

PREDIKSI CUACA DENGAN PERBANDINGAN METODE LSTM DAN GRU

Muhammad Adjie Setiawan^{*1}, Gasim¹, Lastri Widya Astuti¹

¹Teknik Informatika, Fakultas Ilmu Komputer dan Sains, Universitas Indo Global Mandiri,
Palembang, Indonesia

Penulis korespondensi: Muhammad Adjie Setiawan (2022110089@student.uigm.ac.id)

Prediksi kondisi cuaca yang tepat diperlukan untuk mendukung berbagai kegiatan masyarakat, terutama pada wilayah tropis yang memiliki perubahan cuaca relatif kompleks. Penelitian ini dilakukan untuk mengevaluasi dan membandingkan kemampuan Long Short-Term Memory dan Gated Recurrent Unit dalam mengklasifikasikan kondisi cuaca ke dalam tiga kategori, yaitu cerah, berawan, dan hujan. Data penelitian berupa data klimatologi bulanan periode Januari 2021 sampai Desember 2025 yang diperoleh dari Stasiun Klimatologi Sumatera Selatan. Data tersebut diproses melalui interpolasi linear untuk menghasilkan data harian sebanyak 1.796 observasi. Proses penelitian mencakup pembersihan data, normalisasi, pengkodean kelas, pembentukan sekuens menggunakan sliding window, pembagian data latih dan data uji, serta pengujian model berdasarkan akurasi, presisi, recall, dan F1-score. Hasil pengujian menunjukkan bahwa Gated Recurrent Unit menghasilkan akurasi sebesar 88%, sedangkan Long Short-Term Memory mencapai 77%. Dengan demikian, Gated Recurrent Unit menunjukkan performa yang lebih unggul dalam klasifikasi kondisi cuaca.

Kata Kunci – Cuaca, LSTM, GRU, Klimatologi.

I. PENDAHULUAN

Cuaca merupakan salah satu faktor penting yang memengaruhi berbagai aktivitas manusia, seperti pertanian, transportasi, perikanan, dan mitigasi bencana. Ketidakpastian kondisi cuaca, khususnya di wilayah tropis seperti Indonesia, dapat menimbulkan gangguan aktivitas dan risiko bencana hidrometeorologi [1]. Kondisi cuaca yang dinamis memerlukan sistem prediksi yang mampu memberikan informasi secara objektif dan akurat. Perkembangan *machine learning* dan *deep learning* memberikan peluang untuk memanfaatkan data historis dalam mempelajari pola cuaca secara lebih efektif [2].

Data cuaca memiliki karakteristik deret waktu karena kondisi pada suatu periode berkaitan dengan kondisi sebelumnya. LSTM mampu menangkap ketergantungan


jangka panjang melalui mekanisme memori dan *gates* [3], tetapi memiliki arsitektur yang lebih kompleks dan jumlah parameter yang lebih banyak sehingga membutuhkan sumber daya komputasi lebih besar [4]. Sebagai alternatif, GRU memiliki struktur yang lebih sederhana dan efisien dengan jumlah parameter yang lebih sedikit [5], meskipun kesederhanaannya dapat memengaruhi kemampuan dalam menangkap pola temporal yang kompleks [6].

Penelitian terdahulu menunjukkan hasil yang belum konsisten mengenai kinerja kedua metode. Cahyo dan Sunyoto [7] menunjukkan bahwa LSTM dan GRU memiliki performa yang relatif kompetitif dalam prediksi hujan, sedangkan Islamy et al. [8] menunjukkan bahwa LSTM lebih baik dalam prediksi arah dan kecepatan angin. Perbedaan tersebut menunjukkan bahwa kinerja LSTM dan GRU dipengaruhi oleh karakteristik data dan permasalahan yang dikaji [5]. *Research gap* penelitian ini terletak pada masih terbatasnya kajian yang membandingkan kedua metode tersebut untuk klasifikasi kondisi cuaca berdasarkan karakteristik klimatologi lokal.

