

# Perbandingan Metode Deep Learning dengan Model LSTM dan GRU untuk Prediksi Perubahan Iklim

Amin Mustofa\*, Hendra Setiawan

Teknologi Industri, Magister Rekayasa Elektro, Universitas Islam Indonesia, Yogyakarta, Indonesia

Email: <sup>1</sup>\*22925001@students.uii.ac.id, <sup>2</sup>Hendrasetiawan@uui.ac.id

Email Penulis Korespondensi: 22925001@students.uui.ac.id

Submitted: 24/07/2024; Accepted: 13/08/2024; Published: 13/08/2024

**Abstrak**—Iklim memainkan peran kritis dalam menentukan kualitas kehidupan di Indonesia, yang menuntut pemahaman mendalam melalui klasifikasi iklim Koppen dan teknologi terkini. Dari pertanian hingga infrastruktur perkotaan, kesehatan publik, hingga keberlangsungan ekosistem, setiap aspek kehidupan kita dipengaruhi oleh kondisi iklim. Metode Deep Learning seperti Long Short-Term Memory (LSTM) dan Gated Recurrent Units (GRU) digunakan untuk memprediksi data time series karena kemampuan adaptifnya dalam mempelajari pola data yang kompleks. Model LSTM dan GRU diuji dengan data 2010-2021 menggunakan batch\_size 64, epochs 150, optimizer adam, dan menunjukkan akurasi tinggi (<10%). LSTM mencatat MAPE: Curah Hujan 5,50%, Kelembaban 7,60%, Temperatur 4,36%, Penyinaran Matahari 8,29%. GRU mencatat MAPE: Curah Hujan 5,01%, Kelembaban 6,86%, Temperatur 4,35%, Penyinaran Matahari 8,28%. Prediksi 2028 menunjukkan Daerah Istimewa Yogyakarta memiliki iklim Monsun Tropis (Am), Sabana Tropis (As), dan Hutan Hujan Tropis (Af). Perubahan iklim ini berdampak signifikan: peningkatan curah hujan meningkatkan risiko banjir, mengancam infrastruktur dan kehidupan, sementara iklim As mengurangi produktivitas pertanian dan meningkatkan kerawanan pangan. Perubahan curah hujan dan temperatur mempengaruhi kesehatan masyarakat, dengan kelembapan tinggi meningkatkan risiko penyakit tropis dan suhu tinggi menyebabkan heat stress. Perubahan iklim pada tipe Am meningkatkan risiko banjir dan tanah longsor, sedangkan pada tipe Af mengancam ekosistem hutan hujan tropis.

**Kata Kunci:** Iklim; Deep learning; LSTM; GRU; Klasifikasi Koppen

**Abstract**—Climate plays a critical role in determining the quality of life in Indonesia, which demands in-depth understanding through the Koppen climate classification and the latest technology. From agriculture to urban infrastructure, public health, to ecosystem sustainability, every aspect of our lives is affected by climate conditions. Deep Learning methods such as Long Short-Term Memory (LSTM) and Gated Recurrent Units (GRU) are used to predict time series data because of their adaptive ability in learning complex data patterns. The LSTM and GRU models were tested with 2010-2021 data using batch\_size 64, epochs 150, optimizer adam, and showed high accuracy (<10%). LSTM recorded MAPE: Rainfall 5.50%, Humidity 7.60%, Temperature 4.36%, Sunlight 8.29%. GRU recorded MAPE: Rainfall 5.01%, Humidity 6.86%, Temperature 4.35%, Sunlight 8.28%. Predictions for 2028 show that the Special Region of Yogyakarta has a Tropical Monsoon (Am), Tropical Savannah (As) and Tropical Rain Forest (Af) climate. These climate changes have significant impacts: increased rainfall increases the risk of flooding, threatening infrastructure and lives, while the As climate reduces agricultural productivity and increases food insecurity. Changes in rainfall and temperature affect people's health, with high humidity increasing the risk of tropical diseases and high temperatures causing heat stress. Climate change in the Am type increases the risk of floods and landslides, while in the Af type it threatens tropical rainforest ecosystems.

**Keywords:** Climate; Deep Learning; LSTM; GRU; Koppen Classification

## 1. PENDAHULUAN

Daerah Istimewa Yogyakarta, yang terletak di Pulau Jawa dan dikelilingi oleh pegunungan serta laut, memiliki karakteristik geografis unik, sejarah panjang, dan budaya yang kaya[1]. Namun, di balik keunikan tersebut, perubahan iklim dapat mengancam keseimbangan ekosistem dan kehidupan sehari-hari penduduknya[2][3]. Iklim memainkan peran penting dalam berbagai sektor kehidupan masyarakat, khususnya pertanian, perikanan, kesehatan, dan pariwisata[4]. Variabilitas iklim dapat memberikan dampak signifikan pada aspek-aspek tersebut, terutama di kawasan tropis seperti Indonesia[5][6].

Selama dekade terakhir, perubahan iklim dan variabilitasnya telah menjadi fokus perhatian bagi pemerintah dan peneliti di seluruh dunia[7]. Perubahan pola hujan, peningkatan temperatur, dan perubahan kelembapan udara dapat memberikan dampak langsung dan tidak langsung pada kehidupan masyarakat di Yogyakarta, seperti banjir di Sleman yang dapat dikaitkan dengan kurangnya kesiapan dalam menghadapi bencana, akibat dari perubahan iklim yang tidak menentu[5]. Dampak lain dari perubahan iklim mencakup kekeringan yang berdampak negatif pada produktivitas pertanian[8]. Tanpa kesiapan yang memadai dalam menghadapi kekeringan, petani dapat mengalami kerugian signifikan. Perubahan iklim global telah menjadi topik diskusi yang signifikan di seluruh dunia, dengan implikasi serius terhadap ekosistem, cuaca, pertanian, dan banyak aspek lain dari kehidupan manusia[9], [10]. Menurut Lisa, seorang petugas di divisi Data dan Informasi BMKG, model prediksi iklim yang digunakan oleh BMKG mencakup model statistik, yang mengandalkan nilai statistik dari data curah hujan historis, dan model dinamik, yang mempertimbangkan kondisi atmosfer, termasuk fenomena El Niño, yang diprediksi dapat menyebabkan musim kemarau yang lebih panjang[11].

Banyak penelitian telah membahas prediksi iklim dengan menggunakan model statistik dan dinamis. Kedua model tersebut efektif dalam memproses data historis untuk mengidentifikasi tren dan pola, namun sering kali kurang fleksibel dalam menyesuaikan diri dengan perubahan non-linier dan anomali dalam data iklim[12].

Model dinamis menawarkan kemampuan dalam memodelkan proses fisik yang kompleks tetapi membutuhkan asumsi dan parameterisasi yang sulit diverifikasi. Kedua model ini memiliki keterbatasan dalam mengakomodasi kompleksitas dan variabilitas data iklim yang tinggi, sehingga muncul pertanyaan tentang bagaimana meningkatkan akurasi prediksi iklim di Daerah Istimewa Yogyakarta[13]. Metode *deep learning* dapat mengatasi masalah berkaitan dengan kompleksitas data yang besar. Model yang biasa digunakan untuk *deep learning* terkait dengan prediksi yaitu LSTM dan GRU. Model *Gated Recurrent Unit* (GRU), menawarkan efisiensi yang lebih baik dari segi komputasi dan memori dibandingkan dengan LSTM. Ini dilengkapi dengan mekanisme pembaruan dan penghapusan yang memudahkan jaringan dalam mengidentifikasi dependensi jangka panjang tanpa menghadapi masalah *vanishing gradient*[14].

Kedua metode ini dipilih karena keunikan mereka dalam mengatasi ketergantungan jangka panjang yang sering ditemukan dalam data deret waktu. Khususnya, kemampuan unik LSTM dalam mempertahankan informasi untuk periode waktu yang panjang dan efisiensi GRU dalam pengolahan data menjadikan kedua model ini pilihan yang tepat untuk meningkatkan keakuratan prediksi iklim di Daerah Istimewa Yogyakarta. Penggunaan model-model ini diharapkan dapat mengatasi beberapa keterbatasan metode tradisional, dengan memberikan insight yang lebih dalam dan akurat mengenai pola iklim yang kompleks[10], [15], [16].

Penelitian serupa juga dilakukan oleh C. Chen et al. pada tahun 2023[17] yang berjudul “Research on Improved GRU-Based Stock Price Prediction Method.” Dalam penelitiannya, Chen dan rekan-rekannya meneliti perbandingan hasil akurasi model menggunakan dataset Nasdaq-100 index dari 3 Januari 2017 hingga 31 Desember 2021 sebanyak 1259 datapoint. Penelitian ini menggunakan model ARIMA dan GRU untuk memprediksi harga saham dan menghitung nilai akurasi dengan matriks RMSE. Hasil penelitian menunjukkan bahwa model ARIMA mendapatkan hasil yang lebih baik dibandingkan dengan model GRU.

