

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

Nida Nur Fadhilah¹, Iqbal Kharisudin²

¹ Matematika, FMIPA, Universitas Negeri Semarang

² Statistika dan Sains Data, FMIPA, Universitas Negeri Semarang

[1nidanf2103@gmail.com](mailto:nidanf2103@gmail.com), [2iqbalkharisudin@mail.unnes.ac.id](mailto:iqbalkharisudin@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) selama periode 1 September 2021 hingga 2 Oktober 2025, dengan total lebih dari 1.400 observasi. Data diproses melalui normalisasi dan pembentukan window deret waktu, kemudian dibagi menjadi 80% data pelatihan dan 20% data pengujian. Optimasi hiperparameter dilakukan menggunakan Bayesian Optimization berbasis Optuna untuk memperoleh konfigurasi model yang optimal. Evaluasi dilakukan menggunakan MSE, RMSE, MAE, dan MAPE. Hasil menunjukkan bahwa model LSTM dan GRU-LSTM memberikan performa terbaik dalam prediksi suhu harian, sementara perbedaan kinerja pada prediksi kelembapan relatif kecil antar model. Prediksi 30 hari ke depan menunjukkan pola yang konsisten dengan karakteristik musiman wilayah Semarang. Temuan ini menunjukkan bahwa pendekatan deep learning yang dioptimasi secara Bayesian efektif untuk pemodelan deret waktu meteorologis dan berpotensi mendukung sistem pemantauan iklim berbasis data.

Kata Kunci: deep learning; analisis runtun waktu; optimasi Bayesian; LSTM; GRU; prediksi meteorologi.

ABSTRACT

This study compares the performance of Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and hybrid GRU-LSTM models for forecasting daily average temperature and relative humidity in Semarang City, Indonesia. Secondary meteorological data from September 2021 to October 2025 were obtained from the Indonesian Meteorological Agency (BMKG). After normalization and time-window transformation, the dataset was split into 80% training and 20% testing sets. Bayesian hyperparameter optimization using Optuna was applied to enhance model performance. Evaluation results based on MSE, RMSE, MAE, and MAPE indicate that LSTM and GRU-LSTM achieved the most competitive performance in temperature forecasting, while model differences in humidity prediction were marginal. The 30-day ahead forecasts captured seasonal patterns consistent with local climatic characteristics. The findings highlight the effectiveness of optimized deep learning architectures for meteorological time series forecasting and their potential application in climate-informed decision support systems.

Keywords: deep learning; time series forecasting; Bayesian optimization; LSTM; GRU; meteorological prediction.

PENDAHULUAN

Prediksi parameter cuaca seperti suhu rata-rata harian dan kelembapan relatif merupakan aspek penting dalam kajian klimatologi serta perencanaan berbasis iklim. Informasi prediksi yang akurat diperlukan untuk mendukung berbagai sektor strategis, seperti pertanian, kesehatan masyarakat, mitigasi bencana, dan perencanaan wilayah

perkotaan. Di wilayah tropis seperti Indonesia, variabilitas cuaca yang tinggi serta pengaruh fenomena iklim global, seperti El Niño dan La Niña, menjadikan proses prediksi parameter cuaca sebagai tantangan yang kompleks. Kota Semarang sebagai wilayah pesisir dengan karakteristik iklim tropis lembap sering mengalami fluktuasi suhu dan kelembapan yang cukup dinamis, sehingga memerlukan pendekatan prediksi yang lebih akurat dan adaptif terhadap perubahan pola iklim (Handayani et al., 2023).

Secara tradisional, metode statistik seperti *Autoregressive Integrated Moving Average* (ARIMA) telah banyak digunakan dalam peramalan data runtun waktu (*time series*). Meskipun metode ini cukup efektif dalam memodelkan pola linier, kemampuannya terbatas dalam menangkap hubungan non-linear dan dependensi jangka panjang yang sering muncul pada data meteorologi (Box et al., 2015). Data cuaca pada umumnya memiliki karakteristik kompleks, seperti pola musiman, tren jangka panjang, serta interaksi *non-linear* antarvariabel atmosfer. Keterbatasan tersebut mendorong berkembangnya pendekatan berbasis *machine learning* dan *deep learning* yang mampu mempelajari pola kompleks secara lebih fleksibel (LeCun et al., 2015).

Dalam beberapa tahun terakhir, model *deep learning* khususnya jaringan saraf berulang (*Recurrent Neural Network* atau RNN) telah banyak digunakan dalam prediksi data runtun waktu. Dua arsitektur yang banyak dikembangkan adalah *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Model LSTM dirancang untuk mengatasi permasalahan *vanishing gradient* pada RNN dengan menggunakan mekanisme gerbang (*gate*) yang mampu mempertahankan informasi dalam jangka waktu yang panjang (Hochreiter & Schmidhuber, 1997). Sementara itu, GRU merupakan pengembangan dari LSTM dengan struktur yang lebih sederhana dan jumlah parameter yang lebih sedikit sehingga lebih efisien secara komputasi tanpa mengorbankan performa prediksi secara signifikan (Cho et al., 2014; Chung et al., 2014).