Kebaruan penelitian ini terletak pada perbandingan langsung LSTM dan GRU untuk mengklasifikasikan kondisi cuaca ke dalam kategori cerah, berawan, dan hujan. Fokus tersebut memberikan kajian yang lebih spesifik dibandingkan penelitian sebelumnya yang banyak berfokus pada prediksi parameter cuaca tertentu, seperti curah hujan atau arah dan kecepatan angin. Oleh karena itu, penelitian ini bertujuan membandingkan kinerja LSTM dan GRU serta menentukan metode yang lebih optimal dalam klasifikasi kondisi cuaca. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan sistem klasifikasi cuaca berbasis *deep learning* dan pemilihan arsitektur yang sesuai untuk data deret waktu.

II. METODE PENELITIAN

Tahapan penelitian yang dilakukan dalam penelitian ini disajikan pada Gambar 1, yang menunjukkan alur proses penelitian secara keseluruhan.



Gambar 1. Tahapan Penelitian

A. Data Acquisition

Pengumpulan data merupakan tahap yang dilakukan untuk memperoleh dataset yang digunakan dalam penelitian [9]. Data penelitian berupa data klimatologi yang diperoleh dari Stasiun Klimatologi Sumatera Selatan. Dataset yang digunakan merupakan data deret waktu (*time series*) dengan periode Januari 2021 hingga Desember 2025, yang terdiri atas data pengamatan klimatologi bulanan. Data tersebut mencakup beberapa parameter meteorologi yang digunakan sebagai variabel masukan dan kondisi cuaca sebagai variabel target. Variabel yang digunakan meliputi suhu udara, kelembaban udara, curah hujan, kecepatan angin, arah angin, tekanan udara, dan lama penyinaran matahari. Rincian variabel yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1 Variabel Dataset Penelitian

No	Nama Variabel	Tipe Data	Keterangan
1	Suhu Udara	Numerik	Tingkat panas atau dinginnya udara
2	Kelembaban Udara	Numerik	Kandungan uap air di udara
3	Curah Hujan	Numerik	Intensitas hujan dalam periode tertentu
4	Kecepatan Angin	Numerik	Kecepatan angin di atmosfer
5	Arah Angin	Nominal	Arah datangnya angin
6	Tekanan Udara	Numerik	Tekanan udara sebagai indikator perubahan cuaca
7	Lama Penyinaran Matahari	Numerik	Lama penyinaran matahari
8	Kondisi Cuaca	Numerik	Kondisi cuaca

B. Data Interpolation

Data Interpolation dilakukan untuk mengekspansi jumlah sampel data agar mencukupi kebutuhan pelatihan model. Pada penelitian ini, penambahan data dilakukan menggunakan metode interpolasi linear. Pendekatan ini dipilih karena mampu mengestimasi nilai-nilai baru di antara dua titik data yang berurutan menggunakan persamaan polinomial orde pertama (garis lurus) [10]. Secara matematis, perhitungan interpolasi linear yang digunakan dirumuskan pada (11).

$$f_1(x) = f(x_0) + \frac{f(x_1) - f(x_0)}{x_1 - x_0}(x_1 - x_0) \quad (11)$$

Metode ini diaplikasikan pada dataset awal yang berjumlah 60 titik data historis dengan skala pencatatan bulanan selama periode 5 tahun. Melalui perhitungan tersebut, rentang waktu antardata dirapatkan menjadi skala harian, sehingga diperoleh 1.796 titik data hasil estimasi. Penggunaan interpolasi linear memungkinkan terbentuknya rangkaian waktu harian yang diperlukan dalam proses pembentukan sekuens dengan *time steps* 7 pada model LSTM dan GRU.

Namun, perlu diperhatikan bahwa interpolasi linear tidak menghasilkan informasi pengamatan baru, melainkan mengestimasi nilai di antara data yang tersedia. Asumsi perubahan nilai secara linear juga tidak sepenuhnya sesuai dengan karakteristik cuaca yang dapat mengalami perubahan secara tidak teratur dan stokastik. Penerapan interpolasi linear berpotensi menghaluskan (*smoothing*) fluktuasi cuaca harian yang sebenarnya sehingga pola yang dihasilkan lebih merepresentasikan tren sintetis (*synthetic trend*) antarbulan. Kondisi tersebut dapat menyebabkan model mempelajari pola hasil interpolasi dan belum sepenuhnya merepresentasikan

dinamika cuaca harian yang sebenarnya. Oleh karena itu, penggunaan data hasil interpolasi menjadi salah satu keterbatasan penelitian yang perlu dipertimbangkan dalam menginterpretasikan hasil evaluasi model.

