



Perbandingan Gated Recurrent Unit dan Time Series Transformer untuk Prediksi Kabut Menggunakan Sliding Window

Chandra Dwi Pratomo^{1,2,*}, Agung Budi Susanto¹, Arya Adhyaksa Waskita¹

¹ Program Magister Teknik Informatika, Pascasarjana Universitas Pamulang, Tangerang Selatan, Indonesia

² Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), Jakarta, Indonesia

Email: ^{1,*} chandra.pratomo@bmkg.go.id, ² dosen02680@unpam.ac.id, ³ aawaskita@unpam.ac.id

Email Penulis Korespondensi: chandra.pratomo@bmkg.go.id

Abstrak—Fenomena kabut adalah salah satu cuaca yang berbahaya bagi operasional penerbangan. Fenomena kabut tebal dapat menurunkan jarak pandang (*visibility*) hingga di bawah 1.000 meter, yang dapat menyebabkan penundaan, pembatalan, hingga terjadinya insiden penerbangan. Sampai saat ini, prediksi kabut khususnya di Bandar Udara Budiarto masih bergantung pada analisis manual prakirawan cuaca, sehingga rawan terhadap subjektivitas dan keterlambatan dalam penyampaian informasi. Penelitian ini mengusulkan dan membandingkan dua arsitektur *deep learning*, yaitu *Gated Recurrent Unit* (GRU) sebagai representasi model rekuren yang efisien dan *Time Series Transformer* (TST) berbasis *self-attention* sebagai model mutakhir untuk prediksi kejadian kabut berbasis data *Meteorological Aerodrome Report* (METAR). Data METAR akan diproses terlebih dahulu menggunakan teknik *sliding window* sebelum menjadi dataset yang siap dipakai. Data METAR yang digunakan berasal dari Stasiun Meteorologi Budiarto—Curug periode September 2015 hingga Februari 2026 sebanyak 153.838 data yang diolah melalui *pipeline parsing* sandi METAR, imputasi median berbasis aturan BMKG, normalisasi *Min-Max*, dan pembentukan *dataset sliding window* 9-1. Hasil pengujian pada data uji menunjukkan bahwa TST 9-1 memberikan kinerja terbaik dengan *Root Mean Squared Error* (RMSE) 0,452427 dan akurasi klasifikasi tiga kelas (Tidak Kabut, Kabut Tipis, Kabut Tebal) sebesar 88,21%, jauh lebih unggul daripada GRU 9-1 dengan RMSE 0,883981 dan akurasi 72,97%. *Novelty* utama penelitian ini terletak pada perbandingan arsitektur GRU dan TST untuk prediksi kabut berbasis METAR di bandar udara, yang dipadukan dengan teknik *sliding window* dan konversi regresi *visibility* menjadi klasifikasi multi kelas kejadian kabut. Penelitian ini memberikan kontribusi berupa kerangka pemodelan prediksi kabut yang mampu memproses data deret waktu secara berurutan dan lebih efektif, sehingga dapat dijadikan sebagai dasar dalam pengembangan sistem peringatan dini kejadian kabut otomatis yang akurat di lingkungan bandar udara.

Kata Kunci: Prediksi Kabut; METAR; *Gated Recurrent Unit*; *Time Series Transformer*; *Deep Learning*

