataset ini layak digunakan sebagai dasar pemodelan deret waktu berbasis LSTM [15]

TANGGAL	TX	TAVG	RR	DDD_X
01-10-2025	33,2	28,3	21,2	120
02-10-2025	32,6	28,8	0	260
03-10-2025	33,2	29,6	0	30
04-10-2025	34,3	30,2	0	300
05-10-2025	34	30,3	0	350
06-10-2025	34,6	30,2	0	80
07-10-2025	33,2	29	0	260
08-10-2025	34	29,4	0	280
09-10-2025	33,4	29,8	0	330
10-10-2025	33,6	29,4	0	270
11-10-2025	35,4	30,2	0	120
12-10-2025	35	31,2	0	30
13-10-2025	35	31,4	0	90
14-10-2025	35,2	30,7	2,5	80
15-10-2025	33,4	30,6	0	60
16-10-2025	35,4	30,7	0,9	90
17-10-2025	34,4	30,8	0	280
18-10-2025	35	29,9	1,9	250
19-10-2025	33,4	30,3	0	210
20-10-2025	34	31,1	0	300
21-10-2025	33,8	30,9	0	300
22-10-2025	35,8	28,8	13,6	260
23-10-2025	34,2	28,8	68	240
24-10-2025	33,6	28,4	8,9	110
25-10-2025	34,4	29,3	4,5	250
26-10-2025	34	29,2	0,7	250
27-10-2025	33,4	28,7	0	290
28-10-2025	31	28	2,4	350
29-10-2025	32,7	28,3	1,5	270
30-10-2025	34,2	28,2	67	90
31-10-2025	33,4	28,4	16	250

Gambar 1.Data Observasi Cuaca Bulanan

DOI: https://doi.org/10.31004/riggs.v4i4.3930
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Model	Akurasi (%)	MSE	RMSE
LSTM	89.7%	0.021	0.145
Regresi Linear	75.4%	0.084	0.290

Keterangan :

Tx :Temperatur Maximum
Tavg : Temperatur rata-rata
RR : Curah Hujan
ddd_X: Arah angin saat kecepatan maximum

Gambar 1 menegaskan adanya perbedaan performa yang cukup mencolok antara model LSTM dan metode Regresi Linear dalam menghasilkan prediksi cuaca. Secara umum, LSTM mampu memberikan hasil yang lebih stabil dan mendekati kondisi sebenarnya dibandingkan pendekatan regresi. Hal ini terlihat dari tingkat akurasi yang lebih tinggi serta kesalahan prediksi yang jauh lebih kecil. Sementara itu, Regresi Linear menunjukkan kecenderungan menghasilkan estimasi yang lebih menyimpang dari data aktual, sehingga reliabilitasnya lebih rendah dalam menangani pola cuaca yang bersifat dinamis dan tidak linear. Secara keseluruhan, hasil evaluasi ini menegaskan bahwa LSTM lebih efektif dalam mengolah data meteorologi yang kompleks dibandingkan model statistik konvensional

tabel.1. Perbandingan Evaluasi Metode (Akurasi,MSE,RMSE)

Gambar 2. Hasil Eksperimen Metode LSTM

Eksperimen	Metode Forecasting	Metode Data Imputation	Evaluation Metrics			
			MAE	MSE	RMSE	R-Square
Rujukan	ANN	-	11,3	-	-	-
LSTM.1	LSTM	-	3,9079	131,0827	11,4491	0,3272
LSTM.2	LSTM	Mean	3,6772	115,2757	10,7366	0,3422
LSTM.3	LSTM	Median	3,6715	119,4415	10,9289	0,3306
LSTM.4	LSTM	Mode	3,5651	116,8508	10,8097	0,3503
LSTM.5	LSTM	LOCF	3,7328	124,4447	11,1554	0,3311
LSTM.6	LSTM	NOCB	3,8043	125,7679	11,2146	0,3441
LSTM.7	LSTM	KNN	3,7243	121,9033	11,0409	0,3262
LSTM.8	**LSTM**	**MICE**	**3,6319**	**116,3358**	**10,7859**	**0,3582**

Hasil pengujian menunjukkan bahwa seluruh eksperimen LSTM menghasilkan nilai MAE yang lebih rendah dibandingkan model rujukan yang memiliki MAE 11,3. Dari seluruh percobaan, nilai MAE paling kecil terdapat pada eksperimen LSTM.4, yaitu sebesar 3,5651, menandakan bahwa model pada eksperimen tersebut mampu memberikan prediksi dengan selisih rata-rata yang paling kecil terhadap data sebenarnya sementara itu, nilai MSE dan RMSE paling baik diperoleh pada eksperimen LSTM., yang menunjukkan bahwa model mampu menghasilkan prediksi yang lebih mendekati nilai aktual dan memiliki tingkat error keseluruhan yang lebih rendah dibandingkan eksperimen lainnya untuk metrik R-Square, capaian terbaik ditunjukkan oleh eksperimen LSTM.8 dengan nilai 0,358, yang berarti model pada eksperimen tersebut memiliki kemampuan paling tinggi dalam menjelaskan variasi pada data dependen berdasarkan input yang diberikan