Selain penggunaan model tunggal, perkembangan penelitian terbaru juga mengarah pada pengembangan model hibrida yang menggabungkan keunggulan beberapa arsitektur *deep learning*. Salah satu pendekatan yang mulai banyak digunakan adalah model hibrida GRU-LSTM, yang mengombinasikan kemampuan GRU dalam efisiensi komputasi dengan kemampuan LSTM dalam mempelajari dependensi temporal jangka panjang. Pendekatan hibrida ini diharapkan dapat meningkatkan kemampuan model dalam menangkap pola kompleks pada data runtun waktu yang bersifat non-linear dan dinamis (Trivedi & Patel, 2022).

Beberapa penelitian sebelumnya telah menunjukkan potensi penggunaan model LSTM dan GRU dalam prediksi parameter cuaca. Shao et al. (2021) melakukan perbandingan antara LSTM dan GRU dalam memprediksi suhu dan kelembapan di wilayah subtropis dan menemukan bahwa GRU mampu menghasilkan tingkat akurasi yang sebanding dengan LSTM dengan waktu pelatihan yang lebih singkat. Penelitian lain oleh Trivedi dan Patel (2022) mengembangkan model hibrida GRU-LSTM untuk prediksi curah hujan dan menunjukkan peningkatan performa dibandingkan dengan model tunggal. Di Indonesia, penerapan *deep learning* untuk prediksi cuaca juga mulai berkembang. Akbar et al. (2023) menggunakan model LSTM untuk memprediksi temperatur di Kota Semarang menggunakan data BMKG periode 2019–2021 dan memperoleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1,896% serta *Root Mean Square Error* (RMSE) sebesar 0,725. Meskipun menunjukkan hasil yang cukup baik, penelitian tersebut hanya berfokus pada satu arsitektur model sehingga belum memberikan gambaran komparatif terhadap model lain. Penelitian lain oleh Rachmawati et al. (2023) menerapkan model GRU untuk memprediksi

kelembapan di Surabaya, namun kajian tersebut juga terbatas pada satu jenis model tanpa melakukan perbandingan dengan arsitektur lain.

Selain pemilihan arsitektur model, kinerja model *deep learning* juga sangat dipengaruhi oleh proses optimasi parameter atau *hyperparameter tuning*. Parameter seperti jumlah neuron, ukuran *batch*, jumlah *epoch*, serta *learning rate* memiliki peran penting dalam menentukan kemampuan model dalam mempelajari pola data secara optimal. Proses optimasi yang tepat dapat meningkatkan stabilitas pelatihan model serta menghasilkan prediksi yang lebih akurat pada data baru. Oleh karena itu, penerapan strategi optimasi menjadi aspek penting dalam meningkatkan performa model LSTM, GRU, maupun model hibrida GRU-LSTM pada prediksi data cuaca yang bersifat kompleks.

Berdasarkan telaah literatur tersebut, masih terdapat celah penelitian berupa belum adanya kajian komprehensif yang secara langsung membandingkan kinerja model LSTM, GRU, dan GRU-LSTM dalam memprediksi suhu rata-rata harian dan kelembapan relatif di wilayah tropis Indonesia, khususnya Kota Semarang yang memiliki karakteristik variabilitas cuaca yang cukup tinggi. Oleh karena itu, penelitian ini bertujuan untuk melakukan optimasi dan perbandingan kinerja ketiga model *deep learning* tersebut dalam memprediksi kedua parameter cuaca tersebut. Evaluasi performa model dilakukan berdasarkan tingkat akurasi prediksi serta efisiensi komputasi untuk menentukan model yang paling optimal.

Hasil penelitian ini diharapkan dapat memberikan kontribusi empiris dalam pengembangan metode prediksi cuaca berbasis *deep learning*, khususnya untuk wilayah tropis. Selain itu, temuan dari penelitian ini juga diharapkan dapat mendukung pengembangan sistem informasi iklim dan sistem peringatan dini berbasis data yang lebih akurat, sehingga dapat membantu proses pengambilan keputusan dalam berbagai sektor yang bergantung pada kondisi cuaca dan iklim.

METODE PENELITIAN

Analisis data dalam penelitian ini dilakukan secara sistematis melalui pendekatan kuantitatif dengan metode pemodelan time series (Box et al., 2015). Fokus utama penelitian adalah 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. Rangkaian analisis dilaksanakan dengan menggunakan bahasa pemrograman Python serta pustaka pendukung seperti TensorFlow/Keras, Pandas, NumPy, Matplotlib, dan Optuna untuk optimasi hiperparameter.

Data yang digunakan merupakan data sekunder yang diperoleh melalui unduhan langsung dari portal resmi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Stasiun Klimatologi Jawa Tengah (<https://dataonline.bmkg.go.id/>), mencakup periode 1 September 2021 hingga 2 Oktober 2025. Setelah data diperoleh, dilakukan tahap pengumpulan dan penyiapan data dengan teknik tidak langsung, termasuk pembersihan (*cleaning*) dan penyesuaian format agar data siap untuk diproses lebih lanjut.