Abstract—Fog is one of the most hazardous weather phenomena for aviation operations. Dense fog can reduce visibility to below 1,000 meters, potentially causing flight delays, cancellations, and even aviation incidents. To date, fog prediction, particularly at Budiarto Airport, still relies on manual analysis by weather forecasters, making it prone to subjectivity and delays in information delivery. This study proposes and compares two deep learning architectures: the Gated Recurrent Unit (GRU) as an efficient recurrent model, and Time Series Transformer (TST) based on self-attention as a state-of-the-art model for METAR (Meteorological Aerodrome Report) data-based fog event prediction. The METAR data is initially processed using a sliding window technique before becoming a ready-to-use dataset. The dataset comprises 153,838 METAR records from the Budiarto—Curug Meteorological Station spanning from September 2015 to February 2026, which were processed through a METAR code parsing pipeline, BMKG rule-based median imputation, Min-Max normalization, and the construction of a 9-1 sliding window dataset. Experimental results on the test data demonstrate that TST 9-1 delivers the best performance with a Root Mean Squared Error (RMSE) of 0.452427 and a three class classification accuracy (No Fog, Light Fog, Dense Fog) of 88.21%, significantly outperforming GRU 9-1, which achieved an RMSE of 0.883981 and an accuracy of 72.97%. The main novelty of this research lies in the comparative study of GRU and TST architectures for METAR based fog prediction at airports, combined with a sliding window technique and the conversion of visibility regression into a multi class classification of fog events. This research contributes a fog prediction modeling framework capable of processing time-series data sequentially and more effectively, which can serve as a foundation for the development of an accurate, automated early warning system for fog events in airport environments.

Keywords: Fog Prediction; METAR; *Gated Recurrent Unit*; *Time Series Transformer*; *Deep Learning*

1. PENDAHULUAN

Industri penerbangan merupakan salah satu sektor transportasi yang sangat sensitif terhadap kondisi cuaca. Dibandingkan dengan moda transportasi darat, faktor meteorologi dalam operasional penerbangan memiliki tingkat sensitivitas yang jauh lebih tinggi terhadap faktor meteorologi, tidak hanya berdampak pada kenyamanan, tetapi juga berimplikasi langsung pada aspek keselamatan, ketepatan waktu, hingga efisiensi biaya operasional. Salah satu fenomena cuaca yang paling berbahaya bagi penerbangan adalah kabut, yaitu kondisi atmosfer di permukaan bumi yang ditandai dengan turunnya *visibility* horizontal di daratan hingga di bawah 1.000 meter (WMO, 1992). Pada saat terjadi kabut, pilot kehilangan referensi visual terhadap landasan pacu sehingga prosedur pendaratan dan lepas landas menjadi sangat berisiko, terutama bagi penerbangan yang dilaksanakan dengan prosedur VFR. Adapun gangguan yang ditimbulkan oleh kabut meliputi penundaan penerbangan, pembatalan, hingga pengalihan rute. Gangguan tersebut tidak hanya merugikan secara ekonomi, tetapi juga meningkatkan risiko kecelakaan saat lepas landas dan pendaratan pesawat (Shankar dkk., 2024).

Tragedi penerbangan terbesar dalam sejarah, yaitu Musibah Bandar Udara Tenerife pada tahun 1977 yang menewaskan 583 jiwa, terjadi pada kondisi *visibility* yang rendah akibat kabut tebal (Wikipedia, 2025). Di Indonesia, gangguan yang sama juga sering terjadi, misalnya pada Maret 2022 di Bandar Udara Sultan Syarif Kasim II Pekanbaru yang menyebabkan tujuh penerbangan terganggu (Antaranews, 2022). Studi sebelumnya menunjukkan bahwa kabut



berkontribusi pada sebagian besar penundaan dan pembatalan penerbangan, terutama di bandar udara dengan karakteristik *visibility* yang fluktuatif. Oleh karena itu, kemampuan memprediksi kejadian kabut secara akurat menjadi hal yang penting bagi manajemen lalu lintas udara dan untuk menjaga keselamatan operasional penerbangan (Hue Dinh Thi Hong, 2021).

Bandar Udara Budiarto merupakan salah satu bandar udara di Indonesia dengan karakteristik operasional yang spesifik yang berlokasi di Tangerang, dengan kode *International Civil Aviation Organization* (ICAO) yaitu WIRR. Bandar udara ini menjadi basis kegiatan pendidikan penerbangan Politeknik Penerbangan Indonesia (PPI) Curug (Imam Sonhaji, 2022), dan tingkat aktivitas take off dan landing dapat mencapai 200 pergerakan pesawat per satu hari (D. F. Laksana, 2021). Sebagian besar penerbangannya merupakan latihan terbang menggunakan pesawat kecil yang dioperasikan dengan prosedur VFR. Dalam prosedur VFR, pilot memerlukan *visibility* yang memadai dan rujukan visual yang jelas, sehingga sangat bergantung pada kondisi cuaca setempat. Kabut yang muncul tiba-tiba dapat membatalkan jadwal latihan, menunda penerbangan, dan mengganggu kurikulum pendidikan penerbang.

