

Peramalan Kelembapan Relatif di Kabupaten Bogor Menggunakan Model CNN-LSTM

Thariq Abdullah¹, Achmad Lukman², Dede Rohidin³

^{1,3} Informatika, Informatika, Telkom University, Kabupaten Bandung, Indonesia

² Informatika, Teknologi Informasi, Telkom University, Kabupaten Bandung, Indonesia

¹thariqabdullah@student.telkomuniversity.ac.id, ²alukman@telkomuniversity.ac.id, ³dede.rohidin@tass.telkomuniversity.ac.id

Info Artikel

Riwayat Artikel:

Received 2025-12-31

Revised 2026-03-14

Accepted 2026-04-09

Abstract – Air humidity is a parameter that influences the environment and human activities. Accurate air humidity prediction can be helpful for various purposes, including weather-based decision-making. However, a single model has limitations in capturing non-linear patterns and long-term dependencies in time-series data, making it difficult to predict data well, especially complex and time-series data such as weather. Therefore, a model with a hybrid approach is needed. Hybrid modeling is a combination of two or more learning methods. This study proposes a hybrid approach by combining Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM) layers to predict air humidity more accurately and effectively than a single model. CNN is used to extract temporal representations from historical weather data in the form of time sequences, while LSTM is for long-term memory. Prediction is carried out by collecting weather data, data preprocessing, feature transformation (including cyclic feature transformation), designing the CNN-LSTM architecture, model training, and evaluation using evaluation metrics such as mean absolute error (MAE), mean square error (MSE), root mean square error (RMSE), and coefficient of determination (R^2). This study uses weather data from Bogor Regency for the period January 1, 2020 to October 31, 2025 obtained from the Citeko Meteorological Station at coordinates Latitude -6.70000, Longitude 106.85000, and an altitude of 920 meters. The results obtained are that the CNN-LSTM model has an average MAE value of 4.3596, MSE 29.9126, RMSE 5.4689, and R^2 0.0756 show that the CNN-LSTM hybrid model is able to improve the accuracy of air humidity prediction compared to a single model.

Keywords: CNN; Deret Waktu; Humidity; LSTM.

Corresponding Author:

Achmad Lukman

Email:

alukman@telkomuniversity.ac.id



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstrak – Kelembapan udara merupakan salah satu parameter yang berpengaruh terhadap lingkungan dan aktivitas manusia. Prediksi kelembapan udara secara akurat dapat membantu dalam berbagai keperluan, termasuk pengambilan keputusan berbasis cuaca. Namun, model tunggal memiliki keterbatasan dalam menangkap pola non-linear dan ketergantungan jangka panjang pada data deret waktu, sehingga sulit memprediksi data dengan baik, terutama data yang bersifat kompleks seperti cuaca. Oleh karena itu, diperlukan model dengan pendekatan hibrida. Pemodelan hibrida merupakan gabungan dari dua atau lebih metode pembelajaran. Penelitian ini mengusulkan pendekatan hibrida dengan menggabungkan lapisan Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM) untuk melakukan prediksi kelembapan udara yang lebih akurat dan efektif dibandingkan dengan model tunggal. CNN digunakan untuk mengekstraksi representasi temporal dari data cuaca historis dalam bentuk urutan waktu, sedangkan LSTM berperan dalam mengingat dependensi jangka panjang. Prediksi dilakukan dengan pengumpulan data cuaca, prapemrosesan data, transformasi fitur (termasuk transformasi fitur siklik), perancangan arsitektur CNN-LSTM, pelatihan model, serta evaluasi menggunakan metrik evaluasi seperti mean absolute error (MAE), mean square error (MSE), root mean square error (RMSE), dan coefficient of determination (R^2). Penelitian ini menggunakan data cuaca dari Kabupaten Bogor dalam rentang waktu 1 Januari 2020 hingga 31 Oktober 2025 yang diperoleh dari Stasiun Meteorologi Citeko pada koordinat Lintang -6.70000, Bujur 106.85000, dan elevasi 920 meter. Hasil yang diperoleh yaitu Model CNN-LSTM memiliki rata-rata nilai MAE sebesar 4.3596, MSE sebesar 29.9126, RMSE sebesar 5.4689, dan R^2 sebesar 0.0756 menunjukkan bahwa model hibrida CNN-LSTM mampu meningkatkan akurasi prediksi kelembapan udara dibandingkan model Tunggal

Kata Kunci: CNN, Deret Waktu, Kelembapan, LSTM.

