

Pemodelan Prediksi Suhu Rata Rata Harian dan Kelembapan Relatif di Kota Semarang Menggunakan LSTM, GRU, dan GRU-LSTM

Nida Nur Fadhilah¹, Iqbal Kharisudin²

^{1,2}Universitas Negeri Semarang

[1nidanf2103@gmail.com](mailto:nidanf2103@gmail.com), [2iqbal.mat@mail.unnes.ac.id](mailto:iqbal.mat@mail.unnes.ac.id)

ABSTRAK

Penelitian ini bertujuan membandingkan kinerja tiga model deep learning, yaitu Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan model hibrida GRU-LSTM dalam memprediksi suhu rata-rata harian dan kelembapan relatif di Kota Semarang. Data sekunder diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) periode 1 September 2021 hingga 2 Oktober 2025. Setelah dilakukan pra-pemrosesan dan normalisasi, data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Optimasi hiperparameter dilakukan dengan Bayesian Optimization menggunakan pustaka Optuna. Hasil evaluasi berdasarkan metrik MSE, RMSE, MAE, dan MAPE menunjukkan bahwa ketiga model mampu menangkap pola non-linier dan ketergantungan jangka panjang dalam data dengan baik. Model LSTM dan GRU-LSTM memberikan kinerja paling kompetitif pada prediksi suhu, sementara untuk kelembapan, perbedaan kinerja antarmodel relatif kecil. Prediksi 30 hari ke depan yang dihasilkan konsisten dengan pola musiman di Kota Semarang. Hasil penelitian ini dapat menjadi dasar pertimbangan dalam pengembangan sistem peringatan dini dan strategi adaptasi perubahan iklim berbasis data.

Kata Kunci: *deep learning; GRU; GRU-LSTM; LSTM; Semarang.*

ABSTRACT

This study aims to compare the performance of three deep learning models, namely Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and the hybrid GRU-LSTM model in predicting daily average temperature and relative humidity in Semarang City. Secondary data were obtained from the Meteorology, Climatology, and Geophysics Agency (BMKG) for the period from September 1, 2021, to October 2, 2025. After preprocessing and normalization, the data were split into 80% for training and 20% for testing. Hyperparameter optimization was performed using Bayesian Optimization with the Optuna library. Evaluation results based on MSE, RMSE, MAE, and MAPE metrics showed that all three models were capable of capturing non-linear patterns and long-term dependencies in the data effectively. The LSTM and GRU-LSTM models demonstrated the most competitive performance in temperature prediction, while for humidity, the performance differences among the models were relatively small. The 30-day-ahead forecasts produced were consistent with the seasonal patterns in Semarang. The findings of this study can serve as a basis for developing early warning systems and data-driven climate change adaptation strategies.

Keywords: *deep learning; GRU; GRU-LSTM; LSTM; Semarang.*

PENDAHULUAN

Revолюси digital dalam bidang kecerdasan buatan telah membawa paradigma baru dalam analisis data yang kompleks dan dinamis. Perkembangan teknologi *deep learning* khususnya, menawarkan kemampuan yang superior dalam mengekstraksi pola-pola tersembunyi dari data historis. Kemampuan ini menjadikan *deep learning* sebagai alat yang sangat potensial untuk memprediksi fenomena kompleks seperti parameter cuaca(Soyer, 2023). Berbeda dengan metode statistik tradisional, pendekatan ini dapat menangkap hubungan non-linier dan interaksi kompleks antar variabel cuaca dengan tingkat akurasi yang lebih tinggi (Lecun et al., 2015).

Keterbatasan *Artificial Neural Network* (ANN) dalam memproses informasi sekuensial memicu inovasi arsitektur *Recurrent Neural Network* (RNN). Namun, RNN konvensional

menghadapi masalah *vanishing* dan *exploding gradient*, yang menyulitkan jaringan untuk mempelajari dependensi jangka panjang (Lecun *et al.*, 2015). Inovasi untuk mengatasi kelemahan ini melahirkan arsitektur yang lebih kompleks dan robust, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). LSTM dikembangkan dengan mekanisme gerbang (*gate*) yang selektif untuk menentukan informasi mana yang perlu diingat, dilupakan, atau dikeluarkan (Brownlee, 2018). Sementara GRU hadir sebagai varian yang lebih sederhana dan efisien secara komputasi, dengan menyederhanakan struktur gerbang menjadi hanya *update gate* dan *reset gate* (Handayani *et al.*, 2023). Evolusi arsitektur terus berlanjut dengan munculnya model-model hibrida seperti GRU-LSTM, yang bertujuan memadukan efisiensi komputasi GRU dengan kemampuan memori jangka panjang LSTM (Trivedi & Patel, 2022).

Konteks permasalahan ini menjadi semakin krusial melihat realitas dampak perubahan iklim global yang kian nyata. NASA mencatat tahun 2023 sebagai tahun terpanas dalam sejarah, yang diperparah oleh siklus El Niño 2023–2024. Indonesia, dengan karakteristik sebagai negara kepulauan tropis, sangat rentan terhadap dampak ini. Kota Semarang, sebagai ibu kota Provinsi Jawa Tengah yang terletak di pesisir utara Pulau Jawa, menjadi salah satu wilayah yang paling terdampak. Karakteristik iklim tropis lembabnya ditandai dengan suhu udara yang relatif tinggi sepanjang tahun (24°C–33°C) dan kelembapan relatif yang cenderung tinggi (Handayani *et al.*, 2023). Dampak fluktuasi suhu dan kelembapan di Kota Semarang bersifat multidimensi, mulai dari peningkatan risiko kesehatan, tekanan pada sektor pertanian (Judijanto *et al.*, 2023), hingga ancaman terhadap ketahanan pangan.