C. Data Preprocessing

Data Preprocessing dilakukan sebelum pembentukan model untuk menjamin kualitas data yang akan digunakan. Proses ini bertujuan untuk menangani berbagai permasalahan pada data mentah hasil pengumpulan, seperti data duplikat, atribut yang tidak esensial, *missing values*, dan perbedaan skala variabel yang dapat memengaruhi kinerja model [11].

Tahap awal dilakukan dengan membersihkan data dan menangani *missing values* untuk memastikan kualitas data. Selanjutnya, proses *encoding* diterapkan pada variabel kategorikal, seperti arah angin dan kondisi cuaca, agar dapat diproses dalam bentuk numerik. Kondisi cuaca diklasifikasikan menjadi tiga kategori, yaitu cerah, berawan, dan hujan.

Selanjutnya, dilakukan normalisasi menggunakan *Min-Max Scaler* untuk menyamakan skala setiap fitur numerik ke dalam rentang 0 hingga 1. Setelah itu, data dibentuk menjadi sekuens menggunakan *sliding window* dengan ukuran *time steps* sebanyak 7 hari. Artinya, data selama tujuh hari digunakan sebagai masukan untuk memprediksi kondisi cuaca pada hari berikutnya. Hasil pembentukan sekuens berupa tensor tiga dimensi dengan format [jumlah sampel, *time steps*, jumlah fitur] yang sesuai dengan kebutuhan model LSTM dan GRU.

D. Data Splitting

Data Splitting memisahkan data menjadi data latih dan data uji. Data latih dialokasikan untuk proses pengenalan pola oleh model, sementara data uji digunakan secara khusus untuk mengukur kinerja model setelah tahap pelatihan selesai [12].

Setelah seluruh tahapan *preprocessing* selesai, data dibagi menjadi data pelatihan dan pengujian dengan proporsi 80:20 tanpa pengacakan untuk mempertahankan urutan waktu. Selanjutnya, data digunakan dalam proses pemodelan dan evaluasi LSTM serta GRU.

E. Modeling LSTM dan GRU

Tahap *modeling* dilakukan dengan menerapkan arsitektur LSTM dan GRU menggunakan data latih yang telah melalui proses *preprocessing* dan pembentukan sekuens. Masukan (input) untuk kedua model berupa format sekuensial yang dibentuk menggunakan metode *sliding window* dengan ukuran *time steps* sebanyak 7 hari. Arsitektur jaringan yang dibangun untuk kedua model memiliki spesifikasi yang seragam agar perbandingan menjadi objektif. Arsitektur tersebut terdiri atas *input layer*, satu lapisan LSTM atau GRU dengan 25 neuron, lapisan *dropout* sebesar 0,3, serta *dense layer* dengan 3 *neuron* sebagai lapisan keluaran. Ketiga *neuron* pada lapisan keluaran tersebut merepresentasikan tiga target kelas kondisi cuaca, yaitu cerah, berawan, dan hujan. Lapisan ini menggunakan fungsi aktivasi *softmax* untuk menghasilkan nilai probabilitas klasifikasi pada masing-masing kelas. Untuk mengukur kesalahan prediksi, fungsi *categorical cross-entropy* diterapkan sebagai *loss function* yang ideal untuk kasus klasifikasi multikelas.

Selama proses pelatihan, kedua model dioptimasi menggunakan algoritma *Adam optimizer* dengan tingkat pembelajaran (*learning rate*) yang ditetapkan sebesar 0,01. Setelah proses pelatihan diselesaikan, kemampuan generalisasi model LSTM dan GRU diuji secara langsung menggunakan data uji.