I. PENDAHULUAN

Kelembapan udara [1][2][3] menjadi salah satu parameter penting dalam sistem monitoring cuaca yang berpengaruh langsung terhadap berbagai aspek kehidupan manusia, seperti kesehatan hingga kenyamanan. Penelitian telah menunjukkan bahwa kondisi lingkungan yang tidak nyaman, termasuk kelembapan yang tinggi, dapat memengaruhi konsentrasi belajar, kualitas tidur, dan kesehatan fisik serta mental [2]. Dalam dunia kesehatan, kelembapan yang tinggi juga dapat menjadikan kondisi yang ideal bagi nyamuk, yang dapat menyebabkan

meningkatnya risiko DBD[4]. Informasi tentang kelembapan yang akurat sangat dibutuhkan untuk mendukung pengambilan keputusan yang efektif.

Dalam beberapa tahun terakhir, perkembangan teknologi dan ketersediaan data cuaca historis secara digital memungkinkan diterapkannya pendekatan berbasis data untuk meramalkan kondisi cuaca, termasuk kelembapan udara. Namun, peramalan kelembapan bukanlah hal yang sederhana, karena melibatkan dinamika atmosfer yang bersifat kompleks dan non-linear. Oleh sebab itu, dibutuhkan metode yang mampu menangkap hubungan temporal serta pola tertentu dari data untuk menghasilkan peramalan yang akurat. Model hibrida dengan menggabungkan dua lapisan *deep learning* mampu menjadi solusi untuk data yang bersifat kompleks[5].

Penelitian sebelumnya yang berfokus pada peramalan harga saham menunjukkan menunjukkan model CNN-BiLSTM mampu menangani fluktuasi dan kompleksitas data saham[5]. Hasil prediksi dari 3 tren saham Bank, bahwa nilai MAPE yang diperoleh untuk setiap mode yang dihasilkan kurang dari 10% yang berarti bahwa model yang dihasilkan memiliki akurasi yang sangat baik.

CNN merupakan *deep learning* yang cocok untuk mengekstrak fitur lokal jangka pendek dari urutan data[6]. Pada penelitian[6], hasil menunjukkan CNN mendapatkan nilai yang cukup baik untuk prediksi jangka pendek. Sedangkan pendekatan yang banyak digunakan untuk menangani data berurutan jangka panjang ialah LSTM[7][8][9], yang merupakan bagian dari jaringan saraf tiruan Recurrent Neural Network (RNN). Dengan memanfaatkan LSTM, model dapat memahami pola perubahan cuaca dari waktu ke waktu secara lebih akurat[8][10]. Penelitian[8][11][12] yang melakukan peramalan cuaca menunjukkan bahwa LSTM dengan kombinasi GRU mampu meramalkan curah hujan dengan fitur data cuaca[13][14].

Berdasarkan uraian pada paragraf sebelumnya tentang LSTM dengan kemampuan untuk menangani kontinyu jangka panjang, namun terdapat keterbatasan mengatasi fitur spasial sehingga untuk mengatasi kekurangan tersebut penelitian ini menawarkan kombinasi layer CNN dan LSTM, penelitian ini mengusulkan model hibrida yang memanfaatkan kekuatan CNN dalam ekstraksi fitur temporal dan kekuatan LSTM untuk mengingat pola jangka panjang. Melalui pendekatan ini, model mampu melakukan peramalan kelembapan secara lebih akurat. Penggunaan model hibrida CNN-LSTM dapat memberikan kontribusi dalam pengembangan sistem peramalan cuaca berbasis *deep learning* yang cerdas dan adaptif terhadap data historis.

Rumusan masalah dalam penelitian ini adalah bagaimana merancang model yang menggabungkan lapisan CNN dan LSTM untuk peramalan kelembapan relatif, serta apakah model tersebut dapat memberikan kontribusi signifikan dalam meningkatkan akurasi peramalan kelembapan relatif.

Tujuan penelitian ini adalah membangun model yang menggabungkan lapisan CNN dan LSTM untuk peramalan kelembapan relatif, mengevaluasi kinerja metode tersebut, serta membandingkan hasil kinerjanya dengan model lain seperti CNN, LSTM, BiLSTM, dan GRU[15].