Tahap analisis data diawali dengan *preprocessing data*, yang bertujuan untuk menyiapkan data dalam kondisi optimal sebelum pemodelan. Langkah pertama adalah penanganan nilai kosong (*missing values*), yang ditemukan pada beberapa tanggal tertentu. Untuk tanggal 2022-08-01 hingga 2022-08-07, nilai yang hilang untuk kedua variabel (suhu dan kelembapan) diisi menggunakan metode interpolasi rata-rata dari data tujuh hari sebelum dan tujuh hari setelahnya, yaitu dengan rumus $(h_{-7} + h_{+7}) / 2$ (Brownlee, 2018). Sementara itu, untuk tanggal-tanggal tertentu yang mengalami *missing value* secara individual

yaitu 2022-05-01, 2022-07-25, dan 2022-08-01 pada variabel kelembapan, serta 2023-05-11 dan 2023-12-01 pada variabel suhu dilakukan imputasi menggunakan rata-rata nilai hari sebelum dan hari setelahnya dengan rumus $(h_{-1} + h_{+1}) / 2$ (Judijanto et al., 2023). Langkah ini bertujuan untuk menjaga kontinuitas temporal tanpa mengganggu pola alami data. Selanjutnya, normalisasi data dilakukan menggunakan teknik *Min-Max Scaling* untuk mengubah seluruh nilai ke dalam rentang $[0, 1]$. Normalisasi penting untuk meningkatkan stabilitas numerik dan mempercepat konvergensi selama pelatihan model (Lecun et al., 2015).

Setelah *preprocessing data*, data dibagi menjadi subset pelatihan dan pengujian dengan menjaga urutan kronologis. Sebanyak 80% data awal digunakan sebagai data pelatihan (*training*), sedangkan 20% data terakhir digunakan sebagai data pengujian (*testing*). Pembagian ini dilakukan secara berurutan waktu untuk mematuhi prinsip dasar pemodelan *time series*, di mana model hanya menggunakan informasi masa lalu untuk memprediksi masa depan (Box et al., 2015).

Bayesian Optimization diformulasikan sebagai permasalahan optimasi global terhadap fungsi objektif tak diketahui $f: \mathcal{X} \rightarrow \mathbb{R}$, dengan tujuan memperoleh solusi $x^* \in \arg \max_{x \in \mathcal{X}} f(x)$ sebagaimana dirumuskan pada Bab 1 buku Garnett (2023). Dalam pendekatan Bayesian, fungsi objektif diperlakukan sebagai proses stokastik dengan prior $p(f)$, yang pada praktiknya sering dimodelkan menggunakan *Gaussian Process* (GP). Setelah diperoleh data observasi $D = (x, y)$, distribusi posterior fungsi dihitung melalui prinsip Bayes:

$$p(f | D) \propto p(f) p(y | x, f), \tag{1}$$

yang pada bentuk diskrit nilai fungsi $\phi = f(x)$ dituliskan sebagai

$$p(\phi | D) \propto p(\phi | x) p(y | x, \phi). \tag{2}$$

Posterior ini kemudian digunakan untuk membangun *acquisition function* $\alpha(x; D)$, yang menentukan lokasi evaluasi berikutnya dengan memaksimalkan:

$$x_{t+1} = \arg \max_{x \in \mathcal{X}} \alpha(x; D_t). \tag{3}$$

Salah satu *acquisition function* yang umum digunakan adalah *Expected Improvement* (EI), yang dirumuskan sebagai:

$$\alpha_{EI}(x) = (\mu(x) - f^+) \Phi(Z) + \sigma(x) \phi(Z), \tag{4}$$

dengan $Z = \frac{\mu(x) - f^+}{\sigma(x)}$, di mana $\mu(x)$ dan $\sigma(x)$ masing-masing adalah *mean* dan deviasi standar posterior *Gaussian Process*, serta $\Phi(\cdot)$ dan $\phi(\cdot)$ adalah fungsi distribusi dan densitas normal standar. Dengan demikian, *Bayesian Optimization* secara sistematis menggabungkan pembaruan posterior melalui inferensi Bayesian dan strategi eksplorasi–eksploitasi melalui optimasi *acquisition function*.

Tree-structured Parzen Estimator (TPE) merupakan varian *Bayesian Optimization* yang memodelkan distribusi parameter secara terbalik menggunakan prinsip Teorema Bayes. Alih-alih memodelkan $p(y | x)$ seperti pada pendekatan *Gaussian Process*, TPE memodelkan $p(x | y)$ dengan membagi observasi menjadi dua kelompok berdasarkan ambang performa y^* :

$$l(x) = p(x | y < y^*), g(x) = p(x | y \geq y^*). \tag{5}$$

Proses pemilihan kandidat selanjutnya dilakukan dengan memaksimalkan rasio:

$$x_{t+1} = \arg \max_x \frac{l(x)}{g(x)}, \tag{6}$$

yang ekuivalen dengan memaksimalkan Expected Improvement dalam bentuk alternatif. Dengan pendekatan density estimation non-parametrik ini, TPE tetap berada dalam kerangka Bayesian karena pembaruan distribusi dilakukan berdasarkan data yang diamati, namun tanpa mengasumsikan model Gaussian Process terhadap fungsi objektif.

Arsitektur *Long Short-Term Memory* (LSTM) diperkenalkan pada tahun 1997 untuk mengatasi keterbatasan *Recurrent Neural Network* (RNN), terutama masalah *vanishing gradient* dan *exploding gradient* saat pelatihan. LSTM menggunakan mekanisme gerbang (*gating mechanism*) untuk mengatur aliran informasi sehingga mampu menangkap dependensi jangka panjang secara lebih stabil dibandingkan RNN standar (Hochreiter & Schmidhuber, 1997; Goodfellow, 2016).

