

**PREDIKSI SUHU MAKSIMUM BERBASIS DEEP LEARNING DENGAN MODEL
LONG SHORT-TERM MEMORY DAN GATED RECURRENT UNIT
(STUDI KASUS WILAYAH CIPUTAT)**

**DEEP LEARNING-BASED MAXIMUM TEMPERATURE PREDICTION USING A
LONG SHORT-TERM MEMORY MODEL AND GATE RECURRENT UNIT
(CIPUTAT AREA CASE STUDY)**

Hesti Rahayuningsih¹, Tukiya², Abu Khalid Rivai³

Universitas Pamulang, Tangerang Selatan, Banten^{1,2,3}

hestirahayuningsih79@gmail.com¹

ABSTRACT

Maximum temperature prediction is an important aspect of meteorological studies because it affects various sectors, including agriculture, public health, energy management, and urban planning. Ciputat is a relevant location for local climate prediction studies, as it has experienced extreme temperatures reaching 37.2 °C on April 17, 2023. This study aims to compare the performance of Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) models in predicting daily maximum temperature in the Ciputat area and to determine the best-performing model. The dataset consists of daily maximum temperature, rainfall, humidity, and air pressure data from 2009 to 2025 obtained from BMKG Region II Ciputat, representing seasonal variability and long-term tropical climate patterns. Model evaluation is conducted using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Coefficient of Determination (R^2), and Mean Absolute Percentage Error (MAPE). The evaluation results indicate that the LSTM model outperforms the GRU model in predicting maximum temperature based on all evaluation metrics. The findings are expected to support the development of more accurate deep learning-based temperature prediction methods and serve as a reference for climate risk mitigation decision-making.

Keywords: Temperature prediction, LSTM, GRU, Deep Learning, Ciputat

ABSTRAK

Prediksi suhu maksimum merupakan hal yang penting dalam kajian meteorologi karena berpengaruh terhadap berbagai sektor, seperti pertanian, kesehatan masyarakat, manajemen energi, dan perencanaan wilayah. Wilayah Ciputat menjadi lokasi yang relevan untuk studi prediksi iklim lokal, karena pernah sebagai wilayah dengan suhu ekstrem sebesar 37,2 °C pada 17 April 2023. Penelitian ini bertujuan untuk membandingkan kinerja model **Long Short-Term Memory (LSTM)** dan **Gated Recurrent Unit (GRU)** dalam memprediksi suhu maksimum harian di wilayah Ciputat serta menentukan model dengan performa terbaik. Data yang digunakan meliputi suhu maksimum harian, curah hujan, kelembapan, dan tekanan udara periode 2009–2025 yang diperoleh dari BMKG Wilayah II Ciputat, sehingga merepresentasikan variabilitas musiman dan pola iklim tropis jangka panjang. Evaluasi model dilakukan menggunakan metrik *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, *Coefficient of Determination (R^2)*, dan *Mean Absolute Percentage Error (MAPE)*. Hasil evaluasi menunjukkan model LSTM dengan performa yang lebih baik dalam memprediksi suhu maksimum dibandingkan model GRU berdasarkan nilai *MAE*, *RMSE*, R^2 dan *MAPE*. Hasil penelitian ini diharapkan dapat mendukung pengembangan metode prediksi suhu berbasis deep learning yang lebih akurat serta menjadi referensi dalam pengambilan keputusan terkait mitigasi risiko iklim.

Kata Kunci: Prediksi suhu maksimum, LSTM, GRU, Deep learning, Ciputat.

PENDAHULUAN

Ciputat adalah salah satu kecamatan yang terletak di Kota Tangerang Selatan, Provinsi Banten di ujung barat Pulau Jawa, Indonesia, dengan koordinat geografis sekitar 5°07'50" LU - 7°01'11" LS dan 105°01'11" BT - 106°07'12" BT (Sumber: Website Resmi Pemerintah Provisni Banten, 2025). Berdasarkan tinjauan

geografis, suhu maksimum harian di Ciputat dipengaruhi oleh kombinasi faktor regional dan lokal. Secara regional, iklim tropis muson Banten akan menentukan pola suhu musiman. Namun, pada skala lokal Ciputat, efek *urban heat island* dan kepadatan aktivitas manusia yang kemungkinan besar menjadi faktor dominan yang meningkatkan suhu

maksimum harian dan menyebabkan variabilitas yang kompleks.