Berdasarkan uraian tersebut, prediksi yang akurat terhadap suhu rata-rata harian dan kelembapan relatif menjadi kebutuhan mendesak. Penelitian ini secara khusus dirancang untuk mengisi celah akademik dan aplikatif dengan melakukan perbandingan komprehensif terhadap kinerja tiga model deep learning, yaitu LSTM, GRU, dan model hibrida GRU-LSTM, dalam memprediksi dua parameter cuaca tersebut di Kota Semarang. Fokus penelitian adalah mengidentifikasi model mana yang paling optimal dalam menangkap pola kompleks data cuaca lokal, dengan harapan hasilnya dapat diadopsi oleh pemangku kepentingan untuk mendukung sistem peringatan dini dan strategi adaptasi perubahan iklim yang lebih efektif.

METODE PENELITIAN

Analisis data dilakukan dalam beberapa tahapan sebagai berikut:

1. Pendekatan dan Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode pemodelan runtun waktu (*time series*). Tujuan utama penelitian adalah membandingkan kinerja tiga model *deep learning* LSTM, GRU, dan GRU-LSTM dalam memprediksi suhu rata-rata dan kelembapan relative di Kota Semarang.

Desain Penelitian disusun secara sistematis mulai dari pengumpulan data klimatologi, analisis deskriptif, preprocessing data, pemodelan menggunakan LSTM, GRU, dan GRU-LSTM, evaluasi kinerja model, hingga visualisasi hasil prediksi. Setiap tahap dilaksanakan menggunakan bahasa pemrograman Python dan berbagai library pendukung seperti TensorFlow/Keras, Pandas, NumPy, dan Matplotlib.

2. Data dan Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder berupa suhu rata-rata harian dan kelembapan relatif di Kota Semarang selama periode 1 September 2021

hingga 2 Oktober 2025. Data diperoleh dengan mengunduh langsung dari portal resmi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Stasiun Klimatologi Jawa Tengah.

3. Teknik Pengumpulan Data

Data dikumpulkan secara tidak langsung dari BMKG dengan mengunduh riwayat data iklim harian selama periode empat tahun terakhir. Setelah data diperoleh, dilakukan tahap pembersihan (cleaning) dan penyesuaian format untuk memastikan data siap digunakan dalam analisis pemodelan.

4. Teknik Analisis Data

Analisis data dilakukan dalam beberapa tahapan sebagai berikut:

a) *Preprocessing* Data

Analisis data dalam penelitian ini diawali dengan tahap *preprocessing* yang bertujuan untuk mempersiapkan data agar dapat digunakan dalam pemodelan. Pada tahap ini, fokus utama adalah dua hal, yaitu penanganan nilai kosong (*missing values*) dan normalisasi data. Normalisasi dilakukan menggunakan teknik Min-Max Scaling untuk mengubah nilai data ke dalam rentang [0, 1], sehingga mempercepat proses pelatihan model dan meningkatkan stabilitas numerik.

b) Pembagian Data

Setelah tahap *preprocessing* selesai dilakukan, data kemudian dibagi menjadi dua bagian utama, yaitu data *training* dan data *testing*. Pembagian ini bertujuan agar model dapat dilatih menggunakan sebagian data historis, dan kemudian dievaluasi performanya terhadap data yang belum pernah dilihat sebelumnya. Sebanyak 80% data awal digunakan sebagai data *training*, yang berfungsi untuk membangun model dan mengenali pola historis dari suhu dan kelembapan. Sementara itu, 20% data sisanya digunakan sebagai data *testing* untuk mengukur akurasi prediksi dari model yang telah dibangun. Proses pembagian dilakukan secara kronologis berdasarkan urutan waktu agar struktur data deret waktu tetap terjaga. Hal ini penting untuk memastikan bahwa model hanya menggunakan informasi dari masa lalu untuk melakukan peramalan terhadap masa depan, sebagaimana prinsip dasar dalam analisis *time series*.

c) Pembuatan Model

Tahap selanjutnya dalam analisis data adalah pembuatan model peramalan dengan menggunakan tiga arsitektur *deep learning*, yaitu LSTM, GRU, dan GRU-LSTM. Model LSTM dirancang dengan mekanisme gerbang (*gate*) untuk mengontrol alur informasi jangka panjang. Model GRU menyederhanakan struktur LSTM dengan hanya menggunakan dua gerbang, yaitu *update* dan *reset*, sehingga lebih efisien secara komputasi. Sementara itu, model hibrida GRU-LSTM menggabungkan lapisan GRU dan LSTM secara berurutan untuk memanfaatkan efisiensi GRU dan kemampuan memori jangka panjang LSTM (Dey & Salem, 2017; Trivedi & Patel, 2022).

Pembangunan Pembangunan ketiga model dilakukan dengan pendekatan optimasi hiperparameter otomatis menggunakan metode *Bayesian Optimization* berbasis algoritma *Tree-structured Parzen Estimator* (TPE), yang

difasilitasi oleh pustaka Optuna. Proses ini bertujuan untuk mencari konfigurasi terbaik dari sejumlah parameter yang memengaruhi performa model, antara lain jumlah lapisan, jumlah unit LSTM/GRU, *dropout rate*, *learning rate*, jumlah *epoch*, dan ukuran *batch*.

d) Evaluasi Model

Tahap akhir dalam analisis data adalah evaluasi model, yang bertujuan untuk mengukur kinerja model peramalan yang telah dibangun, baik menggunakan LSTM, GRU, maupun GRU-LSTM. Evaluasi dilakukan dengan menggunakan lima metrik utama, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). MSE dan RMSE digunakan untuk mengukur kesalahan prediksi secara kuadrat, MAE memberikan gambaran kesalahan absolut, MAPE mengukur kesalahan dalam bentuk persentase.