Penelitian ini menggunakan data cuaca dari Kabupaten Bogor dalam rentang waktu 1 Januari 2020 hingga 31 Oktober 2025 dengan rata-rata kelembapan udara 74 sampai 86% yang diperoleh dari Stasiun Meteorologi Citeko pada koordinat Lintang -6.70000 , Bujur 106.85000 , dan elevasi 920 meter. Dataset terdiri atas 2.142 baris yang memuat catatan waktu, suhu udara, penyinaran matahari, dan kelembapan udara. Manfaat yang diharapkan dari hasil penelitian ini untuk membantu BMKG menemukan pola kelembapan relatif yang berpengaruh terhadap peramalan cuaca sehingga dapat menjadi masukan yang penting dalam hal sektor pertanian lokal untuk menentukan masa tanam yang lebih efisien sehingga dapat meningkatkan hasil pertanian.

II. METODE

A. Studi Teoritis

Studi literatur dilakukan untuk memahami teori dasar dan perkembangan terkini terkait peramalan data, metode *deep learning*, khususnya *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM), serta implementasi model CNN-LSTM dalam pemrosesan data deret waktu.

B. Pengumpulan dan Pengukuran Empiris

Data catatan cuaca Kabupaten Bogor diperoleh dari situs web resmi BMKG. Data berisi catatan cuaca rata-rata harian yang dicatat secara berkala. Data yang digunakan adalah data suhu dan penyinaran matahari dengan jumlah data 2142 baris dengan rentang pengamatan mulai 1 Januari 2020 hingga 31 Oktober 2025. Untuk pembuatan model digunakan pembagian data yaitu pelatihan 70%, validasi 15% dan pengujian 15%.

C. Simulasi dan Perancangan Sistem


Sistem peramalan dirancang dengan arsitektur yang menggabungkan CNN dan LSTM. Desain arsitektur dilakukan secara bertahap dan melalui beberapa studi.

D. Implementasi

Model CNN-LSTM diimplementasikan menggunakan bahasa pemrograman Python dan pustaka TensorFlow. Hasil peramalan diuji menggunakan metrik evaluasi meliputi *mean absolute error* (MAE), *mean square error* (MSE), *root mean square error* (RMSE), dan *coefficient of determination* (R^2).

E. Arsitektur CNN-LSTM

Pada penelitian ini, arsitektur yang ditawarkan adalah kombinasi CNN-LSTM [16], seperti yang terlihat pada Gambar 1.



Gambar 1. Arsitektur CNN-LSTM

Berdasarkan Gambar 1, kombinasi CNN-LSTM menggunakan layer konvolusi 1D sebanyak 1 buah, kemudian output dari layer konvolusi tersebut masuk ke layer maxpooling yang menggunakan hanya satu lapisan saja. Setelah itu output dari layer maxpooling masuk ke layer Flatten, yang kemudian output dari *layer Flatten* ini adalah merupakan input yang digunakan oleh LSTM. Selanjutnya, model CNN-LSTM yang digunakan dalam penelitian ini dengan hyperparameter setup yang ditunjukkan pada Table 1.

TABEL 1
 HYPERPARAMETER SETUP MODEL CNN-LSTM

Parameter	Nilai
Input	(1960, 30, 6, 2)
Output	(1960, 3, 1)
Optimizer	Adam
Learning Rate	0.0005
Epoch	100
Batch Size	128
Callback	LR Schedule

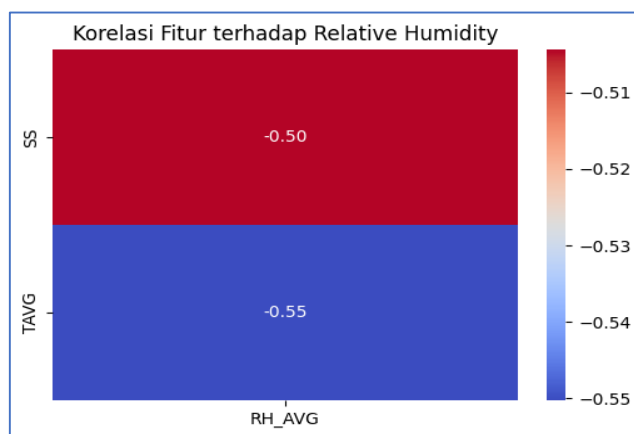
Hyperparameter yang dipilih sesuai Tabel 1 merupakan hasil terbaik yang didapatkan dalam melakukan percobaan sebelum membandingkan dengan metode penelitian yang lain yang dibahas pada Bab selanjutnya.

