

Perbandingan Model LSTM dan GRU untuk Peramalan Angin

A Comparative Study of LSTM and GRU Models for Wind Forecasting

¹Chaidir Chalaf Islamy*, ²Adnan Wahabi

^{1,2}Program Studi Teknik Informatika, Fakultas Teknik, Universitas 17 Agustus 1945 Surabaya

^{1,2}Jl. Semolowaru No. 45, Surabaya, Jawa Timur 60118, Indonesia

*e-mail: chaidirc@untag-sby.ac.id

(received: 31 July 2025, revised: 20 August 2025, accepted: 21 August 2025)

Abstrak

Pemanfaatan *deep learning* di era teknologi saat ini semakin meluas, termasuk dalam bidang meteorologi untuk mendukung keselamatan penerbangan. Indonesia sebagai negara kepulauan menghadapi tantangan besar dalam menjaga keselamatan penerbangan akibat kondisi cuaca yang tidak menentu, khususnya arah dan kecepatan angin yang memengaruhi proses lepas landas dan pendaratan. Untuk mengatasi tantangan tersebut, sistem *Automatic Weather Observing System* (AWOS) berperan penting dalam menyediakan data cuaca *real-time*. Penelitian ini bertujuan membandingkan performa dua model *deep learning* populer untuk data deret waktu, yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), dalam meramalkan arah dan kecepatan angin berdasarkan data AWOS di Bandar Udara Internasional Sultan Hasanuddin periode Januari 2020–Desember 2022 dari situs *National Oceanic and Atmospheric Administration* (NOAA). Setelah melalui tahap *preprocessing*, lima dari delapan atribut digunakan dalam pemodelan. Hasil evaluasi menunjukkan model LSTM secara konsisten memberikan performa lebih baik dibandingkan GRU pada semua skenario peramalan (30 menit, 1 jam, dan 1,5 jam). Untuk arah angin, LSTM memiliki nilai MAE 10,92°–11,01°, MSE 242,45–247,89, dan RMSE 15,57°–15,74°, lebih rendah dari GRU. Untuk kecepatan angin, LSTM mencatat MAE 30,32–31,72 *knots*, MSE 1868,53–2013,92, dan RMSE 43,23–44,88 *knots*, yang juga lebih unggul. Penelitian ini diharapkan dapat berkontribusi dalam pengembangan sistem mitigasi risiko dan peningkatan teknologi peramalan cuaca di masa mendatang.

Kata kunci: deep learning, long short-term memory, gated recurrent unit, peramalan angin

Abstract

The use of deep learning in the current technological era is increasingly widespread, including in the field of meteorology to support aviation safety. As an archipelagic country, Indonesia faces significant challenges in ensuring flight safety due to unpredictable weather conditions, particularly wind direction and speed, which greatly influence takeoff and landing operations. To address these challenges, the *Automatic Weather Observing System* (AWOS) plays a crucial role in providing real-time weather data. This study aims to compare the performance of two popular deep learning models for time series data, namely *Long Short-Term Memory* (LSTM) and *Gated Recurrent Unit* (GRU), in forecasting wind direction and speed based on AWOS data from Sultan Hasanuddin International Airport for the period of January 2020–December 2022, obtained from the *National Oceanic and Atmospheric Administration* (NOAA) website. After preprocessing, five out of eight attributes were used for modeling. The evaluation results show that the LSTM model consistently outperformed GRU in all forecasting scenarios (30 minutes, 1 hour, and 1.5 hours). For wind direction, LSTM achieved MAE values of 10.92°–11.01°, MSE 242.45–247.89, and RMSE 15.57°–15.74°, all lower than those of GRU. For wind speed, LSTM recorded MAE values of 30.32–31.72 *knots*, MSE 1868.53–2013.92, and RMSE 43.23–44.88 *knots*, also outperforming GRU. This research is expected to contribute to the development of risk mitigation systems and the advancement of weather forecasting technology in the future.

Keywords: deep learning, long short-term memory, gated recurrent unit, wind forecasting

1 Pendahuluan

Indonesia, sebagai negara kepulauan terbesar di dunia dengan populasi lebih dari 280 juta jiwa pada tahun 2024 [1]. Dengan ini Indonesia sangat bergantung pada transportasi udara untuk menjaga konektivitas antarwilayah. Moda transportasi ini menjadi pilar utama mobilitas penduduk dan distribusi logistik di antara lebih dari 17.000 pulau. Tingginya ketergantungan ini menempatkan keselamatan dan kelancaran penerbangan sebagai prioritas utama.

Tantangan dalam operasional penerbangan di Indonesia adalah kondisi cuaca tropis yang sangat dinamis dan sulit diprediksi. Faktor cuaca, khususnya arah dan kecepatan angin, merupakan salah satu aspek paling kritis yang memengaruhi keselamatan pesawat, terutama selama fase *take-off* dan *landing* [2]. Ketidaktepatan dalam peramalan angin dapat berakibat fatal, sehingga penyediaan data cuaca yang presisi dan *real-time* menjadi hal yang sangat penting. Untuk menjawab kebutuhan ini, sistem pemantauan modern seperti *Automatic Weather Observing System* (AWOS) telah diimplementasikan di berbagai bandara untuk merekam data parameter cuaca secara otomatis dan berkelanjutan.

Seiring dengan kemajuan era digital, pemanfaatan kecerdasan buatan (*artificial intelligence*), khususnya *deep learning*, telah membuka peluang baru untuk meningkatkan akurasi peramalan berdasarkan data historis yang kompleks. Metode *deep learning* dikenal sangat efektif untuk menganalisis data berbentuk deret waktu (*time-series*), seperti data cuaca yang direkam oleh AWOS. Di antara berbagai arsitektur *deep learning*, varian *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah terbukti unggul. Kemampuan utama LSTM dan GRU mengatasi degradasi pembelajaran akibat *vanishing gradient* yang sering terjadi pada arsitektur *Recurrent Neural Network* (RNN) standar, yang memungkinkan model untuk mempelajari dan mengingat pola jangka panjang dalam data sekuensial [3].