Salah satu bentuk layanan informasi cuaca penerbangan yang digunakan untuk menyampaikan prakiraan cuaca di bandar udara adalah *Terminal Aerodrome Forecast* (TAF), yaitu sandi untuk prakiraan cuaca di bandar udara dalam perencanaan penerbangan. TAF diterbitkan secara rutin setiap enam jam, yaitu: 00 UTC, 06 UTC, 12 UTC, dan 18 UTC, dengan cakupan waktu prakiraan 12 jam hingga 30 jam ke depan. Informasi yang dilaporkan dalam sandi TAF mencakup unsur-unsur cuaca utama, seperti angin, *visibility*, awan, dan kondisi cuaca, salah satunya adalah kabut (BMKG, 2024). Saat ini, prediksi kabut di Bandar Udara Budiarto dilakukan secara manual oleh prakirawan cuaca BMKG melalui analisis sinoptik dan interpretasi data METAR secara berurutan. METAR adalah laporan cuaca penerbangan yang diterbitkan setiap 30 menit atau 60 menit yang memuat informasi suhu udara, suhu titik embun, arah dan kecepatan angin, *visibility*, kondisi cuaca signifikan, awan, dan tekanan udara (BMKG, 2025). Dalam hal ini, METAR menyediakan data suhu udara dan suhu titik embun secara konsisten, sehingga menjadi sumber yang ideal untuk analisis deret waktu dan pelatihan model prediktif. Sebagaimana dijelaskan oleh (Liu, 2024), nilai *dew point spread* yang sangat rendah dapat digunakan sebagai parameter utama dalam deteksi awal kabut pada wilayah dengan morfologi kompleks. Walaupun data METAR sangat kaya secara temporal, analisis manualnya rawan terhadap subjektivitas, ketergantungan pada pengalaman prakirawan, serta keterlambatan informasi peringatan dini.

Perkembangan teknologi *Artificial Intelligence* (AI), khususnya *deep learning* (DL), telah membuka peluang baru untuk membangun sistem prediksi kabut otomatis yang lebih cepat dan lebih akurat. Penelitian sebelumnya pada data berurutan (*time series*), yaitu penelitian Kurniawan dan Aziz, menunjukkan bahwa model *Random Forest* mampu mencapai akurasi hingga 69,44% dalam memprediksi kabut (Kurniawan & Aziz, 2024). Penelitian oleh Wiujianna dkk. di Bandar Udara Ruteng, penggunaan *Recurrent Neural Network* (RNN) dan *Long Short-Term Memory* (LSTM) dapat memprediksi kabut dengan lebih baik dibandingkan metode statistik (Wiujianna dkk., 2025). Penelitian Kışmıroğlu dan Isik (2025) mencatat bahwa LSTM dapat mengingat informasi jangka panjang dan melupakan informasi yang tidak relevan, namun, mengalami penurunan performa pada sekuen data yang panjang. Meskipun demikian, dalam pemodelan data sekuensial jangka pendek hingga menengah masih banyak menggunakan model GRU karena efisiensi komputasinya dan strukturnya yang lebih sederhana daripada LSTM. Hal ini didukung oleh penelitian Sharma dkk. (2024) yang membuktikan model GRU mampu menghasilkan akurasi prediksi kabut yang sangat kompetitif dan stabil.

