



Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan

M Devid Alam Carnegie, Chairani*

Program Studi Teknik Informatika, IIB Darmajaya, Lampung, Indonesia

Email: ¹devidcarnegie@gmail.com, ^{2,*}Chairani@darmajaya.ac.id

Email Penulis Korespondensi: Chairani@darmajaya.ac.id

Abstrak—Salah satu dampak ancaman yang diakibatkan oleh hujan lebat adalah banjir yang dapat memberikan dampak negatif terhadap kehidupan manusia. Banyak faktor yang menyebabkan hujan lebat sehingga prediksi intensitas curah hujan yang dikeluarkan oleh BMKG merupakan solusi awal untuk melakukan perencanaan dan tindakan dalam menanggulangi dampak bencana alam. Metode machine learning dapat digunakan untuk memprediksi parameter cuaca khususnya curah hujan yang bersifat time series, bagian dari machine learning yang dapat memahami sebuah pola dan mampu melakukan prediksi parameter cuaca dengan akurasi yang tinggi adalah deep learning, terdapat beberapa algoritma deep learning yang banyak digunakan untuk menganalisis dan memprediksi parameter cuaca yaitu Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Pada penelitian ini akan membandingkan kedua algoritma dan mengetahui manakah yang terbaik dalam melakukan prediksi curah hujan di Stasiun Geofisika Lampung Utara. Dari hasil penelitian evaluasi nilai RMSE 16.81, MSE 282.55 dan MAD 10.43 diketahui bahwa nilai model LSTM 1 dengan pembagian dataset 7:3 memiliki performa terbaik dalam memprediksi curah hujan sedangkan untuk prediksi terjadinya hujan model GRU 1 dengan dataset 7:3 memiliki performa terbaik dengan nilai akurasi 62%, precision 58%, recall 66%, dan f1score 62%.

Kata Kunci: BMKG; LSTM; GRU; Curah Hujan; Prediksi

Abstract—One of the impacts of the threat caused by heavy rain is flooding, which can have negative effects on human life. There are many factors that contribute to heavy rain, and predicting the intensity of rainfall issued by BMKG (Meteorology, Climatology, and Geophysics Agency) is an initial solution for planning and taking actions to mitigate the impacts of natural disasters. Machine learning methods can be used to predict weather parameters, especially time series rainfall. Deep learning, a branch of machine learning that can understand patterns and make weather parameter predictions with high accuracy, includes several algorithms commonly used for analyzing and predicting weather parameters, namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU). This research aims to compare both algorithms and determine which one performs best in predicting rainfall at the North Lampung Geophysics Station. From the evaluation results with RMSE (Root Mean Square Error) value of 16.81, MSE (Mean Square Error) value of 282.55, and MAD (Mean Absolute Deviation) value of 10.43, it is known that the LSTM model 1 with a dataset split of 7:3 has the best performance in predicting rainfall. As for the rain prediction, the GRU model 1 with a dataset split of 7:3 performs best with an accuracy value of 62%, precision of 58%, recall of 66%, and f1score of 62%.

Keywords: BMKG; LSTM; GRU; Rainfall; Prediction

1. PENDAHULUAN

Berdasarkan Indeks Risiko Bencana Indonesia (IRBI) tahun 2021 [1], salah satu dampak ancaman yang diakibatkan oleh hujan lebat adalah banjir yang dapat memberikan dampak negatif terhadap kehidupan manusia. Banyak faktor yang menyebabkan hujan lebat sehingga prediksi intensitas curah hujan yang dikeluarkan oleh BMKG merupakan solusi awal untuk melakukan perencanaan dan tindakan dalam menanggulangi dampak bencana alam. Salah satu model prediksi intensitas curah hujan berbasis statistik yang dikembangkan oleh Pusat Penelitian dan Pengembangan (Pusdiklat) BMKG adalah HyBMKG, HyBMKG merupakan suatu model machine learning untuk memprediksi curah hujan secara time series dengan menggabungkan beberapa metode yaitu Adaptive Neuro-Fuzzy Inference System (ANFIS), Autoregressive Integrated Moving Average (ARIMA), dan Transformasi Wavelet [2].

Metode machine learning tidak hanya digunakan untuk memprediksi curah hujan tetapi juga dapat digunakan untuk memprediksi parameter cuaca lainnya yang bersifat time series, bagian dari machine learning yang dapat memahami sebuah pola dan mampu melakukan prediksi parameter cuaca dengan akurasi yang tinggi adalah deep learning, salah satu algoritma deep learning yang banyak digunakan untuk menganalisis dan memprediksi parameter cuaca yaitu Long Short Term Memory (LSTM). Penelitian menggunakan algoritma LSTM pada data curah hujan menunjukkan nilai evaluasi menggunakan Root mean square error (RMSE) sebesar 1.744 – 15.719.

Pada tahun 2019, Atika dkk melakukan penelitian dengan tujuan meramalkan data deret waktu curah hujan di Surabaya, Jawa Timur. Mereka menggunakan metode Long Short-Term Memory (LSTM) dan metode Moving Average tunggal. Hasil penelitian menunjukkan bahwa metode LSTM memiliki nilai RMSE antara 13.766 hingga 15.719 dan MSE antara 189.514 hingga 247.090 [3]. Pada tahun 2020, Rizki dkk melakukan penelitian yang bertujuan untuk mengimplementasikan Deep Learning menggunakan arsitektur Long Short-Term Memory (LSTM) dalam prediksi curah hujan di Kota Malang, Jawa Timur. Hasil penelitian menunjukkan bahwa nilai RMSE untuk data latih adalah 12.079 dan untuk data uji adalah 11.288. Penelitian ini memberikan kontribusi dalam penggunaan LSTM dalam prediksi curah hujan dan memberikan informasi yang berguna dalam manajemen



sumber daya air dan mitigasi risiko bencana terkait cuaca di daerah tersebut [4]. Pada tahun 2022, Lattifia dkk melakukan penelitian yang bertujuan untuk mengembangkan model prediksi cuaca menggunakan metode Long Short-Term Memory (LSTM). Penelitian ini fokus pada prediksi suhu dan curah hujan. Metode LSTM digunakan dalam pengolahan data, dan untuk menghasilkan prediksi yang akurat, mereka menerapkan proses denormalisasi. Hasil penelitian menunjukkan bahwa model LSTM ini memiliki nilai RMSE sebesar 1.744 untuk prediksi curah hujan [5].

Algoritma selanjutnya yang sering digunakan untuk melakukan prediksi adalah Gated Recurrent Unit (GRU), GRU dapat dikatakan sebagai variasi dari algoritma LSTM karena memiliki kesamaan yaitu menyelesaikan vanishing gradient problem yang terdapat pada Recurrent Neural Network (RNN), vanishing gradient problem sendiri adalah ketika nilai gradient mengecil bersamaan dengan waktu, jika nilai gradient tersebut mengecil maka tidak akan berkontribusi banyak pada proses learning.