Penelitian terkait prediksi suhu umumnya mengandalkan metode statistik dan model linier yang mengasumsikan hubungan sederhana antar variabel atmosfer. Penelitian berbasis *deep learning* telah mulai dilakukan, yang membuktikan efektivitas LSTM dan GRU dalam memprediksi parameter suhu dan cuaca di beberapa wilayah Indonesia.

Tujuan dari penelitian ini untuk menganalisis serta membandingkan efektivitas kinerja model *deep learning*, khususnya *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi suhu maksimum di Ciputat. Penelitian ini diharapkan tidak hanya berkontribusi pada pengembangan metode prediksi meteorologi berbasis *machine learning*, tetapi juga memberikan manfaat praktis dalam pengembangan sistem peringatan dini cuaca ekstrem dan perencanaan tata kota berkelanjutan di wilayah perkotaan Indonesia.

Machine learning (ML) adalah bidang kecerdasan buatan yang berfokus pada pembelajaran komputer untuk memperoleh pengetahuan dari data atau pengalaman masa lalu untuk memecahkan masalah tertentu (Pratama et al., 2025).

Data meteorologi, seperti suhu, secara intrinsik bersifat deret waktu, menunjukkan ketergantungan temporal yang kuat. Meskipun model statistik tradisional seperti ARIMA telah lama digunakan, keterbatasan dalam menangkap *non-linearitas* dan dependensi jangka panjang telah mendorong inovasi dalam bidang pembelajaran mesin, khususnya *deep learning* (Song et al., 2025)

TINJAUAN PUSTAKA

Prediksi suhu maksimum harian merupakan salah satu tantangan dalam meteorologi karena sifat data suhu yang sangat dipengaruhi oleh pola musiman, tren jangka panjang, dan fluktuasi harian (Carnegie & Chairani, 2023). Metode tradisional seperti regresi linier dan

ARIMA seringkali kurang mampu menangkap kompleksitas data deret waktu meteorologi, sehingga pendekatan berbasis *deep learning* menjadi solusi yang semakin banyak digunakan (Montolalu et al., 2024).

Dalam beberapa tahun terakhir, model *deep learning* telah menunjukkan kinerja superior dalam prediksi deret waktu, termasuk aplikasi meteorologi, karena kemampuannya dalam memodelkan dinamika temporal yang rumit (Lim & Zohren, 2021). Secara teknis, *deep learning* adalah suatu bentuk *machine learning* yang terdiri dari lebih dari satu *hidden layer*, dengan setiap *layer* mempunyai jumlah *node* yang berbeda (Rizki et al., 2020).

Prediksi suhu dan cuaca merupakan salah satu tantangan terbesar dalam ilmu atmosfer, contohnya kondisi atmosfer yang berubah-ubah tidak stabil, kesalahan pengukuran, data yang terlalu besar, dan pemahaman yang tidak lengkap terhadap performansi prakiraan cuaca yang dihasilkan (Intan et al., 2021). Sistem cuaca memiliki sifat chaotic yang membuat prediksi jangka panjang menjadi sangat sulit (Molina et al., 2023).

Iklim adalah kondisi cuaca suatu tempat dalam jangka waktu panjang (lebih dari satu dekade), iklim dipengaruhi oleh letak geografis, ketinggian tempat (*altitude*), topografi, jarak dari laut, vegetasi. Unsur iklim yaitu suhu, curah hujan, kelembapan, tekanan udara, angin, dan penyinaran matahari.

Sinar matahari pada suatu bidang atau area tertentu adalah faktor utama penyebab suhu udara, sedangkan yang menyebabkan suhu udara tinggi atau rendah adalah sifat benda dan daerah tertentu seperti sifat pantul dan penyerap sinar matahari. Suhu udara permukaan diukur dari ketinggian 1,20 - 1,25 meter di atas permukaan tanah dan diamati menggunakan thermometer bola kering (Arsali, A., Satya, O. C., Supardi, S., & Purna, 2015). Tekanan udara merupakan salah satu faktor yang dapat mempengaruhi kelembapan udara dan suhu. Tekanan udara dapat dipengaruhi beberapa pengaruh seperti temperature

ditempat ketinggian, perairan laut serta daratan (Saputra et al., 2024)

Suhu maksimum harian merujuk pada nilai suhu tertinggi yang tercatat dalam periode 24 jam. Dinamikanya dipengaruhi oleh interaksi kompleks antara faktor-faktor meteorologis seperti radiasi matahari, tutupan awan, kelembaban, kecepatan angin, serta karakteristik geografis lokal (Zhang et al., 2022).