Pemilihan GRU dan TST sebagai dua model yang dibandingkan dalam penelitian ini didasari oleh pertimbangan keilmuan, baik teoritis maupun praktis. GRU mewakili RNN generasi baru yang lebih efisien dibandingkan LSTM karena hanya memiliki dua *gate*, yaitu *reset* dan *update*, namun tetap mampu memodelkan dependensi temporal yang pendek hingga menengah. Pada banyak studi di bidang meteorologi, GRU bahkan menunjukkan performa setara atau lebih baik daripada LSTM dengan waktu training yang lebih singkat. Di sisi lain, TST merupakan model prediksi berbasis arsitektur *Transformer* yang memanfaatkan mekanisme *self-attention* untuk menangkap hubungan temporal jangka pendek maupun jangka panjang secara paralel tanpa memerlukan proses perulangan (*recurrent*). Mekanisme ini memungkinkan model mempelajari keterkaitan antar waktu secara lebih efektif, sehingga mampu menghasilkan representasi data yang lebih komprehensif. El-Saieed (2025) menjelaskan bahwa mekanisme *attention* memungkinkan model memproses data secara paralel sekaligus memberikan bobot yang lebih besar pada fitur-fitur yang paling relevan untuk proses prediksi. Selanjutnya, representasi pada *time-step* terakhir digunakan sebagai keluaran (*output*) yang merangkum seluruh informasi historis dalam satu vektor kontekstual untuk memprediksi nilai target pada waktu berikutnya (Chen, 2025). Keunggulan arsitektur *Transformer* pada data deret waktu juga telah dibuktikan oleh Zhou dkk. (2021) melalui model *Informer*, yang mampu meningkatkan efisiensi penggunaan memori sekaligus menghasilkan performa prediksi yang lebih baik pada data *time-series* berdimensi panjang. Kedua model dipilih karena keduanya dapat dilatih dengan ukuran dataset seperti yang tersedia pada arsip METAR Stasiun Meteorologi Budiarto sebanyak 153.838 baris data, selama sekitar sepuluh tahun.

Model dalam penelitian ini terlebih dahulu memprediksi nilai parameter yang berkaitan dengan nilai kabut. Nilai prediksi tersebut kemudian dikonversi menjadi kategori kejadian kabut tipis, kabut tebal dan tidak kabut menggunakan threshold visibilitas tertentu. Dalam penelitian sebelumnya, kejadian kabut tebal didefinisikan ketika *visibility* kurang dari 1.000 meter, sementara halimun (kabut tipis) berkisar antara 1.000 meter hingga 5.000 meter (Dewita & Alfiandy, 2024). Kontribusi utama dari penelitian ini adalah penyediaan evaluasi komprehensif terkait kinerja arsitektur berbasis rekuren konvensional dibandingkan dengan arsitektur berbasis *self-attention* dalam menangani data kabut sekuensial yang panjang. Selain itu, penelitian ini berkontribusi dalam menghasilkan model prediksi kabut yang *robust* untuk sistem operasional peringatan dini guna mendukung keselamatan penerbangan.

2. METODOLOGI PENELITIAN


2.1 Kerangka Dasar Penelitian

Penelitian ini berfokus pada analisis *time series* untuk memprediksi kejadian kabut di Bandar Udara Budiarto. Secara umum, alur penelitian dimulai dari identifikasi permasalahan utama, yaitu fenomena kabut yang merupakan salah satu kondisi cuaca berbahaya dalam dunia penerbangan karena dapat menurunkan *visibility* secara signifikan. Kondisi ini sangat berpengaruh terhadap keselamatan operasional penerbangan, terutama pada penerbangan latih yang menggunakan aturan *Visual Flight Rules* (VFR). Selain itu, metode prediksi kabut yang masih bergantung pada analisis manual menjadi tantangan tersendiri karena membutuhkan ketelitian tinggi dan dapat dipengaruhi oleh subjektivitas analis.