Penelitian menggunakan LSTM dan GRU menunjukkan bahwa performa LSTM lebih baik dibandingkan GRU, Hanifa dkk melakukan penelitian mengenai “Perbandingan Metode LSTM dan GRU (RNN) Untuk Klasifikasi Berita Palsu Berbahasa Indonesia” pada tahun 2021, penelitian tersebut mengklasifikasi berita bohong berbahasa Indonesia dengan menggunakan model RNN yaitu LSTM dan GRU. Nilai akurasi yang dihasilkan oleh model sebesar 73 % menggunakan LSTM dan 64 % menggunakan GRU [6]. Penelitian selanjutnya yang dilakukan Mochammad agus sholeh dan Rahmat hidayat pada tahun 2022, tentang “Perbandingan Model LSTM dan GRU Untuk Memprediksi Harga Minyak Goreng Di Indonesia”, pada penelitian ini model LSTM memiliki performa yang lebih unggul dibandingkan model GRU dengan MAE validation nilai ± 0.04 dan MSE validation loss bernilai ± 0.002 [7]. Yadi karyadi dan Handri santoso (2022) dalam penelitiannya yang berjudul “Prediksi Kualitas Udara Dengan Metoda LSTM, Bidirectional LSTM, dan GRU. Dari hasil penerapan algoritma dilakukan evaluasi menggunakan RMSE dari data testing dan dibandingkan dengan standar deviasi, LSTM dan LSTM Bidirectional menunjukkan hasil yang lebih bagus dibandingkan model GRU untuk data yang bersifat time series kualitas udara [8], akan tetapi pada penelitian lainnya GRU menunjukkan performa yang lebih baik dari LSTM [9][10] [11] [12],

Perbedaan penelitian ini dan penelitian sebelumnya terdapat pada arsitektur model yang digunakan, pada penelitian sebelumnya prediksi curah hujan hanya dilakukan menggunakan LSTM [3] [4] [5], maka dari itu pada penelitian ini ditambahkan satu (1) arsitektur model lagi yaitu GRU. Pada penelitian ini running LSTM dan GRU akan menggunakan beberapa input, istilah ini kita sebut dengan “multivariate”, perbedaan dengan pendekatan “univariate” di mana hanya satu atribut yang digunakan sebagai input, pendekatan “multivariate” memperhitungkan beberapa variabel sekaligus. Dengan menggunakan data multivariate, model LSTM dan GRU dapat mempelajari korelasi dan interaksi antara atribut tersebut. selanjutnya kedua model dibandingkan nilai evaluasinya untuk mengetahui model manakah yang terbaik dalam melakukan prediksi curah hujan di Stasiun Geofisika Lampung Utara.

Berdasarkan pernyataan sebelumnya maka pada penelitian ini akan membandingkan kedua algoritma dan mengetahui manakah yang terbaik dalam melakukan prediksi curah hujan dan prediksi kejadian hujan/tidak hujan di Stasiun Geofisika Lampung Utara, serta harapan pada penelitian ini menjadikan solusi awal untuk melakukan perencanaan dan tindakan dalam menanggulangi dampak bencana alam khususnya yang disebabkan oleh hujan lebat.

2. METODOLOGI PENELITIAN

2.1 Landasan Teori

2.1.1 Hujan

Hujan adalah sebuah bentuk presipitasi yang berbentuk cair maupun padat, sedangkan curah hujan ialah air hujan yang jatuh ke permukaan bumi dengan asumsi permukaan tersebut tidak menguap, meresap dan mengalir. Satuan curah hujan dinyatakan dalam millimeter (mm) yang diukur menggunakan penakar hujan observatorium dan penakar hujan tipe Hellman. Intensitas curah hujan merupakan jumlah curah hujan yang terjadi pada periode waktu tertentu, BMKG sendiri membagi kriteria intensitas curah hujan menjadi 5 kriteria. Terdapat 3 (tiga) pola curah hujan di Indonesia, dimana pembagian pola tersebut di bagi berdasarkan wilayah di Indonesia [13], Pola Curah Hujan di Stasiun Geofisika Lampung Utara memiliki satu puncak curah hujan yang terjadi pada bulan November hingga bulan Maret dan curah hujan terendah terjadi pada bulan mei hingga September, pola hujan ini juga dapat kita sebut sebagai pola hujan Monsun, dimana terdapat perbedaan yang jelas antara periode musim hujan dan musim kemarau

Tabel 1. Intensitas Curah Hujan

NO	Kriteria Hujan	Intensitas Curah Hujan Per Jam	Intensitas Curah Hujan Per Hari
1	Sangat Ringan	< 1 mm	< 5 mm
2	Ringan	1 - 5 mm	5 – 20 mm
3	Normal	5 – 10 mm	20 – 50 mm
4	Lebat	10 – 20 mm	50 – 100 mm


NO	Kriteria Hujan	Intensitas Curah Hujan Per Jam	Intensitas Curah Hujan Per Hari
5	Sangat Lebat	> 20 mm	> 100 mm

Tabel 2. Kriteria Hujan

NO	Kriteria Hujan	Intensitas Curah Hujan Per Bulan
1	Rendah	0 - 100 mm
2	Menengah	101 – 300 mm
3	Tinggi	301 – 500 mm
4	Sangat Tinggi	> 500mm

2.1.2 Long Short Term Memory (LSTM)

LSTM dirancang oleh Hochreiter dan Schmidhuber pada tahun 1997, Jaringan terdiri dari lapisan LSTM dengan proses berulang. Dalam modul LSTM terdapat beberapa perhitungan seperti penjumlahan, perkalian, penggabungan, penggandaan vektor, dan fungsi matematika seperti operasi tanh dan sigmoid, jika pada RNN menyambungkan neuron dan meneruskan ke depan, sedangkan LSTM meneruskan dan melihat neuron yang ada di belakangnya [14]. LSTM Di desain untuk menangani persoalan pada RNN berupa long-term dependency problem, RNN dapat dapat kehilangan informasi penting di awal jika sequeunce cukup panjang, pada backward propagation RNN bias mengalami vanishing gradient dimana nilai gradient nya sangat kecil sehingga tidak berkontribusi pada gate, kasus ekstrim pada RNN menyebabkan kondisi stop training hal ini terjadi pada sequeunce yang lebih panjang 5 – 10 steps. LSTM dirancang sebagai unit pengembangan dari RNN, RNN mempunyai struktur yang simple sedangkan pada LSTM di usulkan untuk menambah cell State dan menambahkan 3 gate [15]. Struktur LSTM terdiri dari 4 bagian, yaitu :