Beberapa penelitian sebelumnya telah menunjukkan efektivitas kedua model ini, meskipun dengan hasil perhitungan performa yang bervariasi. Sebagai contoh, studi oleh Suranata [4] menemukan bahwa LSTM (RMSE: 8,853) sedikit lebih unggul dari GRU (RMSE: 9,698) dalam peramalan cuaca. Berdasarkan potensi dan rekam jejak tersebut, penelitian ini memiliki keterkaitan yang kuat untuk melakukan analisis perbandingan secara langsung pada data spesifik. Pemilihan model LSTM dan GRU didasarkan pada kemampuannya yang secara teori relevan serta hasil penelitian terdahulu yang menunjukkan potensinya dalam peramalan cuaca.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk melakukan analisis komparatif antara model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), guna menentukan metode yang paling optimal dalam meramalkan arah dan kecepatan angin menggunakan data dari sistem AWOS. Tujuan utama dari penelitian ini adalah memberikan kontribusi dalam pengembangan teknologi peramalan cuaca yang lebih akurat dan efektif. Hasil dari analisis ini diharapkan dapat dimanfaatkan untuk mendukung peningkatan sistem keselamatan transportasi udara serta menjadi dasar bagi pengembangan sistem mitigasi risiko bencana terkait cuaca di masa depan.

2 Tinjauan Literatur

Seiring meningkatnya kebutuhan akan model peramalan yang mampu menangani data berbasis deret waktu, berbagai varian dari arsitektur *Recurrent Neural Network* (RNN) telah dikembangkan untuk mengatasi keterbatasan RNN standar, terutama dalam mengingat pola data jangka panjang. Salah satu varian yang paling populer adalah *Long Short-Term Memory* (LSTM). Arsitektur LSTM memungkinkan aliran gradien yang konstan, sehingga jaringan dapat belajar untuk menyimpan informasi dalam jangka waktu yang sangat panjang tanpa kehilangan sensitivitas terhadap input jangka pendek [5]. Di sisi lain, *Gated Recurrent Unit* (GRU) dikembangkan sebagai alternatif. GRU mampu memberikan performa yang sebanding dengan LSTM dalam beberapa kondisi, model ini menunjukkan performa yang lebih cepat [6]. Keunggulan-keunggulan inilah yang mendorong banyak peneliti untuk menggunakan LSTM dan GRU dalam berbagai studi peramalan deret waktu, termasuk dalam konteks meteorologi dan sistem pemantauan cuaca.

Seperti pada penelitian terdahulu yang relevan pertama oleh Suranata [4], yang mengembangkan model prediksi curah hujan menggunakan metode LSTM dan GRU dengan data BMKG Denpasar tahun 2019. Dari 10 atribut kondisi cuaca, digunakan 7 atribut, yaitu suhu minimum, curah hujan, lamanya penyinaran matahari, kecepatan angin maksimum, arah angin saat kecepatan maksimum,

kecepatan rata-rata angin, dan arah angin. Model LSTM menggunakan 3 *layer* dengan 50, 10, dan 5 unit, sedangkan model GRU menggunakan 3 *layer* dengan 95, 15, dan 5 unit. Kedua model menggunakan fungsi aktivasi *ReLU*. Hasil penelitian menunjukkan model LSTM memiliki performa lebih baik dengan RMSE 8,853; MAE 4,090; dan MSE 78,383, dibandingkan model GRU dengan RMSE 9,698; MAE 4,291; dan MSE 94,058.

Penelitian selanjutnya dilakukan oleh Ryan [7], yang mengembangkan model prediksi kecepatan angin 12 jam ke depan menggunakan *Automatic Weather Observing System* (AWOS) berbasis regresi linear. Data yang digunakan berasal dari AWOS di Bandar Udara Budiarto, Curug, dengan variabel suhu, jarak pandang, dan kecepatan angin dalam periode 6, 12, dan 18 jam ke belakang. Data diambil dari 1 Januari 2020 hingga 30 Juni 2020 untuk pelatihan dan 1–10 Juli 2020 untuk validasi. Metode regresi linear dipilih karena tidak membutuhkan komputasi yang besar dibanding *deep learning*. Model menggunakan algoritma *least squared method* dengan tiga variabel terikat, yaitu kecepatan angin terendah, rata-rata, dan tertinggi untuk 12 jam ke depan. Hasil penelitian menunjukkan nilai RMSE untuk prediktor 12 jam adalah 0,63; 1,14; dan 3,07 untuk kecepatan angin terendah, rata-rata, dan tertinggi secara berurutan, dengan durasi komputasi yang sangat singkat, yaitu 1,2 detik untuk pelatihan dan 1,1 detik untuk prediksi.


Adapun penelitian yang dilakukan oleh Empi [8], yang memanfaatkan data AWOS untuk mengidentifikasi karakteristik angin di landas pacu Bandara Supadio Pontianak dengan menggunakan perangkat lunak *WRPLOT*. Data yang digunakan adalah data arah dan kecepatan angin setiap jam dari Januari 2019 hingga September 2022. Hasil penelitian menunjukkan bahwa angin dominan di *Runway* 15 bergerak dari arah timur laut ($22,5^{\circ}$ – $67,5^{\circ}$) dengan persentase 31% dan kecepatan dominan 1,75–4,86 *knot* (55,6%), sedangkan di *Runway* 33 angin dominan dari arah timur ($67,5^{\circ}$ – $112,5^{\circ}$) sebesar 28,5% dengan kecepatan yang sama, yaitu 1,75–4,86 *knot* (55,0%). Angin dengan kecepatan lebih dari 10 *knot* sering terjadi dari arah tenggara–utara, dengan komponen *cross wind* terjadi sebanyak 1,61% di R15 dan 1,47% di R33.