Tahap berikutnya adalah studi literatur yang dilakukan untuk memahami perkembangan penelitian sebelumnya, khususnya penerapan kecerdasan buatan (*Artificial Intelligence/AI*) pada data meteorologi seperti METAR. Studi literatur juga digunakan untuk melihat bagaimana metode prediksi kabut telah diterapkan di wilayah lain, sehingga dapat menjadi dasar dalam penyusunan pendekatan penelitian di Bandar Udara Budiarto. Setelah landasan teori diperoleh, penelitian dilanjutkan dengan pengumpulan dataset yang bersumber dari data observasi cuaca permukaan BMKG di Stasiun Meteorologi Budiarto.

Variabel yang digunakan sebagai fitur masukan meliputi suhu udara, suhu titik embun, kecepatan angin, dan *visibility*. Parameter-parameter tersebut dipilih karena memiliki hubungan dengan proses pembentukan kabut, terutama melalui perubahan kelembapan udara, pendinginan permukaan, serta penurunan *visibility*. Dataset yang telah dikumpulkan kemudian melalui tahap *pre-processing* untuk memastikan data siap digunakan dalam proses pemodelan. Pada tahap ini diterapkan metode *sliding window* 9-1, yaitu sembilan data historis digunakan sebagai masukan untuk memprediksi kondisi berikutnya. Metode ini bertujuan untuk menangkap pola sekuensial data cuaca secara lebih sistematis. Selanjutnya dilakukan penentuan arsitektur model deep learning dengan membandingkan dua model, yaitu model GRU dan TST. Model GRU digunakan karena mampu memproses data berurutan dan menangkap ketergantungan temporal, sedangkan TST digunakan karena memiliki mekanisme *self-attention* yang memungkinkan model mengenali hubungan antarwaktu secara lebih fleksibel. Kedua model kemudian dilatih dan diuji menggunakan dataset yang sama agar perbandingan performa dapat dilakukan secara objektif.

Tahap evaluasi dilakukan menggunakan dua indikator utama, yaitu RMSE dan akurasi klasifikasi. Nilai RMSE digunakan untuk menilai tingkat kesalahan prediksi numerik, sedangkan akurasi digunakan untuk mengukur kemampuan model dalam mengklasifikasikan jenis kabut. Hasil kedua model kemudian dianalisis untuk menentukan model yang terbaik. Dengan demikian, kerangka penelitian ini menggambarkan proses yang sistematis mulai dari perumusan masalah, studi literatur, pengolahan data, pemodelan deep learning, evaluasi performa, hingga analisis hasil pengujian sebagai dasar pengembangan sistem prediksi kabut otomatis. Alur sistematis dari seluruh tahapan rencana penelitian ini dirangkum dan digambarkan secara visual dalam Kerangka Pemikiran yang tertera pada Gambar 1.




Gambar 1. Kerangka Pemikiran

2.2 Tahapan Penelitian

Tahapan penelitian dimulai dengan mengumpulkan data METAR, yang kemudian melalui proses pra-pemrosesan untuk membersihkan dan menyiapkan data sehingga terbentuk dataset yang siap digunakan. Dalam waktu mengisi kekosongan data menggunakan metode median dengan aturan sebagai berikut:

- Untuk fitur *visibility* dibulatkan ke bawah, tapi tergantung range *visibility*-nya. Untuk *visibility* di antara 5000 meter dan 9999 meter, maka dibulatkan ke bawah ke perseribu; untuk *visibility* 800 meter hingga 5000 meter, maka dibulatkan ke bawah ke 100 meter; serta untuk *visibility* di bawah 800 meter, maka dibulatkan ke bawah ke 50 meter.
- Untuk suhu udara dan suhu titik embun, dibulatkan ke bilangan bulat terdekat jika ada desimal pada hasil median; jika desimal bernilai setengah, dibulatkan ke atas.
- Untuk fitur kecepatan angin dibulatkan ke atas jika ada desimal di median di fitur tersebut.

Kemudian, dari dataset tersebut disusun dengan *sliding window* 9-1, seperti yang diilustrasikan pada Gambar 2. Waktu satu hingga waktu sembilan untuk memprediksi waktu sepuluh. Waktu dua hingga waktu sepuluh untuk memprediksi waktu sebelas, dan seterusnya.