Gambar 1. Perbandingan RNN dan LSTM

Forget gate

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

Input gate

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(U_c x_t + W_c h_{t-1} + b_c) \tag{3}$$

Cell State

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{4}$$

Output gate

$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \tag{5}$$

$$h_t = o_t * \tanh(C_t) \tag{6}$$


Keterangan :

- σ : Fungsi Sigmoid
- \tanh : Fungsi hyperbolic tangent
- x_t : Input vektor
- h_{t-1} : Hidden state vector
- \tilde{C}_t : Cell input aktifasi vektor
- C_t : Cell state vektor
- $U_{f,i,o,c}, W_{f,i,o,c}, b_{f,i,o,c}$: Pembobotan matriks



2.1.3 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) diperkenalkan pertama kali oleh Cho dkk pada tahun 2014, yang mempunyai tujuan untuk menyelesaikan vanishing gradient problem yang terdapat pada RNN, vanishing gradient problem sendiri adalah ketika nilai gradient mengecil bersamaan dengan waktu, jika nilai gradient tersebut mengecil maka tidak akan berkontribusi banyak pada learning. GRU menggunakan 2 (dua) gate yaitu Update Gate dan Reset Gate untuk memutuskan informasi apa yang dapat diteruskan pada output. kedua bagian tersebut dapat dilatih untuk menyimpan informasi terdahulu tanpa harus membuang atau menghapus informasi yg tidak berhubungan dengan prediksi [16].



Gambar 2. Diagram GRU

Reset Gate

$$r_t = \sigma (W_r [h_{t-1}, x_t] + b_r) \tag{7}$$

$$\tilde{h}_t = \tanh(W_h[r_t * h_t, x_t] + b_h) \tag{8}$$

Update Gate

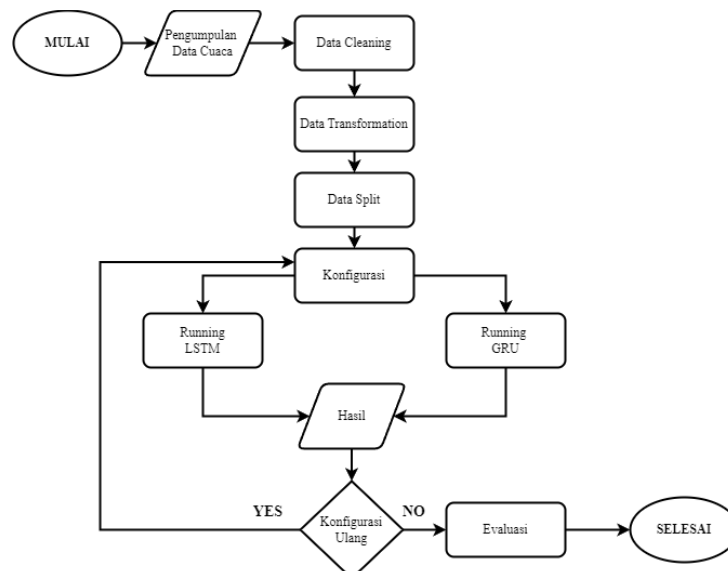
$$z_t = \sigma (W_z [h_{t-1}, x_t] + b_z) \tag{9}$$

$$\tilde{h}_t = \tanh(W_h[r_t * h_{t-1}, x_t] + b_h) \tag{10}$$

Keterangan :

- x_t : Input vektor
- $h_t,$: Output vektor
- h_{t-1} : Hidden state vector
- \tilde{h}_t : Kandidat aktifasi vektor
- σ : Fungsi Sigmoid
- \tanh : Fungsi hyperbolic tangent
- W_r, b_r, W_z, b_z : Pembobotan matriks

2.2 Tahapan Penelitian



Gambar 1. Tahapan Proses Penelitian Algoritma LSTM dan GRU Untuk Prediksi Curah Hujan



Berikut adalah penjelasan tentang tahapan penelitian yang menggambarkan urutan dalam melakukan penelitian menggunakan algoritma LSTM dan GRU untuk prediksi curah hujan, serta tahapan penerapan metode dan pengujian metode untuk mendapatkan hasil penelitian sesuai dengan harapan. Pada penelitian ini running LSTM dan GRU akan menggunakan beberapa input, istilah ini kita sebut dengan “multivariate”, perbedaan dengan pendekatan “univariate” di mana hanya satu atribut yang digunakan sebagai input, pendekatan “multivariate” memperhitungkan beberapa variabel sekaligus. Dengan menggunakan data multivariate, model LSTM atau GRU dapat mempelajari korelasi dan interaksi antara atribut tersebut.

Dalam proses training, model LSTM atau GRU akan menganalisis hubungan antar atribut cuaca selama beberapa waktu dengan data cuaca historis. contohnya, model akan mempelajari bahwa saat suhu tinggi dan kelembaban rendah, kemungkinan curah hujan rendah. Atau mungkin ada pola tertentu yang mengindikasikan bahwa saat tekanan atmosfer turun drastis, ada kecenderungan curah hujan yang tinggi. Pada fase prediksi, model akan menerima nilai-nilai aktual dari atribut saat ini dan menggunakan pengetahuan yang diperoleh selama proses training untuk memprediksi curah hujan yang mungkin terjadi.

- Pengumpulan Data Cuaca:** Tahap pertama dalam penelitian ini adalah mengumpulkan data cuaca yang mencakup informasi curah hujan historis dll. Data ini dapat diperoleh dari sumber-sumber seperti stasiun meteorologi, basis data cuaca, atau sumber terpercaya lainnya.
- Data cleaning:** Setelah data cuaca dikumpulkan, tahap selanjutnya adalah membersihkan data. Dalam tahap ini, Anda dapat melakukan tindakan seperti menghilangkan data yang tidak relevan, mengisi nilai yang hilang atau menghapusnya, dan merapikan data yang tidak valid.
- Data Transformation:** Pada tahap ini, dapat melakukan transformasi pada data cuaca, seperti mengubah format tanggal menjadi format yang konsisten (misalnya, dari mm/dd/yyyy menjadi yyyy-mm-dd), menambah atribut baru dari data yang sudah tersedia ataupun mensklalakan suatau atribut dalam suatu rentang nilai
- Pembagian Data:** Data akan dibagi menjadi subset train dan test dengan rasio tertentu, seperti 7:3, 8:2, atau 9:1. data train akan digunakan untuk melatih model, sedangkan data test akan digunakan untuk menguji kinerja model.
- Konfigurasi:** Pada tahap ini, algoritma LSTM dan GRU akan dikonfigurasi dengan menggunakan parameter-parameter tertentu. Misalnya, epoch (jumlah iterasi pelatihan), batch size (jumlah sampel yang diproses dalam satu iterasi), dan jumlah layer dalam algoritma. Konfigurasi ini dapat disesuaikan berdasarkan kebutuhan penelitian.
- Evaluasi Curah Hujan:** Setelah model dilatih, tahap evaluasi dilakukan menggunakan metrik evaluasi seperti Root Mean Square Error (RMSE), Mean Square Error (MSE), dan Mean Absolute Deviation (MAD). Metrik-metrik ini digunakan untuk mengevaluasi seberapa baik model LSTM dan GRU dalam memprediksi curah hujan.
- Evaluasi Kejadian Hujan/Tidak Hujan:** Selain mengukur kinerja dalam memprediksi curah hujan, tahap ini juga melibatkan evaluasi kejadian hujan/tidak hujan. Confusion matrix dapat digunakan untuk menganalisis jumlah prediksi benar (true positive dan true negative) dan kesalahan prediksi (false positive dan false negative).