Prediksi suhu maksimum harian yang akurat memiliki implikasi signifikan di berbagai sektor. Dalam pertanian, informasi ini esensial untuk optimalisasi jadwal irigasi, manajemen risiko stres panas pada tanaman, dan menentukan waktu tanam yang optimal berkontribusi signifikan terhadap peningkatan produktivitas di sektor pertanian. (Lin et al., 2021). *Applied Sciences* menggabungkan LSTM dengan *Genetic Algorithm* untuk weather forecasting, membuktikan bahwa optimisasi hyperparameter dapat meningkatkan performa model secara signifikan (Teixeira et al., 2024).

Penelitian serupa menggunakan LSTM dan GRU dengan judul “Pengembangan Model Prediksi Curah Hujan di Kota Denpasar Menggunakan Metode LSTM dan GRU” (Wayan & Suranata, n.d.).

Penelitian serupa yang berjudul “Perbandingan Long Short -Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk Prediksi Curah Hujan di Lampung Utara” (Carnegie & Chairani, 2023).

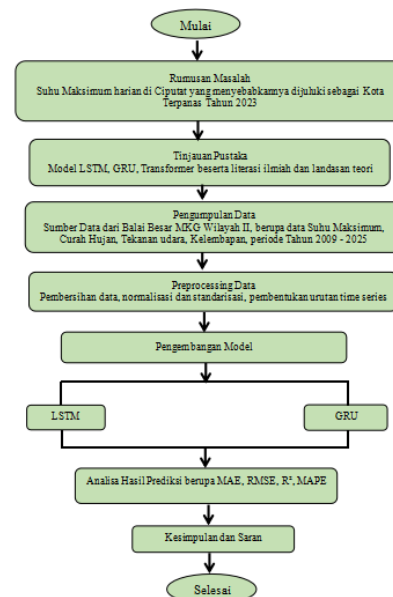
Penelitian menggunakan LSTM dan GRU yang berjudul “*Climate change predict hybrid deep learning model in al Qassim region*” oleh (Alotaibi et al., 2018).

Penelitian yang sama yang berjudul “Deep Learning Approach Using the GRU-LSTM Hybrid Model for Air Temperature Prediction on Daily Basis”, jumlah parameter input sangat mempengaruhi kinerja model dalam memprediksi suhu udara menggunakan model LSTM dan GRU (Sari et al., 2022). Penelitian komparatif dalam *ResearchGate* menunjukkan bahwa *hybrid* GRU-LSTM

model memberikan performa superior dalam prediksi suhu harian dibandingkan model individual, dengan tingkat akurasi yang lebih stabil. Penelitian dalam jurnal *AIP Advances* menunjukkan bahwa model LSTM dapat mencapai akurasi tinggi dalam prediksi suhu dengan minimal data training, menjadikannya kandidat kuat untuk aplikasi forecasting masa depan (Yan et al., 2025).

METODE

Pada Gambar 1. Menunjukkan alur penelitian, yang menjelaskan secara terperinci mengenai tahapan yang diambil dalam penelitian.



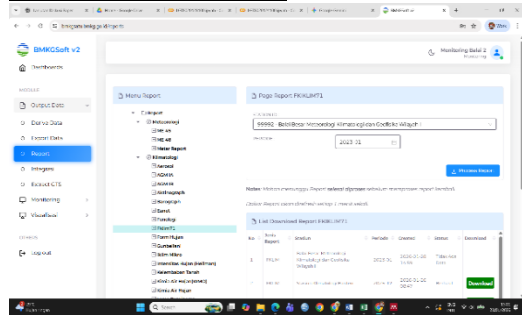
Gambar 1. Alur Penelitian

Tahapan penelitian

Setiap tahapan pada pada Gambar 1. disusun dan dipastikan dapat menghasilkan model yang dapat memprediksi secara akurat dengan data yang dikumpulkan dan selanjutnya diolah. Berikut penjelasan tahapan penelitian sesuai Gambar 1.