Lapisan input pada LSTM menerima urutan data dalam bentuk vektor $\mathbf{x} = (x_1, x_2, \dots, x_n)$, dengan n menyatakan panjang sekuens. Pada setiap waktu ke- t , model memproses pasangan (x_t, h_{t-1}) , di mana x_t adalah input saat ini dan h_{t-1} adalah *hidden state* dari waktu sebelumnya. Kombinasi keduanya menjadi dasar bagi perhitungan seluruh gerbang dalam sel LSTM.

Forget gate berfungsi untuk menentukan informasi mana dari *cell state* sebelumnya yang perlu dipertahankan atau dihapus. Mekanisme ini memungkinkan LSTM untuk mengontrol memori jangka panjang secara adaptif. Secara matematis, *forget gate* dirumuskan sebagai:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f). \quad (7)$$

Nilai f_t berada pada rentang 0 hingga 1 karena menggunakan fungsi sigmoid, sehingga setiap elemen pada *cell state* sebelumnya C_{t-1} dapat dilemahkan atau dipertahankan sesuai kebutuhan informasi.

Input gate berperan dalam mengatur informasi baru yang akan ditambahkan ke dalam *cell state*. Gerbang ini bekerja bersama kandidat nilai memori baru untuk memperbarui keadaan sel. Persamaan matematisnya adalah:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i). \quad (8)$$

Nilai i_t menentukan seberapa besar informasi baru akan disimpan, sehingga proses pembaruan memori tidak dilakukan secara sembarangan, melainkan terkontrol melalui bobot pembelajaran.

Output gate bertugas menentukan bagian mana dari *cell state* yang akan diteruskan sebagai keluaran atau *hidden state* saat ini. Dengan demikian, tidak seluruh informasi dalam memori jangka panjang langsung diekspos ke lapisan berikutnya. Persamaannya adalah:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o). \quad (9)$$

Nilai o_t kembali berada pada rentang 0 hingga 1 untuk mengatur proporsi informasi yang dikeluarkan.

Cell state merupakan komponen inti LSTM yang berfungsi sebagai jalur memori jangka panjang. Pertama, dihitung kandidat pembaruan memori sebagai:

$$c_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (10)$$

Selanjutnya, pembaruan *cell state* dilakukan dengan mengombinasikan hasil *forget gate* dan *input gate*:

$$c_t = f_t * c_{t-1} + i_t * c_t \quad (11)$$

Operator $*$ menyatakan perkalian elemen-per-elemen (*Hadamard product*). Mekanisme ini memungkinkan LSTM mempertahankan informasi penting dalam jangka panjang sekaligus menambahkan informasi baru yang relevan.

Keluaran LSTM pada waktu ke- t diperoleh dengan mengalikan hasil *output gate* dengan aktivasi hiperbolik dari *cell state*:

$$y_t = o_t * \tanh(C_t), \quad (12)$$

$$h_t = y_t$$

Nilai y_t merepresentasikan keluaran pada waktu tersebut dan sekaligus menjadi *hidden state* h_t yang diteruskan ke langkah waktu berikutnya. Kombinasi mekanisme ini menjadikan LSTM mampu menangkap dependensi jangka panjang secara lebih stabil dibandingkan RNN konvensional, sehingga tetap relevan dan banyak digunakan dalam berbagai aplikasi modern.

Gated Recurrent Unit (GRU) diperkenalkan sebagai varian yang lebih sederhana dari LSTM dengan struktur yang lebih ringkas namun tetap mampu menangani ketergantungan jangka panjang pada data sekuensial (Cho et al., 2014; Chung et al., 2014). Arsitektur ini menyederhanakan mekanisme gerbang dengan menggabungkan beberapa komponen pada LSTM, sehingga proses komputasi menjadi lebih efisien tanpa kehilangan kemampuan representasi yang signifikan.

Update gate berperan dalam menentukan seberapa besar informasi dari *hidden state* sebelumnya h_{t-1} akan dipertahankan untuk membentuk *hidden state* baru. Gerbang ini mengontrol keseimbangan antara memori lama dan informasi baru yang masuk pada waktu ke- t . Secara matematis dirumuskan sebagai:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z). \quad (13)$$

Nilai z_t berada pada rentang 0 hingga 1, sehingga mampu mengatur proporsi kontribusi informasi sebelumnya dalam pembaruan *state*.

Reset gate berfungsi untuk mengatur seberapa banyak informasi masa lalu yang perlu diabaikan sebelum membentuk kandidat *hidden state* baru. Mekanisme ini memungkinkan model lebih fokus pada pola jangka pendek ketika diperlukan. Persamaannya adalah:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r). \quad (14)$$

Nilai r_t mengontrol bagian dari h_{t-1} yang akan dipertimbangkan dalam pembentukan kandidat *state*.

Kandidat hidden state merepresentasikan informasi baru yang dihasilkan berdasarkan input saat ini dan *hidden state* sebelumnya yang telah difilter oleh *reset gate*. Dengan demikian, hanya informasi relevan dari masa lalu yang digunakan dalam pembaruan. Secara matematis dirumuskan sebagai:

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t * h_{t-1}) + b_h). \quad (15)$$

Proses ini memungkinkan GRU menghasilkan representasi baru yang adaptif terhadap konteks temporal.