Kelima metrik ini dihitung pada data pengujian (*testing*) untuk membandingkan kinerja ketiga model secara objektif. Penelitian ini tidak bertujuan untuk memilih satu model terbaik, melainkan untuk menganalisis karakteristik dan performa masing-masing model dalam memprediksi suhu dan kelembapan. Perbandingan ini akan mengungkap kelebihan dan kekurangan setiap arsitektur, serta memberikan wawasan tentang model mana yang paling sesuai untuk tujuan prediksi tertentu.

e) Peramalan dan Visualisasi

Setelah proses evaluasi dan perbandingan dilakukan, tahap selanjutnya adalah menampilkan hasil prediksi dari ketiga model untuk periode mendatang. Pendekatan ini memungkinkan analisis yang komprehensif dengan memvisualisasikan bagaimana setiap model memproyeksikan pola suhu dan kelembapan di masa depan.

Hasil peramalan dari LSTM, GRU, dan GRU-LSTM disajikan bersama-sama dalam bentuk grafik dan tabel komparatif. Visualisasi ini mencakup perbandingan antara nilai aktual dan nilai prediksi dari ketiga model pada periode historis, serta estimasi nilai masa depan yang ditampilkan dalam bentuk kurva waktu yang saling berdampingan. Penyajian hasil dari semua model ini memberikan perspektif yang lebih kaya untuk memahami ketidakpastian prediksi, konsistensi pola yang dihasilkan oleh arsitektur yang berbeda, serta dasar yang lebih kuat untuk pengambilan keputusan strategis terkait mitigasi bencana, perencanaan pertanian, dan kebijakan lingkungan di Kota Semarang.

HASIL DAN PEMBAHASAN

Pada bagian ini, hasil pemodelan dan analisis data disajikan secara sistematis, dimulai dengan eksplorasi karakteristik data, dilanjutkan dengan evaluasi performa model LSTM, GRU, dan GRU-LSTM. Pembahasan dilakukan dengan membandingkan kelebihan dan keterbatasan masing-masing model berdasarkan metrik evaluasi yang telah ditetapkan.

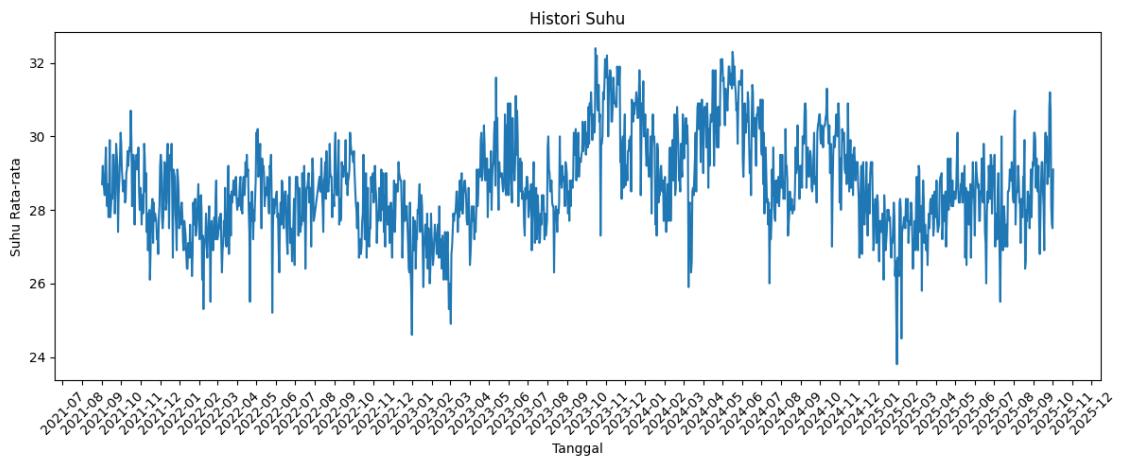
1. Karakteristik Data

Penelitian ini menggunakan data historis suhu rata-rata harian (T_{avg}) dan kelembapan relatif (RH) dari Kota Semarang. Data meteorologi tersebut diperoleh secara

online melalui portal resmi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) pada Stasiun Klimatologi Jawa Tengah via laman <https://dataonline.bmkg.go.id/>. Rentang data yang digunakan mencakup periode dari 1 September 2021 hingga 2 Oktober 2025, yang kemudian diolah dan disesuaikan untuk kebutuhan analisis dalam penelitian ini.