2.2.1 Pengumpulan Data Cuaca

Pada Penelitian ini data yang digunakan adalah data pengamatan cuaca dengan 10 atribut yaitu : penyinaran matahari, kelembaban(jam 07,13,18), tekanan, suhu (maksimum dan minimum), kecepatan angin, curah hujan dan keadaan cuaca. Data tersebut didapatkan dari aplikasi IRIS yang merupakan sistem database di Stasiun Geofisika Lampung Utara selama 5 tahun dari tahun 2018-2022.

2.2.2 Preprocessing Data

Preprocessing merupakan bagian dari data preparation dan merupakan langkah yang wajib dilakukan untuk mengubah data yang tidak berguna menjadi data baru. Preprocessing data adalah sebuah teknik yang dapat dilakukan pada dataset untuk menghilangkan data error, data yang tidak relevan, missing data/value serta noise data. Kegunaan preprocessing data adalah untuk mengubah data mentah sehingga dapat meningkatkan kualitas data yang akan di analisis [17].

- Data cleaning**
Data cleaning atau data cleansing merupakan kegiatan mengisi data yang hilang, memfilter beberapa data yang salah dari kumpulan data dan mengurangi detail data yang tidak diperlukan. Pada penelitian ini jika pada dataset terdapat pengukuran hujan dengan keterangan tidak terukur (TTU) maka nilai curah hujan akan dianggap bernilai 0, dan keterangan “-“ yang berarti curah hujan 0 (tidak ada hujan).
- Data Transformation**
Data transformation digunakan untuk mengubah, menggabung dan menyamakan format data sehingga data yang akan dihasilkan lebih efisien dan lebih mudah dipahami sehingga dapat dibaca oleh algoritma. Pada tahap ini data pada kolom “DATE” memiliki format mm/dd/yyyy kemudian di konversi menjadi format yyyy-mm-dd, format data yang sebelumnya menggunakan .xls diubah menjadi format .csv dengan menyisipkan tanda “;” (koma) sebagai pemisah antara nilai curah hujan dan tanggal, tujuan data transformation ini agar data dapat di baca oleh algoritma yang akan digunakan

**2.2.4 Data Split**

Dataset yang di bagi menjadi data training dan test disebut metode holdout, pembagian 50:50 data training dan test umumnya tidak ideal untuk digunakan, akan lebih baik jika data training digunakan lebih dari setengahnya. Threefold cross validation adalah pembagian dataset 2/3 untuk data training dan 1/3 untuk test yang kemudian dilakukan pengulangan sebanyak 3 (tiga) kali [18] Pada pembelajaran sebuah machine learning ataupun deep learning semakin besar data training maka akan semakin baik pengklasifikasian, dan semakin besar data test maka akan semakin akurat perkiraan kesalahan. Penelitian yang telah dilakukan oleh [19] menggunakan LSTM data split menggunakan perbandingan 9:1 yang sudah dapat mewakili sifat dari seluruh data, sedangkan pada penelitian ini data split di bagi menjadi 3 bagian bagian yaitu 7:3, 8:2, dan 9:1.

2.2.5 Konfigurasi

Konfigurasi pada algoritma LSTM dan GRU akan menggunakan epoch 50 dan batch size 32, kemudian penggunaan data train dan test sebanyak tiga bagian yaitu pembagian dataset train 7: test 3, train 8 : test 2, dan train 9 : test 1, serta menggunakan 4 layer pada kedua algoritma. Melakukan scaling menggunakan StandarScaler dan optimizer "adam"

2.2.6 Evaluasi

Evaluasi merupakan hal yang sangat penting untuk dilakukan untuk menentukan kinerja dan untuk menentukan kelebihan dan kekurangan suatu metode sehingga dapat ditingkatkan melalui penyesuaian dan modifikasi, evaluasi suatu metode menggunakan statistik menggunakan data yang tersedia dan menganalisis besarnya variasi dan menentukan kinerja suatu metode, diantara metode statistik yang sering digunakan untuk melakukan evaluasi adalah :

a. Root Mean Square Error (RMSE)

RMSE digunakan untuk menghitung jumlah kesalahan dalam memprediksi suatu metod serta menghitung selisih antara nilai aktual dan nilai harapan dan membagi hasil total yang diperoleh dengan nilai hasil prediksi dan kemudian diakarkan.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (11)$$

b. Mean Square Error (MSE)

Mean square error menghitung rata-rata kesalahan kuadrat antara nilai aktual dan prediksi, metode ini biasanya digunakan untuk mengecek estimasi nilai error dalam suatu prediksi. Nilai MSE yang kecil atau nilai MSE yang mendekati nol berarti hasil prediksi sesuai dengan data aktual dan dapat digunakan untuk perhitungan prediksi periode mendatang.

$$MSE = \sum \frac{|\hat{y}_i - y_i|}{n} \quad (12)$$

c. Mean Absolute Deviation (MAD)

Mean absolute deviation merupakan hitungan yang digunakan untuk menghitung rata-rata kesalahan absolut. MAD mengukur keakuratan prediksi dengan menyamakan ukuran kesalahan sehingga setiap prediksi memiliki nilai absolut untuk setiap kesalahan.

$$MAD = \frac{\sum |\hat{y}_i - y_i|}{n} \quad (13)$$

Keterangan :

\hat{y}_i : Nilai data prediksi

y_i : Nilai data sebenarnya

n : Banyaknya data

d. Confusion Matrix

Confusion matrix merupakan hasil ringkasan kinerja dari proses klasifikasi yang berhubungan dengan data uji, dengan cara mengukur performanya sehingga kita dapat mengetahui seberapa baik sebuah model. Terdapat 4 kategori pada proses klasifikasi pada confusion matrix : True Positive (TP), False Positive (FP), True Negatif (TN) dan False Negative (FN) [20].