Penelitian berikutnya oleh Karyadi [9], yang mengembangkan sistem prediksi kualitas udara menggunakan metode LSTM, *Bidirectional LSTM*, dan GRU. Data yang digunakan berasal dari Kota Bandung tahun 2019 dengan empat variabel yaitu: suhu, PM10, kelembaban, dan ISPU. Model menggunakan *batch size* 32, *optimizer* Adam, dan 1.500 *epoch*. LSTM dan BiLSTM menunjukkan performa lebih baik, dengan RMSE untuk suhu (LSTM: 3,18; BiLSTM: 3,23), kelembaban (LSTM: 6,96; BiLSTM: 7,07), PM10 (LSTM: 1,76; BiLSTM: 1,76), dan ISPU (LSTM: 1,84; BiLSTM: 1,86). Model GRU menunjukkan performa yang kurang baik dibandingkan kedua model lainnya.

Terakhir, penelitian oleh Anjani [10], yang mengembangkan model prediksi suhu udara di *Runway* 10 Bandara Juanda menggunakan *Hybrid LSTM–GRU*. Data yang digunakan adalah data suhu per menit dari AWOS selama 3 bulan (Desember 2022–Februari 2023) dengan pembagian 70% *training*, 15% *validasi*, dan 15% *testing*. Model menggunakan arsitektur 4 *layer* dengan *ReLU* sebagai fungsi aktivasi dan *optimizer* Adam, *batch size* 64, dan 20 *epoch*. Hasil penelitian menunjukkan model *hybrid LSTM–GRU* memiliki performa terbaik dengan MSE 0,0181; MAE 0,0814; RMSE 0,1345; dan MAPE 0,29% untuk prediksi jangka pendek (5 menit).

3 Metode Penelitian

Metode penelitian yang digunakan meliputi beberapa rangkaian tahapan yang diimplementasikan menggunakan bahasa pemrograman *Python* dan *IDE Google Colab*, yaitu pengumpulan data, praproses data, pencarian *hyperparameter*, implementasi model LSTM dan GRU, pelatihan dan pengujian model, peramalan, serta evaluasi hasil.



Gambar 1 Tahapan penelitian


Berdasarkan tahapan-tahapan yang telah digambarkan pada Gambar 1, proses penelitian ini terdiri atas beberapa langkah utama yang dilakukan secara sistematis untuk mencapai tujuan penelitian. Penjelasan lebih rinci mengenai masing-masing tahapan disajikan pada uraian berikut:

A) *Pengumpulan Data*

Penelitian ini menggunakan data historis kondisi cuaca dari sistem *Automatic Weather Observing System* (AWOS) yang diperoleh melalui situs resmi *National Oceanic and Atmospheric Administration* (NOAA). Data spesifik yang dianalisis berasal dari Bandar Udara Sultan Hasanuddin untuk periode Januari 2020 hingga Desember 2022, yang terdiri dari 59.252 baris data. Parameter cuaca yang digunakan mencakup 8 atribut, yaitu arah dan kecepatan angin (*wind*), suhu (*temperature*), suhu titik embun (*dew point*), tekanan udara (*pressure*), jarak pandang (*visibility*), ketinggian awan (*ceiling*), dan curah hujan (*precipitation*).

B) *Praproses Data*

Data AWOS yang diperoleh tidak dapat langsung diproses untuk melakukan permodelan, dikarenakan masih bersifat data mentah dan dapat menyebabkan hasil dari peramalan menjadi kurang baik serta permodelan menjadi sulit disebabkan ketidaksesuaian data. Tahap *preprocessing* data dilakukan untuk menghasilkan data yang lebih layak untuk analisis dan permodelan. Proses ini mencakup beberapa langkah utama yang disajikan dalam Gambar 2.



Gambar 2 Tahapan praproses data

Berikut penjelasan detail terkait Gambar 2 di atas:

- 1) *Menggabung Data*: Data mentah yang berasal dari situs NOAA terdiri dari file CSV yang terpisah, masing-masing terbagi berdasarkan periode tahunnya. Agar proses penelitian dapat dilakukan secara menyeluruh dan efisien, ketiga file tersebut kemudian digabungkan menjadi satu file CSV tunggal.
- 2) *Format Waktu Data*: Proses ini bertujuan untuk menyeragamkan format pada seluruh kolom *DATE* dalam *dataset*. Setelah format waktu diseragamkan, data kemudian diurutkan berdasarkan urutan menaik (*ascending*).
- 3) *Hapus Duplikasi Data*: Proses pemeriksaan harus dilakukan terhadap adanya data duplikat yang mungkin terjadi akibat kesalahan pencatatan oleh alat AWOS. Jika ditemukan entri yang sama pada kolom *DATE*, maka hanya satu baris data pertama yang dipertahankan, sementara baris duplikat lainnya dihapus.
- 4) *Ekstrak Data*: Proses ekstraksi dilakukan untuk memperoleh nilai dengan satuan yang relevan dari setiap atribut utama. Atribut *wind* diekstrak menjadi dua bagian, yaitu *wind_dir* (derajat) dan *wind_speed* (knot). Atribut *temp* diambil dalam bentuk *temp_c* (°C), sedangkan atribut *dewpoint* diekstrak menjadi *dewpoint_c* (°C). Selanjutnya, *pressure* diambil sebagai *pressure_hpa* (hPa), *visibility* sebagai *visibility_km* (km), *ceiling* sebagai *ceiling_ft* (ft), dan *precip* sebagai *precip_mm* (mm).
- 5) *Reindex Data*: Berdasarkan data yang diperoleh, pencatatan data AWOS seharusnya dilakukan setiap 30 menit secara konsisten. Namun, dikarenakan ada baris data yang hilang, rentang waktu antarbaris menjadi tidak konsisten. Oleh karena itu, dilakukan proses *reindexing* dengan menetapkan interval yang seharusnya, yaitu setiap 30 menit.
- 6) *Penanganan Missing Value*: Dalam pengambilan data oleh alat AWOS, terdapat kemungkinan data hilang atau tidak terukur akibat kegagalan sensor yang menyebabkan *missing value*. Dalam penelitian ini, data yang hilang diproses menggunakan teknik median pada rumus (1). Metode median bekerja dengan mencari nilai tengah sebuah *dataset* yang telah diurutkan secara *ascending* pada proses sebelumnya, yang kemudian akan diisi kembali dengan data hasil perhitungan pada kolom yang sama.