Penelitian serupa juga dilakukan oleh A. Bhavani pada tahun 2022[15] yang berjudul “Comparative Analysis between LSTM and GRU in Stock Price Prediction.” Dalam penelitiannya, Bhavani membandingkan dua model jaringan saraf tiruan, yaitu LSTM (Long Short-Term Memory) dan GRU (Gated Recurrent Unit), yang keduanya dirancang untuk memproses data berurutan. Model LSTM memiliki kemampuan untuk menyimpan informasi dalam memori jangka panjang, sementara GRU memiliki struktur yang lebih sederhana dan menggunakan konsep gerbang untuk mengatur aliran informasi. Meskipun penelitian ini memberikan wawasan tentang perbedaan struktural dan fungsional antara kedua model, penelitian ini tidak mendalam dalam hal perbandingan akurasi prediksi.

Penelitian serupa juga dilakukan oleh A. A. Ningrum et al. pada tahun 2021 [18] yang berjudul “Algoritma Deep Learning-LSTM untuk Memprediksi Umur Transformator.” Dalam penelitiannya, Ningrum dan rekan-rekannya membandingkan kinerja model LSTM dengan beberapa algoritma lain, seperti Multilayer Perceptron, Linear Regression, dan Gradient Boosting Regressor, untuk memprediksi umur transformator. Hasil penelitian menunjukkan bahwa LSTM unggul dalam hal kinerja dibandingkan dengan algoritma lainnya, yang mengindikasikan potensi besar LSTM dalam aplikasi prediksi yang kompleks.

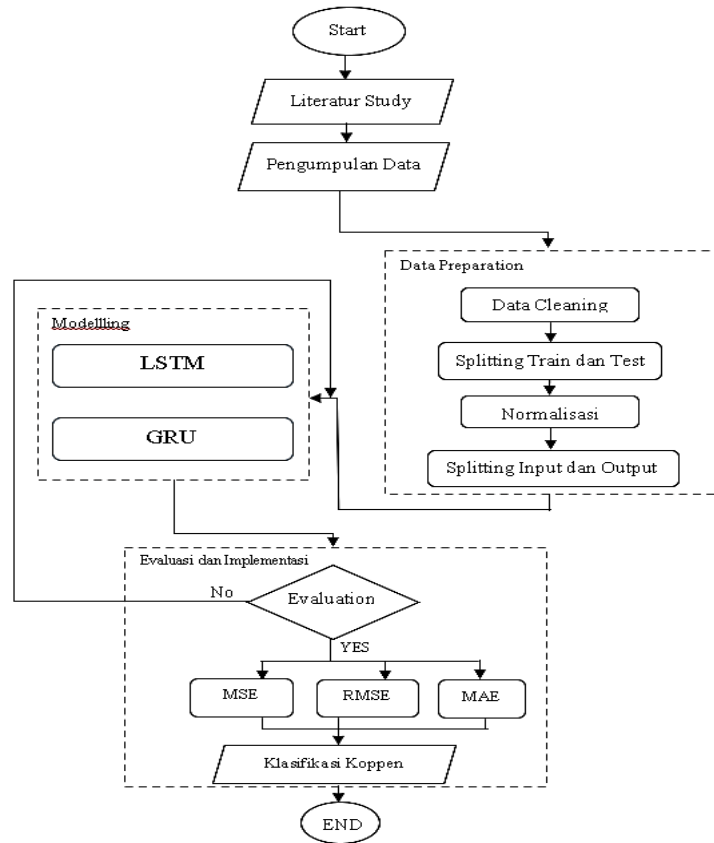
Penelitian serupa juga dilakukan oleh S. Mahjoub pada tahun 2022[8] yang berjudul “Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks.” Dalam penelitiannya, Mahjoub memodelkan dan membandingkan tiga algoritma machine learning, yaitu Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), dan Drop-GRU, yang digunakan untuk meramalkan konsumsi daya pada data time series. Hasil eksperimen menunjukkan bahwa model LSTM menghasilkan prediksi yang lebih baik dibandingkan dengan GRU dan Drop-GRU, terutama dalam meramalkan konsumsi daya pada berbagai jangka waktu (time horizons). Keunggulan LSTM ini diukur berdasarkan jumlah kesalahan prediksi yang lebih sedikit dan presisi yang lebih tinggi, yang menunjukkan bahwa LSTM mampu memberikan prediksi yang lebih akurat terkait dengan konsumsi daya di masa depan.

Penelitian yang dilakukan oleh H. Song dan H. Choi pada tahun 2023[19] yang berjudul “Forecasting Stock Market Indices Using the Recurrent Neural Network Based Hybrid Models: CNN-LSTM, GRU-CNN, and Ensemble Models.” Dalam penelitiannya, Song dan Choi menggunakan model prediksi harga saham berbasis Gated Recurrent Unit (GRU). Model ini dirancang untuk memanfaatkan data saham dari industri yang sama, dengan tujuan memperkaya fitur dan mengurangi risiko overfitting. Selain itu, mereka melakukan rekonstruksi kumpulan data untuk meningkatkan kelengkapan pelatihan dan generalisasi model. Hasil eksperimen menunjukkan peningkatan yang signifikan dalam akurasi prediksi harga saham di berbagai industri, di mana penggunaan GRU bersama dengan modul tambahan untuk rekonstruksi data berhasil mengatasi masalah overfitting dan meningkatkan kemampuan prediksi harga saham.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Dari metodologi, didapatkan diagram alur penelitian. Alur penelitian ini dapat dilihat pada diagram gambar 1 ini memberikan gambaran terperinci tentang setiap langkah yang diambil dalam penelitian, mulai dari kajian literatur hingga evaluasi dan implementasi model.



Gambar 1. Alur penelitian

Setiap tahap dalam alur penelitian ini dirancang untuk memastikan bahwa data yang dikumpulkan dan diolah menghasilkan model yang akurat dan dapat diandalkan untuk klasifikasi iklim. Diagram ini juga membantu memvisualisasikan proses penelitian secara keseluruhan, sehingga memudahkan pemahaman dan pelaksanaan setiap langkah penelitian.

## 2.2 Studi Literatur

Studi literatur sejenis merupakan kegiatan mencari literatur yang mempunyai persamaan atau keterkaitan dengan penelitian yang sedang dilakukan. Literatur sejenis yang didapatkan berupa skripsi atau jurnal sejenis yang kemudian ditelaah dan dibuat perbandingan sehingga penelitian ini dapat menjadi pelengkap atau penyempurnaan dari penelitian-penelitian yang sudah dilakukan sebelumnya.

## 2.3 Pengumpulan Data

Pada tahapan pengumpulan data, metode pengumpulan data dirancang untuk memperoleh data yang relevan, meliputi landasan teori, metodologi penelitian, metodologi proses, dan referensi dari penelitian sejenis. Penelitian ini diawali dengan kajian terhadap variabel yang berkaitan dengan data iklim yang mencakup informasi tentang Suhu Udara, Curah Hujan, Kelembaban Udara, Kecepatan Angin. Tahap selanjutnya melibatkan pengumpulan data dari situs resmi BMKG di <https://dataonline.bmkg.go.id/home>

## 2.4 Data Preparation

Tahap persiapan data dilakukan dengan beberapa langkah yang nantinya akan digunakan untuk model LSTM dan GRU. Tahap ini sering ditinjau kembali saat ditemukan masalah dalam pembangunan model. Iterasi dilakukan hingga menemukan metode yang cocok dengan data.

### 2.4.1 Data Cleaning

Pada tahap ini, pembersihan data dilakukan untuk memastikan kualitas data yang akan digunakan dalam analisis. Pembersihan data melibatkan beberapa langkah berikut:

#### 1. Identifikasi Data Tidak Valid:

Identifikasi data dilakukan untuk mencari nilai yang hilang (missing values) pada dataset Iklim. Nilai yang tidak terukur (misalnya, 8888) dan nilai yang menunjukkan tidak ada data (misalnya, 9999) diidentifikasi sebagai data yang tidak valid. Data yang tidak valid ini dapat berasal dari kesalahan input, kerusakan data, atau metode pengumpulan data yang tidak tepat. Contoh nilai yang hilang dapat dilihat pada Tabel 1.