1. Rumusan masalah mengenai suhu maksimum harian Ciputat yang menyebabkannya dijuluki sebagai Kota Terpanas di tahun 2023.
2. Tinjauan Pustaka yang bersumber dari publikasi jurnal dan landasan teori untuk mendukung penelitian ini.
3. Pengumpulan dan sumber data, berasal dari Balai Besar Meteorologi,

Klimatologi dan Geofisika Wilayah II Ciputat, dengan data suhu maksimum harian, Curah hujan, tekanan udara, dan kelembapan rata-rata periode tahun 2009 - 2025. Pengumpulan data dilakukan dengan mengunduh melalui portal website BMKGSoft pada url berikut <https://bmkgsatu.bmkg.go.id/reports>. dan tampilannya ditunjukkan pada Gambar di bawah ini.



Gambar 2. Halaman Download Data

- Preprocessing data yaitu melakukan pembersihan, normalisasi dan standarisasi data dan pembentukan urutan time series. Pembersihan pada nilai tidak terukur (data 8888).

TGL	TEMPERATUR °C						CURAH Hujan DITAKAR JAM 07.00-16.00 (mm)	PENYINARAN MATAHARI (% 10.00-16.00)	PERISTIAHA CUACA KHUSUS
	07.00	13.00	18.00	RATA ²	MAX	MIN			
01	26,2	33,0	30,4	29,2	34,6	26,2	0	7,8	
02	25,7	33,4	31,8	29,1	35,0	24,6	0	8,0	
03	25,6	33,0	29,0	27,3	33,6	24,8	0	8,0	
04	25,1	31,9	28,2	26,6	32,7	25,1	82	3,8	
05	24,8	32,6	24,6	26,7	33,0	23,4	68	4,3	
06	25,0	33,2	31,1	28,6	33,5	25,0	26	6,7	
07	26,0	32,6	30,2	28,7	32,8	24,4	0	6,9	
08	25,8	30,8	29,9	28,1	32,2	25,8	0	5,3	
09	26,0	32,0	30,0	28,5	33,6	25,4	0	4,4	
10	24,4	33,0	30,2	28,0	33,0	23,8	0	5,4	
11	25,6	30,6	29,4	26,6	31,0	25,4	0	6,8	
12	25,2	28,6	24,0	25,8	29,4	25,0	17	2,2	
13	24,0	30,8	28,8	26,9	31,6	23,4	29	0,0	
14	25,0	29,8	27,0	26,7	31,4	23,4	1	7,1	
15	24,2	32,2	29,8	27,6	33,4	23,4	1	1,3	
16	24,6	32,3	29,8	27,8	33,5	24,5	0	6,9	
17	25,0	33,0	30,4	28,4	33,4	24,8	0	7,5	
18	26,2	32,6	27,8	28,2	32,8	25,0	0	8,0	
19	24,4	28,0	28,0	26,2	29,0	24,4	6	3,7	
20	25,2	31,8	24,4	26,6	32,0	24,6	3	0,0	
21	23,8	31,6	29,2	27,1	32,8	23,8	14	2,7	
22	25,2	32,0	30,4	28,2	32,9	25,2	0	4,7	
23	26,0	32,6	27,0	27,9	32,8	25,6	0	7,1	
24	25,2	31,8	27,2	27,4	33,0	25,0	5	5,2	
25	24,8	31,3	24,7	26,4	32,1	24,8	1	6,1	
26	23,8	32,6	30,4	27,6	33,2	23,0	25	4,4	
27	24,8	34,3	31,3	28,8	35,6	24,8	0	6,9	
28	26,0	32,4	30,0	28,6	32,8	24,6	0	8,0	
29	24,7	33,2	26,8	27,3	34,4	24,7	52	3,8	
30	25,4	30,8	29,2	27,7	31,4	24,0	14	7,3	
31	24,8	31,8	30,0	27,9	32,0	24,2	3	3,4	
Jumlah	778,5	991,0	879,0	856,7	1014,5	762,1	377	163,5	
Rata ²	25,1	32,0	28,4	27,6	32,7	24,6	12,6	5,3	
T Min abs					0°C				
T Max abs					35,6°C				
Hari Hujan (>=1 mm)					18 hari				