$$median = x_{(\frac{n+1}{2})} \quad (1)$$

x : nilai dalam dataset

n : jumlah total baris dataset

- 7) *Normalisasi Data*: Diperlukan transformasi data melalui normalisasi untuk menyamakan rentang nilai setiap atribut ke dalam skala tertentu. Pada penelitian ini, proses normalisasi menggunakan metode *min-max normalization*, yaitu metode yang menyeragamkan skala data ke rentang tertentu (0 hingga 1). Proses ini bekerja dengan cara menskalakan nilai asli x berdasarkan selisih nilai maksimum dan minimum dari atribut tersebut pada *dataset*, kemudian mengalikan nilai tersebut ke dalam rentang baru yang diinginkan *maxRange* sampai *maxRange* seperti pada rumus (2).

$$normalized(x) = \frac{minRange + (x - minValue)(maxRange - minRange)}{maxValue - minValue} \quad (2)$$

x : nilai asli yang akan di normalisasi

$minRange$: rentang minimum normalisasi (0)

$maxRange$: rentang maximum normalisasi (1)

$minValue$: nilai minimum dari atribut dataset

$maxValue$: nilai maximum dari atribut dataset

- 8) *Matriks Korelasi Data*: Proses pemilihan atribut dilakukan untuk mendapatkan *dataset* yang relevan demi meningkatkan kinerja model dan mengurangi dimensi data. Metode yang di gunakan adalah dengan perhitungan matematis demi menghitung korelasi antara matriks seperti pada rumus (3). Dimana x_i dan y_i adalah nilai individu dari setiap variable x dan y , $\bar{x}$ dan $\bar{y}$ adalah rata- rata dari seluruh nilai variable x dan y , dan r_{xy} adalah hasil korelasi antar atribut yang menunjukkan hubungan linier antara x dan y . Nilai $r_{xy} > 0$ menunjukkan hubungan linier positif (x meningkat, y juga cenderung meningkat), sementara jika $r_{xy} < 0$ berarti hubungan linier negatif (x meningkat, y cenderung menurun) dan $r_{xy} \approx 0$ menandakan tidak ada hubungan linier sama sekali.

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}} \quad (3)$$

r_{xy} : korelasi diantara atribut

x_i : nilai individu dari variable pertama

$\bar{x}$: rata- rata dari seluruh nilai variable pertama

y_i : nilai individu dari variable kedua

$\bar{y}$: rata- rata dari seluruh nilai variable kedua

- 9) *Split Data*: *Split data* adalah proses untuk memisahkan *dataset* menjadi dua bagian yang digunakan dalam proses pemodelan. Proses *split data* dilakukan dengan metode *chronological split* menggunakan perbandingan 80:20, yaitu sebanyak 80% data digunakan untuk *training*, dan 20% sisanya digunakan untuk *testing*.
- 10) *Windowing Data*: Teknik *windowing* dilakukan dengan membagi data ke dalam jendela waktu (*window*), di mana setiap jendela berisi beberapa langkah waktu sebelumnya sebagai *input* dan satu langkah setelahnya sebagai *target*. Dalam penelitian ini, digunakan variasi ukuran *window* (1, 6, 24, dan 50) untuk melihat pengaruhnya terhadap hasil peramalan arah dan kecepatan angin. Setiap skenario dibandingkan berdasarkan nilai *error* untuk menentukan konfigurasi terbaik.

C) Pencarian Hyperparameter

Proses *hyperparameter tuning* dilakukan untuk menemukan kombinasi parameter terbaik guna meningkatkan performa model. Metode yang digunakan dalam penelitian ini adalah

random search dengan 10 iterasi, untuk nilai *default* tertera pada Tabel 1. Kombinasi terbaik dipilih berdasarkan nilai *Mean Squared Error* (MSE) terendah pada data validasi.

Tabel 1 Nilai default random search

Unit	Learning Rate	Batch Size	Validation Split	Epoch
32	0.001	16	0,2 & 0.3	100
64	0.005	32		200
128	0.009	64		300

Dalam proses ini, *random search* menggunakan arsitektur model yang mirip dengan proses pelatihan, yaitu 2 *layer*, 2 *dropout*, dan 1 *dense layer*. Berdasarkan hasil pada Tabel 2 dan Tabel 3, kombinasi terbaik untuk LSTM diperoleh pada iterasi ke-9 dengan unit 32, *learning rate* 0.001, *batch size* 128, *validation split* 0.3, dan 100 *epoch*, menghasilkan nilai MSE sebesar 0.019869. Untuk GRU, performa terbaik terdapat pada iterasi ke-4 dengan konfigurasi serupa, namun dengan *batch size* 64 dan 150 *epoch*, menghasilkan MSE sebesar 0.019916.

Tabel 2 Hasil pencarian hyperparameter LSTM

Iterasi Ke-	Model	Units	Learning Rate	Batch Size	Val Split	Epoch	Best Val Loss (MSE)
9	LSTM	32	0,001	128	0,3	100	0,018969
7	LSTM	128	0,001	32	0,3	100	0,019934
6	LSTM	64	0,005	64	0,3	100	0,019997
3	LSTM	32	0,001	64	0,3	200	0,020215
0	LSTM	32	0,001	32	0,3	150	0,02022
2	LSTM	64	0,001	32	0,3	100	0,020341
1	LSTM	32	0,001	64	0,3	100	0,020563
4	LSTM	128	0,009	16	0,2	100	0,020833
5	LSTM	64	0,009	64	0,2	150	0,021143
8	LSTM	32	0,005	32	0,2	200	0,021126

Tabel 3 Hasil pencarian hyperparameter GRU

Iterasi Ke-	Model	Units	Learning Rate	Batch Size	Val Split	Epoch	Best Val Loss (MSE)
4	GRU	32	0,001	64	0,3	150	0,019916
1	GRU	64	0,001	64	0,3	200	0,020018
6	GRU	128	0,005	16	0,3	200	0,020469
5	GRU	64	0,005	16	0,3	100	0,020598
7	GRU	128	0,005	32	0,3	100	0,020692
2	GRU	32	0,005	32	0,2	100	0,020996
9	GRU	64	0,005	16	0,2	200	0,021155
3	GRU	32	0,001	64	0,2	200	0,021159
8	GRU	128	0,009	64	0,2	150	0,021266
0	GRU	32	0,005	16	0,2	100	0,021375

D) Implementasi Model

Setelah memperoleh kombinasi *hyperparameter* terbaik, tahap selanjutnya adalah membangun model menggunakan dua arsitektur berbasis *Recurrent Neural Network* (RNN), yaitu *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Kedua model ini dikembangkan untuk mengatasi keterbatasan RNN standar, terutama dalam masalah *vanishing gradient* yang sering muncul saat memproses data deret waktu dalam jangka panjang [3].