F. Evaluation Model

Tahap ini dilakukan untuk mengukur kinerja LSTM dan GRU dalam mengklasifikasikan kondisi cuaca. Evaluasi menggunakan data pengujian (*testing data*) yang tidak digunakan selama proses pelatihan, sehingga kemampuan generalisasi kedua model dapat dinilai secara objektif terhadap data yang belum pernah dipelajari.

Evaluasi dilakukan menggunakan *confusion matrix* untuk membandingkan hasil prediksi model dengan label aktual pada tiga kelas kondisi cuaca, yaitu cerah, berawan, dan hujan. *Confusion matrix* menunjukkan jumlah prediksi yang benar maupun salah pada setiap kelas [13].

Berdasarkan hasil *confusion matrix*, kinerja kedua model dievaluasi menggunakan empat metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score* [14]. *Accuracy* digunakan untuk mengukur tingkat ketepatan prediksi secara keseluruhan. *Precision* mengukur ketepatan prediksi pada setiap kelas, sedangkan *recall* mengukur kemampuan model dalam mengenali data aktual pada setiap kelas. Sementara itu, *F1-score* merupakan rata-rata harmonis antara *precision* dan *recall* yang digunakan untuk memberikan penilaian kinerja yang lebih seimbang [15].

Hasil evaluasi dari LSTM dan GRU kemudian dibandingkan berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Perbandingan tersebut digunakan untuk menentukan model yang memiliki kinerja lebih optimal dalam mengklasifikasikan kondisi cuaca pada dataset penelitian. Rumus metrik evaluasi dapat dilihat sebagai berikut [16].

$$Accuracy = \frac{TN+TP}{TN+FP+FN+TN} \quad (12)$$

$$Precision = \frac{TP}{TP+FP} \quad (13)$$

$$Recall = \frac{TP}{TP+FN} \quad (14)$$

$$F1 - Score = \frac{2 \times (Recall \times Precision)}{(Recall + Precision)} \quad (15)$$

III. HASIL DAN PEMBAHASAN

A. Hasil

Preprocessing diawali dengan penerapan interpolasi linear dan metode *forward fill*, yang berhasil mengekspansi dataset dari 60 observasi bulanan menjadi 1.796 observasi harian. Peningkatan resolusi ini menghasilkan deret waktu yang kontinu untuk mendukung pembentukan sekuens harian pada model LSTM dan GRU. Namun, penambahan jumlah observasi tersebut tidak menunjukkan adanya penambahan informasi pengamatan baru karena nilai harian yang terbentuk merupakan hasil estimasi dari data bulanan. Interpolasi linear juga berpotensi menghaluskan (*smoothing*) fluktuasi cuaca yang sebenarnya dan

menghasilkan pola tren sintetis (*synthetic trend*) di antara pengamatan bulanan. Kondisi ini menjadi keterbatasan penelitian karena pola yang dipelajari model dapat dipengaruhi oleh karakteristik data hasil interpolasi dan belum sepenuhnya merepresentasikan dinamika cuaca harian yang bersifat stokastik.

Dataset kemudian dibersihkan dari anomali melalui penghapusan atribut tidak relevan, penanganan nilai kosong (*missing values*), dan pembuangan data duplikat. Selanjutnya, data kategorikal dikonversi ke format numerik melalui tahapan *encoding*, di mana atribut WinDir dipetakan menjadi bilangan bulat dan atribut target *Weather* direpresentasikan ke dalam kelas cuaca Cerah, Berawan, dan Hujan. Seluruh fitur kemudian diseragamkan ke dalam rentang 0 hingga 1 melalui proses normalisasi.

Sebagai tahap akhir *preprocessing*, penerapan teknik *sliding window* dengan *time steps* = 7 menghasilkan dimensi masukan (*input*) X_{seq} sebesar (1789, 7, 7) dan dimensi target Y_{seq_cat} sebesar (1789, 3). Transformasi ini membentuk 1.789 sampel, di mana angka 7 pertama merepresentasikan data historis selama satu minggu (*time steps*) dan angka 7 berikutnya adalah jumlah fitur meteorologi. Sementara itu, dimensi target (1789, 3) menunjukkan tiga kelas cuaca yang telah dikonversi ke format *encoding*. Struktur data akhir ini telah sepenuhnya sesuai dengan spesifikasi yang dibutuhkan oleh arsitektur LSTM dan GRU untuk mempelajari pola temporal dan melakukan klasifikasi.