1. Accuracy : menghitung keakuratan model dalam melakukan klasifikasi

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (14)$$

2. Precision : menunjukkan tingkat keakuratan antara data yang diminta dengan hasil prediksi dari model, dengan kata lain merupakan rasio prediksi benar positif dibandingkan keseluruhan hasil prediksi positif.

$$Precision = \frac{TP}{TP+FP} \quad (15)$$



3. Recall : menggambarkan keberhasilan model dalam pencarian informasi. Jadi rasio prediksi benar positif terhadap semua prediksi benar-positif.

$$Recall : \frac{TP}{TP+FN} \tag{16}$$

4. F1-score menunjukkan perbandingan nilai precision dan recall yang telah dibobotkan

$$F1\ score : \frac{2*Recall*Precision}{Recall+Precision} \tag{17}$$

3. HASIL DAN PEMBAHASAN

3.1 Analisis Prediksi Curah Hujan Dataset 7:3 (LSTM 1 & GRU 1)

Dataset yang digunakan untuk analisis prediksi curah hujan untuk semua dataset menggunakan 9 atribut pengamatan cuaca kecuali atribut keadaan cuaca karena atribut tersebut merupakan data biner yang terdiri dari angka 0 (cerah) dan 1 (hujan). Perbandingan data train test 7:3 pada gambar 4 menggunakan data train dari tahun 2018 sampai bulan akhir bulan juni tahun 2021 dan data test dimulai dari bulan Juli tahun 2021 sampai akhir tahun 2022.



Gambar 4. Perbandingan Dataset 7:3

Pada tabel 3 nilai RMSE dari kedua arsitektur model yang terbaik adalah LSTM 1 dengan nilai 16.81 sedangkan nilai GRU 1 19.23. Nilai RMSE semakin kecil maka nilainya akan semakin dekat dengan nilai prediksi. Nilai MSE pada LSTM 1 sebesar 282.55 sedangkan pada GRU 1 369.82. Menunjukkan bahwa nilai MSE pada LSTM 1 lebih baik dibandingkan dengan GRU 1, nilai MSE yang lebih rendah menandakan bahwa semakin baik model dalam melakukan prediksi. Pada nilai evaluasi MAD semakin kecil nilainya maka akan semakin bagus nilai prediksi, dapat kita lihat bahwa nilai MAD LSTM 1 lebih baik dari nilai MAD GRU 1.

Tabel 3. Nilai Evaluasi LSTM 1 & GRU 1

	LSTM 1		GRU 1
RMSE	16.81	RMSE	19.23
MSE	282.55	MSE	369.82
MAD	10.43	MAD	11.05

3.2 Analisis Prediksi Curah Hujan Dataset 8:2 (LSTM 2 & GRU 2)

Dataset pada gambar 5 menggunakan perbandingan 8:2 antara data train dan test. Data train mencakup periode dari tahun 2018 hingga akhir bulan Desember 2022, sementara data test dimulai dari bulan Januari tahun 2022 hingga bulan Desember tahun 2022. Dalam penggunaan dataset ini, model akan dilatih dengan data train untuk mempelajari pola dan kemudian diuji dengan data test yang terpisah untuk mengukur kinerjanya.



Gambar 5. Perbandingan Dataset 8:2




Arsitektur model yang terbaik ditunjukkan pada tabel 4 adalah GRU 2 dengan nilai 19.41 dan nilai LSTM 2 19.50. Nilai MSE pada LSTM 2 sebesar 380.18 sedangkan pada GRU 2 376.66, menunjukkan bahwa nilai MSE pada GRU 2 lebih baik dibandingkan dengan LSTM 2, nilai MSE yang lebih rendah menandakan bahwa semakin baik model dalam melakukan prediksi. Pada nilai evaluasi MAD semakin kecil nilainya maka akan semakin bagus nilai prediksi, dapat kita lihat bahwa nilai MAD LSTM 2 lebih baik dari nilai MAD GRU 2.

Tabel 4. Nilai Evaluasi LSTM 2 & GRU 2

	LSTM	GRU		
RMSE	19.50	RMSE	19.41	
MSE	380.18	MSE	376.66	
MAD	11.00	MAD	11.16	

3.3 Analisis Prediksi Curah Hujan Dataset 9:1 (LSTM 3 & GRU 3)

Dataset ini menggunakan perbandingan 9:1 antara data train dan test. Data train mencakup rentang waktu dari tahun 2018 hingga akhir bulan Juni tahun 2022, sementara data test dimulai dari bulan Juli tahun 2022 hingga bulan Desember tahun 2022 yang ditunjukkan pada gambar 6. Dalam penggunaan dataset ini, model akan dilatih menggunakan data train untuk mempelajari pola dan melakukan prediksi, sedangkan data test akan digunakan untuk menguji sejauh mana model dapat melakukan prediksi yang akurat.



Gambar 6. Perbandingan Dataset 9:1

Nilai RMSE yang terbaik adalah LSTM ditunjukkan pada tabel 5 dengan nilai 21.10 dan nilai algoritma GRU 22.20. Nilai RMSE semakin kecil maka nilainya akan semakin dekat dengan nilai prediksi. Nilai MSE pada LSTM sebesar 445.34 dan pada GRU 492.89, menunjukkan bahwa nilai MSE pada GRU lebih baik dibandingkan dengan LSTM, nilai MSE yang lebih rendah menandakan bahwa semakin baik model dalam melakukan prediksi. Pada nilai evaluasi MAD semakin kecil nilainya maka akan semakin bagus nilai prediksi, dapat di lihat bahwa nilai MAD LSTM 10.65 dan MAD GRU 12.03.

Tabel 5. Nilai Evaluasi LSTM 2 & GRU 2

	LSTM	GRU		
RMSE	21.10	RMSE	22.20	
MSE	445.34	MSE	492.89	
MAD	10.65	MAD	12.03	

Model LSTM 1 dengan pembagian dataset train test 7:3 memiliki performa terbaik dalam memprediksi curah hujan dengan nilai RMSE 16.81, MSE 282.55, dan MAD 10.43. Selain itu, model LSTM 2 dengan pembagian dataset train test 8:2 juga memiliki performa yang cukup baik dengan nilai RMSE 19.50, MSE 380.18, dan MAD 11.0. Meskipun model GRU 1 dan GRU 2 memiliki performa yang cukup baik, namun performa dari kedua model tersebut masih di bawah performa dari model LSTM 1 dan LSTM 2.