Model LSTM memiliki tiga gerbang utama seperti pada persamaan (4) sampai (6), yaitu *input gate* (I_t), *forget gate* (F_t), dan *output gate* (O_t), yang memungkinkan model menyimpan, membuang, dan menghasilkan informasi secara selektif [5]. Sementara itu, model GRU merupakan versi yang lebih sederhana karena hanya memiliki dua gerbang utama, yaitu *reset gate* (r_t) dan *update gate* (z_t), sehingga lebih ringan secara komputasi [6]. Rumus untuk model GRU terlihat pada persamaan (7) dan (8).

Kedua model dalam penelitian ini menggunakan arsitektur yang mirip, yaitu terdiri dari dua *layer* utama untuk masing-masing model. *Layer* pertama diatur dengan *return_sequences=True* agar seluruh output dari setiap langkah waktu dapat diteruskan ke *layer* berikutnya. Sementara itu, *layer* kedua menggunakan *return_sequences=False*, sehingga hanya mengeluarkan hasil dari langkah waktu terakhir sebagai hasil peramalan. Lalu, terdapat satu *dense layer* berisi 6 unit yang berfungsi menghasilkan output ramalan arah dan kecepatan angin. Demi mengurangi risiko *overfitting*, pada penelitian ini setiap lapisan utama diberi *dropout* sebesar 0,2.

$$F_t = \text{sigmoid}([H_{t-1}, x_t] \cdot W_f + b_f) \quad (4)$$

$$I_t = \text{sigmoid}([H_{t-1}, x_t] \cdot W_i + b_i) \quad (5)$$

$$O_t = \text{sigmoid}(W_o \cdot [H_{t-1}, X_t] + b_o) \quad (6)$$

$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z) \quad (7)$$

$$r_t = \sigma_g(W_r x_t + U_r h_{t-1} + b_r) \quad (8)$$

E) Pelatihan & Pengujian

Pada tahap ini, nilai *hyperparameter* terbaik hasil *random search* digunakan untuk membangun kedua model. Selama pelatihan, sebagian data *training* digunakan sebagai data *validasi* sesuai nilai *validation_split* yang telah ditentukan. Data ini digunakan untuk memantau performa model serta mengidentifikasi potensi *overfitting* atau *underfitting*. Hasil pelatihan divisualisasikan melalui grafik *line chart* yang menampilkan nilai *training loss* dan *validation loss* terhadap jumlah *epoch*.

F) Peramalan

Proses peramalan dilakukan menggunakan pendekatan *direct multi-step forecasting*, di mana model secara langsung meramalkan tiga langkah ke depan: 30 menit, 1 jam, dan 1,5 jam. Rentang waktu ini dipilih berdasarkan kebutuhan operasional *Air Traffic Control* (ATC), seperti dijelaskan dalam laporan FAA-RD-76-23 oleh MIT Lincoln Laboratory, yang menyebutkan bahwa peramalan cuaca jangka sangat pendek (0–30 menit) penting untuk mendukung keputusan cepat saat terjadi perubahan cuaca lokal [11]. Hasil peramalan kemudian dibandingkan dengan data aktual dalam bentuk grafik, yang menampilkan dua garis utama untuk *wind speed* dan *wind direction* pada setiap *horizon* waktu. Untuk skenario peramalan *real-case*, model menggunakan data terakhir dari *window size* pada data *testing* untuk menghasilkan output peramalan dalam satuan asli.

G) Evaluasi Hasil

Setelah proses pelatihan dan peramalan menggunakan model LSTM dan GRU, tahap selanjutnya adalah evaluasi performa model. Evaluasi dilakukan dengan menghitung nilai *error* menggunakan tiga metrik umum: *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Squared Error* (MSE). Ketiga metrik ini banyak digunakan dalam studi peramalan deret waktu, seperti oleh Suranata [4], Sofi [12], serta Panggabean [13] khususnya untuk mengevaluasi model LSTM dan GRU.

Pada konteks penelitian ini ketiga matriks ini memiliki kelebihan dan fungsi yang berbeda, yaitu MAE mengukur kesalahan peramalan rata-rata yang dilakukan model, kemudian MSE dan RMSE mengukur kesalahan peramalan saat ada lonjakan data yang tidak normal (*outlier*) hanya saja, RMSE akan mengembalikan nilai ke bentuk semula. Persamaan untuk ketiga teknik ini dapat dilihat pada rumus (9) sampai (11) yang mana n adalah jumlah data observasi, y_i adalah nilai aktual atau data asli, dan $\tilde{y}_i$ merupakan data hasil ramalan.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{n}} \quad (9)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \tilde{y}_i|}{n} \quad (10)$$

$$MSE = \frac{\sum_{i=1}^n |y(i) - \tilde{y}_i|^2}{n} \quad (11)$$

4 Hasil dan Pembahasan

Pada tahapan ini, seluruh hasil dari proses sebelumnya akan dijelaskan dan dianalisis lagi untuk memperoleh kesimpulan akhir terkait perbandingan model LSTM dan GRU dalam meramalkan arah dan kecepatan angin.