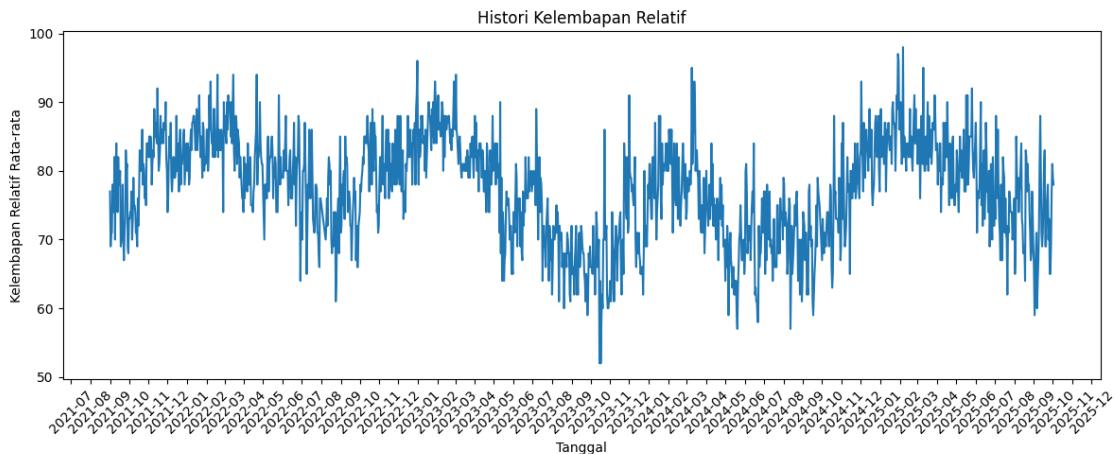
Seperti umumnya data cuaca, kedua variabel ini menunjukkan pola musiman, tren, dan fluktuasi harian yang kompleks, dipengaruhi oleh interaksi berbagai faktor meteorologis seperti pergerakan massa udara, musim, dan tekanan udara.

Karakteristik data cuaca sejalan dengan temuan Box et al. (2015) yang menyatakan bahwa data deret waktu meteorologi seringkali mengandung komponen tren, musiman, dan noise yang saling tumpang-tindih. Hal ini menunjukkan pentingnya penggunaan metode peramalan yang mampu menangkap pola linier dan non-linier, serta ketergantungan jangka panjang dalam data.



Gambar 1. Data Historis Suhu

Gambar 1 menunjukkan bahwa Kota Semarang memiliki pola fluktuasi yang konsisten dari tahun ke tahun. Suhu bergerak dalam rentang sekitar 26–31°C dengan variasi harian yang cukup tinggi, ditandai oleh perubahan nilai yang tajam dari hari ke hari. Pola musiman juga terlihat jelas, di mana suhu cenderung meningkat pada pertengahan hingga akhir tahun dan menurun pada awal tahun seiring masuknya musim hujan. Beberapa puncak suhu yang lebih tinggi, terutama pada periode 2023–2024, mengindikasikan adanya variabilitas iklim yang lebih intens, yang kemungkinan terkait dengan fenomena cuaca regional seperti El Niño. Meskipun terdapat beberapa outlier dengan penurunan suhu ekstrem, nilai-nilai tersebut tidak memengaruhi pola umum yang tetap mengikuti siklus musiman tahunan. Pola yang berulang sekaligus dinamis ini menjadi penting karena memberikan dasar yang kaya bagi model LSTM, GRU, dan GRU-LSTM dalam menangkap hubungan sekuensial jangka panjang maupun perubahan harian yang cepat.



Gambar 2. Data Historis Kelembapan Relatif

Sementara itu, Gambar 2 memperlihatkan pola yang saling melengkapi dengan suhu. Kelembapan berada pada kisaran 60–95%, menandakan kondisi udara yang lembap hampir sepanjang tahun. Kelembapan menunjukkan variabilitas yang lebih besar dibandingkan suhu, dengan perubahan cepat yang sangat dipengaruhi oleh kondisi harian seperti hujan, angin laut, dan perubahan tekanan udara. Pola musiman juga terlihat jelas, di mana kelembapan meningkat signifikan pada periode musim hujan dan menurun pada musim kemarau. Selain itu, terdapat kecenderungan korelasi terbalik antara suhu dan kelembapan: ketika suhu meningkat, kelembapan umumnya menurun, dan sebaliknya. Karakteristik ini penting dalam konteks pemodelan multivariat, karena hubungan antara kedua variabel dapat meningkatkan kemampuan model dalam melakukan prediksi. Kedua visualisasi tersebut secara keseluruhan menegaskan bahwa data suhu dan kelembapan di Semarang memiliki pola musiman yang kuat serta variabilitas harian yang tinggi, menjadikannya sangat sesuai untuk pendekatan berbasis jaringan saraf berulang seperti LSTM, GRU, dan model hibrida GRU-LSTM.

Tabel 1. Statistik Deskriptif

	Date	Tavg	RH_avg
Count	1486	1486	1486
Mean	2023-09-18	28.661725	77.374663
Min	2021-09-01	23.8	52
25%	2022-09-14	27.8	72
50%	2023-09-20	28.5	78
75%	2024-09-25	29.4	83
Max	2025-10-02	32.4	98
Std	NaN	1.282208	7.455894

Tabel statistik deskriptif menunjukkan gambaran umum data suhu rata-rata harian (Tavg) dan kelembapan relatif (RH_avg) di Kota Semarang selama periode pengamatan. Data terdiri dari 1.486 titik observasi dengan rentang waktu dari 1 September 2021 hingga 2 Oktober 2025. Nilai rata-rata suhu harian berada pada kisaran 28,66°C, dengan deviasi standar 1,28°C, yang menandakan bahwa fluktuasi suhu harian relatif stabil dan tidak terlalu menyimpang dari nilai tengahnya. Suhu minimum tercatat 23,8°C, sedangkan suhu maksimum mencapai 32,4°C, sehingga rentang data ini memperlihatkan dinamika suhu tropis yang cukup khas, namun tetap dalam batas wajar untuk wilayah pesisir.