Hidden state update merupakan tahap akhir pembaruan *state* pada waktu ke- t . Nilai akhir h_t diperoleh dari kombinasi antara *hidden state* sebelumnya dan kandidat *hidden state* baru, dengan proporsi yang dikendalikan oleh *update gate*. Persamaannya adalah:

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t. \quad (16)$$

Melalui mekanisme ini, GRU mampu mempertahankan informasi penting dalam jangka panjang sekaligus memperbarui *state* secara efisien, sehingga sering digunakan pada berbagai tugas pemodelan sekuensial dengan keterbatasan sumber daya komputasi (Gruber & Jockisch, 2020; Tony & Sasikumar, 2024).

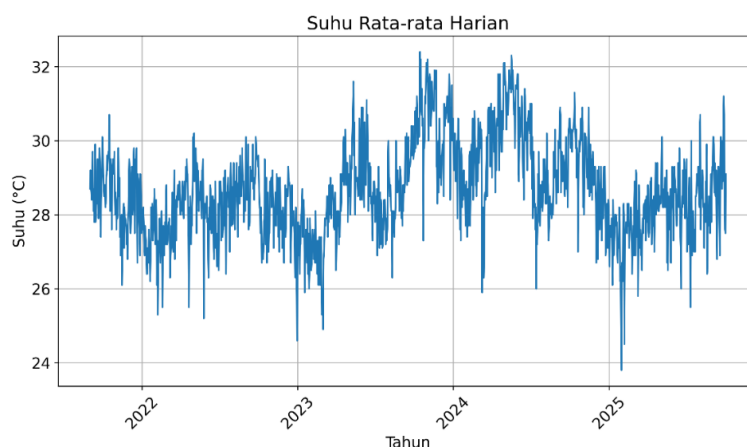
Sementara itu, model hibrida GRU-LSTM dikembangkan dengan menggabungkan lapisan GRU dan LSTM secara berurutan, bertujuan untuk memanfaatkan efisiensi GRU dan kemampuan memori jangka panjang dari LSTM (Dey & Salem, 2017; Trivedi & Patel,

2022). Untuk setiap arsitektur, optimasi *hyperparameter* dilakukan secara otomatis menggunakan *Bayesian Optimization* berbasis algoritma *Tree-structured Parzen Estimator* (TPE) yang diimplementasikan melalui pustaka Optuna. Parameter yang dioptimasi meliputi jumlah lapisan, jumlah unit *neuron*, *dropout rate*, *learning rate*, jumlah epoch, dan ukuran batch. Proses optimasi dilakukan dengan time step 7, untuk merepresentasikan satu siklus mingguan pada data harian.

Evaluasi model dilakukan dengan menggunakan empat metrik kinerja utama, yaitu *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Metrik-metrik ini dihitung baik pada data pelatihan maupun pengujian untuk menilai akurasi dan kemampuan generalisasi masing-masing model (Soyer, 2023). Evaluasi tidak hanya bertujuan untuk membandingkan kinerja model, tetapi juga untuk menganalisis karakteristik masing-masing arsitektur dalam menangkap kompleksitas data cuaca.

HASIL DAN PEMBAHASAN

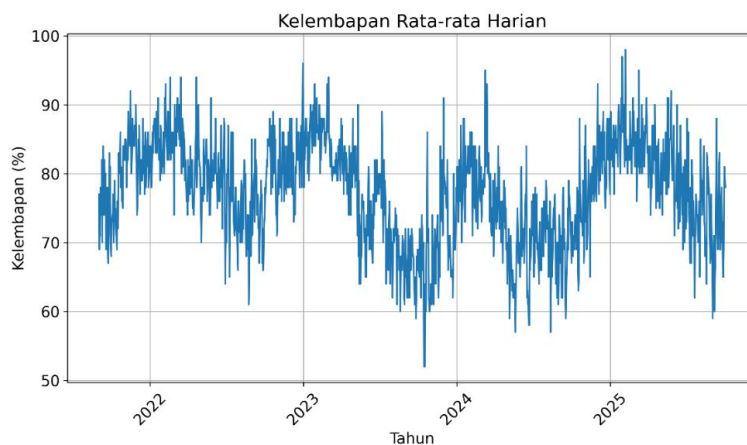
Data historis suhu rata-rata harian (T_{avg}) dan kelembapan relatif (RH) diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Stasiun Klimatologi Jawa Tengah untuk periode 1 September 2021 hingga 2 Oktober 2025. Sebelum analisis, data melalui tahap *preprocessing* untuk memastikan kualitas dan kesiapan data. Tahap pertama adalah identifikasi dan penanganan *missing values*. Terdapat dua kategori *missing values*: (1) rentang tanggal 2022-08-01 hingga 2022-08-07 untuk kedua variabel, dan (2) tanggal-tanggal tertentu yaitu 2022-05-01, 2022-07-25, dan 2022-08-01 untuk RH, serta 2023-05-11 dan 2023-12-01 untuk T_{avg} . Untuk rentang *missing values* yang berurutan, digunakan metode interpolasi berbasis rata-rata tujuh hari sebelum dan sesudahnya $((h-7)+(h+7))/2$, sementara untuk *missing values* tunggal digunakan rata-rata hari sebelum dan sesudahnya $((h-1)+(h+1))/2$ (Judijanto et al., 2023). Pendekatan ini dipilih untuk menjaga kontinuitas temporal dan pola musiman tanpa mengganggu struktur data asli. Setelah penanganan *missing values*, data dinormalisasi menggunakan teknik Min-Max Scaling ke rentang $[0, 1]$ untuk meningkatkan stabilitas numerik selama pelatihan model (Lecun et al., 2015). Data kemudian dibagi secara kronologis menjadi 80% data pelatihan dan 20% data pengujian.