4.1 Penentuan Input Sequence

Dalam proses menentukan *input sequence*, digunakan beberapa variasi *input sequence* atau *window size* yang berbeda, yakni (1, 6, 24, dan 50). Proses ini dilakukan untuk melihat dan mendapatkan hasil peramalan yang paling konsisten terhadap distribusi *dataset* pada penelitian ini. Berdasarkan Tabel 4 dan 5, *window size* 1 secara konsisten menghasilkan nilai *error* MAE tertinggi pada semua skenario, baik untuk model LSTM maupun GRU. Ini menunjukkan bahwa data yang terlalu pendek tidak memberikan kesempatan model untuk belajar pola data. Sebaliknya, *window size* 50 menunjukkan hasil yang tidak konsisten. Pada model GRU, *error* cenderung meningkat signifikan, menunjukkan bahwa informasi historis yang terlalu panjang dapat menjadi *noise*. Model LSTM masih menunjukkan performa cukup baik pada *window size* 50, tetapi tidak lebih baik dibandingkan *window size* menengah. Sementara itu, *window size* 6 memberikan hasil paling stabil untuk kedua model. Baik LSTM maupun GRU menunjukkan *error* MAE yang relatif rendah dan konsisten, baik pada peramalan arah maupun kecepatan angin. Di sisi lain, ada potensi untuk kedua model bisa melakukan peramalan hingga 12 jam ke depan, mengingat pada *window size* 24, model masih mampu mengolah informasi dari *dataset* dengan baik.

Tabel 4 Hasil perbandingan input sequence peramalan arah angin

Forecast Step	LSTM (win=1)	GRU (win=1)	LSTM (win=6)	GRU (win=6)	LSTM (win=24)	GRU (win=24)	LSTM (win=50)	GRU (win=50)
t+30	11,83	11,71	10,15	10,47	10,63	10,91	10,46	10,99
t+60	11,49	11,52	10,38	10,81	10,74	10,9	10,48	11,09
t+90	11,34	11,32	10,41	11,15	10,8	11,01	10,65	11,18


Tabel 5 Hasil perbandingan input sequence peramalan kecepatan angin

Forecast Step	LSTM (win=1)	GRU (win=1)	LSTM (win=6)	GRU (win=6)	LSTM (win=24)	GRU (win=24)	LSTM (win=50)	GRU (win=50)
t+30	32,99	32,84	30,20	30,73	31,06	30,8	30,94	31,56
t+60	32,98	32,76	30,12	31,23	31,32	31,46	31,38	32,26
t+90	33,42	33,35	30,83	31,49	32,15	32,09	32,11	32,76


4.2 Training Model

Berdasarkan proses *training* yang telah dilakukan, maka diperoleh hasil dari kedua model tersebut. Hasil ini diperoleh berdasarkan perhitungan nilai *training loss* dan *validation loss* pada saat proses pelatihan berlangsung. Perhitungan ini dilakukan untuk mengetahui model mana yang memiliki performa terbaik dalam melakukan pembelajaran. Proses *training* dilakukan dengan menggunakan konfigurasi *hyperparameter* terbaik yang diperoleh dari proses sebelumnya. Berdasarkan hasil grafik pelatihan pada Gambar 3, terlihat bahwa model LSTM mampu mempelajari pola data dari AWOS dengan cukup baik. Hal ini ditunjukkan oleh nilai *training loss* dan *validation loss* yang terus menurun secara bertahap dari *epoch* ke-1 hingga *epoch* ke-100. Penurunan ini berarti bahwa model mampu mempelajari data secara efektif tanpa mengalami *overfitting*.

Sementara untuk model GRU, terlihat pada Gambar 4 menunjukkan bahwa model juga memiliki kemampuan dalam mempelajari pola data dari AWOS dengan nilai *loss* yang menurun secara konsisten seiring pembelajaran. Meskipun model dapat dengan baik dalam memahami pola data, terdapat perbedaan, yaitu model GRU cenderung mengalami fluktuasi pada nilai *validation loss* di beberapa titik *epoch*, yang mengindikasikan bahwa model ini lebih sensitif terhadap perubahan data validasi.




Gambar 3 Hasil training LSTM




Gambar 4 Hasil training GRU

4.3 Testing Model


Selanjutnya adalah hasil peramalan dengan data *testing* untuk menguji apakah model mampu meramalkan data yang belum pernah dilihat sebelumnya. Pada percobaan ini, output hasil akan berupa *line chart* untuk 3 langkah, yaitu 30 menit, 1 jam, dan 1,5 jam. Masing-masing *chart* akan memperlihatkan perbandingan antara data aktual dan ramalan untuk *wind speed* dan *wind direction*. Dapat dilihat dari Gambar 5–7 yang merupakan grafik hasil perbandingan antara data hasil peramalan (garis putus-putus) dan data aktual (garis tidak putus-putus). Yang mana pada grafik ini menunjukkan bahwa model LSTM yang telah dilatih dapat mengikuti pola data aktual di 3 waktu berbeda, meskipun tidak sepenuhnya mirip. Di lain sisi, pada grafik ini terlihat juga kelemahan model, yaitu bahwa pada beberapa kondisi seperti data yang terlalu cepat berubah dan jarang terjadi pada *epoch* 0–25, model LSTM tidak mampu mengikuti pola data dan menghasilkan ramalan yang tidak akurat. Kemudian, untuk hasil dari *testing* GRU dapat dilihat pada Gambar 8–10. Gambar ini memperlihatkan bahwa model GRU memiliki kemiripan dengan LSTM, yaitu sama-sama dapat menangkap pola data. Namun, model ini mengalami kesulitan saat terdapat data yang tidak normal, yang menyebabkan hasil ramalan pada kondisi tersebut menjadi tidak akurat.