Untuk kelembapan relatif, nilai rata-rata yang diperoleh adalah 77,37%, dengan deviasi standar 7,46%—lebih besar dibandingkan suhu, yang menunjukkan bahwa kelembapan mengalami fluktuasi harian yang lebih variatif. Kelembapan minimum tercatat 52%, sementara nilai maksimumnya mencapai 98%, menandakan bahwa kondisi lingkungan Semarang dapat berubah dari cukup kering hingga sangat lembap tergantung musim dan kondisi cuaca harian. Nilai kuartil juga memperlihatkan persebaran yang seimbang: Tavg berada pada 27,8°C (Q1), 28,5°C (median), dan 29,4°C (Q3); sedangkan RH_avg berada pada 72% (Q1), 78% (median), dan 83% (Q3). Pola ini menunjukkan distribusi data yang tidak terlalu skewed dan menggambarkan kondisi iklim lokal yang stabil secara jangka panjang, namun tetap memiliki variabilitas yang cukup untuk mempengaruhi kinerja model prediksi.

Secara keseluruhan, statistik ini menegaskan bahwa data suhu cenderung lebih stabil dibandingkan kelembapan, yang memiliki rentang perubahan lebih lebar. Kondisi tersebut penting dalam konteks pemodelan LSTM, GRU, dan GRU-LSTM karena model berbasis jaringan saraf berulang sangat sensitif terhadap pola fluktuasi dan distribusi data. Data yang relatif stabil pada suhu memungkinkan model lebih mudah menangkap pola musiman, sedangkan variabilitas kelembapan memberikan tantangan tambahan dalam prediksi tetapi juga menyediakan informasi dinamis yang kaya bagi model sekuenzial.

Tabel 2. Skewness dan Kurtosis Data

Suhu		Kelembapan	
Statistik	Nilai	Statistik	Nilai
Skewness	0,251	Skewness	-0,293
Kurtosis	0,161	Kurtosis	-0,362

Hasil analisis skewness dan kurtosis memberikan gambaran tambahan mengenai bentuk distribusi suhu rata-rata harian dan kelembapan relatif di Kota Semarang. Nilai skewness suhu sebesar 0,251 menunjukkan bahwa distribusi suhu memiliki kemencengan positif ringan. Artinya, sebagian besar data suhu cenderung berkumpul pada nilai yang sedikit lebih rendah dari rata-rata, sedangkan ekor distribusi memanjang ke arah nilai yang lebih tinggi. Kondisi ini konsisten dengan fenomena iklim tropis dimana hanya pada periode-periode tertentu, misalnya saat cuaca sangat panas atau terjadi gelombang panas, suhu melonjak lebih tinggi dari kondisi normal. Walaupun ada kecenderungan tersebut, nilai skewness yang kecil menandakan bahwa distribusi suhu relatif simetris dan tidak mengalami penyimpangan ekstrem. Nilai kurtosis suhu sebesar 0,161 memperkuat hal ini, menunjukkan bahwa distribusi memiliki peak yang mendekati distribusi normal, tanpa ekor tebal atau kejadian ekstrem yang terlalu sering.

Sementara itu, kelembapan relatif menunjukkan pola yang sedikit berbeda. Nilai skewness sebesar -0,293 mengindikasikan adanya kemencengan negatif ringan. Hal ini berarti data kelembapan cenderung lebih sering berada pada nilai yang lebih tinggi, sedangkan ekor distribusi memanjang ke arah nilai yang lebih rendah. Secara iklim, kondisi ini wajar mengingat Kota Semarang memiliki kelembapan udara yang tinggi sepanjang tahun, sehingga nilai kelembapan rendah terjadi lebih jarang dan hanya muncul pada kondisi tertentu seperti puncak musim kemarau. Nilai kurtosis kelembapan sebesar -0,362 menunjukkan bahwa distribusinya sedikit platykurtic, atau lebih “datar” dibanding distribusi normal. Artinya, kejadian ekstrem baik kelembapan yang sangat rendah maupun sangat tinggi tidak terlalu sering muncul, dan data lebih tersebar merata di sekitar nilai tengahnya.

Secara keseluruhan, kombinasi nilai skewness dan kurtosis ini menunjukkan bahwa baik suhu maupun kelembapan memiliki distribusi yang relatif mendekati normal. Hanya terdapat sedikit kecenderungan asimetri, dengan suhu condong ke arah nilai yang lebih

tinggi dan kelembapan condong ke arah nilai yang lebih rendah. Kondisi distribusi yang mendekati normal ini menguntungkan untuk proses pemodelan berbasis LSTM, GRU, dan GRU-LSTM, karena model dapat lebih mudah mengenali pola tanpa terlalu terganggu oleh outlier ekstrem atau distribusi yang terlalu miring.

2. Identifikasi dan Evaluasi Model LSTM, GRU, dan GRU-LSTM

Pemodelan dengan pendekatan *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), dan Hybrid GRU-LSTM dilakukan untuk menangkap pola nonlinier dan ketergantungan jangka panjang pada data *time series* suhu rata-rata harian (Tavg) dan kelembapan relatif (RH) yang tidak dapat diakomodasi secara optimal oleh model statistik konvensional. Dalam penelitian ini, pembangunan model dilakukan melalui proses optimasi hiperparameter menggunakan *Bayesian Optimization* berbasis *Tree-structured Parzen Estimator* (TPE) dengan bantuan pustaka Optuna.