Proses LSTM modeling dilakukan melalui 30 *epoch* dengan *batch size* sebesar 16. Konfigurasi ini diterapkan untuk memungkinkan model mempelajari pola cuaca secara bertahap sekaligus menjaga efisiensi komputasi selama pembaruan bobot. Selama proses pelatihan berlangsung, data uji digunakan sebagai data validasi guna memantau kinerja model pada setiap *epoch* serta mendeteksi secara dini potensi *overfitting* maupun *underfitting*. Seluruh riwayat metrik pelatihan direkam untuk kebutuhan analisis performa. Hasil evaluasi klasifikasi dari LSTM modeling dapat dilihat pada Tabel 2.

Tabel 2. Hasil LSTM Modeling

Target	Precision	Recall	F1-Score	Accuracy
Cerah	0,64	0,64	0,64	-
Berawan	0,84	0,88	0,86	-
Hujan	0,82	0,79	0,80	-
Macro Avg	0,77	0,77	0,77	0,77

Sebagai pembandingan terhadap kinerja model LSTM tersebut, tahap pemodelan dilanjutkan menggunakan arsitektur GRU. Proses pelatihan model GRU dilakukan dengan konfigurasi yang identik, yakni 30 *epoch* dan *batch size* sebesar 16. Selama pelatihan berlangsung, data uji digunakan sebagai data validasi untuk memantau kinerja model serta mendeteksi potensi *overfitting*. Seluruh riwayat metrik direkam untuk menganalisis proses konvergensi model. Adapun hasil evaluasi


klasifikasi dari pemodelan GRU dapat dilihat pada Tabel 3.

Tabel 3. Hasil GRU Modeling

Target	Precision	Recall	F1-Score	Accuracy
Cerah	0,83	0,79	0,81	-
Berawan	0,89	0,98	0,93	-
Hujan	0,91	0,85	0,88	-
Macro Avg	0,88	0,87	0,87	0,88

Setelah proses pelatihan pemodelan selesai, tahap selanjutnya adalah pengujian model menggunakan data uji (X_{test} dan y_{test}) yang sebelumnya tidak dilibatkan dalam proses pembelajaran.

Tahap pengujian diawali dengan menghasilkan prediksi melalui fungsi *predict* pada pustaka Keras, yang menghasilkan keluaran berupa nilai probabilitas untuk setiap kelas. Distribusi hasil prediksi ini divisualisasikan menggunakan *confusion matrix* pada Gambar 2, sedangkan rincian nilai metrik evaluasi untuk model LSTM disajikan pada Tabel 4.



Gambar 2. Confusion Matrix Pengujian LSTM


Tabel 4. Hasil Evaluasi Pengujian LSTM

Target	Precision	Recall	F1-Score	Accuracy
Cerah	0,63	0,65	0,64	-
Berawan	0,82	0,93	0,87	-
Hujan	0,87	0,73	0,79	-
Macro Avg	0,77	0,77	0,77	0,77

Berdasarkan hasil pengujian pada Tabel 4, model LSTM mencapai tingkat akurasi total sebesar 0,77 atau 77%, yang menunjukkan kapabilitas model yang baik secara keseluruhan. Analisis mendalam pada setiap kategori memperlihatkan bahwa cuaca Berawan mencatatkan performa terbaik dengan *F1-score* sebesar 0,87, didorong oleh nilai *recall* yang sangat tinggi yakni 0,93. Hal ini menandakan bahwa model memiliki sensitivitas yang sangat baik dalam mengenali hampir seluruh kejadian aktual cuaca berawan. Selanjutnya, kategori Hujan menunjukkan tingkat *precision* tertinggi sebesar 0,87, yang menegaskan bahwa ketika model memprediksi kondisi hujan, tingkat keyakinan prediksinya sangat akurat. Di sisi lain, kategori Cerah menjadi tantangan tersendiri dengan perolehan *F1-score* terendah (0,64), kemungkinan besar disebabkan oleh adanya irisan pola data yang serupa dengan kategori lain.