Gambar 3. Halaman Data Fklm 71

Normalisasi data dilakukan dengan menggunakan *MinMaxScaler* dengan mengubah nilai suhu maksimum dalam suatu dataset ke rentang tertentu, seperti 0 hingga 1 sebelum digunakan sebagai input model. Dataset dibuat dalam data dasarian yang ditunjukkan pada Gambar 3, dan grafiknya seperti Gambar 4 dibawah ini.

Tahun	Bulan	Dasarian	Tx	Tanggal	
0	2009	8	1	32.86	2009-08-05
1	2009	8	2	34.06	2009-08-15
2	2009	8	3	33.50	2009-08-25
3	2009	9	1	34.38	2009-09-05
4	2009	9	2	34.88	2009-09-15


Gambar 4. Dataset Bentuk Dasarian



Gambar 5. Grafik Dataset dalam Dasarian

Pemodelan LSTM.

LSTM mempunyai tiga *gates* dan satu *memory cell* yang mampu melupakan atau menghafal informasi untuk menentukan berapa banyak informasi yang harus ditransfer ke sel selanjutnya (Tholib et al., 2023) seperti gambar arsitektur di bawah ini.



Gambar 6. Arsitektur LSTM

Tahapan pemrosesan pada model LSTM meliputi:

- Input gate:**

$$i_t = \sigma(W_i \times X_i + U_i \times h_{t-1} + b_i)$$
- Forget gate:**

$$f_t = \sigma(W_f \times X_i + U_f \times h_{t-1} + b_f)$$
- Cell State:**

$$c_t = \sigma(W_c \times X_i + U_c \times h_{t-1} + b_c)$$
- New Candidate:**

$$c_t = \sigma(W_c \times X_i + U_c \times h_{t-1} + b_c)$$
- Output gate:**

$$o_t = \sigma(W_o \times X_i + U_o \times h_{t-1} + b_o)$$
- Hidden State:**

$$h_t = o_t \odot \sigma(c_t)$$

Dimana:

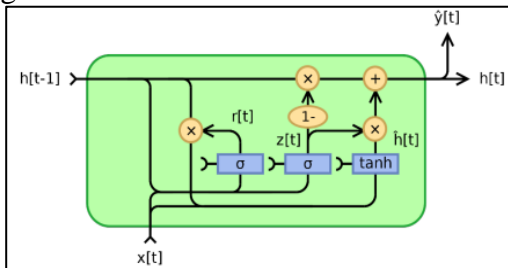
W = Bobot

U = hidden state

$c_t = cell\ state$
 $c'_t = tanh\ layer$
 $\sigma = fungsi\ aktivasi\ sigmoid$

Pemodelan GRU

GRU memiliki komponen yang disebut *gate* berfungsi untuk mengatur alur informasi model GRU. GRU hanya mempunyai dua gate, yaitu *reset gate* dan *update gate*. *Reset gate* pada GRU menggabungkan *input* baru dengan informasi masa lalu (Ripto & Heryanto, 2023), yang dideskripsikan seperti gambar di bawah ini.



Gambar 7. Arsitektur GRU

Tahapan pemrosesan pada model GRU meliputi:

1. *Update gate*:
 $z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z)$
2. *Reset gate*:
 $r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r)$
3. *Current memory content*:
 $\tilde{h} = \tanh(W_h x_t + r_t * U_h h_{t-1} + b_h)$
4. *Final Memory*:
 $h_t = z_t * h_{(t-1)} + (1 - z_t) * \tilde{h}$

Dimana:

$z = Update\ gate$

$x_t = Input$

$r = Reset\ gate$

$U = hidden\ state$

$h = Final\ Memory$

$b = Bias\ Vector$

$\sigma = fungsi\ aktivasi\ sigmoid$


$\tilde{h} = Current\ Memory\ content$

$Tanh = fungsi\ aktivasi\ tanh$


$W = Bobot$

GRU dapat menghasilkan prediksi *runoff* yang akurat tanpa memerlukan optimasi *time step* yang kompleks, menunjukkan efisiensi komputasi yang baik (Gao et al., 2020).