III. HASIL DAN PEMBAHASAN

Pada bagian ini berisi hasil dan pembahasan dari topik penelitian, yang bisa di buat terlebih penerapan metode yang digunakan, baik secara sederhana dengan mengemukakan data yang ada pada penelitian. Bagian ini juga merepresentasikan penjelasan yang berupa penjelasan, gambar, tabel dan lainnya.

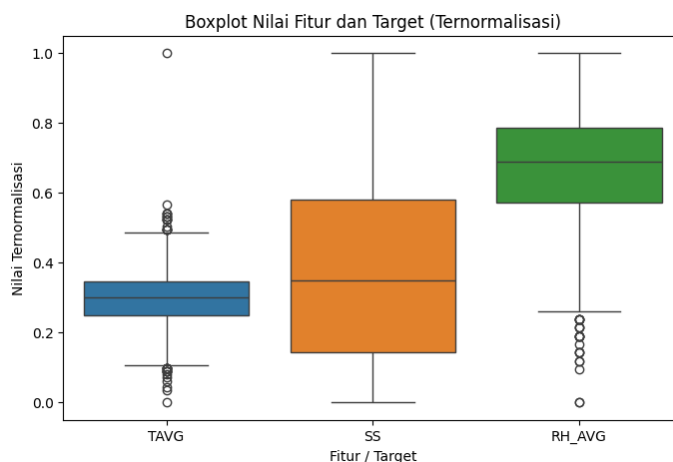
A. Eksplorasi Data

Eksplorasi data dilakukan untuk melihat korelasi antara data target dan fitur serta kualitas persebaran data yang dilihat dari boxplot data.



Gambar 2. Korelasi Fitur dan Target

Data suhu rata-rata (TAVG) memiliki korelasi yang paling besar dengan data target kelembapan relatif dengan korelasi sebesar 0.55, sementara data penyinaran matahari (ss) memiliki korelasi sebesar 0.50 dengan data target kelembapan relatif.




Gambar 3. Boxplot Data

Berdasarkan boxplot, data memiliki ragam yang cukup untuk membantu model mengenali pola hubungan antar variabel. Suhu memiliki nilai yang cenderung rendah dengan penyebaran data yang sangat sempit dan memiliki *outlier* yang sangat ekstrem. Penyinaran matahari memiliki penyebaran data yang luas dan tidak ada *outlier*, sehingga kualitas data pada penyinaran terlihat lebih baik dibandingkan data lain, diikuti data kelembapan relatif. Sementara data suhu terlihat memiliki kualitas data yang paling buruk.

B. Grafik Loss

Grafik yang menunjukkan tren kesalahan model selama proses pelatihan dan validasi seperti yang terlihat pada Gambar 3. Grafik ini juga dapat menunjukkan bahwa model yang dibuat terhindari dari fenomena overfit, underfit, atau bestfit (hal ini yang diharapkan).




Gambar 4. Grafik Loss Model CNN-LSTM

Training loss dan validasi *loss* model CNN-LSTM selama 100 kali pelatihan cenderung mengalami penurunan dan sangat stabil, hal ini menunjukkan model bekerja dengan baik dalam melakukan generalisasi data training, sehingga boleh dikatakan model terhindar dari fenomena overfit dan underfit.

C. Grafik Nilai Aktual dan Prediksi

Perbandingan nilai aktual dan prediksi menunjukkan kinerja model dari hasil pelatihan dengan data yang digunakan seperti pada Gambar 5.



Gambar 5. Data Nilai Aktual dan Prediksi

Gambar 4, menunjukkan grafik nilai prediksi model CNN-LSTM yang direpresentasikan oleh garis warna oranye dan data aktual yang direpresentasikan oleh garis warna biru. Grafik hasil prediksi model CNN-LSTM cenderung tidak menyerupai nilai aktual. Terlihat bahwa ada jarak yang besar antara hasil representasi data aktual dengan hasil prediksi (overfit), hal ini menandakan bahwa data yang didapatkan dari sumber cenderung masih sedikit, sehingga kemampuan model dalam melakukan generalisasi masih belum cukup.