Beberapa parameter yang dioptimasi meliputi jumlah lapisan tersembunyi (hidden layers), jumlah unit neuron pada masing-masing layer, tingkat dropout, jumlah epoch, serta ukuran batch. Proses optimasi dilakukan dengan time step yang ditetapkan sebesar 30, mengacu pada pola harian dalam data meteorologi. Berikut adalah hasil konfigurasi terbaik untuk setiap arsitektur dan variabel:

Tabel 3. Konfigurasi Model Terbaik Variabel Tavg

Model Terbaik	Layer	Neuron	Dropout	Epoch	Batch Size
LSTM_25_ts30	2	[28, 165]	0.2	87	16
GRU_32_ts30	5	[199, 140, 169, 218, 213]	0.3	21	16
GRU-LSTM_29_ts30	2	[62, 43]	0.2	42	8

Tabel 4. Konfigurasi Model Terbaik Variabel RH

Model Terbaik	Layer	Neuron	Dropout	Epoch	Batch Size
LSTM_21_ts30	3	[54, 62, 193]	0.1	54	8
GRU_26_ts30	4	[231, 169, 153, 97]	0.2	48	8
GRU-LSTM_36_ts30	5	[224, 228, 185, 9, 79]	0.4	57	8

Evaluasi terhadap model dilakukan menggunakan empat metrik utama, yaitu Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE), baik untuk data pelatihan maupun pengujian. Hasil evaluasi disajikan pada tabel berikut:

Tabel 5. Evaluasi Kinerja Model Terbaik untuk Variabel Tavg

Model	Kriteria	Train	Test
LSTM_25_ts30	MSE	0.5976	0.7000
	RMSE	0.7730	0.8367
	MAE	0.5968	0.6526
	MAPE	0.0210	0.0231
GRU_32_ts30	MSE	0.8654	0.6773
	RMSE	0.9303	0.8230
	MAE	0.7310	0.6302
	MAPE	0.0254	0.0223
GRU-LSTM_29_ts30	MSE	0.5983	0.6950
	RMSE	0.7735	0.8337
	MAE	0.6005	0.6500
	MAPE	0.0211	0.0230

Tabel 5. Evaluasi Kinerja Model Terbaik untuk Variabel RH

Model	Kriteria	Train	Test
LSTM_21_ts30	MSE	20.2245	25.7727
	RMSE	4.4972	5.0767
	MAE	3.4704	4.0077
	MAPE	0.0456	0.0522
GRU_26_ts30	MSE	19.9340	25.6265
	RMSE	4.4648	5.0623
	MAE	3.4419	4.0065
	MAPE	0.0454	0.0523
GRU-LSTM_36_ts30	MSE	18.9705	25.8059
	RMSE	4.3555	5.0799
	MAE	3.3634	4.0728
	MAPE	0.0440	0.0536

3. Perbandingan Hasil Prediksi Semua Model Terbaik

Berdasarkan evaluasi menyeluruh, model terbaik dari setiap arsitektur dipilih untuk memprediksi nilai Tavg dan RH 30 hari ke depan. Pemilihan model terbaik didasarkan pada nilai MSE yang paling optimal pada data testing.

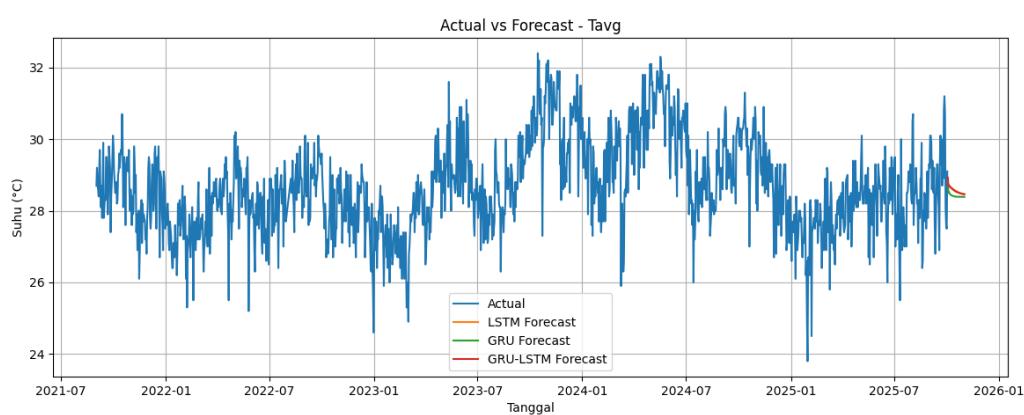
Tabel 6. Hasil Prediksi Tavg 30 Hari ke Depan

Tanggal	LSTM_25_ts30	GRU_32_ts30	GRU-LSTM_29_ts30
2025-10-03	28.7988	28.7715	28.9238
2025-10-04	28.6619	28.5045	28.6939
2025-10-05	28.6940	28.5180	28.7107
2025-10-06	28.6718	28.4798	28.6895
2025-10-07	28.6641	28.4626	28.6688
2025-10-08	28.6524	28.4468	28.6516
2025-10-09	28.6417	28.4347	28.6347
2025-10-10	28.6302	28.4251	28.6191
2025-10-11	28.6188	28.4175	28.6046
2025-10-12	28.6076	28.4115	28.5911
2025-10-13	28.5961	28.4068	28.5786
2025-10-14	28.5845	28.4030	28.5670
2025-10-15	28.5731	28.4000	28.5563
2025-10-16	28.5622	28.3976	28.5465
2025-10-17	28.5520	28.3957	28.5374
2025-10-18	28.5427	28.3942	28.5291
2025-10-19	28.5343	28.3930	28.5213
2025-10-20	28.5260	28.3920	28.5142
2025-10-21	28.5179	28.3912	28.5077
2025-10-22	28.5106	28.3906	28.5017
2025-10-23	28.5036	28.3901	28.4962
2025-10-24	28.4974	28.3897	28.4911
2025-10-25	28.4915	28.3894	28.4864
2025-10-26	28.4861	28.3892	28.4821
2025-10-27	28.4806	28.3890	28.4781
2025-10-28	28.4753	28.3888	28.4745
2025-10-29	28.4703	28.3887	28.4711
2025-10-30	28.4663	28.3886	28.4680