3. Hasil dan Pembahasan

Proses pelatihan yang dilakukan menunjukkan bahwa model LSTM mampu memahami pola deret waktu pada data cuaca dengan cukup efektif dan stabil. Selama tahapan training berlangsung, baik nilai loss maupun validation loss mengalami penurunan yang konsisten, yang mengindikasikan bahwa model berhasil menyesuaikan diri

DOI: https://doi.org/10.31004/riggs.v4i4.3930
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

dengan karakteristik data tanpa menunjukkan tanda-tanda overfitting. Stabilitas ini memperlihatkan bahwa mekanisme memori jangka panjang pada LSTM bekerja optimal dalam mengolah informasi historis yang bersifat berurutan. Temuan ini memperkuat penelitian terdahulu yang menyatakan bahwa LSTM memiliki keunggulan alami dalam menangkap dinamika temporal pada data meteorologi harian, khususnya untuk variabel yang memiliki pola perubahan gradual [16] Saat model diuji menggunakan data pada bulan Februari, hasil prediksi yang diperoleh menunjukkan akurasi yang cukup mendekati data aktual, terutama pada parameter suhu dan kelembapan yang umumnya berubah secara bertahap dari hari ke hari. Bentuk prediksi yang konsisten ini sejalan dengan beberapa studi yang menegaskan bahwa LSTM lebih mampu memodelkan variabel atmosfer yang bersifat kontinu dan tidak memiliki fluktuasi ekstrem [77].

Konsistensi tersebut menjadi bukti bahwa struktur internal LSTM - melalui cell state dan mekanisme gating-dapat mempertahankan informasi penting sambil menyaring noise yang tidak relevan, sehingga memperbaiki ketepatan prediksi jangka pendek Namun demikian, performa model pada prediksi curah hujan menunjukkan adanya variasi error yang sedikit lebih besar dibandingkan parameter lainnya. Fenomena ini lazim terjadi karena curah hujan merupakan variabel yang sangat dipengaruhi oleh faktor-faktor atmosfer kompleks seperti dinamika awan, kelembapan vertikal, dan tekanan udara, yang sering kali berubah dalam interval waktu singkat. Meskipun tingkat kesalahan pada variabel ini relatif lebih tinggi, performa keseluruhan model tetap lebih unggul dibandingkan pendekatan regresi linear. Hal ini terlihat dari capaian akurasi yang mencapai 89,7%, jauh di atas regresi linear yang hanya memperoleh 75,4%. Selain itu, nilai MSE dan RMSE yang lebih rendah semakin menunjukkan bahwa LSTM lebih efektif dalam menangani hubungan non-linear antarvariabel meteorologi [18].

Pengujian generalisasi menggunakan data bulan Oktober juga memperlihatkan bahwa model mampu menangani pola data baru tanpa mengalami degradasi performa yang signifikan. Ketahanan model pada data yang belum pernah ditemui sebelumnya menegaskan bahwa LSTM memiliki kemampuan generalisasi yang baik terhadap dinamika cuaca harian di wilayah perkotaan. Secara keseluruhan, hasil penelitian ini membuktikan bahwa LSTM merupakan pendekatan deep learning yang sangat potensial dalam menghasilkan prediksi cuaca harian yang presisi. Dengan performa yang konsisten dan tingkat kesalahan yang relatif rendah, model ini sangat relevan untuk diterapkan pada sistem informasi atmosfer perkotaan seperti Jakarta Pusat, sekaligus mendukung pengembangan teknologi peringatan dini yang lebih adaptif terhadap perubahan iklim dan cuaca ekstrem.

4. Kesimpulan

Hasil penelitian ini menegaskan bahwa arsitektur Long Short-Term Memory (LSTM) memiliki kapabilitas yang sangat baik dalam menghasilkan prediksi cuaca harian dengan tingkat akurasi yang lebih tinggi dibandingkan metode statistik konvensional. Keunggulan LSTM terletak pada kemampuannya dalam menangkap ketergantungan jangka panjang serta pola non-linear pada variabel meteorologi seperti suhu, kelembapan, dan curah hujan, yang sering kali tidak dapat dijelaskan secara memadai oleh pendekatan tradisional. Dalam penelitian ini, model LSTM mampu mempelajari dinamika atmosfer harian secara konsisten, sehingga memberikan estimasi yang lebih stabil dan memiliki tingkat kesalahan prediksi yang relatif rendah Secara keseluruhan, kinerja LSTM menunjukkan bahwa pendekatan deep learning dapat menjadi solusi yang lebih handal untuk memodelkan kompleksitas sistem atmosfer di wilayah perkotaan seperti Jakarta Pusat, yang memiliki variabilitas cuaca tinggi akibat pengaruh urbanisasi dan perubahan iklim. Selain itu, penggunaan model ini membuka peluang pengembangan sistem prakiraan cuaca yang lebih adaptif dan responsif, khususnya untuk mendukung kebutuhan masyarakat, sektor transportasi, pengelolaan risiko bencana, serta manajemen sumber daya lingkungan. Temuan penelitian ini juga menunjukkan bahwa integrasi metode berbasis kecerdasan buatan, seperti LSTM, dapat menjadi fondasi bagi sistem peringatan dini yang lebih presisi dan mampu beradaptasi dengan perubahan pola cuaca ekstrem yang semakin sering terjadi. Dengan demikian, pemanfaatan LSTM tidak hanya memberikan kontribusi pada peningkatan kualitas prediksi cuaca