Secara keseluruhan, nilai *macro average* sebesar 0,77 menegaskan bahwa model LSTM memiliki reliabilitas yang stabil dalam menangkap pola temporal cuaca.

Prosedur pengujian dan penyelarasan format prediksi yang sama kemudian diterapkan pada model GRU. Visualisasi hasil pengujian GRU dapat dilihat pada Gambar 3.



Gambar 3. Confusion Matrix Pengujian GRU

Evaluasi pada arsitektur GRU ini dilakukan guna membandingkan efektivitasnya terhadap model LSTM dalam memproses dataset yang sama. Hasil evaluasi metrik untuk pengujian model GRU dapat dilihat pada Tabel 5.

Tabel 5. Hasil Evaluasi Pengujian GRU

Target	Precision	Recall	F1-Score	Accuracy
Cerah	0,84	0,72	0,78	-
Berawan	0,86	0,98	0,92	-
Hujan	0,90	0,88	0,89	-
Macro Avg	0,87	0,86	0,86	0,87

Berdasarkan hasil pengujian, model GRU menunjukkan lonjakan performa klasifikasi yang sangat impresif dengan tingkat akurasi total mencapai 0,87 (87%) dan *macro average F1-score* sebesar 0,86. Berbeda dengan LSTM yang kesulitan pada kategori Cerah, model GRU justru memperoleh *F1-score* tertinggi pada kelas Berawan (0,92) dengan tingkat *recall* mencapai 0,98. Hal ini menunjukkan kemampuan luar biasa GRU dalam mendeteksi kondisi cuaca Berawan. Kategori Hujan juga memberikan hasil yang sangat baik dengan *F1-score* 0,89 dan *precision* tertinggi 0,90, menandakan prediksi hujan yang sangat presisi. Sementara itu, kategori Cerah memperoleh *F1-score* sebesar 0,78, yang tetap tergolong dalam performa klasifikasi yang cukup baik. Secara keseluruhan, hasil ini membuktikan bahwa arsitektur GRU sangat efektif dan superior dalam menangkap pola temporal pada dataset cuaca ini, serta mampu menghasilkan prediksi yang lebih stabil dibandingkan LSTM.

B. Pembahasan

Berdasarkan komparasi hasil pengujian, model GRU menunjukkan performa klasifikasi yang jauh lebih superior dibandingkan LSTM pada seluruh metrik evaluasi. Model GRU berhasil memperoleh nilai *precision*, *recall*, *F1-score*, dan *accuracy* pada kisaran

0,86 hingga 0,87. Di sisi lain, kinerja model LSTM tertahan pada angka rata-rata 0,77. Peningkatan akurasi sebesar 10% (dari 77% menjadi 87%) ini membuktikan bahwa arsitektur GRU lebih efektif dalam mengenali pola cuaca dan menghasilkan prediksi yang lebih akurat pada dataset penelitian ini.

Perbedaan performa yang signifikan ini sangat dipengaruhi oleh karakteristik arsitektur kedua model dalam mengelola aliran informasi temporal. LSTM memiliki struktur yang jauh lebih kompleks karena memisahkan memori internal (*cell state*) dari *hidden state*, serta menggunakan tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*. Kompleksitas ini berimplikasi pada banyaknya jumlah parameter bobot yang harus diperbarui selama proses pelatihan. Pada dataset dengan ukuran sampel yang relatif terbatas, tingginya kompleksitas parameter pada LSTM justru dapat membuat proses pembelajaran menjadi kurang optimal dan rentan kehilangan fokus dalam mengekstraksi fitur penting.