Tabel 1. Data Missing Value

Tanggal	Tn	Tx	Tavg	RH_avg	RR	ss	ff_x	ddd_x	ff_avg	ddd_car
01-01-2010	23	32,1	28,1	75	0,4	7,3	4	192	0	SW
02-01-2010	24	32,8	28,3	75	0	5,4	4	220	0	SW
03-01-2010	24	34,2	29,2	74	0	7,4	4	211	0	SW
04-01-2010	24	31,5	28,4	76	0	3,8	4	216	0	SW
05-01-2010	24	32,7	28,8	72	0	3,6	4	229	0	SW
06-01-2010	23	33	27,5	79	8888	4,1	3	221	0	SW
07-01-2010	23	32,6	27,2	76	8888	3,1	3	226	0	NE
08-01-2010	22	31	26,8	80	4,5	2,3	3	206	0	NE
09-01-2010	22	30,8	26,3	84	9,8	2	2	217	0	NE
10-01-2010	23	31,6	27,3	76	0,4	4	3	221	0	NW
11-01-2010	23	31,4	26,6	81	15	3,1	4	226	0	SW
12-01-2010	23	28,4	25,3	91	74	1,6	3	296	0	NW
13-01-2010	23	31,4	27,3	76	0	8	4	220	0	SW
14-01-2010	22	32	26,6	78	66	4,7	4	231	1	SW
15-01-2010	23	32,7	27,7	74	8888	7	5	212	0	NW
16-01-2010	22	32,2	27,2	78	8888	2,8	4	225	0	SW
17-01-2010	22	33,5	27,1	74	0,7	5,9	5	228	0	NE
18-01-2010	22	33,8	28,2	72	12,5	7,5	4	211	0	SW
19-01-2010	22	33,4	27,6	76	8,5	6,7	3	199	0	NE
20-01-2010	23	32,6	26,7	82	2,9	4,4	4	195	0	N
21-01-2010	23	31,9	26,9	80	0	1,6	6	178	0	NW
22-01-2010	23	32,7	28,4	74	0	4,5	4	212	0	SW
23-01-2010	23	32,4	28,2	72	0	7,4	4	208	0	SW
24-01-2010	23	32,3	27,2	80	3,6	5,3	5	220	0	SW
25-01-2010	23	32,7	26,9	80	1,8	1,7	2	218	0	NE
26-01-2010	22	33,1	27,8	74	8888	5,2	3	218	0	NE
27-01-2010	23	32,3	28,1	72	0	5,4	5	226	0	SW
28-01-2010	23	33	26,5	80	1,3	4,9	3	207	0	S
29-01-2010	23	31,5	27,5	78	1	4,1	4	217	0	SW
30-01-2010	23	32,7	28,3	74	0	6,5	4	208	0	SW
31-01-2010	23	33,6	27,9	78	5,6	5,5	4	208	0	NW

2. Penghapusan Data Tidak Valid

Nilai 8888, yang merupakan data tidak terukur maka nilai tersebut dihapus dari dataset. Demikian pula, nilai 9999 yang menunjukkan tidak ada data juga dihapus. Penghapusan ini dilakukan untuk memastikan bahwa analisis tidak dipengaruhi oleh data yang tidak akurat atau tidak relevan. Proses penghapusan dilakukan dengan menggunakan fungsi replace (CTRL+F) mengisi *Find what* dengan nilai *error* yang akan dicari yaitu 8888 atau 9999 kemudian *replace with* di kosongkan kemudian *replace all* hal tersebut dilakukan untuk menghapus nilai *error* pada data tersebut dapat dilihat pada Tabel 2

Tabel 2. Colom Missing Value

Tanggal	Tn	Tx	Tavg	RH_avg	RR	ss	ff_x	ddd_x	ff_avg	ddd_car
01-01-2010	23	32,1	28,1	75	0,4	7,3	4	192	0	SW
02-01-2010	24	32,8	28,3	75	0	5,4	4	220	0	SW
03-01-2010	24	34,2	29,2	74	0	7,4	4	211	0	SW
04-01-2010	24	31,5	28,4	76	0	3,8	4	216	0	SW
05-01-2010	24	32,7	28,8	72	0	3,6	4	229	0	SW
06-01-2010	23	33	27,5	79	4,1	3	3	221	0	SW
07-01-2010	23	32,6	27,2	76	3,1	3	3	226	0	NE
08-01-2010	22	31	26,8	80	4,5	2,3	3	206	0	NE
09-01-2010	22	30,8	26,3	84	9,8	2	2	217	0	NE
10-01-2010	23	31,6	27,3	76	0,4	4	3	221	0	NW
11-01-2010	23	31,4	26,6	81	15	3,1	4	226	0	SW
12-01-2010	23	28,4	25,3	91	74	1,6	3	296	0	NW
13-01-2010	23	31,4	27,3	76	0	8	4	220	0	SW
14-01-2010	22	32	26,6	78	66	4,7	4	231	1	SW
15-01-2010	23	32,7	27,7	74	7	5	5	212	0	NW
16-01-2010	22	32,2	27,2	78	2,8	4	4	225	0	SW
17-01-2010	22	33,5	27,1	74	0,7	5,9	5	228	0	NE

Tanggal	Tn	Tx	Tavg	RH_avg	RR	ss	ff_x	ddd_x	ff_avg	ddd_car
18-01-2010	22	33,8	28,2	72	12,5	7,5	4	211	0	SW
19-01-2010	22	33,4	27,6	76	8,5	6,7	3	199	0	NE
20-01-2010	23	32,6	26,7	82	2,9	4,4	4	195	0	N
21-01-2010	23	31,9	26,9	80	0	1,6	6	178	0	NW
22-01-2010	23	32,7	28,4	74	0	4,5	4	212	0	SW
23-01-2010	23	32,4	28,2	72	0	7,4	4	208	0	SW
24-01-2010	23	32,3	27,2	80	3,6	5,3	5	220	0	SW
25-01-2010	23	32,7	26,9	80	1,8	1,7	2	218	0	NE
26-01-2010	22	33,1	27,8	74	5,2	5,2	3	218	0	NE
27-01-2010	23	32,3	28,1	72	0	5,4	5	226	0	SW
28-01-2010	23	33	26,5	80	1,3	4,9	3	207	0	S
29-01-2010	23	31,5	27,5	78	1	4,1	4	217	0	SW
30-01-2010	23	32,7	28,3	74	0	6,5	4	208	0	SW
31-01-2010	23	33,6	27,9	78	5,6	5,5	4	208	0	NW

3. Penanganan Nilai Hilang

Hasil nilai hilang (*missing values*) dari nilai 8888 dan 9999 yang sudah di hapus akan diisi dengan menggunakan interpolasi dengan *library* *pandas* dalam *python*. Ketika *missing value* sudah di hapus pada tahap sebelumnya kemudian di inputkan ke *pandas*. Cara menangani *missing values* dengan tipe ini bisa dilakukan dengan cara menghapus secara keseluruhan baris atau *row*.

2.4.2 Data Splitting Train, Valid dan Test

Pada tahap ini juga dilakukan pembagian data dengan menggunakan 4 skenario pembagian data dapat dilihat pada Tabel 3

Tabel 3. Splitting data training dan Validasi

Skenario	Training	Validasi
1	2010-2018	2019-2023
2	2010-2019	2020-2023
3	2010-2020	2021-2023
4	2010-2021	2022-2023

Analisis *Regresi Linear* adalah metode yang digunakan untuk memahami pengaruh atau hubungan antara satu variabel *dependen* dan satu variabel *independen*. Parameter *regresi* menggunakan data curah hujan, kelembaban rata-rata, suhu rata-rata, dan lama penyinaran matahari.

2.4.3 Data Normalization

Tahap selanjutnya dari data *preparation* adalah melakukan normalisasi pada data. pada proses normalisasi ini data akan diolah agar memiliki skala yang sama, tidak ada yang terlalu besar maupun terlalu kecil. Maka untuk mencegah terjadinya anomali pada data, peneliti melakukan normalisasi dengan metode *Min-Max scaller*, dimana angka pada data akan dibuat rata dengan skala 0-1 menormalisasinya berdasarkan data yang sudah di split yaitu *X\_scaled* dan *y\_scaled*.

2.5 Modelling

Pada tahap ini yaitu membangun metode *deep learning* menggunakan *Long Short-Term Memory* dan *Gated Recurrent Unit* dengan menggunakan *hyperparameter tuning Grid Search*

2.6 Evaluation

Pada proses ini, dilakukan evaluasi kinerja model dengan menggunakan grafik yang dihasilkan dari nilai asli dan nilai prediksi. Selain itu, dilakukan evaluasi terhadap nilai *error* dari tiap-tiap model serta perbandingan waktu yang dibutuhkan oleh model dalam memproses data. Pengukuran Performa, yaitu dengan menggunakan *Mean Square Error* (MSE), *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), yang dikategorikan pada Tabel 4 berikut:

Tabel 4. Akurasi Prediksi Mean Absolute Percentage Error[20]

Mape	<10%	<20%	20%~49%	≥50%
Akurasi	Sangat Akurat	Baik	Wajar	Tidak Akurat

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Modelling

Pada penelitian ini sudah melakukan beberapa pengujian menggunakan beberapa nilai layer. Dimana hasil dari pengujian tersebut menunjukkan bahwa semakin kecil nilai layer semakin buruk nilai prediksinya, dan semakin besar nilai layer semakin semakin baik nilai prediksinya, namun jika terlalu besar nilai prediksi akan jadi semakin buruk dan akan cenderung mengalami *overfitting*. Nilai layer yang digunakan pada penelitian adalah nilai yang menghasilkan nilai akurasi terbaik dapat dilihat pada.