Gambar 5 Hasil testing LSTM peramalan 30mnt




Gambar 6 Hasil testing LSTM peramalan 1jam




Gambar 7 Hasil testing LSTM peramalan 1.5jam



Gambar 8 Hasil testing GRU peramalan 30mnt



Gambar 9 Hasil testing GRU peramalan 1jam



Gambar 10 Hasil testing GRU peramalan 1.5jam

4.4 Evaluasi MAE, MSE, dan RMSE

Dalam penelitian ini, evaluasi performa model LSTM dan GRU dilakukan secara terpisah untuk variabel arah angin (*wind direction*) dan kecepatan angin (*wind speed*) pada tiga skenario langkah peramalan: 30 menit, 1 jam, dan 1,5 jam ke depan. Berdasarkan hasil evaluasi arah angin (*wind direction*) pada Tabel 6 dan Tabel 7, model LSTM menunjukkan performa yang sedikit lebih baik dibandingkan GRU. Pada skenario peramalan 30 menit ke depan, model LSTM memperoleh MAE sebesar 10,92°, MSE sebesar 242,45, dan RMSE sebesar 15,57°, sedangkan model GRU menghasilkan MAE sebesar 11,21°, MSE sebesar 251,08, dan RMSE sebesar 15,85°. Pada skenario peramalan 1 jam, model LSTM mencatatkan MAE 10,95°, MSE 244,40, dan RMSE 15,63°, sementara GRU memperoleh MAE 11,13°, MSE 248,09, dan RMSE 15,75°. Selanjutnya, pada peramalan 1,5 jam, LSTM kembali unggul dengan MAE 11,01°, MSE 247,89, dan RMSE 15,74°, dibandingkan GRU yang memiliki MAE 11,29°, MSE 253,09, dan RMSE 15,91°.

Tabel 6 Evaluasi eror peramalan arah angin LSTM

Forecast Step	MAE	MSE	RMSE
30 menit	10,92°	242,4518	15,57°
1 jam	10,95°	244,3976	15,63°
1.5 jam	11,01°	247,8916	15,74°

Tabel 7 Evaluasi eror peramalan arah angin GRU

Forecast Step	MAE	MSE	RMSE
30 menit	11,21°	251,0788	15,85°
1 jam	11,13°	248,0879	15,75°
1.5 jam	11,29°	253,0866	15,91°

Sementara itu, untuk variabel kecepatan angin (*wind speed*) seperti yang terlihat pada Tabel 8 dan Tabel 9, hasil evaluasi juga menunjukkan bahwa model LSTM cenderung memberikan performa yang lebih baik dibandingkan GRU. Pada peramalan 30 menit, model LSTM memiliki MAE sebesar 30,32 *knots*, MSE sebesar 1868,53, dan RMSE sebesar 43,23 *knots*, sedangkan GRU mencatatkan MAE 30,41 *knots*, MSE 1887,39, dan RMSE 43,44 *knots*. Tren serupa juga terlihat pada langkah peramalan 1 jam, di mana LSTM memperoleh MAE 30,95 *knots*, MSE 1939,58, dan RMSE 44,04 *knots*, sementara GRU menghasilkan MAE 31,05 *knots*, MSE 1980,11, dan RMSE 44,50 *knots*. Pada langkah 1,5 jam, model LSTM mencatatkan MAE 31,72 *knots*, MSE 2013,92, dan RMSE 44,88 *knots*, dibandingkan GRU yang memperoleh MAE 32,35 *knots*, MSE 2035,84, dan RMSE 45,12 *knots*.

Tabel 8 Evaluasi eror peramalan kecepatan angin LSTM

Forecast Step	MAE	MSE	RMSE
30 menit	30,32 <i>Knots</i>	1868,5253	43,23 <i>Knots</i>
1 jam	30,95 <i>Knots</i>	1939,5757	44,04 <i>Knots</i>
1.5 jam	31,72 <i>Knots</i>	2013,9244	44,88 <i>Knots</i>

Tabel 9 Evaluasi eror peramalan kecepatan angin GRU

Forecast Step	MAE	MSE	RMSE
30 menit	30,41 <i>Knots</i>	1887,3873	43,44 <i>Knots</i>
1 jam	31,05 <i>Knots</i>	1980,1099	44,5 <i>Knots</i>
1.5 jam	32,35 <i>Knots</i>	2035,8353	45,12 <i>Knots</i>

4.5 Hasil Peramalan Real-Case

Tahapan terakhir dalam penelitian ini adalah melakukan peramalan *real-case* menggunakan model yang telah dibangun. Pada tahap ini, data input diambil dari data terbaru dalam *dataset* berdasarkan *window size* yang telah ditentukan, yaitu *window_size* = 6, dan digunakan untuk menghasilkan ramalan tiga langkah ke depan, yaitu 30 menit, 1 jam, dan 1,5 jam. Hasil peramalan ditampilkan dalam Tabel 10. Tabel hasil ini memuat beberapa kolom utama, yaitu “Model” adalah model yang digunakan, “Datetime” adalah waktu yang diramalkan, “Ahead” adalah berapa jauh ramalan, “Wind Speed (*knot*)” merupakan hasil peramalan kecepatan angin dalam satuan *knot*, “Wind Direction (°)” merupakan hasil peramalan arah angin dalam satuan derajat, dan “Wind Direction Name” adalah nama arah angin. Angin sendiri dinamai berdasarkan arah asalnya. Sebagai contoh, “angin barat” berarti angin tersebut bertiup dari arah barat menuju timur [14]. Selain itu, sesuai dengan standar pelaporan dalam METAR dan SPECI [15], arah angin dilaporkan dalam kelipatan 10 derajat. Pada Tabel 10 keterangan *NbE* pada kolom *Wind Direction Name* merupakan singkatan dari *North by East*, yang merupakan salah satu dari 36 penamaan arah mata angin berdasarkan pembagian setiap 10° pada kompas angin. Penamaan ini umum digunakan dalam navigasi dan meteorologi untuk mengkonversi derajat arah angin menjadi nama arah angin.