5. Pemodelan prediksi dengan menggunakan model LSTM dan GRU. Pembagian data pelatihan dan data uji untuk menguji kinerja model. Pemodelan dengan LSTM dan GRU ditunjukkan dalam gambar di bawah ini.



Gambar 8. Pemodelan LSTM



Gambar 9. Pemodelan GRU

6. Metrik Evaluasi, pada proses ini dilakukan evaluasi kinerja model dengan menganalisa grafik yang dihasilkan dari data asli dan data prediksi. Selain itu juga dilakukan evaluasi terhadap nilai error pada tiap-tiap model berupa *MAE*, *RMSE*, *RSquare* dan *MAPE*.

Formulasi MAE:

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

Formulasi RMSE:

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

Formulasi R²:

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

Formulasi MAPE:

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

Dimana:

$n = Jumlah\ data$

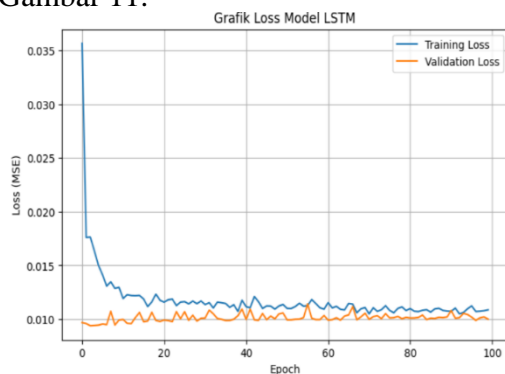
$y_i = nilai\ aktual\ ke-i$

$\hat{y}_i = nilai\ prediksi\ ke-i$

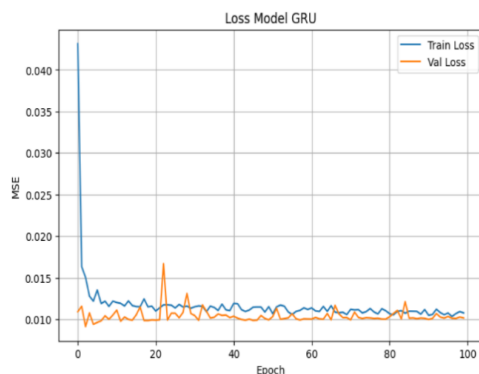
$\bar{y}_i = rata-rata\ nilai\ aktual$

$R^2 = Koefisien\ Determinan$

Selain itu untuk evaluasi performa model juga dilakukan dengan menganalisis kurva pembelajaran (*loss curve*) pada data observasi dengan hasil prediksi. Berdasarkan grafik *loss* model LSTM dan GRU, terlihat *Training Loss* dan *Validation Loss* diawal epoch mengalami penurunan yang tajam pada dan mencapai titik konvergensi yang stabil tanpa indikasi *overfitting*. Hal ini menunjukkan model mempunyai kemampuan generalisasi yang baik untuk mengenali pola fluktuasi suhu maksimum dasarian, seperti yang ditunjukkan pada Gambar 10. dan Gambar 11.



Gambar 10. Grafik Loss LSTM



Gambar 11. Grafik Loss GRU

7. Kesimpulan dan Saran.

HASIL DAN PEMBAHASAN

Penelitian ini diuji coba dengan beberapa pengujian dengan menggunakan skenario hyperparameter antara lain: *epoch* 25, 50, 100, data pelatihan dan data uji 90:10, 80:20, 70:30, *batch size* 4, 8 serta *learning rate* 0.001 dan 0.0001, sehingga

didapatkan hasil metrik evaluasi terbaik ditampilkan pada tabel di bawah ini.

Tabel 1. Hasil Evaluasi Model LSTM dan GRU

MODEL	MAE	RMSE	R ²	MAPE
LSTM	0.739	0.925	0.533	2.2%
GRU	0.798	0.974	0.481	2.3%

Berdasarkan tabel di atas, **model LSTM memberikan kinerja yang lebih baik daripada GRU** dalam memprediksi suhu maksimum. Hal ini ditunjukkan nilai **MAE LSTM sebesar 0,739** lebih rendah daripada GRU 0,798, artinya rata-rata kesalahan absolut prediksi LSTM lebih kecil. Hal serupa pada **RMSE**, LSTM nilainya **0,925** lebih rendah dibanding GRU **0,974**, ini membuktikan LSTM lebih stabil dalam menangani fluktuasi suhu ekstrem dibanding GRU.