Tabel 5.

**Tabel 5.** Nilai Layer

Nilai Layer	MSE	RMSE	MAE
1	0.00248009	0.0548009	0.03128175
50	0.0025877	0.0508704	0.0323826
100	0.00254948	0.0504924	0.0322683
150	0.00252410	0.0505370	0.03194331
200	0.00256279	0.05062408	0.03171712

Dalam penelitian Tabel 5, telah dilakukan beberapa pengujian menggunakan berbagai jumlah layer pada model neural network. Hasil dari pengujian ini menunjukkan bahwa semakin kecil nilai layer, semakin buruk pula hasil prediksi yang diperoleh, sedangkan semakin besar jumlah layer, semakin baik prediksi yang dihasilkan. Namun, jika jumlah layer terlalu besar, nilai prediksi justru menjadi buruk dan cenderung mengalami *overfitting*. Berdasarkan Tabel 5, dapat dilihat bahwa nilai layer yang menghasilkan akurasi terbaik ditemukan pada jumlah layer tertentu. Nilai-nilai seperti MSE (Mean Squared Error), RMSE (Root Mean Squared Error), dan MAE (Mean Absolute Error) yang tercantum dalam tabel tersebut diperoleh dari proses pelatihan dan pengujian model dengan jumlah layer yang berbeda. Dari hasil ini, dapat disimpulkan bahwa ada jumlah layer 150 optimal yang memberikan kinerja terbaik, dan meskipun penambahan layer dapat meningkatkan akurasi prediksi, terdapat batasan tertentu di mana penambahan layer lebih lanjut justru akan merugikan performa model.

#### 3.1.1 Model LSTM

Setelah data *training* di *fitting* dengan model LSTM didapatkan hasil parameter terbaik dari model yang sudah di *fitting* tersebut dapat dilihat pada Gambar 2.

```
1 print("Best parameters found: ", grid_result.best_params_)
Best parameters found: {'batch_size': 64, 'epochs': 150, 'optimizer': 'adam'}
```

**Gambar 2.** Parameter terbaik dari model dari model LSTM

Hasil parameter terbaik adalah *'batch\_size': 64*, *'epochs': 150*, *'optimizer': 'adam'* kemudian parameter model LSTM tersebut digunakan untuk membuat prediksi dengan memanfaatkan seluruh data dari tahun 2010 hingga 2021. Model LSTM akan memprediksi menggunakan model diinisialisasi menjadi *my\_model*, berikut hasil dapat dilihat pada Gambar 3.

```
[ [ 0.31454182  0.57607144  0.13450643  0.443232 ]
  [ 0.32500726  0.4384482  -0.00190645  0.6141839 ]
  [ 0.30439466  0.45872992  0.01913419  0.58730793 ]
  ...
  [ 0.30311126  0.41209975  0.05913616  0.5507388 ]
  [ 0.29675698  0.42384937  0.06631953  0.5423831 ]
  [ 0.28015524  0.44208542  0.07806536  0.5356649 ] ]
```

**Gambar 3.** Hasil prediksi LSTM

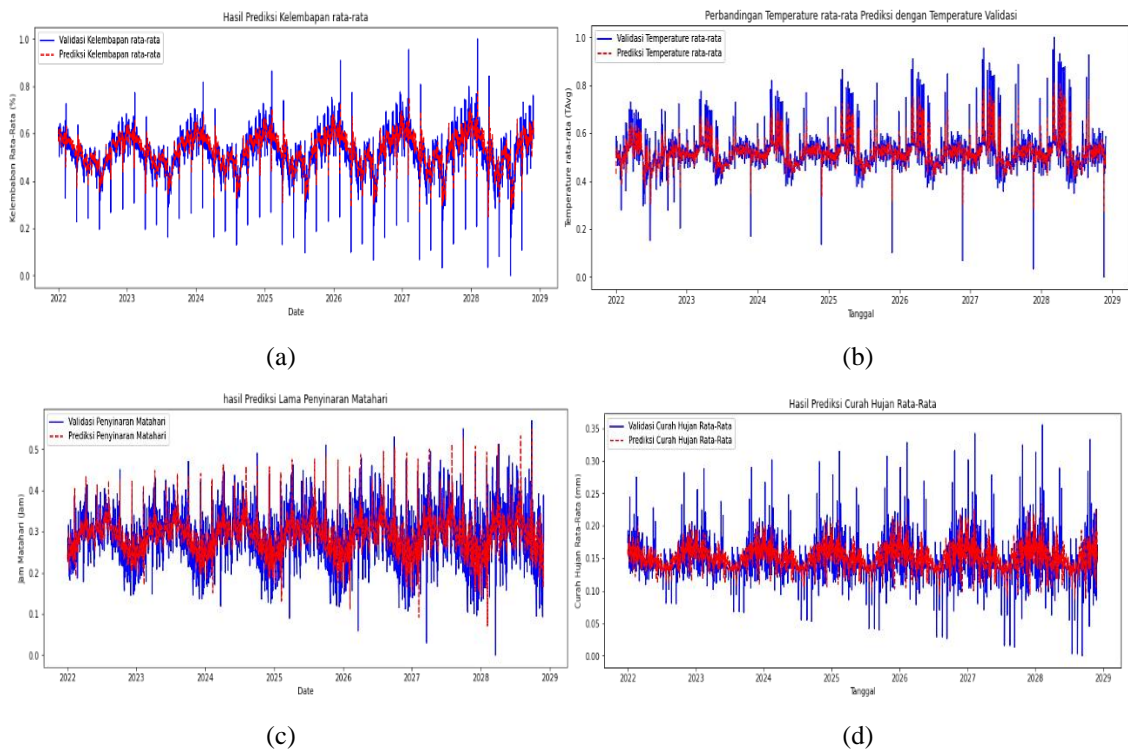
Kemudian hasil scaler dikembalikan nilai yang di skalakan ke nilai aslinya dapat dilihat pada Gambar 4

```
[[ 26.913044 103.56902 40.318855 -3.2354329]
 [ 27.221695 90.54196 -10.7132015 7.583372 ]
 [ 26.613781 92.46178 -2.8419 5.8825083]
 ...
 [ 26.575932 88.0479 12.122837 3.5682073]
 [ 26.388529 89.16008 14.810135 3.039409 ]
 [ 25.898905 90.88626 19.20425 2.6142457]]
[[26.21818182 90.39393939 17.32121212 3.9969697 ]
 [26.68939394 88.95454545 2.83636364 5.56060606]
 [26.08636364 97.59090909 24.56969697 4.82121212]
 ...
 [25.03927739 92.07575758 18.62739628 4.32470862]
 [24.80361305 96.2960373 16.94727972 6.08717949]
 [25.23531469 93.5979021 15.26716317 1.06386946]]
```

Gambar 4. Hasil pengembalian scaler model LSTM

3.1.2 Plotting Model LSTM

Gambar 5 menampilkan grafik perbandingan nilai aktual dan nilai prediksi model LSTM. Berikut source code untuk menampilkan grafik perbandingannya :



Gambar 5. Model LSTM (a) Plot Temperature Rata-rata, (b) Plot Kelembapan Rata-rata, (c) Plot Curah Hujan Rata-rata, (d) Lama Penyinaran Matahari

Dapat dilihat dari Gambar 5 merupakan grafik penyinaran matahari bahwa secara visual nilai prediksi menunjukkan hasil yang baik, dimana grafik nilai prediksi (berwarna merah) bergerak persis seperti grafik nilai aktual (berwarna biru), sehingga dapat dikatakan nilai prediksi yang dibuat oleh model LSTM memiliki tingkat keakuratan (presisi) yang sangat tinggi dengan nilai aktual. Namun, agar tidak menjadi spekulasi, peneliti membuktikannya dengan mencari nilai selisih kesalahan (*error*) yang dibuat oleh nilai prediksi dengan nilai aktual.