D. Metrik Evaluasi

Pada bagian ini, pengujian dilakukan dengan menggunakan beberapa metrik evaluasi yaitu MAE, MSE, RMSE, dan R² terhadap timestep data. Berikut hasil model dievaluasi dengan melakukan pengujian data uji yang disajikan pada Tabel 1.

TABEL 1
METRIK EVALUASI MODEL CNN-LSTM

Timestep	MAE	MSE	RMSE	R ²
1	4.3166	28.9413	5.3797	0.1052
2	4.3736	30.2218	5.4974	0.0667
3	4.3887	30.5749	5.5295	0.0548
Rata-rata	4.3596	29.9126	5.4689	0.0756

Metrik evaluasi menunjukkan bahwa model CNN-LSTM memiliki rata-rata nilai MAE sebesar 4.3596, MSE sebesar 29.9126 RMSE sebesar 5.4689, dan R² Score sebesar 0.0756 dengan hasil terbaik MAE sebesar 4.3166, MSE sebesar 28.9413, RMSE sebesar 5.3793, dan R² sebesar 0.1052 pada timestep 1.

E. Pembahasan

Pelatihan model CNN-LSTM menghasilkan *loss* dari data latih dan validasi yang menunjukkan generalisasi dari model. Model CNN-LSTM dengan konfigurasi yang berbeda tidak memiliki perbedaan generalisasi yang signifikan. Semua model CNN-LSTM memiliki generalisasi yang cukup baik.

Model CNN-LSTM yang memiliki semua komponen memiliki generalisasi yang baik. Grafik menunjukkan penurunan *loss* yang stabil dan seimbang antara *training* dan *validation*.

Berdasarkan grafik, *validation loss* dan *training loss* model CNN-LSTM tanpa subsekuen mengalami penurunan dengan baik. Namun, nilai *validation loss* sedikit lebih tinggi dibandingkan *training loss* yang dapat menandakan bahwa model mengalami *overfitting* walaupun hanya sedikit. Hal ini menunjukkan bahwa tanpa pembagian subsekuen, model dapat kehilangan konteks pola lokal pada data deret waktu.

Grafik *loss* model CNN-LSTM yang tidak menggunakan *learning schedule* pada awal pelatihan memiliki hasil *validation loss* yang lebih tinggi dari model lain, tetapi pada pelatihan berikut grafik *validation loss* mengalami penurunan yang stabil dan cenderung sama seperti model CNN-LSTM yang memiliki *learning schedule*. Hal ini menunjukkan bahwa tanpa *learning schedule*, model CNN-LSTM masih memiliki generalisasi yang baik.

Sementara model CNN-LSTM yang tidak menggunakan regularisasi mempunyai generalisasi yang sangat baik. *Validation loss* dan *training loss* mengalami penurunan yang sangat cepat. Model belajar dengan sangat cepat dan mampu mempelajari data dengan sangat baik. Atribut regularisasi tidak berpengaruh baik terhadap regularisasi model CNN-LSTM yang memiliki subsekuen dan *learning schedule*.

Namun, grafik nilai peramalan yang dihasilkan oleh model CNN-LSTM masih berbeda secara signifikan dibandingkan grafik nilai aktual. Hal ini disebabkan oleh data yang didapatkan berupa data rata-rata harian yang memiliki ketergantungan antar-waktu sangat rendah, sehingga pengaruh data terhadap data sebelumnya cenderung rendah. Oleh sebab itu, model menghasilkan pola lokal yang cenderung linear untuk mendapatkan hasil maksimal dan memiliki bentuk grafik yang sangat jauh dibandingkan grafik nilai aktual data. Sebagai perbandingan, model CNN-LSTM tanpa subsekuen menghasilkan grafik peramalan yang lebih bergelombang. Hal ini terjadi karena model lebih fokus ke pola jangka panjang atau musiman dan kurang memperhatikan pola lokal, sehingga akurasi model mengalami penurunan.