Kemampuan model menjelaskan variasi data, **nilai R² LSTM sebesar 0,533** lebih tinggi daripada GRU 0,481, artinya LSTM mampu menjelaskan sekitar **53,3% variasi suhu maksimum**, sedangkan GRU hanya sekitar **48,1%**. Artinya, struktur memori jangka panjang pada LSTM lebih efektif dalam menangkap pola temporal data suhu yang memiliki ketergantungan waktu (time dependency), seperti pengaruh kelembapan, tekanan udara, dan lama penyinaran matahari terhadap suhu maksimum harian.

Selain itu, nilai **MAPE LSTM sebesar 2,2%** yang lebih kecil dibandingkan GRU 2,3% mengindikasikan bahwa kesalahan prediksi relatif terhadap nilai aktual sangat rendah (di bawah 5%), sehingga kedua model sebenarnya sudah masuk kategori **sangat baik**, namun LSTM tetap unggul secara konsisten di semua metrik evaluasi. Dengan demikian pada penelitian ini disimpulkan bahwa **model LSTM merupakan model terbaik** dalam untuk prediksi suhu maksimum, karena memberikan tingkat kesalahan paling kecil serta kemampuan generalisasi yang lebih baik terhadap pola deret waktu meteorologi.

KESIMPULAN

Penelitian berbasis *deep learning* model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi suhu di wilayah Ciputat, dapat disimpulkan bahwa kedua model mampu memodelkan pola deret waktu meteorologi dengan tingkat akurasi yang baik.

Model LSTM secara keseluruhan menunjukkan performa yang lebih unggul dibandingkan GRU pada seluruh metrik evaluasi yang digunakan. LSTM menghasilkan nilai kesalahan yang lebih rendah (*MAE*, *RMSE*, dan *MAPE*) serta nilai koefisien determinasi (R^2) yang lebih tinggi. Hasil ini menunjukkan bahwa mekanisme memori jangka panjang pada LSTM lebih mampu menangkap pola kompleks dan fluktuasi suhu maksimum yang dipengaruhi oleh variabel meteorologis seperti kelembapan, tekanan udara, dan curah hujan.

Kedua model memiliki nilai *MAPE* yang rendah menunjukkan bahwa pendekatan *deep learning* dapat memberikan prediksi suhu maksimum yang presisi dan berpotensi mendukung kebutuhan analisis iklim lokal, perencanaan sektor pertanian, manajemen energi, serta mitigasi dampak perubahan cuaca ekstrem di wilayah Ciputat. Dengan demikian, LSTM dapat direkomendasikan sebagai model terbaik dalam penelitian ini untuk prediksi suhu maksimum berbasis data deret waktu meteorologi.

DAFTAR PUSTAKA

Alotaibi, K., Ghumman, A. R., Haider, H., Ghazaw, Y. M., & Shafiquzzaman, M. (2018). Future predictions of rainfall and temperature using GCM and ANN for arid regions: A case study for the Qassim region, Saudi Arabia. *Water (Switzerland)*, 10(9). <https://doi.org/10.3390/w10091260>

Arsali, A., Satya, O. C., Supardi, S., & Purna, I. (2015). PENENTUAN KOEFISIEN UNTUK PERHITUNGAN SUHU UDARA

RATA-RATA HARIAN DATA STASIUN KLIMATOLOGI PALEMBANG. *Jurnal Meteorologi Dan Geofisika*, 16((1)). <https://doi.org/https://doi.org/10.31172/jmg.v16i1.260>

Carnegie, M. D. A., & Chairani, C. (2023). Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan. *Jurnal Media Informatika Budidarma*, 7(3), 1022.

<https://doi.org/10.30865/mib.v7i3.6213>

Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., & Lin, Q. (2020). Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188.