3.1.3 Model GRU

Setelah data *training* di *fitting* dengan model GRU, didapatkan hasil parameter terbaik dari model yang sudah di *fitting* tersebut dapat dilihat pada Gambar 6

```
1 print("Best parameters found: ", grid_result.best_params_)
Best parameters found: {'batch_size': 64, 'epochs': 150, 'optimizer': 'adam'}
```

Gambar 6. Parameter terbaik dari model dari model GRU

Hasil parameter terbaik adalah '*batch\_size*': 64, '*epochs*': 150, '*optimizer*': '*adam*' hasil Kemudian parameter model GRU digunakan untuk membuat prediksi dengan memanfaatkan seluruh data dari tahun 2010

hingga 2021. Model LSTM akan memprediksi menggunakan model diinisialisasi menjadi *my\_model*, berikut hasil dapat dilihat pada Gambar 7

```
[[0.26483095 0.62428176 0.14887019 0.46780017]
 [0.31363857 0.48065752 0.04142753 0.60980874]
 [0.3041885 0.46424052 0.05676705 0.59990036]
 ...
 [0.30259904 0.41906476 0.07137631 0.56439096]
 [0.29631135 0.43190363 0.07748897 0.55680925]
 [0.27886856 0.44924122 0.08732089 0.5538675 ]]
```

Gambar 7. Hasil prediksi GRU

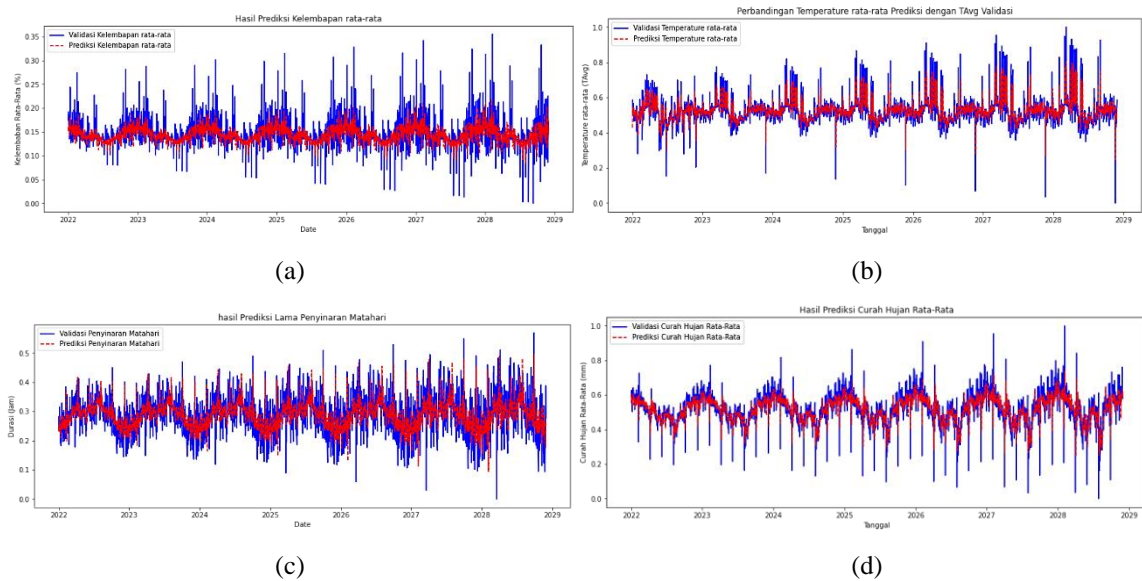
Kemudian hasil *scaler* dikembalikan nilai yang diskalakan ke nilai aslinya dapat dilihat pada Gambar 8

```
[[ 25.446957 108.13248 45.692337 -1.6806197]
 [ 26.886406 94.537384 5.4980392 7.306487 ]
 [ 26.6077 92.9834 11.236553 6.6794286]
 ...
 [ 26.560823 88.707184 16.701878 4.4321923]
 [ 26.375385 89.92248 18.988623 3.9523787]
 [ 25.860958 91.56361 22.666746 3.7662096] ]
[[26.21818182 90.39393939 17.32121212 3.9969697 ]
 [26.68939394 88.95454545 2.83636364 5.56060606]
 [26.08636364 97.59090909 24.56969697 4.82121212]
 ...
 [25.93927739 92.07575758 18.62739628 4.32470862]
 [24.80361305 96.2960373 16.94727972 6.08717949]
 [25.23531469 93.5979021 15.26716317 1.06386946]]
```

Gambar 8. Hasil pengembalian scaler model GRU

### 3.1.4 Plotting Model GRU

Perbandingan nilai aktual dan nilai prediksi model GRU dapat dilihat pada grafik Gambar



Gambar 9. Model GRU (a) Plot Temperature Rata-rata, (b) Plot Kelembaban Rata-rata, (c) Plot Curah Hujan Rata-rata, (d) Lama Penyinaran Matahari

Dapat dilihat dari Gambar merupakan grafik penyinaran matahari bahwa secara visual nilai prediksi dari model GRU menunjukkan hasil yang baik, dimana grafik nilai prediksi (berwarna merah) bergerak persis seperti grafik nilai aktual (berwarna biru), sehingga dapat dikatakan nilai prediksi yang dibuat oleh model GRU memiliki tingkat keakuratan (presisi) yang sangat tinggi dengan nilai aktual. Namun, agar tidak menjadi spekulasi, peneliti membuktikannya dengan mencari nilai selisih kesalahan (*error*) yang dibuat oleh nilai prediksi dengan nilai aktual.

### 3.2 Evaluasi Hasil Pengujian Model

#### 3.2.1 Matriks Evaluasi

Matriks Evaluasi model dilakukan untuk mengecek estimasi berapa nilai kesalahan (*error*) untuk mengukur akurasi model dan membandingkan performa dua model LSTM dan GRU dalam melakukan prediksi, digunakan

4 matriks evaluasi, yaitu *Mean Square Error*, *Mean Absolute Error*, *Root Mean Square Error*, dan *Mean Absolute Percentage Error*. Hasil matrik evaluasi dapat di lihat pada Tabel 6 menunjukkan bahwa model memiliki kinerja yang cukup baik dalam memprediksi, yaitu suhu rata-rata, dengan MAPE sekitar 4.36%, yang menunjukkan bahwa prediksi sangat akurat (<10%), Model juga memiliki kinerja yang baik dalam memprediksi kelembaban rata-rata, dengan MAPE sekitar 7.60%, yang menunjukkan bahwa prediksi sangat akurat (<10%), Model menunjukkan kinerja yang wajar dalam memprediksi curah hujan rata-rata, dengan MAPE sekitar 5%, yang masih masuk kategori sangat akurat, Prediksi lama penyinaran matahari juga cukup akurat, dengan MAPE sekitar 8.29%, yang menunjukkan prediksi sangat akurat.

**Tabel 6.** Matrik Evaluasi Model LSTM

Variabel	MSE	RMSE	MAE	MAPE
Temperature Rata-rata	0,00605	0,07780	0,04696	4,36%
Kelembaban Rata-rata	0,00108	0,03281	0,02256	7,60%
Curah Hujan Rata-rata	0,00551	0,07424	0,04837	5,00%
Lama Penyinaran Matahari	0,00375	0,06119	0,04699	8,29%

Tabel kedua yaitu hasil evaluasi kinerja model GRU dapat dilihat pada Tabel 7 prediksi terhadap beberapa variabel iklim yang diukur dengan metrik kesalahan yang sama seperti pada Tabel 6. Nilai kesalahan menunjukkan bahwa model masih memiliki kinerja yang baik dalam memprediksi suhu rata-rata, dengan MAPE sekitar 4.35%, yang menunjukkan bahwa prediksi sangat akurat (<10%), Model menunjukkan kinerja yang sangat baik dalam memprediksi kelembaban rata-rata, dengan MAPE sekitar 6.86%, yang menunjukkan bahwa prediksi sangat akurat, Model memiliki kinerja yang baik dalam memprediksi curah hujan rata-rata, dengan MAPE sekitar 5.01%, yang masih masuk kategori sangat akurat, Prediksi lama penyinaran matahari juga cukup akurat, dengan MAPE sekitar 8.28%, yang menunjukkan prediksi sangat akurat.

**Tabel 7.** Matrik Evaluasi Model GRU

Variabel	MSE	RMSE	MAE	MAPE
Temperature Rata-rata	0,00607	0,07788	0,04691	4,35%
Kelembaban Rata-rata	0,00097	0,03116	0,02017	6,86%
Curah Hujan Rata-rata	0,00550	0,07417	0,04833	5,01%
Lama Penyinaran Matahari	0,00363	0,06022	0,04677	8,28%

Kedua tabel menunjukkan bahwa model prediksi yang digunakan memiliki kinerja yang sangat baik dalam memprediksi variabel cuaca seperti suhu, kelembaban, curah hujan, dan lama penyinaran matahari. Nilai MAPE yang rendah di semua variabel menunjukkan bahwa model ini mampu memberikan prediksi yang sangat akurat, yang sangat bermanfaat untuk aplikasi yang memerlukan ketepatan tinggi dalam prakiraan iklim.

### 3.2.2 Perbandingan Performa Kinerja Model

1. Suhu Rata-rata (Temperature Rata-rata):

**Tabel 8.** Perbandingan Matrik Evaluasi Temperature Rata-rata

Model	MSE	RMSE	MAE	MAPE	
Temperature Rata-rata	LSTM	0,0061	0,0778	0,0470	4,36%
	GRU	0,0061	0,0779	0,0469	4,35%
	Selisih	-0,0002	-0,0010	0,0001	0,01%

Pada Tabel 8 Model LSTM Temperature Rata-rata memiliki MSE sebesar 0,0061, RMSE sebesar 0,0778 dan MAE sebesar 0,0470, MAPE sebesar 4,36%, Model GRU memiliki MSE sebesar 0,0061, RMSE sebesar 0,0779 dan MAE sebesar 0,0469 MAPE sebesar 4,35%. Perbedaan antara kedua model sangat kecil, menunjukkan bahwa keduanya hampir sama baik dalam memprediksi suhu rata-rata.