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 | 1493 | 1493 | 1493 |
| Mean | 2023-09-18 | 28.662793 | 77.357502 |
| 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 | 1.281779 | 7.455254 |
|-----|-----|----------|----------|

Setelah melalui tahap *preprocessing*, termasuk penanganan missing values dan normalisasi, data akhir yang digunakan untuk pemodelan terdiri dari 1.493 observasi untuk setiap variabel (Tavg dan RH). Suhu rata-rata harian berkisar antara 23.8°C hingga 32.4°C dengan simpangan baku relatif rendah (1.28°C), menunjukkan fluktuasi suhu yang stabil sepanjang periode pengamatan. Sementara itu, kelembapan relatif memiliki rentang yang lebih lebar (52–98%) dengan simpangan baku yang lebih tinggi (7.46%), mengindikasikan variabilitas harian yang lebih besar. Distribusi data yang relatif simetris (ditunjukkan oleh nilai median yang mendekati mean) dan tidak adanya outlier ekstrem setelah imputasi mendukung kelayakan data untuk pemodelan berbasis *deep learning*.

Pemodelan dilakukan menggunakan tiga arsitektur *deep learning*: LSTM, GRU, dan model hibrida GRU-LSTM. Untuk meningkatkan kinerja model, optimasi hiperparameter dilakukan menggunakan *Bayesian Optimization* berbasis algoritma *Tree-structured Parzen Estimator* (TPE) yang diimplementasikan melalui pustaka Optuna (Bergstra et al., 2011). Metode ini dipilih karena kemampuannya dalam mengeksplorasi ruang parameter secara efisien dengan memanfaatkan informasi dari evaluasi sebelumnya. Parameter yang dioptimasi meliputi jumlah lapisan (1–5), jumlah unit neuron per lapisan (32–256), dropout rate (0.1–0.5), learning rate (0.001–0.01), jumlah epoch (maksimal 200), dan ukuran batch (8, 16, 32). Proses optimasi dilakukan dengan time step 7, yang dipilih karena tidak ada pola autokorelasi dalam data. Hasil konfigurasi terbaik untuk setiap model disajikan pada Tabel 2 dan 3.

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 4. Evaluasi Kinerja Model Terbaik untuk Variabel Tavg

| Model | Kriteria | Train | Test |
|----------|----------|--------|--------|
| LSTM | MSE | 0.6461 | 0.7053 |
| | RMSE | 0.8038 | 0.8398 |
| | MAE | 0.6381 | 0.6458 |
| | MAPE | 0.0221 | 0.0231 |
| GRU | MSE | 0.6510 | 0.7086 |
| | RMSE | 0.8069 | 0.8418 |
| | MAE | 0.6402 | 0.6418 |
| | MAPE | 0.0222 | 0.0230 |
| GRU-LSTM | MSE | 0.6341 | 0.7134 |
| | RMSE | 0.7963 | 0.8446 |
| | MAE | 0.6304 | 0.6450 |
| | MAPE | 0.0219 | 0.0231 |

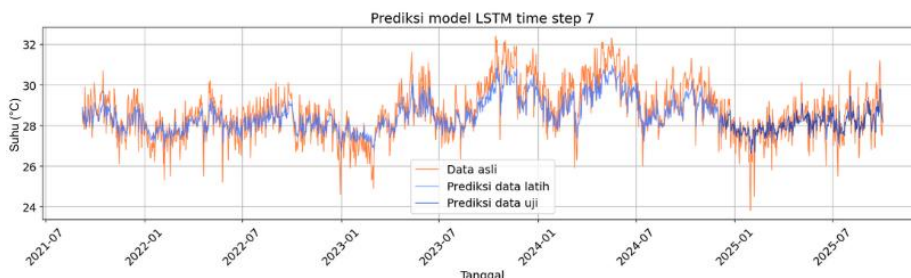
Tabel 5. Evaluasi Kinerja Model Terbaik untuk Variabel RH

| Model | Kriteria | Train | Test |
|-------|----------|---------|---------|
| LSTM | MSE | 20.3055 | 23.9377 |
| | RMSE | 4.5062 | 4.8926 |
| | MAE | 3.4671 | 3.8108 |


| | | | |
|----------|------|---------|---------|
| GRU | MAPE | 0.0460 | 0.0484 |
| | MSE | 20.3276 | 23.9386 |
| | RMSE | 4.5086 | 4.8927 |
| | MAE | 3.4839 | 3.8394 |
| | MAPE | 0.0466 | 0.0489 |
| GRU-LSTM | MSE | 20.4417 | 23.9843 |
| | RMSE | 4.5212 | 4.8974 |
| | MAE | 3.5034 | 3.8245 |
| | MAPE | 0.0468 | 0.0488 |