Model LSTM 3 dan GRU 3 dengan pembagian dataset train test 9:1 memiliki performa yang paling rendah dibandingkan dengan model lainnya. Oleh karena itu, dalam konteks ini, model LSTM 1 dengan pembagian dataset train test 7:3 dapat dipilih sebagai model yang terbaik dalam memprediksi curah hujan. Namun, perlu diingat bahwa performa model ini juga harus dievaluasi dengan data uji yang lebih luas untuk memastikan keandalannya dalam memprediksi curah hujan.

Tabel 6. Hasil Evaluasi model LSTM dan GRU Prediksi Curah Hujan

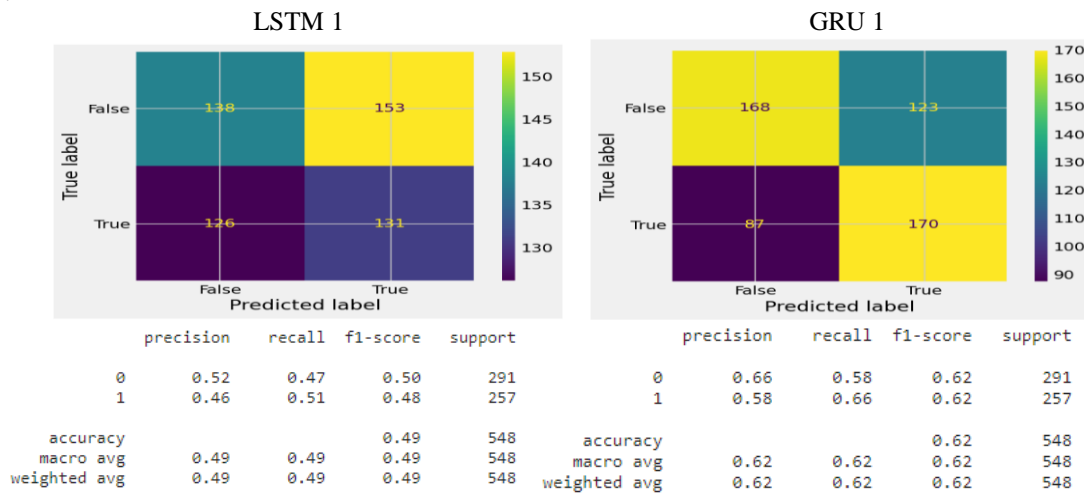
MODEL	PEMBAGIAN DATASET	RMSE	MSE	MAD
LSTM 1	7:3	16.81	282.55	10.43
GRU 1	7:3	19.23	369.82	11.05
LSTM 2	8:2	19.50	380.18	11.00
GRU 2	8:2	19.41	376.66	11.16
LSTM 3	9:1	21.10	445.34	10.65



MODEL	PEMBAGIAN DATASET	RMSE	MSE	MAD
GRU 3	9:1	22.20	492.89	12.03

3.4 Analisis Prediksi Hujan/Tidak Hujan Dataset 7:3 (LSTM 1 & GRU 1)

Pada tabel confusion matrix yang ditunjukkan pada gambar 7 LSTM 1 memprediksi kejadian hujan dengan benar sebanyak 131, dan memprediksi hujan akan tetapi yang terjadi adalah cerah sebanyak 153 kejadian. model GRU 1 memprediksi terjadinya hujan dengan benar sebanyak 170, dan memprediksi hujan akan tetapi yang terjadi adalah cerah sebanyak 123 kejadian. Nilai akurasi GRU 1 sebesar 62 % sedangkan LSTM 1 sebesar 49% yang menunjukkan bahwa ketidakmampuan model LSTM 1 dalam memprediksi hujan dan cerah dengan baik. Nilai precision sebesar 46% menandakan perbandingan hujan yang benar terjadi dengan hasil prediksi hujan, sedangkan nilai recall 51% menerangkan seberapa banyak prediksi terjadinya hujan dibandingkan dengan seluruh hujan yang sebenarnya. F1 score merupakan perbandingan antara recall dan precision, dengan nilai f1 score 48% dapat kita simpulkan bahwa LSTM 1 dibandingkan dengan GRU 1 memiliki performa yang kurang baik dalam memprediksi hujan.

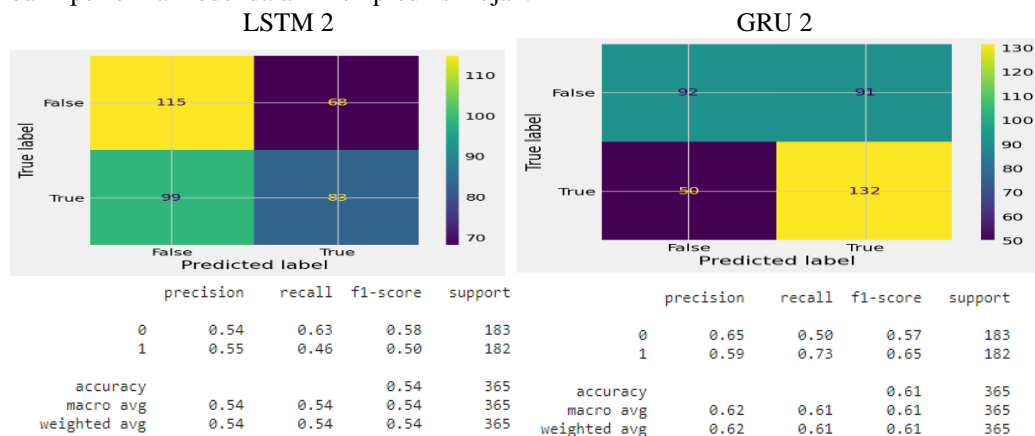


Gambar 2. Confusion matrix LSTM 1 dan GRU 1 (7:3)

3.5 Analisis Prediksi Hujan/Tidak Hujan Dataset 8:2 (LSTM 2 & GRU 2)

Berdasarkan confusion matrix yang diberikan pada gambar 8 model LSTM 2, terdapat true positif sebanyak 83, false positif sebanyak 68, true negatif sebanyak 115, dan false negatif sebanyak 99. Pada hasil running menggunakan model GRU 2 dengan pembagian data train test 8:2 yang di tunjukan pada gambar 8, terdapat 132 true positive (TP) yang artinya model berhasil memprediksi hujan dengan benar. Namun, terdapat 91 false positive (FP) yang artinya model salah memprediksi bahwa akan terjadi hujan padahal sebenarnya tidak. Selain itu, terdapat 92 true negative (TN) yang artinya model berhasil memprediksi cerah dengan benar. Namun, terdapat 50 false negative (FN) yang artinya model salah memprediksi bahwa akan terjadi cerah padahal sebenarnya hujan.