TABEL 2
PERBANDINGAN HASIL BEBERAPA MODEL CNN-LSTM

Model	Metrik Evaluasi			
	MAE	MSE	RMSE	R ²
CNN-LSTM	4.3596	29.9126	5.4689	0.0756
Tanpa Subsekuen	4.4423	30.6642	5.5370	0.0523
Tanpa Learning schedule	4.4072	30.2076	5.4958	0.0664
Tanpa Regularisasi	4.4079	30.0467	5.4811	0.0714

Model-model CNN-LSTM mampu mendapatkan hasil MAE dan RMSE cukup baik. Namun, nilai R² dari model-model tersebut masih sangat kecil, menandakan pola data sulit dipelajari. Model CNN-LSTM (baseline) memiliki performa terbaik, diikuti model CNN-LSTM tanpa learning schedule, model CNN-LSTM tanpa regularisasi, dan model CNN-LSTM tanpa subsekuen menjadi model dengan performa yang paling buruk.

Model CNN-LSTM memiliki rata-rata nilai MAE sebesar 4.3596, MSE sebesar 29.9126, RMSE sebesar 5.4689, dan R² sebesar 0.0756. Hasil ini menunjukkan bahwa model dapat meramalkan data dengan kesalahan peramalan rata-rata absolut melesat 4.3596 dari nilai aktual dengan rentang target 42 satuan.

Model CNN-LSTM lain mengalami penurunan performa dalam meramalkan data. Model CNN-LSTM yang tidak menggunakan subsekuen pada sliding window mengalami penurunan performa terbesar, dengan kenaikan MAE sebesar 0.1173 dan penurunan R² sebesar 0.0233. Hal ini menunjukkan bahwa penggunaan subsekuen pada sliding window dapat membantu model memahami pola lokal dan memperbaiki akurasi peramalan.

Model CNN-LSTM yang tidak menggunakan *learning rate schedule* dan regularisasi *dropout* juga mengalami penurunan performa. Model CNN-LSTM yang tidak menggunakan *learning rate schedule* mengalami kenaikan nilai MAE sebesar 0.0476 dan penurunan R² sebesar 0.0092. Sedangkan model CNN-LSTM yang tidak menggunakan regularisasi *dropout* dan l2 mengalami penurunan performa dengan kenaikan nilai MAE sebesar 0.0483 dan penurunan R² sebesar 0.0042. Hal ini menunjukkan bahwa *learning rate schedule* dan komponen regularisasi turut memengaruhi performa model dalam melakukan peramalan, meskipun efeknya tidak begitu signifikan.

Semua komponen mempunyai pengaruh terhadap performa model, terutama penggunaan subsekuen yang terbukti meningkatkan akurasi dan generalisasi model dengan cukup signifikan dibandingkan komponen lain. Secara keseluruhan, model CNN-LSTM dengan regularisasi, subsekuen, dan *learning schedule* memiliki performa yang seimbang antara akurasi dan generalisasi. Model yang ditawarkan juga dibandingkan dengan model *deep learning* lainnya.

TABEL 3
 METRIK EVALUASI DARI BEBERAPA JENIS MODEL CNN-LSTM

Model	Metrik Evaluasi			
	MAE	MSE	RMSE	R ²
CNN-LSTM	4.3596	29.9126	5.4689	0.0756
CNN-BiLSTM	4.3815	30.4224	5.5153	0.0598
CNN-GRU	4.4232	30.3398	5.5073	0.0624
CNN	4.5989	32.5019	5.7005	-0.0045
LSTM	4.4267	30.3960	5.5131	0.0606
BiLSTM	4.3748	29.9074	5.4687	0.0757
GRU	4.3168	29.3300	5.4150	0.0936

Tabel diatas menunjukkan perbandingan metrik evaluasi dari berbagai model *deep learning*. Untuk model tunggal, semua model RNN mampu meramal data dengan akurasi lebih baik dan presisi dibandingkan model CNN dengan perbedaan yang cukup signifikan. Bahkan nilai R² model CNN kurang dari 0 atau negatif. Hal ini menunjukkan bahwa model RNN lebih cocok untuk data deret waktu dibandingkan model CNN. Namun, hasil tersebut menunjukkan variabel independent (suhu dan lama penyinaran matahari) yang digunakan tidak dapat menyesuaikan dengan variasi variabel dependen (kelembaban relative) yang terbatas sehingga rata-rata nilai R² sangat kurang dari 19%.