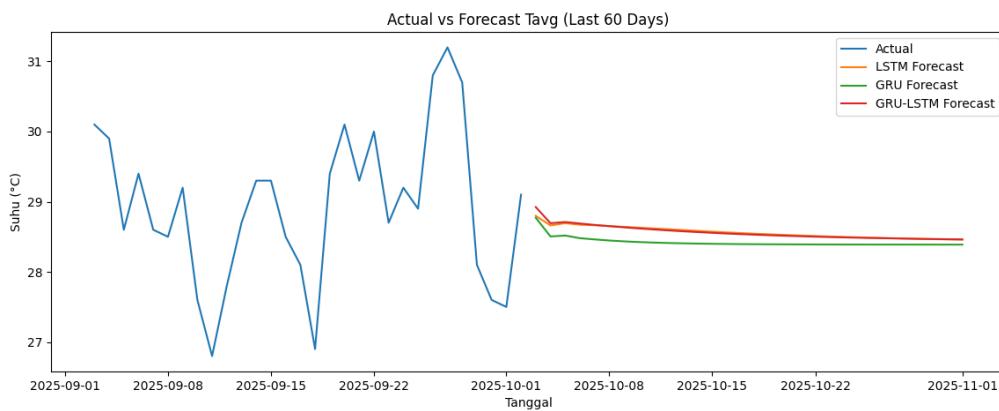
2025-10-31	28.4628	28.3885	28.4652
2025-11-01	28.4596	28.3884	28.4625

Tabel 7. Hasil Prediksi RH 30 Hari ke Depan

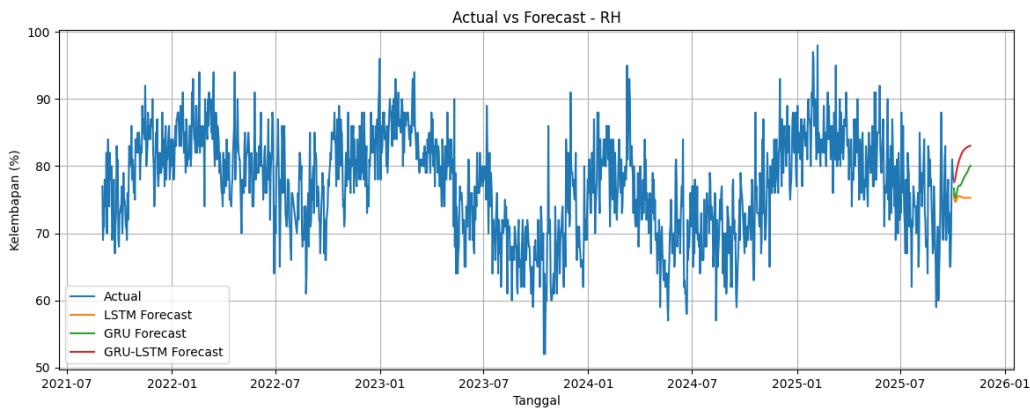
Tanggal	LSTM_21_ts30	GRU_26_ts30	GRU-LSTM_36_ts30
2025-10-03	75.9399	76.6973	77.6266
2025-10-04	75.0749	75.8682	77.6879
2025-10-05	74.7335	75.3905	77.9352
2025-10-06	74.6589	75.2690	78.4750
2025-10-07	74.8090	75.5235	78.9567
2025-10-08	75.0394	75.9834	79.4073
2025-10-09	75.2677	76.4673	79.7854
2025-10-10	75.4419	76.8327	80.1608
2025-10-11	75.5432	77.0256	80.4912
2025-10-12	75.5764	77.0913	80.7998
2025-10-13	75.5637	77.0960	81.0730
2025-10-14	75.5234	77.1124	81.3284
2025-10-15	75.4691	77.1912	81.5428
2025-10-16	75.4116	77.3419	81.7470
2025-10-17	75.3588	77.5393	81.9266
2025-10-18	75.3153	77.7444	82.0817
2025-10-19	75.2852	77.9539	82.2299
2025-10-20	75.2749	78.1463	82.3515
2025-10-21	75.2749	78.3340	82.4533
2025-10-22	75.2778	78.4863	82.5518
2025-10-23	75.2827	78.6208	82.6347
2025-10-24	75.2874	78.7505	82.6932
2025-10-25	75.2949	78.9092	82.7547
2025-10-26	75.2995	79.0394	82.8144
2025-10-27	75.3053	79.1956	82.8474
2025-10-28	75.3086	79.4049	82.9047
2025-10-29	75.3065	79.6344	82.9430
2025-10-30	75.2987	79.7983	82.9806
2025-10-31	75.2887	79.9315	83.0141
2025-11-01	75.2813	80.0524	83.0381