Berdasarkan nilai-nilai metrik performa yang diberikan pada LSTM 2, yaitu akurasi sebesar 54%, precision hujan sebesar 55%, recall hujan sebesar 46%, dan F1 score hujan sebesar 50%, dapat disimpulkan bahwa model prediksi cuaca hujan memiliki performa yang relatif buruk dalam memprediksi cuaca hujan. Pada model GRU 2 meskipun nilai recall cukup tinggi 73%, nilai presisi 59% dan F1 score 65% masih perlu ditingkatkan untuk memperbaiki performa model dalam memprediksi hujan.



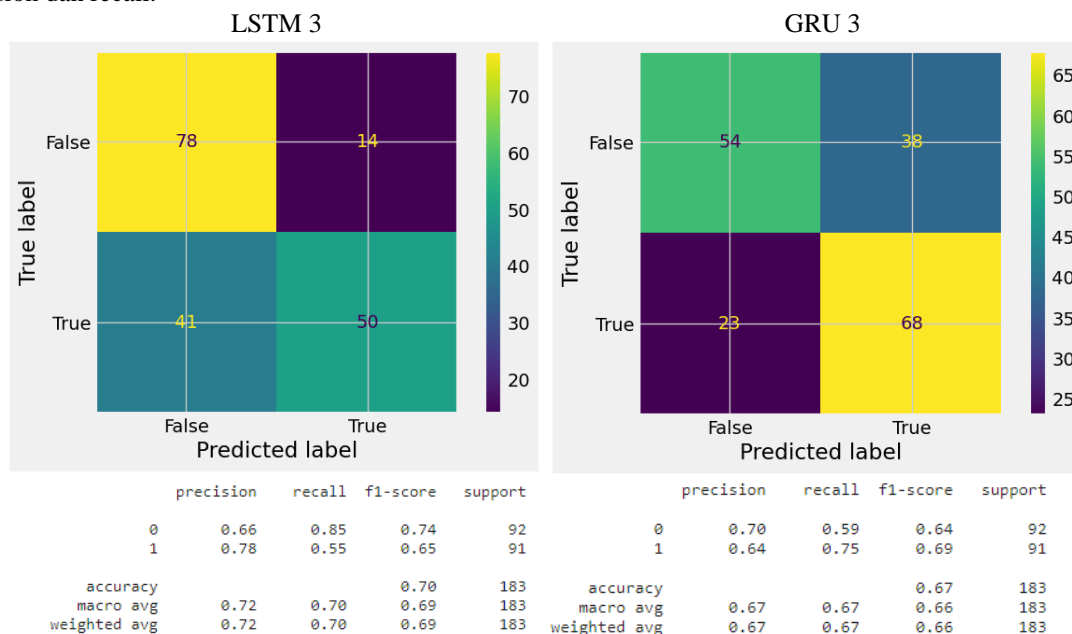
Gambar 3. Confusion matrix LSTM 2 dan GRU 2 (8:2)



3.6 Analisis Prediksi Hujan/Tidak Hujan Dataset 9:1 (LSTM 3 & GRU 3)

Pada gambar 9 hasil model LSTM 3 memprediksi kejadian hujan dengan benar sebanyak 50, dan memprediksi hujan akan tetapi yang terjadi adalah cerah sebanyak 14 kejadian. model GRU 3 memprediksi terjadinya hujan dengan benar sebanyak 68, dan memprediksi hujan akan tetapi yang terjadi adalah cerah sebanyak 38 kejadian. Dari hasil evaluasi pada gambar 9, model LSTM 3 memiliki akurasi sebesar 70% berdasarkan perhitungan manual, yang berarti sekitar 70% dari semua prediksi yang dilakukan oleh model adalah benar. Namun, kita juga dapat melihat bahwa nilai precision untuk prediksi hujan adalah 78%, yang berarti dari semua prediksi yang dilakukan oleh model sebagai hujan, sekitar 78% benar dan sisanya salah. Nilai recall untuk prediksi hujan adalah 55%, yang berarti bahwa dari semua data yang sebenarnya adalah hujan, model dapat mengidentifikasi sekitar 55% dari data tersebut. F1 score untuk prediksi hujan adalah 0.646, yang menunjukkan keseimbangan antara precision dan recall. Dalam kesimpulannya, model ini dapat mengidentifikasi hujan dengan cukup baik dengan nilai akurasi 65%, namun nilai recall yang relatif rendah menunjukkan bahwa masih ada kemungkinan bahwa model akan melewatkan beberapa kejadian hujan.

Model GRU 3 memiliki akurasi sebesar 67%, yang berarti sekitar 67% dari semua prediksi yang dilakukan oleh model adalah benar. Nilai precision untuk prediksi hujan adalah 64%, yang berarti dari semua prediksi yang dilakukan oleh model sebagai hujan, sekitar 64% benar dan sisanya salah. Nilai recall untuk prediksi hujan adalah 75%, yang berarti bahwa dari semua data yang sebenarnya adalah hujan, model dapat mengidentifikasi sekitar 75% dari data tersebut. F1 score untuk prediksi hujan adalah 69%, yang menunjukkan keseimbangan antara precision dan recall.



Gambar 4. Confusion matrix LSTM 3 dan GRU 3 (9:1)

Dari hasil penelitian yang telah dilakukan, dapat kita lihat pada tabel 6 bahwa keseluruhan model GRU memiliki performa yang lebih baik dibandingkan dengan model LSTM, Model GRU 1 dengan dataset (7:3) dan nilai akurasi 62%, precision 58%, recall 66%, dan f1 score 62%, model GRU 1 menunjukkan performa terbaik karena memiliki data test yang cukup besar sehingga dapat memberikan gambaran yang lebih akurat tentang kinerja model, dengan memiliki lebih banyak data test model dapat diuji pada berbagai situasi dan variasi data yang lebih luas, sehingga memberikan informasi yang lebih akurat tentang kemampuan umum model. Namun, perlu diperhatikan juga bahwa performa model tidak hanya dapat ditentukan dari satu kriteria evaluasi saja, melainkan juga harus dilihat secara keseluruhan dari kriteria evaluasi yang diberikan, Pembagian dataset yang baik memungkinkan model untuk mempelajari pola yang lebih umum dan membuat prediksi yang lebih akurat. Namun, perlu dicatat bahwa evaluasi model tidak hanya tergantung pada pembagian dataset, tetapi juga pada arsitektur model dan parameter lainnya.