Secara keseluruhan, model GRU memiliki performa yang paling baik diikuti oleh model BiLSTM dan CNN-LSTM. Model CNN-LSTM memiliki performa sedikit lebih baik dibandingkan model hibrida CNN-RNN lainnya. Hal ini menunjukkan bahwa disamping GRU dan BiLSTM juga model kombinasi CNN - LSTM sangat cocok dalam peramalan data deret.

Berdasarkan hasil percobaan, dimana metode GRU terlihat hasilnya lebih baik dibandingkan dengan metode lain disebabkan karena metode ini lebih sederhana dari LSTM yaitu hanya memiliki reset gate dan update gate. Kedua gerbang ini berguna untuk melakukan seleksi informasi yang berguna maupun tidak berguna, yang mana informasi yang berguna di pertahankan sedangkan informasi yang tidak berguna dihilangkan. Sejalan dengan kinerja LSTM tetapi kekurangannya adalah LSTM mempunyai arsitektur yang sedikit lebih rumit yaitu *Forget Gate, input gate, Input modulation gate, output gate* dan *cell state*. Untuk mendapatkan informasi yang lebih relevan maka tujuannya adalah melakukan kombinasi antara CNN-LSTM tetapi hasil yang didapat belum mampu mengalahkan metode GRU.

IV. SIMPULAN

Dari hasil dan analisis, dapat disimpulkan bahwa penambahan komponen berpengaruh terhadap performa model dalam meramal data. Komponen subsekuen memiliki dampak paling signifikan. Model CNN-LSTM lengkap tetap direkomendasikan sebagai baseline karena mampu menjaga keseimbangan antara kesalahan yang rendah dan kestabilan model. Dari hasil dan analisis, dapat disimpulkan bahwa model CNN-LSTM yang dikembangkan mampu melakukan peramalan kelembapan udara beberapa langkah ke depan dengan performa yang paling baik dibandingkan model CNN-RNN lainnya. Model CNN-LSTM mampu mendapatkan performa yang seimbang antara akurasi dan regularisasi yang baik dibandingkan model lainnya, menunjukkan bahwa model mampu menangani data deret waktu dengan ketergantungan antar waktu yang sangat rendah, sekaligus mengenali pola lokal untuk mendapatkan hasil maksimal dengan baik. Penelitian ini telah berhasil membangun model prediktif menggunakan pendekatan hibrida CNN-LSTM yang mampu melakukan peramalan kelembapan udara untuk 3 hari ke depan tercapai dengan baik. Evaluasi dilakukan secara menyeluruh terhadap data pelatihan maupun pengujian, serta dibandingkan dengan

beberapa konfigurasi dan parameter seperti jumlah unit LSTM, filter CNN, dropout, regulasi L2, dan penyesuaian learning rate. Dari keseluruhan proses ini, dapat disimpulkan bahwa kombinasi arsitektur convolutional dan recurrent network dapat menangani pola sekuensial yang bersifat musiman dan fluktuatif, tetapi tidak berhasil mengalahkan kinerja dari metode GRU dalam melakukan peramalan. Untuk pengembangan penelitian selanjutnya, identifikasi masalah perlu dilakukan secara lebih mendalam sejak awal, khususnya dalam memahami karakteristik data deret waktu yang digunakan. Eksplorasi data perlu dilakukan secara lebih mendalam dan dianalisis terhadap pola musiman, tren jangka panjang, adanya anomali, outlier, atau hal lain yang signifikan. Hal ini akan membantu dalam pemilihan arsitektur model. Pemrosesan data yang tepat juga dapat membantu model dalam melakukan peramalan data. Pemilihan data yang memiliki ketergantungan antar-waktu seperti catatan per jam mungkin dapat membuat data sebelumnya lebih berpengaruh terhadap data selanjutnya. Pemilihan parameter dan hyperparameter juga dapat memperbaiki performa model. Pemanfaatan framework modern serta perangkat keras yang mendukung juga dapat mempercepat eksperimen.