2. Kelembaban Rata-rata (Kelembaban Rata-rata)

**Tabel 9.** Perbandingan Matrik Evaluasi Kelembaban Rata-rata

Model	MSE	RMSE	MAE	MAPE	
Kelembaban Rata-rata	LSTM	0,00108	0,03281	0,02256	7,60%
	GRU	0,00097	0,03116	0,02017	6,86%
	Selisih	0,00012	0,00065	0,00139	-0,74%

Model LSTM Tabel 9 memiliki MSE sebesar 0,00108, RMSE sebesar 0,03281, MAE sebesar 0,02256 MAPE sebesar 7,60%. Model GRU memiliki MSE sebesar 0,00097, RMSE sebesar 0,03116, MAE sebesar 0,02017, MAPE sebesar 6,86 %. LSTM sedikit lebih baik dalam beberapa metrik, tetapi perbedaannya tidak signifikan, sehingga kedua model hampir sama dalam memprediksi kelembaban rata-rata.

3. Curah Hujan Rata-rata (Curah Hujan Rata-rata)

MSE sebesar 0,001, RMSE sebesar 0,033, MAE sebesar 0,023, MAPE sebesar 7,60%. Model GRU memiliki MSE sebesar 0,006, RMSE sebesar 0,074, MAE sebesar 0,048 MAPE sebesar 5,01%. GRU memiliki kesalahan yang lebih rendah dalam MSE dan RMSE, menunjukkan adanya variabilitas yang lebih besar dalam prediksi persentase. Hasil Model LSTM dapat dilihat pada Tabel 10

**Tabel 10.** Perbandingan Matrik Evaluasi Curah Hujan Rata-rata

Model	MSE	RMSE	MAE	MAPE	
Curah Hujan Rata-rata	LSTM	0,00551	0,07424	0,04837	5,00%
	GRU	0,00550	0,07417	0,04833	5,01%
	Selisih	0,0001	0,00007	0,00004	-0,01%

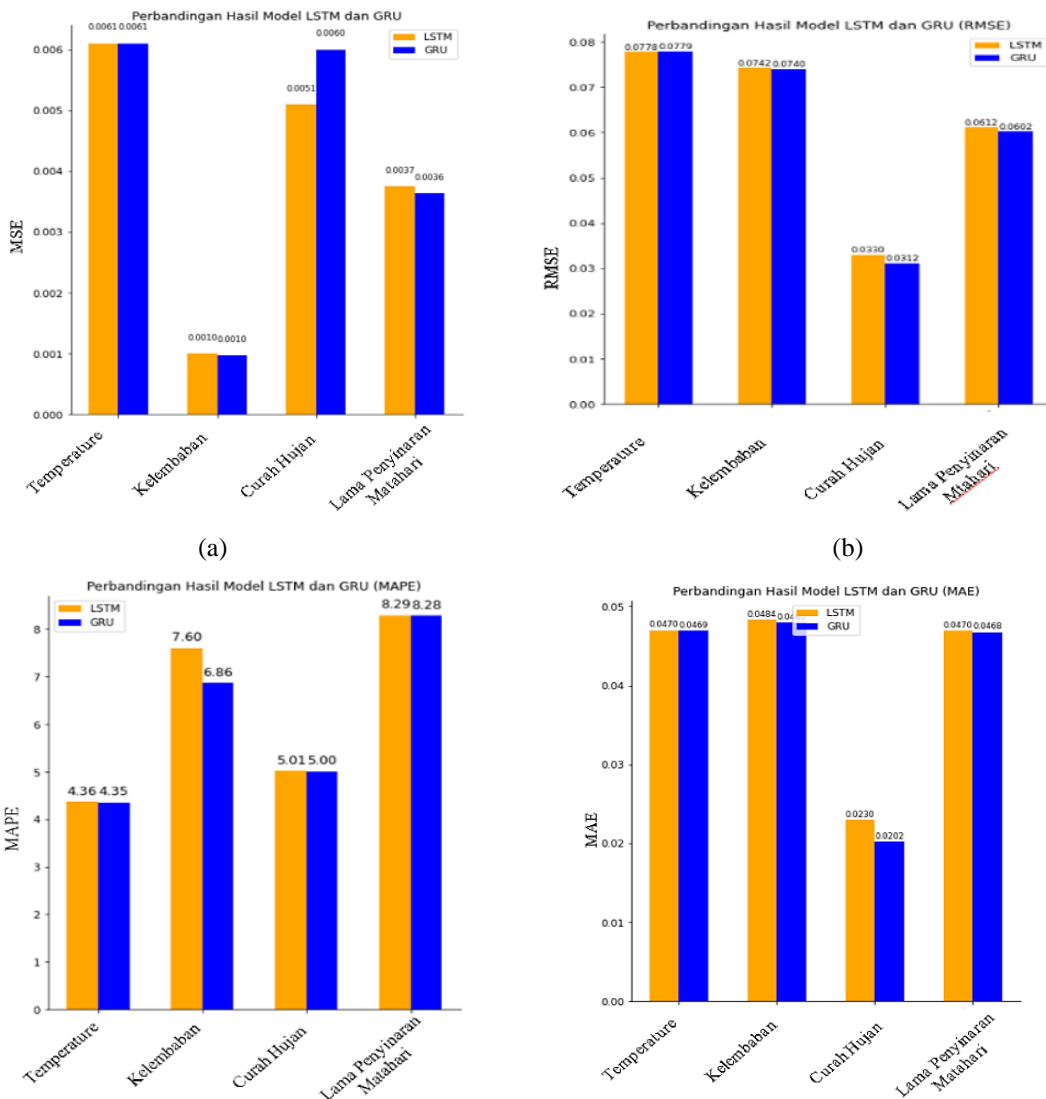
4. Lama Penyinaran Matahari (Lama Penyinaran Matahari)

Hasil Model LSTM berkaitan dengan lama penyinaran matahari dapat dilihat pada Tabel 11

**Tabel 11.** Perbandingan Matrik Evaluasi Lama Penyinaran Matahari

Model	MSE	RMSE	MAE	MAPE	
Lama Penyinaran Matahari	LSTM	0,00375	0,06119	0,04699	8,29%
	GRU	0,00363	0,06022	0,04677	8,28%
	Selisih	0,00012	0,00097	0,00022	0,01%

LSTM memiliki MSE sebesar 0,00375, RMSE sebesar 0,06119, MAE sebesar 0,04699. Model GRU memiliki MSE sebesar 0,00363, RMSE sebesar 0,06022, MAE sebesar 0,04677. GRU lebih baik dalam semua metrik kecuali MSE, menunjukkan bahwa GRU sedikit lebih akurat dalam memprediksi lama penyinaran matahari. Dapat dilihat dari Gambar 9 selisih antara GRU > LSTM, dengan kata lain model LSTM lebih baik dari model GRU.




(c)

(d)

**Gambar 9.** (a) Grafik Perbandingan Nilai MSE, (b) Grafik perbandingan nilai RMSE, (c)Grafik Perbandingan Nilai MAE, (d) Grafik Perbandingan Nilai MAPE dari Model LSTM, dan GRU

### 3.2.3 Durasi Pemodelan

Dalam menentukan performa kinerja terbaik pada suatu model, lamanya waktu yang dibutuhkan untuk membuat prediksi perlu dipertimbangkan, karena untuk membuat prediksi yang baik dari data yang besar membutuhkan waktu yang berbeda-beda dari setiap modelnya, oleh karena itu, menjadikan parameter durasi pemodelan sebagai pertimbangan dalam kinerja model. Berikut grafik perbandingan durasi pemodelan yang dapat dilihat pada Gambar 10.



**Gambar 10.** Grafik Perbandingan Durasi Pemodelan

Dapat dilihat dari Gambar 10, hasil dari perbandingan durasi pemodelan menunjukkan model GRU mendapatkan waktu terbaik dibandingkan dengan model LSTM dengan selisih yang cukup jauh, 184,3341522 detik. Pada penelitian yang dilakukan hasil perbandingan durasi pemodelan oleh model GRU menunjukkan nilai yang lebih baik dibandingkan dengan model LSTM, dimana hal ini sejalan dengan penelitian yang dilakukan oleh dimana pada penelitian menyebutkan bahwasannya model GRU memiliki lebih sedikit parameter model dibandingkan dengan LSTM, sehingga kecepatan konvergensi pada model GRU lebih cepat dari model LSTM.

### 3.3 Klasifikasi Iklim *Koppen*

Setelah mendemonstrasikan kemampuan model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi variabel iklim penting, bab selanjutnya akan membahas aplikasi hasil prediksi ini dalam konteks klasifikasi iklim *Köppen*. Perbandingan Klasifikasi *Köppen* Berdasarkan Prediksi model LSTM dan GRU, yang merupakan sistem pengelompokan iklim yang luas berdasarkan pola curah hujan dan suhu.