Tabel 10 Hasil peramalan real-case

Model	Datetime	Ahead	Wind Speed (<i>knot</i>)	Wind Direction (°)	Wind Direction Name
LSTM	2023-01-01 00:00:00	30 minute	130,1970726	10,88198574	NbE
LSTM	2023-01-01 00:30:00	1 hour	130,138267	11,69237191	NbE
LSTM	2023-01-01 01:00:00	1.5 hour	130,2484964	11,85565997	NbE
GRU	2023-01-01 00:00:00	30 minute	131,5572099	11,6406495	NbE
GRU	2023-01-01 00:30:00	1 hour	129,3684488	12,18408468	NbE
GRU	2023-01-01 01:00:00	1.5 hour	128,4094815	12,06667665	NbE

5 Kesimpulan

Dari keseluruhan proses yang terangkum dalam penelitian ini, ditemukan bahwa model LSTM memiliki kemiripan dengan algoritma GRU dalam meramalkan arah dan kecepatan angin, meskipun LSTM menunjukkan performa yang lebih unggul. Keunggulan ini terlihat dari nilai *error* (MAE, MSE, dan RMSE) yang secara konsisten lebih rendah pada setiap skenario peramalan waktu, yaitu 30 menit, 1 jam, dan 1,5 jam. Hal ini mengindikasikan bahwa mekanisme *cell state* dan *hidden state* pada arsitektur LSTM lebih efektif dalam mengingat serta mengelola informasi historis jangka panjang dibandingkan GRU yang hanya mengandalkan *hidden state*. Di samping itu, kedua model menunjukkan keterbatasan dalam meramalkan data arah dan kecepatan angin yang bersifat ekstrem, karena model dilatih untuk mengenali pola dominan dan bukan kejadian langka, sehingga ketika dihadapkan pada pola yang tidak normal seperti cuaca ekstrem atau perubahan angin mendadak, kemampuan peramalan menjadi kurang akurat. Selain itu, hasil penelitian ini juga menegaskan bahwa *window size* atau panjang *input sequence* sangat memengaruhi akurasi peramalan. *Window size* sebesar 6 terbukti memberikan hasil yang paling stabil untuk model LSTM maupun GRU, khususnya untuk peramalan jangka pendek. Sementara itu, *window size* 1 menghasilkan *error* yang tinggi karena informasi yang diberikan terlalu sedikit, dan *window size* 50 menghasilkan performa yang tidak stabil akibat terlalu banyaknya informasi yang justru menjadi *noise*. Di sisi lain, *window size* 24 masih memberikan hasil yang cukup baik dan memiliki potensi untuk digunakan dalam peramalan hingga 12 jam ke depan.

Referensi

- [1] Badan Pusat Statistik, "Jumlah Penduduk Pertengahan Tahun (Ribuan Jiwa), 2022-2024." Accessed: Jan. 18, 2025. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/MTk3NSMy/jumlah-penduduk-pertengahan-tahun--ribu-jiwa-.html>
- [2] Badan Kebijakan Transportasi Kementerian Perhubungan, "Meteorologi dan Jalur Penerbangan." Accessed: Jan. 18, 2025. [Online]. Available: <https://baketrans.kemhub.go.id/berita/meteorologi-dan-jalur-penerbangan>
- [3] S. H. Noh, "Analysis of Gradient Vanishing of RNNs and Performance Comparison," *Information (Switzerland)*, Vol. 12, No. 11, Nov. 2021, DOI: 10.3390/info12110442.
- [4] I. W. A. Suranata, "View of Pengembangan Model Prediksi Curah Hujan di Kota Denpasar menggunakan Metode LSTM dan GRU," Oct. 2023, Accessed: Jan. 19, 2025. [Online]. Available: <https://mail.jsi.stikom-bali.ac.id/index.php/jsi/article/view/603>
- [5] S. Hochreiter and J. Schmidhuber, "Long Shortterm Memory," 1997, Accessed: Jan. 19, 2025. [Online]. Available: <https://www.bioinf.jku.at/publications/older/2604.pdf>
- [6] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.3555>
- [7] M. Ryan and S. Alfandy, "Prediksi Kecepatan Angin 12 Jam Kedepan menggunakan Automatic Weather Observing System (AWOS) berbasis Regresi Linear," 2022, Accessed: Jan. 22, 2025. [Online]. Available: <https://www.gawpalu.id/bgb/index.php/bgb/article/view/63>
- [8] A. Empi and M. Fitriyawita, "Pemanfaatan Data AWOS untuk mengidentifikasi Angin di Landas Pacu Bandara Supadio Pontianak dengan menggunakan WRPLOT," 2023, Accessed: Jan. 22, 2025. [Online]. Available: https://www.balai2bmkg.id/index.php/buletin_mkg/article/view/44
- [9] Y. Karyadi, "Prediksi Kualitas Udara dengan Metoda LSTM, Bidirectional LSTM, dan GRU," 2022, Accessed: Jan. 22, 2025. [Online]. Available: <https://jurnal.mdp.ac.id/index.php/jatisi/article/view/1588>
- [10] J. Anjani, H. P. A. Tjahyaningtjas, L. G. P. A. Buditjahjanto, and L. Anifah, "Prediction of Air Temperature on Runway 10 Juanda Airport using Hybrid LSTM," 2024, Accessed: Jan. 22, 2025. [Online]. Available: <https://journal.unesa.ac.id/index.php/inajeee/article/view/33130>
- [11] S. I. Krich and S. M. Sussman, "A Concept and Plan for the Development of a Weather Support Subsystem for Air Traffic Control," Apr. 1976. Accessed: Jul. 08, 2025. [Online]. Available: https://www.ll.mit.edu/sites/default/files/publication/doc/2018-12/Krich_1976_ATC-64_WW-15318.pdf

- [12] K. Sofi, A. S. Sunge, S. R. Riady, and A. Z. Kamalia, "Perbandingan Algoritma Linear Regression, LSTM, dan GRU dalam memprediksi Harga Saham dengan Model Time Series," 2021, Accessed: Jan. 22, 2025. [Online]. Available: <https://journal.universitasmulia.ac.id/index.php/seminastika/article/view/275>
- [13] D. A. H. Panggabean, F. M. Sihombing, and N. M. Aruan, "Prediksi Tinggi Curah Hujan dan Kecepatan Angin berdasarkan Data Cuaca dengan Penerapan Algoritma Artificial Neural Network (ANN)," 2021, Accessed: Jan. 22, 2025. [Online]. Available: <https://journal.universitasmulia.ac.id/index.php/seminastika/article/view/237>
- [14] Federal Aviation Administration (FAA), "Advisory Circular," Aug. 2016. Accessed: Jul. 18, 2025. [Online]. Available: https://www.faa.gov/documentlibrary/media/advisory_circular/ac_00-6b.pdf
- [15] International Civil Aviation Organization (ICAO), "Annex 3 to the Convention on International Civil Aviation," Montreal, Kanada, Jul. 2010.