DAFTAR PUSTAKA

- [1] M. Muhaimin, E. Alviawati, and P. Angriani, "Urgensi kenyamanan termal dalam perspektif pembelajaran," vol. 7, pp. 23–32, 2023, doi: 10.29408/geodika.v7i1.6451.
- [2] I. P. Suwarna, F. Pramudita, R. Yulianto, and L. D. Tamala, "Analisis kelembaban udara dan tingkat kenyamanan lingkungan kos-kosan di area sekitar kampus UIN Jakarta," vol. 6, no. 1, pp. 49–56, 2025.
- [3] S. M. Makruf *et al.*, "Analisis Kelembaban Udara terhadap Tingginya Suhu di Sekaran Semarang," vol. 4, no. 1, pp. 93–100, 2025.
- [4] E. Sartati *et al.*, "Analisis Korelasi Kelembaban Udara terhadap Epidem Demam Berdarah yang Terjadi di Kota Bengkulu," vol. 3, no. 2, pp. 170–175, 2024, doi: 10.55123/insolologi.v3i2.3384.
- [5] O. Access, J. Info, J. Journal, and O. F. Mathematics, "Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia," vol. 6, no. 2, pp. 195–203, 2024.
- [6] P. Wardana, N. Daratha, M. K. A. Rosa, T. Elektro, U. Bengkulu, and E. Metrics, "Perbandingan Metode-Metode *Deep learning* Dalam Prediksi Konsumsi Daya Listrik Rumah Jangka Pendek," vol. 14, no. 1, 2024.
- [7] G. Tugas and P. Penanganan, "OPTIMALISASI DATA TERBATAS PREDIKSI JANGKA PANJANG COVID-19 DENGAN KOMBINASI LSTM DAN GRU," vol. 4, no. September, 2020.
- [8] T. Lattifia, P. Wira, N. Kadek, and D. Rusjyanthi, "Model Prediksi Cuaca Menggunakan Metode LSTM," vol. 3, no. 1, 2022.
- [9] C. C. Islamy, A. Wahabi, P. Studi, T. Informatika, and F. Teknik, "Perbandingan Model LSTM dan GRU untuk Peramalan Angin A Comparative Study of LSTM and GRU Models for Wind Forecasting," vol. 14, pp. 2817–2831, 2025.
- [10] G. R. Units, "PREDIKSI POLUSI UDARA KOTA JAKARTA MENGGUNAKAN RECURRENT NEURAL NETWORK-GATED RECURRENT UNITS," vol. 1, no. November 2022, pp. 807–814, 2023.
- [11] F. Kurniawan and A. Triayudi, "Analysis of Interrelationships between Weather Parameters in North Jakarta and Central Jakarta Based on Predictions Using LSTM and GRU," vol. 2, no. 4, pp. 328–343, 2024, doi: 10.58905/SAGA.v2i4.398.
- [12] Y. Karyadi, H. Santoso, S. B. Park, P. Magister, and T. Infomasi, "Prediksi Kualitas Udara Dengan Metoda LSTM , Bidirectional LSTM , dan GRU," vol. 9, no. 1, 2022.
- [13] V. P. Sientika and T. Handayani, "PREDIKSI INDEKS STANDAR PENCEMARAN UDARA DI KOTA YOGYAKARTA DENGAN MODEL *LONG SHORT-TERM MEMORY* DAN GATED RECURRENT UNIT," vol. 9, no. 5, pp. 8776–8781, 2025.
- [14] M. I. Yafik and C. Chairani, "BULLETIN OF COMPUTER SCIENCE RESEARCH Optimalisasi Akurasi Prediksi Curah Hujan Bulanan Menggunakan *Deep learning*," vol. 5, no. 5, pp. 1021–1028, 2025, doi: 10.47065/bulletincsr.v5i5.735.
- [15] M. R. Febrian, A. Rahman, and M. A. Yahya, "Perbandingan LSTM dan GRU untuk Prediksi Kebutuhan Air pada Pertanian Modern Cerdas Berbasis Internet Of Things," vol. 11, no. November, pp. 290–303, 2025.
- [16] A. Fauzul, A. Kustiwa, M. A. Akbar, and A. Pinandito, "Studi Perbandingan pada Metode CNN-LSTM dan LSTM dalam Mendeteksi Emosi pada Data Teks Berbahasa Indonesia pada Media Sosial Twitter," vol. 1, no. 1, pp. 1–9, 2017.