#### 3.3.1 Klasifikasi *Koppen* LSTM

Data hasil prediksi berupa data harian kemudian dirubah ke dalam data hasildapat dilihat pada Gambar 11 Merupakan jumlah curah hujan setiap bulan dan menunjukkan rata-rata suhu setiap bulan dari hasil transposisi rata-rata suhu harian.

```
Tanggal
2021-01-31    285.531403
2021-02-28    281.074707
2021-03-31    175.365519
2021-04-30    117.873431
2021-05-31    18.663211
...
2028-08-31    123.966233
2028-09-30    169.769485
2028-10-31    317.382010
2028-11-30    292.195115
2028-12-31    19.204250
Freq: M, Name: Prediksi Curah Hujan rata-rata, Length: 96, dtype: float64
Tanggal
2021-01-31    26.246455
2021-02-28    26.389614
2021-03-31    27.881293
2021-04-30    27.142736
2021-05-31    25.573389
...
2028-08-31    26.069334
2028-09-30    26.699689
2028-10-31    26.748346
2028-11-30    26.912321
2028-12-31    25.898905
Freq: M, Name: Prediksi Temp rata-rata, Length: 96, dtype: float64
```

**Gambar 11.** Output Transpose data harian menjadi Data Bulanan

Untuk menentukan suhu bulanan minimum setiap tahun, dalam klasifikasi iklim *Köppen* diperlukan beberapa subklasifikasi iklim yang bergantung pada suhu bulanan minimum. Misalnya, untuk mengidentifikasi

apakah suatu wilayah memiliki iklim D (*Snow*), suhu bulan terdingin harus kurang dari atau sama dengan  $-3^{\circ}\text{C}$ . Hasilnya dapat dilihat pada Gambar 12.

```
Tanggal
2021-12-31    24.690580
2022-12-31    25.081844
2023-12-31    25.054661
2024-12-31    25.035621
2025-12-31    25.010176
2026-12-31    24.977503
2027-12-31    24.953255
2028-12-31    24.928071
Freq: A-DEC, Name: Prediksi Temp rata-rata, dtype: float64
```

**Gambar 12.** *Temperature Minimum* Setiap Tahun

Suhu minimum setiap bulan berada di atas  $18^{\circ}\text{C}$ , yang menunjukkan bahwa iklim termasuk dalam iklim A (*Tropical climate*). Gambar 12 merupakan hasil klasifikasi *koppen* menunjukkan bahwa iklim di yogyakarta berada pada iklim tipe A yaitu pada Temperature berada di atas 18 derajat. Kemudian suhu di kategorikan berdasarkan *koppen* klasifikasi *Output* dari program tersebut dapat dilihat pada Gambar 13

```
Year Koppen Classification Model LSTM
0 2021 Am
1 2022 As
2 2023 Am
3 2024 Am
4 2025 Am
5 2026 Am
6 2027 Am
7 2028 As
```

**Gambar 13.** Hasil Klasifikasi *koppen* Model LSTM

### 3.3.2 Klasifikasi *Koppen* GRU

Data hasil prediksi berupa data harian kemudian di rubah ke dalam data bulanan hasil dapat dilihat pada Gambar 14 Merupakan jumlah curah hujan setiap bulan dan menunjukkan rata-rata suhu setiap bulan dari hasil transposisi rata-rata suhu harian.

```
Tanggal
2021-01-31    529.426237
2021-02-28    461.742079
2021-03-31    351.163983
2021-04-30    185.773560
2021-05-31     52.804308
...
2028-08-31    245.079751
2028-09-30    254.519943
2028-10-31    459.398247
2028-11-30    445.163468
2028-12-31    22.666746
Freq: M, Name: Prediksi Curah Hujan rata-rata, Length: 96, dtype: float64
Tanggal
2021-01-31     25.932408
2021-02-28     26.265361
2021-03-31     27.919872
2021-04-30     27.149317
2021-05-31     25.425487
...
2028-08-31     26.034601
2028-09-30     26.653942
2028-10-31     26.777245
2028-11-30     26.927402
2028-12-31     25.860958
Freq: M, Name: Prediksi Temp rata-rata, Length: 96, dtype: float64
```

**Gambar 14.** *Output Transpose* Data Harian Menjadi Data Bulanan

Untuk menentukan suhu bulanan minimum setiap tahun, dalam klasifikasi iklim *Köppen* diperlukan beberapa subklasifikasi iklim yang bergantung pada suhu bulanan minimum. Misalnya, untuk mengidentifikasi apakah suatu wilayah memiliki iklim D (*Snow*), suhu bulan terdingin harus kurang dari atau sama dengan  $-3^{\circ}\text{C}$ . Dapat dilihat pada Gambar 15 merupakan temperature minimum setiap bulan berada di atas  $18^{\circ}\text{C}$ , yang menunjukkan bahwa iklim termasuk dalam iklim A (*Tropical climate*).

```

Tanggal
2021-12-31    24.556032
2022-12-31    25.066841
2023-12-31    25.033002
2024-12-31    25.010024
2025-12-31    24.978982
2026-12-31    24.941179
2027-12-31    24.910590
2028-12-31    24.881728
Freq: A-DEC, Name: Prediksi Temp rata-rata, dtype: float64
    
```

Gambar 15. Temperature minimum setiap bulan

Suhu minimum setiap bulan berada di atas 18°C, yang menunjukkan bahwa iklim termasuk dalam iklim A (*Tropical climate*). Hasil *temperature* diatas dapat dilihat pada Gambar 16

```

Year Koppen Classification Model GRU
0 2021                      Am
1 2022                      Af
2 2023                      Af
3 2024                      Af
4 2025                      Af
5 2026                      Af
6 2027                      Af
7 2028                      Am
    
```

Gambar 16. Hasil Klasifikasi koppen Model GRU

### 3.3.3 Perbandingan Temperature minimum

Perbandingan temperatur minimum tiap tahun yang dihitung menggunakan dua Model prediksi berbeda LSTM (*Long Short-Term Memory*) dan GRU (*Gated Recurrent Unit*). Berikut adalah rincian data dalam Tabel 12:

Tabel 12. Perbandingan Temperatur Minimum Tiap Tahun

Tahun	LSTM	GRU
2021	24,7	24,6
2022	25,1	25,1
2023	25,1	25,0
2024	25,0	25,0
2025	25,0	25,0
2026	25,0	24,9
2027	25,0	24,9
2028	24,9	24,9

Dalam Tabel 12 sistem klasifikasi iklim Köppen, temperatur minimum bulanan adalah salah satu parameter kunci untuk menentukan tipe iklim suatu daerah. Berdasarkan data temperatur minimum yang ditampilkan dalam Tabel 12, kita dapat membuat beberapa observasi berikut:

1. Temperatur Minimum yang Konsisten:  
Temperatur minimum tiap tahun untuk kedua metode (LSTM dan GRU) berkisar antara 24,6°C hingga 25,1°C. Ini menunjukkan bahwa daerah tersebut memiliki temperatur minimum yang cukup tinggi secara konsisten sepanjang tahun.
2. Klasifikasi Iklim Tropis (A):  
Dalam klasifikasi iklim Köppen, untuk memenuhi syarat sebagai iklim tropis (A), temperatur bulan terdingin harus lebih besar atau sama dengan 18°C. Berdasarkan Tabel 12, semua nilai temperatur minimum untuk kedua metode prediksi selalu di atas 18°C, yang mengindikasikan bahwa daerah tersebut termasuk dalam kategori iklim tropis.
3. Subtipe Iklim Tropis:  
Untuk lebih jauh mengklasifikasikan subtipe iklim tropis (Af, Am, atau Aw), curah hujan bulanan dan tahunan juga harus dipertimbangkan. Tabel 12 menunjukkan bahwa klasifikasi iklim Köppen untuk daerah tersebut bervariasi antara "*Tropical Monsoon*" (Am), "*Tropical Rainforest*" (Af), dan "*Tropical Savanna*" (As). Variasi ini mungkin disebabkan oleh perbedaan pola curah hujan meskipun temperatur minimum tetap tinggi dan stabil.

### 3.3.4 Perbandingan Klasifikasi Koppen LSTM dan GRU

Hasil klasifikasi iklim Köppen berdasarkan data suhu dan curah hujan untuk setiap tahun dari 2021 hingga 2028. Hasil klasifikasi dapat dilihat pada Tabel 13 sebagai berikut:

Tabel 13. Klasifikasi Koppen LSTM dan GRU

Tahun	LSTM	GRU
2021	Am	Am
2022	As	Af
2023	Am	Af
2024	Am	Af
2025	Am	Af
2026	Am	Af
2027	Am	Af
2028	As	Am

Tabel 13 membandingkan klasifikasi iklim Köppen yang dihitung menggunakan dua metode prediksi yang berbeda: LSTM (*Long Short-Term Memory*) dan GRU (*Gated Recurrent Unit*).