Tabel 7. Hasil Evaluasi model LSTM dan GRU Prediksi Hujan/Tidak Hujan

MODEL	PEMBAGIAN DATASET	AKURASI	PRECISION	RECALL	F1 SCORE
LSTM 1	7:3	49%	46%	51%	48%
GRU 1	7:3	62%	58%	66%	62%
LSTM 2	8:2	54%	55%	46%	50%
GRU 2	8:2	61%	59%	73%	65%
LSTM 3	9:1	70%	78%	55%	65%



MODEL	PEMBAGIAN DATASET	AKURASI	PRECISION	RECALL	F1 SCORE
GRU 3	9:1	67%	64%	75%	69%

4. KESIMPULAN

Hasil analisis menggunakan algoritma LSTM dan GRU untuk prediksi curah hujan menunjukkan bahwa model LSTM 1 dengan pembagian dataset train-test 7:3 memiliki performa terbaik dalam memprediksi curah hujan. Model ini memiliki nilai evaluasi yang baik, dengan RMSE sebesar 16.81, MSE sebesar 282.55, dan MAD sebesar 10.43. Sementara itu, model GRU 1 dengan dataset (7:3) memiliki performa terbaik dalam memprediksi kejadian hujan/tidak hujan, dengan akurasi sebesar 62%, presisi 58%, recall 66%, dan f1 score 62%. Untuk penelitian selanjutnya, disarankan untuk meningkatkan jumlah data, menambahkan fitur tambahan seperti penguapan dan musim kemarau/hujan, menggunakan model yang lebih kompleks seperti CNN atau ANN, dan meningkatkan jumlah epoch pada pelatihan. Dengan mengikuti saran-saran ini, diharapkan penelitian selanjutnya dapat memberikan prediksi curah hujan yang lebih akurat dan bermanfaat dalam menghadapi tantangan cuaca.

REFERENCES

- [1] BNPB, IRBI: Indeks Risiko Bencana Indonesia, Tahun 2021. Jakarta: Pusat Data, Informasi dan Komunikasi Kebencanaan Badan Nasional Penanggulangan Bencana, 2021.
- [2] T. Astuti Nuraini et al., "Pengembangan Model HyBMG 2.07 Untuk Prediksi Iklim di Indonesia Dengan Menggunakan Data Tropical Rainfall Measuring Mission (TRMM)," *Jurnal Meteorologi dan Geofisika*, vol. 20, pp. 101–112, Jun. 2019.
- [3] R. Atika, A. Fariza, and A. R. Barakbah, "Forecast Rainfall Data Time Series Using Multi-Attribute Long Short Term Memory," R. Atika, A. Fariza, and A. R. Barakbah, Eds., Surabaya: IEEE, Sep. 2019. doi: 10.1109/ELECSYM.2019.8901590.
- [4] M. Rizki, S. Basuki, and Y. Azhar, "Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory Untuk Prediksi Curah Hujan Kota Malang," *REPOSITOR*, vol. 2, no. 3, pp. 331–338, Mar. 2020.
- [5] T. Lattifia, P. Wira Buana, N. Kadek, and D. Rusjyanthi, "Model Prediksi Cuaca Menggunakan Metode LSTM," *JITTER-Jurnal Ilmiah Teknologi dan Komputer*, vol. 3, no. 1, Apr. 2022.
- [6] A. Hanifa, S. A. Fauzan, M. Hikal, and M. B. Ashfiya, "Perbandingan Metode LSTM dan GRU (RNN) Untuk Klasifikasi Berita Palsu Berbahasa Indonesia," *Dinamika Rekayasa*, vol. 17, no. 1, pp. 33–39, 2021, doi: 10.20884/1.DR.2021.17.1.436.
- [7] M. A. Sholeh and R. Hidayat, "Perbandingan Model LSTM dan GRU Untuk Memprediksi Harga Minyak Goreng di Indonesia," *Edusaintek: Jurnal Pendidikan, Sains dan Teknologi*, vol. 9, no. 3, pp. 800–811, 2022, doi: 10.47668/edusaintek.v9i3.593.
- [8] Y. Karyadi and H. Santoso, "Prediksi Kualitas Udara Dengan Metoda LSTM, Bidirectional LSTM, dan GRU," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 1, pp. 671–684, 2022.
- [9] K. E. ArunKumar, D. V. Kalaga, C. M. S. Kumar, M. Kawaji, and T. M. Brenza, "Forecasting of COVID-19 using deep layer Recurrent Neural Networks (RNNs) with Gated Recurrent Units (GRUs) and Long Short-Term Memory (LSTM) cells," *Chaos Solitons Fractals*, vol. 146, May 2021, doi: 10.1016/j.chaos.2021.110861.
- [10] P. T. Yamak, L. Yujian, and P. K. Gadosey, "A comparison between ARIMA, LSTM, and GRU for time series forecasting," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Dec. 2019, pp. 49–55. doi: 10.1145/3377713.3377722.
- [11] J. M. Han, Y. Q. Ang, A. Malkawi, and H. W. Samuelson, "Using recurrent neural networks for localized weather prediction with combined use of public airport data and on-site measurements," *Build Environ*, vol. 192, Apr. 2021, doi: 10.1016/j.buildenv.2021.107601.
- [12] S. Nosouhian, F. Nosouhian, and A. K. Khoshouei, "A review of recurrent neural network architecture for sequence learning: Comparison between LSTM and GRU," 2021, doi: 10.20944/preprints202107.0252.v1.
- [13] E. Aldrian and R. D. Susanto, "Identification Of Three Dominant Rainfall Regions Within Indonesia and Their Relationship to Sea Surface Temperature," *International Journal of Climatology*, vol. 23, no. 12, pp. 1435–1452, Oct. 2003, doi: 10.1002/joc.950.
- [14] S. Hochreiter and S. Jurgen, "Long Short-Term Memory," *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [15] M. Phi, "Illustrated Guide to LSTM's and GRU's: A step by step explanation," <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21> (diakses pada 29 Agustus 2022), Sep. 25, 2018.
- [16] K. Cho, B. van Merriënboer, D. Bahdanau, and Y. Bengio, "On the Properties of Neural Machine Translation: Encoder-Decoder Approaches," *Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*, Sep. 2014, [Online]. Available: <http://arxiv.org/abs/1409.1259>
- [17] J. Han, M. Kamber, and J. Pei, "Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems)," 2011.
- [18] I. H. Witten, E. Frank, and M. A. Hall, "Data Mining: Practical Machine Learning Tools and Techniques. 3rd edition," Burlington, 2011.
- [19] E. Supriyadi, "Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (LSTM)," *Jurnal Meteorologi dan Geofisika*, vol. 21, pp. 55–67, Oct. 2019.
- [20] C. Sammut and G. Webb, "Encyclopedia of Machine Learning," *Encyclopedia of Machine Learning*. pp. 140–259, 2011. doi: 10.1007/978-0-387-30164-8.