Sebaliknya, GRU mengusung pendekatan arsitektur yang lebih sederhana dengan jumlah parameter komputasi yang lebih sedikit. Secara spesifik, GRU memodifikasi komponen LSTM dengan menggabungkan fungsi *forget gate* dan *input gate* menjadi satu gerbang tunggal bernama *update gate*, serta menyatukan *cell state* dan *hidden state* menjadi satu saluran aliran informasi. Selain *update gate*, GRU hanya menggunakan satu gerbang tambahan berupa *reset gate*. Kesederhanaan mekanisme ini terbukti membuat proses pelatihan menjadi lebih efisien, komputasi berjalan lebih cepat, dan model menjadi lebih stabil. Mekanisme *update gate* pada GRU terbukti sangat mumpuni dalam mempertahankan informasi historis yang krusial secara proporsional, sehingga sangat ideal untuk menangkap pola fluktuasi temporal pada data meteorologi.

Lebih lanjut, efisiensi arsitektur GRU tidak hanya berdampak pada kecepatan komputasi, tetapi juga menghasilkan kemampuan generalisasi model yang sangat tinggi terhadap data baru. Keandalan ini dibuktikan melalui selisih metrik yang sangat kecil (sempit) antara performa pelatihan dan pengujian pada model GRU. Tercatat, akurasi pemodelan (pelatihan) GRU berada di angka 88%, sedangkan akurasi pengujiannya mencapai 87%. *Gap* yang hanya sebesar 1% ini menjadi indikator kuat bahwa model tidak mengalami *overfitting* dan sangat stabil saat dihadapkan pada data yang belum pernah dipelajari sebelumnya. Dengan performa klasifikasi yang lebih tinggi, konsisten, dan efisien secara arsitektur, dapat disimpulkan bahwa model GRU merupakan algoritma yang paling optimal dibandingkan LSTM untuk melakukan klasifikasi kondisi cuaca pada penelitian ini.

IV. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa arsitektur GRU merupakan pemodelan yang lebih optimal dan efisien untuk klasifikasi kondisi cuaca dibandingkan LSTM berdasarkan hasil evaluasi model. Namun, penelitian ini memiliki keterbatasan pada penggunaan data bulanan yang diekspansi menjadi 1.796 observasi harian menggunakan interpolasi linear. Data hasil interpolasi

merupakan nilai estimasi yang berpotensi menghaluskan fluktuasi cuaca harian sebenarnya sehingga belum sepenuhnya merepresentasikan dinamika cuaca aktual. Untuk pengembangan selanjutnya, keandalan model dapat ditingkatkan dengan menggunakan data pengamatan harian secara langsung, memperkaya variasi fitur pada dataset seperti intensitas curah hujan dan kelembapan tanah, serta mengeksplorasi pendekatan *hybrid* seperti penggabungan GRU dengan *Convolutional Neural Network* (CNN) atau mekanisme *Attention*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Stasiun Klimatologi Sumatera Selatan yang telah memberikan izin serta fasilitas pendukung dalam proses pengambilan data meteorologi. Ketersediaan data tersebut sangat esensial dan berperan penting terhadap kelancaran serta keberhasilan penelitian ini.