Kinerja model dievaluasi menggunakan empat metrik, *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil evaluasi pada data pengujian untuk variabel Tav_g dan RH disajikan pada Tabel 4 dan 5. Untuk variabel Tav_g, model LSTM mencapai nilai MSE terendah (0.7053), diikuti oleh GRU (0.7086) dan GRU-LSTM (0.7134). Sementara untuk variabel RH, ketiga model menunjukkan kinerja yang sangat mirip dengan MSE berkisar antara 23.94–23.98. Secara keseluruhan, model LSTM dan GRU-LSTM menunjukkan stabilitas yang lebih baik dalam prediksi suhu, sedangkan untuk kelembapan, perbedaan kinerja antarmodel relatif kecil. Hasil ini sejalan dengan temuan Shao et al. (2021) yang menyatakan bahwa baik LSTM maupun GRU mampu menangkap pola kompleks dalam data cuaca dengan akurasi yang setara.

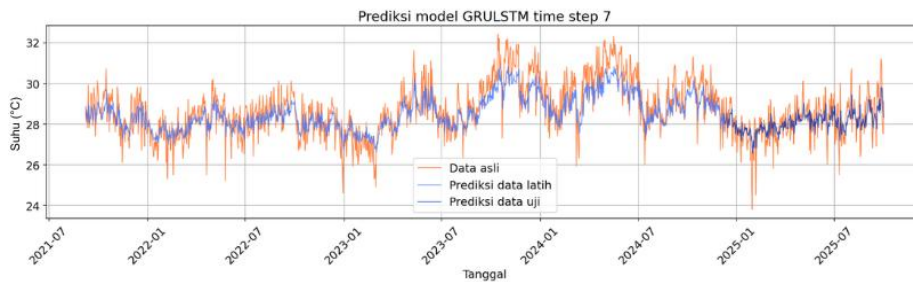
Gambar 3, 4, dan 5 masing-masing menampilkan hasil prediksi RH menggunakan model LSTM, GRU-LSTM, dan GRU dengan time step 7 yang dibandingkan dengan data aktual. Secara umum, ketiga model mampu mengikuti pola fluktuasi suhu harian serta tren musiman yang terlihat pada data historis, termasuk fase kenaikan RH pada pertengahan periode dan penurunan pada awal tahun berikutnya. Garis prediksi pada data latih maupun data uji sebagian besar bertumpang-tindih dengan data asli, menunjukkan kemampuan model dalam menangkap pola utama deret waktu. Namun, ketiga model cenderung menghaluskan lonjakan ekstrem, sehingga beberapa puncak dan lembah tajam tidak sepenuhnya terprediksi. Perbedaan pola prediksi antar model relatif kecil, sehingga model hibrida GRU-LSTM tidak menunjukkan peningkatan performa yang signifikan dibandingkan LSTM dan GRU sebagai model tunggal.