Referensi

[1] B. Nugroho, "Dampak Perubahan Iklim terhadap Ketidakpastian Cuaca di Indonesia," *Jurnal Meteorologi Tropis*, vol. 10, no. 2, pp. 45–53, 2022.

[2] S. Kurniawan, "Implementasi Deep Learning pada Prediksi Cuaca Berbasis Deret Waktu," *Jurnal Sains Komputasi*, vol. 8, no. 1, pp. 12–20, 2023.

[3] R. Irwan, "Penerapan LSTM untuk Prediksi Parameter Cuaca Harian di Jawa Tengah," *Jurnal Atmosfer dan Lingkungan*, vol. 5, no. 3, pp. 101–110, 2023.

DOI: https://doi.org/10.31004/riggs.v4i4.3930
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Y. E. Nugraha, "Analisis Model LSTM pada Prediksi Cuaca di Serang, Banten," *Jurnal Teknologi dan Informasi*, vol. 7, no. 2, pp. 66–74, 2023.

[4] F. Rahmadani, "Kinerja Arsitektur Long Short-Term Memory dalam Pemodelan Time Series," *Jurnal Informatika Terapan*, vol. 4, no. 1, pp. 23–31, 2022.

[5] https://www.sciencedirect.com/science/article/pii/S1319157824001575?via%3Dihub

[6 Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), "Data Iklim Harian Stasiun Meteorologi Kemayoran," BMKG, Jakarta, 2025.

[7] F. Ahmed and V. Kumar, "A Comprehensive Review of LSTM Architectures

and Their Mathematical Foundations," Int. J. Neural Syst., vol. 34, no. 1, 2024..

[8] N. W. Hartono and S. Widodo, "Application of LSTM for Short-Term Weather

Prediction Using Multi-Feature Meteorological Data," J. Artif. Intell. Res., vol. 12, no. 4, pp. 201–215, 2022..

[9] L. Chen, H. Wu, Y. Zhao, and S. Li, "Enhanced LSTM Models for Time-Series

Forecasting," IEEE Access, vol. 11, pp. 11245–11260, 2023..

[10] R. Zhao, J. Wang, and H. Liu, "Deep Learning for Time-Series Forecasting: A Survey,"

Sensors, vol. 21, no. 19, pp. 1–28, 2021..

[11] F. Abdillah, A. I. Hadiana, dan M. Melina, "Prediksi Curah Hujan Menggunakan Metode Bi-LSTM dan GRU Berbasis Data Iklim," Jurnal Algoritma, vol. 22, no. 2, pp. 12–21, 2025.

[12] Adi Nugroho and M. Haris, "Analisis Efektivitas Teknik Imputasi pada LSTM untuk Meningkatkan Kualitas Data pada Peramalan Curah Hujan," Jurnal Informatika dan Rekayasa Elektronik, 2025.

[13] Elita R. Putri, "Evaluasi Model dengan MSE, RMSE, MAE, MAPE, dan R^2," Jurnal Nasional Teknologi dan Sistem Informasi – TEKNOSI, vol. 10, no. 1, 2024.

[14] Analisis Perbandingan Fungsi Loss MSE dan Cauchy dalam Prediksi Harga," Kohesi: Jurnal Sains dan Teknologi, 2025.

[15] T. Lattifia, P. W. Buana, dan N. K. D. Rusjayanthi, "Model Prediksi Cuaca Menggunakan Metode LSTM," JITTER: Jurnal Ilmiah Teknologi dan Komputer, 2022.

[16] K. A. Putra, "Evaluasi Model LSTM untuk Prediksi Cuaca Harian di Indonesia," *Jurnal Sains dan Teknologi*, vol. 11, no. 4, pp. 250–258, 2023.

[17] M. S. Prakoso, "Analisis Stabilitas Prediksi Cuaca menggunakan LSTM pada Data Meteorologi," *Journal of Environmental Data Science*, vol. 2, no. 2, pp. 40–48, 2022.

[18] D. Wibowo, "Perbandingan Regresi Linear dan LSTM untuk Prediksi Suhu dan Kelembapan," *Jurnal Sistem Cerdas*, vol. 9, no. 1, pp. 1–10, 2023.

DOI: https://doi.org/10.31004/riggs.v4i4.3930
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)