DAFTAR PUSTAKA

- [1] T. Lattifiaa, P. W. Buanaa, and N. K. D. Rusjayanthi, "Model Prediksi Cuaca Menggunakan Metode LSTM," *J. Ilm. Teknol. dan Komput.*, vol. 3, no. 1, 2022.
- [2] S. F. Tekin, A. Fazla, S. S. Kozat, and S. Member, "Numerical Weather Forecasting using Convolutional-LSTM with Attention and Context Matcher Mechanisms," *IEEE Trans. Geosci. Remote Sens.*, pp. 1–11, 2023.
- [3] F. Zhang, *Weather Forecasting and Analysis with LSTM Based on Deep learning*, no. Iciaai. Atlantis Press International BV, 2024. doi: 10.2991/978-94-6463-540-9.
- [4] R. Muhammad and I. Nurhaida, "Penerapan LSTM dalam deep learning untuk prediksi harga kopi jangka pendek dan jangka panjang," *J. Ilm. Penelit. dan Pembelajaran Inform.*, vol. 10, no. 1, pp. 554–564, 2025, doi: 10.29100/jipi.v10i1.5904.
- [5] G. Velarde, P. Brañez, A. Bueno, R. Heredia, and M. Lopez-ledezma, "An Open Source and Reproducible Implementation of LSTM and GRU Networks for Time Series Forecasting †," 2022.
- [6] N. D. H. Sadikin and I. W. P. Agung, "Penerapan Metode Forecasting Pada Jumlah Siswa Baru di Sekolah Dasar Berbasis Data Historis Menggunakan ARIMA, LSTM dan GRU," *J. Mhs. Tek. Inform.*, vol. 9, no. 5, pp. 7972–7978, 2025, doi: 10.36040/jati.v9i5.14950.
- [7] D. D. N. Cahyo and A. Sunyoto, "Analisis Perbandingan Klasifikasi dalam Data Mining pada Prediksi Hujan dengan menggunakan Algoritma LSTM dan GRU," vol. 11, pp. 40–49, 2025, doi: 10.34128/jsi.v11i1.1212.
- [8] C. C. Islamy, A. Wahabi, P. Studi, T. Informatika, and F. Teknik, "Perbandingan Model LSTM dan GRU untuk Peramalan Angin A Comparative Study of LSTM and GRU Models for Wind Forecasting," *J. Sist. Inf.*, vol. 14, pp. 2817–2831, 2025.
- [9] M. A. F. Rahman, Z. R. Mair, and D. Sartika, "Klasifikasi Ulasan Pelanggan Shopee Mall Terhadap E-Commerce Penjualan Baju Batik Metode Naïve Bayes," *Idealis Indones. J. Inf. Syst.*, vol. 7, no. 2, pp. 164–177, 2024, doi: 10.36080/idealis.v7i2.3178.
- [10] K. D. Hartomo, "Implementasi Metode Interpolasi Linear Untuk Pembesaran Resolusi Citra," *Teknoin*, vol. 11, no. 3, pp. 219–232, 2006, doi: 10.20885/v11i3.89.
- [11] M. A. Sahona, L. W. Astuti, and M. H. Irfani, "Klasifikasi Usia Pengguna Berdasarkan Nilai Guna Perangkat Seluler Menggunakan Metode Support Vector Machine," *J. Media Inform.*, vol. 7, no. 3, pp. 815–821, 2026, doi: 10.55338/jumin.v7i3.8798.
- [12] M. I. Akbar, R. Heriansyah, and M. H. Irfani, "Pengaruh Splitting Data terhadap Akurasi Klasifikasi Demam Berdarah Dengue Menggunakan K-Nearest Neighbors," *J. Algoritm.*, vol. 6, no. 2, pp. 244–255, 2026, doi: 10.35957/algoritme.v6i2.13274.
- [13] A. F. Azmi and A. Voutama, "Prediksi Churn Nasabah Bank Menggunakan Klasifikasi Random Forest dan Decision Tree Dengan Evaluasi Confusion Matrix," *J. KOMPUTA*, vol. 13, no. 1, 2024, doi: <https://doi.org/10.34010/komputa.v13i1.12639>.
- [14] A. R. Maharani, R. Gustriansyah, and M. H. Irfani, "Analysis Of Public Sentiment Towards The Free Nutritious Meal Program In Schools Based On Tweets Using The K-Nearest Neighbors Method," *J. Tek. Inform. dan Sist. Inf.*, vol. 12, no. 4, pp. 242–259, 2025, doi: 10.35957/jatisi.v12i4.13446.
- [15] R. T. Subakti, Gasim, and M. H. Irfani, "Analisis Pengaruh Pencahayaan Terhadap Identifikasi Daun Cabai Menggunakan GLCM Dan JST," *J. Inform. Manaj. dan Teknol.*, vol. 28, no. 1, pp. 211–220, 2026, doi: 10.23969/infomatek.v28i1.45446.
- [16] M. U. F. M. P, S. Kurniawan, and R. Gustriansyah, "Penerapan Metode Decision Tree Dalam Klasifikasi Status Gizi Balita," *KOMPUTA J. Ilm. Komput. dan Inform.*, vol. 14, no. 2, pp. 2–10, 2025, doi: 10.34010/komputa.v14i2.16468.