Gambar 3. Visualisasi Hasil Prediksi RH oleh Model LSTM

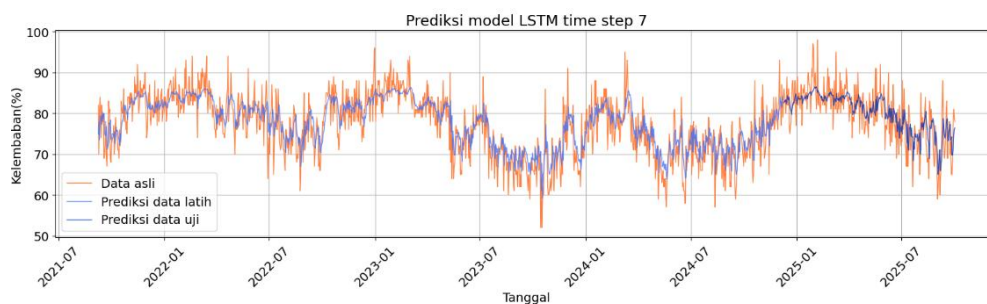


Gambar 4. Visualisasi Hasil Prediksi RH oleh Model GRU

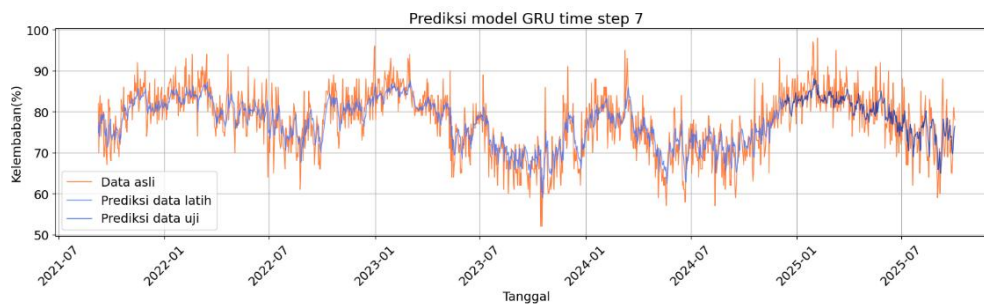


Gambar 5. Visualisasi Hasil Prediksi RH oleh model GRU-LSTM

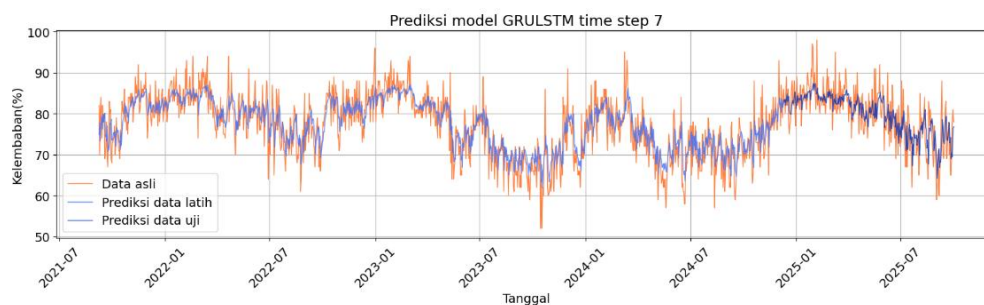
Berdasarkan visualisasi pada Gambar 3, 4, dan 5 masing-masing menampilkan hasil prediksi kelembapan (RH) menggunakan model GRU-LSTM, GRU, dan LSTM dengan time step 7, yang dibandingkan dengan data aktual pada periode pengamatan. Secara umum, ketiga model mampu mengikuti pola fluktuasi dan tren musiman yang terlihat pada data historis, ditunjukkan oleh garis prediksi yang bertumpang-tindih dengan data asli baik pada data latih maupun data uji. Meskipun masih terdapat deviasi pada beberapa titik ekstrem, pola naik-turun kelembapan tahunan tetap dapat ditangkap dengan baik. Perbedaan kinerja antar model relatif kecil, dengan hasil prediksi yang hampir serupa, sehingga menunjukkan bahwa ketiganya efektif dalam merepresentasikan dinamika temporal data kelembapan. Temuan ini mengindikasikan bahwa penambahan arsitektur hibrida GRU-LSTM belum memberikan peningkatan yang signifikan dibandingkan model tunggal pada konfigurasi yang digunakan.



Gambar 6. Visualisasi Hasil Prediksi Tavg oleh Model LSTM



Gambar 7. Visualisasi Hasil Prediksi Tavg oleh Model GRU



Gambar 8. Visualisasi Hasil Prediksi Tavg oleh Model GRU-LSTM

PENUTUP

Hasil penelitian ini mengonfirmasi bahwa ketiga model deep learning LSTM, GRU, dan GRU-LSTM memiliki kemampuan yang baik dalam menangkap pola non-linear dan ketergantungan jangka panjang dalam data suhu rata-rata harian dan kelembapan relatif di Kota Semarang. Khususnya, model LSTM dan GRU-LSTM menunjukkan kinerja yang kompetitif dan stabil dalam prediksi suhu, sementara untuk prediksi kelembapan, perbedaan performa antar model relatif kecil dengan model GRU dan GRU-LSTM menunjukkan efisiensi komputasi yang lebih baik dalam beberapa evaluasi metrik.

Penerapan optimasi hiperparameter menggunakan Bayesian Optimization berhasil menghasilkan konfigurasi optimal yang berbeda untuk setiap arsitektur, sesuai dengan karakteristik masing-masing variabel prediksi. Hal ini memperkuat pentingnya penyesuaian parameter dalam penerapan model deep learning untuk data time series meteorologi. Prediksi 30 hari ke depan yang dihasilkan oleh ketiga model konsisten dengan pola musiman yang ada, menunjukkan kemampuan model dalam mengidentifikasi tren iklim lokal, sehingga dapat menjadi dasar pertimbangan dalam perencanaan berbasis iklim.

Penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem prediksi cuaca berbasis deep learning untuk wilayah tropis, sekaligus membuka peluang pengembangan lebih lanjut seperti integrasi variabel meteorologi tambahan, ekspansi cakupan geografis, dan implementasi dalam sistem peringatan dini real-time untuk mendukung kebijakan adaptasi perubahan iklim di tingkat lokal. Temuan ini tidak hanya memperkaya literatur akademik tetapi juga menawarkan nilai aplikatif dalam mendukung sektor-sektor seperti pertanian, kesehatan, dan manajemen bencana berbasis data.

REFERENSI

Akbar, R., Fadilah, N., & Kurniawan, A. (2023). Prediksi Suhu Harian di Kota Semarang Menggunakan Long Short-Term Memory (LSTM) Berbasis Data BMKG. *Jurnal*

- Komputasi Dan Sains*, 7(2), 45–56.
- 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*.
- Cho, K., Merriënboer, B. van, Gülçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*. 1–9.
- 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>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
- Judijanto, 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.
- Rachmawati, S., Hidayat, R., & Prasetyo, Y. (2023). Penerapan Gated Recurrent Unit (GRU) untuk Prediksi Kelembapan Udara di Surabaya. *Prosiding Seminar Nasional Sains Dan Teknologi*, 10(1), 112–120.
- Shao, H., Li, Y., & Zhang, X. (2021). A Comparative Study of LSTM and GRU for Weather Forecasting in Subtropical Regions. *Journal of Atmospheric and Oceanic Technology*, 38(5), 789–801.
- 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/ffe.14054>
- Trivedi, D. V., & Patel, S. (2022). *An Analysis of GRU-LSTM Hybrid Deep Learning Models for*. 4099, 47–52.
- Goodfellow, I. 2016. *Deep Learning*. MIT Press.