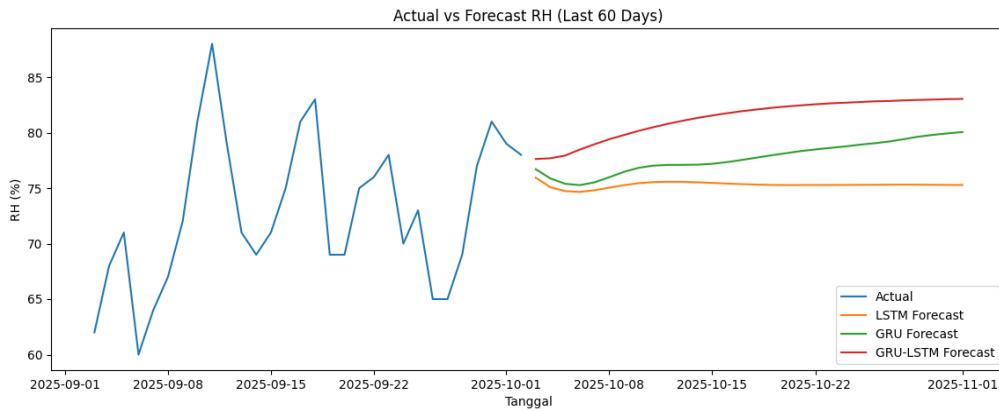
Gambar 3. Visualisasi Hasil Prediksi Tavg oleh Semua Model



Gambar 4. Visualisasi Tavg 60 Hari Terakhir



Gambar 5. Visualisasi Hasil Prediksi RH oleh Semua Model



Gambar 4. Visualisasi RH 60 Hari Terakhir

PENUTUP

Berdasarkan hasil penelitian, dapat disimpulkan bahwa:

1. Ketiga model *deep learning* (LSTM, GRU, GRU-LSTM) mampu menangkap pola non-linear dan ketergantungan jangka panjang dalam data suhu dan kelembapan dengan kinerja yang baik. Model LSTM dan GRU-LSTM menunjukkan stabilitas dan akurasi yang sangat kompetitif, khususnya dalam memprediksi suhu rata-rata harian.

2. Untuk variabel kelembapan relatif, perbedaan kinerja antarmodel relatif kecil, dengan model GRU dan GRU-LSTM menunjukkan efisiensi yang sedikit lebih baik dalam beberapa metrik evaluasi.
3. Optimasi hiperparameter menggunakan Bayesian Optimization berhasil menghasilkan konfigurasi model yang optimal untuk setiap arsitektur, dengan struktur dan parameter yang berbeda-beda sesuai karakteristik data.
4. Prediksi 30 hari ke depan yang dihasilkan oleh ketiga model menunjukkan konsistensi pola dan kecenderungan yang sesuai dengan sifat musiman iklim di Kota Semarang, sehingga dapat dijadikan dasar pertimbangan dalam perencanaan berbasis iklim.
5. Penelitian ini membuka peluang pengembangan lebih lanjut, seperti integrasi variabel meteorologi tambahan, pengujian pada cakupan wilayah yang lebih luas, serta implementasi model dalam sistem *early warning* berbasis *real-time* untuk mendukung kebijakan adaptasi perubahan iklim di tingkat lokal.

UCAPAN TERIMAKASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada orang tua tercinta, Siti Maryam dan Muhammad Zaenuri, atas cinta, doa, dukungan, dan pengorbanan yang diberikan selama masa perkuliahan. Ucapan terima kasih juga disampaikan kepada Dr. Iqbal Kharisudin, M.Sc. selaku dosen pembimbing atas arahan, bimbingan, dan masukan yang diberikan selama proses penelitian dan penulisan artikel ini. Penulis turut mengucapkan terima kasih kepada Putri, Feby, dan Era atas dukungan selama proses perkuliahan, serta kepada Akhmad Latif Mualim, S.H. atas dukungan, perhatian, ketulusan, dan semangat yang diberikan selama proses penulisan artikel ini. Selain itu, penulis menyampaikan apresiasi kepada Universitas Negeri Semarang khususnya Jurusan Matematika, atas fasilitas dan dukungan akademik yang menunjang terlaksananya penelitian ini. Terima kasih juga disampaikan kepada seluruh pihak yang telah memberikan dukungan, baik secara langsung maupun tidak langsung, yang tidak dapat disebutkan satu per satu.

REFERENSI

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). John Wiley & Sons.
- Brownlee, J. (2018). *Deep Learning for Time Series Forecasting Predict the Future with MLPs, CNNs and LSTMs in Python*.
- Dey, R., & Salem, F. M. (2017). *Gate-Variants of Gated Recurrent Unit (GRU) Neural Networks*. 2, 1597–1600.
- Handayani, N. W., Hadibasyir, H. Z., & Sigit, A. A. (2023). *Analysis of the Population Density Correlation with the Temperature Changes in the Semarang Area from 1999 to 2019* (Vol. 2035). Atlantis Press SARL. <https://doi.org/10.2991/978-2-38476-066-4>
- Judjianto, L., Rahayu, S., & Suryaningrum, D. A. (2023). *The Effect of Climate Change and Sustainable Agricultural Practices on Productivity and Food Security in Rural Areas in East Java*. 01(12), 1350–1359.
- Lecun, Y., Bengio, Y., Hinton, G., Lecun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. 521(7553), 436–444.
- Soyer, M. A. (2023). *An investigation of artificial neural network structure and its effects on the estimation of the low-cycle fatigue parameters of various steels*. April, 2929–2948. <https://doi.org/10.1111/fme.14054>
- Trivedi, D. V., & Patel, S. (2022). *An Analysis of GRU-LSTM Hybrid Deep Learning Models for 4099*, 47–52.