<https://doi.org/10.1016/j.jhydrol.2020.125188>

Intan, I., Rismayani, Aminah Dinayati Ghani, S., Nurdin, & Koswara, A. T. (2021). Analisis Performansi Prakiraan Cuaca Menggunakan Algoritma Machine Learning. *Jurnal Pekommas*, 6(2), 1–8. <https://doi.org/10.30818/jpkm.2021.2060221>

Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>

Lin, M. L., Tsai, C. W., & Chen, C. K. (2021). Daily maximum temperature forecasting in changing climate using a hybrid of Multi-dimensional Complementary Ensemble Empirical Mode Decomposition and Radial Basis Function Neural Network. *Journal of Hydrology: Regional Studies*, 38(September), 100923.

- <https://doi.org/10.1016/j.ejrh.2021.100923>
- Molina, M. J., O'Brien, T. A., Anderson, G., Ashfaq, M., Bennett, K. E., Collins, W. D., Dagon, K., Restrepo, J. M., & Ullrich, P. A. (2023). A Review of Recent and Emerging Machine Learning Applications for Climate Variability and Weather Phenomena. *Artificial Intelligence for the Earth Systems*, 2(4), 1–17. <https://doi.org/10.1175/aies-d-22-0086.1>
- Montolalu, V., Munaiseche, C., & Krisnanda, M. (2024). Analisis Performa Autoregressive Integrated Moving Average Model dan Deep Learning Long Short-Term Memory Model untuk Peramalan Data Cuaca. *JOINTER: Journal of Informatics Engineering*, 5(02), 8–21. <https://doi.org/10.53682/jointer.v5i02.112>
- Pratama, A. R., Wabula, F., Ilmandry, H., Isabela, M. L., & Sianipar, R. (2025). *Literature Review The Impact of Machine Learning in Modern Industries. 2021*.
- Ripto, J. A., & Heryanto, H. (2023). Penerapan Gated Recurrent Unit untuk Prediksi Pergerakan Harga Saham pada Bursa Efek Indonesia. *Institut Teknologi Harapan Bangsa*.
- Rizki, M., Basuki, S., & Azhar, Y. (2020). Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory(LSTM) Untuk Prediksi Curah Hujan Kota Malang. *Jurnal Repositor*, 2(3), 331–338. <https://doi.org/10.22219/repositor.v2i3.470>
- Saputra, E. P., Ginanjar, S., Kusumo, A. T., & Saryoko, A. (2024). Monitoring Tekanan Udara Berbasis Internet of Things Menggunakan Thingsboard untuk Kontrol Ruangan. *Jurnal Riset Dan Aplikasi Mahasiswa Informatika (JRAMI)*, 5(4), 869–876. <https://doi.org/10.30998/jrami.v5i4.10973>
- Sari, Y., Arifin, Y. F., Novitasari, N., & Faisal, M. R. (2022). Deep Learning Approach Using the GRU-LSTM Hybrid Model for Air Temperature Prediction on Daily Basis. *International Journal of Intelligent Systems and Applications in Engineering*, 10(3), 430–436.
- Song, X., Deng, L., Wang, H., Zhang, Y., & He, Y. (2025). *Deep learning-based time series forecasting*.
- Teixeira, R., Cerveira, A., Pires, E. J. S., & Baptista, J. (2024). Enhancing Weather Forecasting Integrating LSTM and GA. *Applied Sciences (Switzerland)*, 14(13), 1–23. <https://doi.org/10.3390/app14135769>
- Tholib, A., Agusmawati, N. K., & Khoiriyah, F. (2023). PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3). <https://doi.org/10.23960/jitet.v11i3.3250>
- Wayan, I., & Suranata, A. (n.d.). *Pengembangan Model Prediksi Curah Hujan di Kota Denpasar Menggunakan Metode LSTM dan GRU*.
- Yan, K., Gan, J., Sui, Y., Liu, H., Tian, X., Lu, Z., & Ali Abdo, A. M. (2025). An LSTM neural network prediction model of ultra-short-term transformer winding hotspot temperature. *AIP Advances*, 15(3). <https://doi.org/10.1063/5.0213051>
- Zhang, T., Zhou, Y., Wang, L., Zhao, K., & Zhu, Z. (2022). Estimating 1 km gridded daily air temperature using a spatially varying coefficient model with sign preservation. *Remote Sensing of Environment*, 277, 113072. <https://doi.org/10.1016/j.rse.2022.113072>