1. Am (*Tropical Monsoon*)

Iklim monsun tropis (Am) ditandai dengan musim hujan panjang dan curah hujan tinggi, dengan satu bulan curah hujan di bawah 60 mm. Pertanian diuntungkan oleh curah hujan tinggi, namun bulan kering memerlukan irigasi tambahan. Infrastruktur sering terancam banjir, sehingga penting menjaga saluran air. Musim hujan panjang meningkatkan risiko penyakit seperti malaria dan demam berdarah.

2. Af (*Tropical Rainforest*)

Iklim hutan hujan tropis (Af) memiliki curah hujan tinggi sepanjang tahun tanpa bulan dengan curah hujan di bawah 60 mm. Pertanian subur dan beragam, namun risiko penyakit tanaman dan hama meningkat. Infrastruktur harus tahan kelembapan dan hujan konstan dengan risiko erosi dan banjir. Lingkungan lembab meningkatkan penyakit vektor seperti nyamuk dan penyakit pernapasan.

3. As (*Tropical Savanna with Dry Summer*)

Iklim sabana tropis dengan musim panas kering (As) memiliki musim panas kering dengan curah hujan kurang dari 60 mm. Pertanian memerlukan irigasi selama musim kering dengan tanaman tahan kekeringan seperti jagung dan sorgum. Infrastruktur harus menghadapi kekeringan dengan manajemen air yang baik dan desain untuk kondisi kering dan panas. Kesehatan terancam dehidrasi, penyakit debu, dan panas selama musim kering.

#### 4. KESIMPULAN

Model LSTM dan GRU digunakan untuk memprediksi data dari tahun 2010 hingga 2021 dengan parameter 'batch\_size': 64, 'epochs': 150, dan 'optimizer': 'adam', menunjukkan bahwa berdasarkan matrik evaluasi Target MAPE, kedua model memperoleh akurasi sangat baik, di mana untuk Curah Hujan Rata-rata model LSTM lebih unggul dengan MAPE 5,0% dibandingkan GRU yang memiliki MAPE 5,01%, sementara untuk Kelembaban Rata-rata, Lama Penyinaran Matahari, dan Temperatur Rata-rata, model GRU menunjukkan kinerja lebih baik dengan MAPE masing-masing 6,86%, 8,28%, dan 4,35%; Hyperparameter Tuning menggunakan Grid Search memakan waktu lebih lama, dengan model GRU memiliki durasi terbaik 2319,8 detik dibandingkan LSTM yang memerlukan 2504,2 detik, dan analisis di Daerah Istimewa Yogyakarta menunjukkan bahwa kedua model menghasilkan prediksi temperatur minimum yang sangat mirip, mengindikasikan keandalan dalam konteks klasifikasi iklim tropis Köppen.

#### UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Program Magister Teknik Elektro Universitas Islam Indonesia (UII) yang telah memberikan dukungan dana untuk penelitian ini. Dukungan dan kepercayaan telah memungkinkan kami untuk mengeksplorasi dan menyelidiki lebih lanjut, yang mengarah ke penemuan yang berharga. Terima kasih juga kepada rekan-rekan yang berkontribusi dalam penelitian ini. Diharapkan hasil penelitian ini dapat memberikan kontribusi positif bagi perkembangan dan kemajuan teknik kelistrikan di Indonesia.

#### REFERENCES

- [1] B. D. A. Nugroho, "Relationships among Global Climate Indices and Rainfall Pattern to Detect Impact of Climate Change in Yogyakarta Special Region, Indonesia," *IOP Conf Ser Earth Environ Sci*, vol. 515, no. 1, 2020, doi: 10.1088/1755-1315/515/1/012038.
- [2] E. Saptutyingsih, "Does social capital matter in climate change adaptation? A lesson from agricultural sector in Yogyakarta, Indonesia," *Land use policy*, vol. 95, 2020, doi: 10.1016/j.landusepol.2019.104189.
- [3] S. R. K. Sari, "Strategy mitigation action of climate change of land-based in geopark karst area of Gunungsewu, Yogyakarta, Indonesia," *IOP Conf Ser Earth Environ Sci*, vol. 824, no. 1, 2021, doi: 10.1088/1755-1315/824/1/012071.

- [4] F. Farhangi, A. Sadeghi-Niaraki, J. Safari Bazargani, S. V. Razavi-Termeh, D. Hussain, and S.-M. Choi, "Time-Series Hourly Sea Surface Temperature Prediction Using Deep Neural Network Models," *J Mar Sci Eng*, vol. 11, no. 6, pp. 11–36, May 2023, doi: 10.3390/jmse11061136.
- [5] L. Fitriana, "Climate stresses and its impact towards food sufficiency: A case in Bantul regency Yogyakarta-Indonesia," *IOP Conf Ser Earth Environ Sci*, vol. 653, no. 1, 2021, doi: 10.1088/1755-1315/653/1/012141.
- [6] E. Saptutyningsih, "Climate change adaptability of the agriculture sector in Yogyakarta, Indonesia," *E3S Web of Conferences*, vol. 232, 2021, doi: 10.1051/e3sconf/202123204001.
- [7] J. H. Mulyo, "Assessing the Vulnerability of Farm Households in Yogyakarta to Risks Associated with Climate Change," *E3S Web of Conferences*, vol. 142, 2020, doi: 10.1051/e3sconf/202014203002.
- [8] S. Mahjoub, "Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks," *Sensors*, vol. 22, no. 11, 2022, doi: 10.3390/s22114062.
- [9] G. R. FREDYAN and P. Kusuma, "Spatiotemporal convolutional LSTM with attention mechanism for monthly rainfall prediction," 2022. doi: 10.28919/cmbn/7761.
- [10] A. Saxena, R. Chauhan, D. Chauhan, and G. Aggarwal, "Time Series Prediction of Sea Surface Temperature Using LSTM," 2023. doi: 10.1109/Confluence56041.2023.10048855.
- [11] P. T. Yamak, L. Yujian, and P. K. Gadosey, "A Comparison between ARIMA, LSTM, and GRU for Time Series Forecasting," in *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence*, New York, NY, USA: ACM, Dec. 2019, pp. 49–55. doi: 10.1145/3377713.3377722.
- [12] H. Sak, A. Senior, and F. Beaufays, "Long short-term memory recurrent neural network architectures for large scale acoustic modeling," *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, pp. 338–342, Aug. 2014, doi: DOI:10.21437/Interspeech.2014-80.
- [13] M. Gupta, A. Asthana, N. Joshi, and P. Mehndiratta, "Improving Time Series Forecasting Using Mathematical and Deep Learning Models," 2018, pp. 115–125. doi: 10.1007/978-3-030-04780-1\_8.
- [14] A. Rasyid, D. Agushinta R., and D. Ediraras, "Deep Learning Methods In Predicting Indonesia Composite Stock Price Index (IHSG)," *International Journal of Computer and Information Technology(2279-0764)*, vol. 10, Oct. 2021, doi: 10.24203/ijcit.v10i5.153.
- [15] A. Bhavani, "Comparative Analysis between LSTM and GRU in Stock Price Prediction," *International Conference on Edge Computing and Applications, ICECAA 2022 - Proceedings*, pp. 532–537, 2022, doi: 10.1109/ICECAA55415.2022.9936434.
- [16] B. Aprilia, M. Marzuki, and I. Taufiq, "Prediksi El Nino Southern Oscillation (ENSO) Menggunakan Jaringan Saraf Tiruan (JST)-Backpropagation," *Jurnal Fisika Unand*, vol. 9, no. 4, pp. 421–427, Jan. 2021, doi: 10.25077/jfu.9.4.421-427.2020.
- [17] C. Chen, L. Xue, and W. Xing, "Research on Improved GRU-Based Stock Price Prediction Method," *Applied Sciences*, vol. 13, no. 15, p. 8813, Jul. 2023, doi: 10.3390/app13158813.
- [18] A. A. Ningrum, I. Syarif, A. I. Gunawan, E. Satriyanto, and R. Muchtar, "Algoritma Deep Learning-LSTM untuk Memprediksi Umur Transformator," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 3, pp. 539–548, Jun. 2021, doi: 10.25126/jtiik.2021834587.
- [19] H. Song and H. Choi, "Forecasting Stock Market Indices Using the Recurrent Neural Network Based Hybrid Models: CNN-LSTM, GRU-CNN, and Ensemble Models," *Applied Sciences*, vol. 13, no. 7, p. 4644, Apr. 2023, doi: 10.3390/app13074644.
- [20] A. Mayer and E. K. Smith, "Unstoppable climate change? The influence of fatalistic beliefs about climate change on behavioural change and willingness to pay cross-nationally," 2018. doi: 10.1080/14693062.2018.1532872.