Gambar 2. *Sliding Window* 9-1

Dataset tersebut dibagi menjadi data latih (*training*), data validasi, dan data uji (*testing*) dengan rasio persentase 60:20:20, dan dilakukan secara sekuensial tanpa pengacakan (*no shuffling*) untuk mencegah kebocoran data (*data leakage*). Selanjutnya, model GRU dan TST di-*training* menggunakan data tersebut. Hasil terakhir berupa nilai prediksi suhu udara, suhu titik embun, kecepatan angin, dan *visibility*. Kemudian, hasil prediksi dibandingkan dengan data aktual untuk memperoleh nilai evaluasi RMSE. Detail mengenai parameter dan aturan klasifikasi yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Indikator Pembentukan Kabut

<i>Dew point depression</i> (T-Td)	Kecepatan angin (knot)	<i>Visibility</i> (meter)	Jenis Kabut
$\leq 3^{\circ}\text{C}$	≤ 4 KT	< 1000 m	Kabut Tebal
$\leq 3^{\circ}\text{C}$	≤ 4 KT	1000 m – 5000 m	Kabut Tipis
Semua kondisi	Semua kondisi	> 5000 m	Tidak Kabut

2.3 Model GRU dan Model TST

Model yang digunakan dalam penelitian di jurnal ini adalah GRU dan TST. Adapun kedua model ini dipilih karena model mempertimbangkan *time-series* atau data dengan waktu terurut. Model GRU menggunakan *update gate* dan *reset gate* (Song dkk, 2022). *Gate* ini lebih efisien daripada *gate* di model LSTM yang berjumlah tiga *gate*, yaitu: *input gate*, *forget gate* dan *output gate*. Adapun TST digunakan dalam penelitian ini karena merupakan model mutakhir, akan tetapi hanya menggunakan fungsi *encoder* saja.

Hyperparameter setting dilakukan pada kedua model dengan kondisi yang sama, agar perbandingannya setara, adil, dan seimbang. Detail mengenai nilai dan jenis *hyperparameter* yang diterapkan dalam penelitian ini dirangkum dalam Tabel 2.

Tabel 2. *Hyperparameter setting*

Parameter	Nilai
<i>Learning Rate Scheduling</i>	0,01 – 0,000001
<i>Batch Size</i>	32
<i>Epoch</i>	200
<i>Optimizer</i>	Adam
<i>Early Stop</i>	20 epoch



2.3.1 Model GRU

Arsitektur GRU yang dirancang terdiri dari tiga lapisan utama: lapisan *input* dengan bentuk (9, 4), di mana panjang *sliding window* sebanyak sembilan dan fitur sebanyak empat, dan layer GRU dengan ukuran 64, serta lapisan *dense* dengan empat *output*. Jumlah total parameter pelatihan adalah 13.700 parameter. Rincian struktur lapisan dan distribusi parameter model GRU tersebut disajikan pada Tabel 3.

Tabel 3. Arsitektur GRU

Layer	Shape	Parameter
Input	9, 4	-
GRU	64	13.440
Dense	4	260
Jumlah		13.700

2.3.2 Model TST

Arsitektur TST yang dirancang hanya menggunakan *encoder*. Setelah lapisan *input* (9, 4), diterapkan *Linear Embedding* sebanyak 64, dilanjutkan dengan satu lapisan *Transformer Encoder* yang berisi *self-attention* dengan empat *heads*, *Feed-Forward Network*, dan *Layer Normalization*. *Output* akhir disalurkan ke *Dense* empat *neuron*. Jumlah total parameter model TST sebesar 167.560 parameter, untuk setiap lapisannya dirangkum dalam Tabel 4.

Tabel 4. Arsitektur TST

Layer	Shape	Parameter
Input	9, 4	-
Linear Embedding	64	320
Transformer Encoder (1 layer, 4 heads)	64	166.980
Dense	4	260
Jumlah		167.560

2.4 Evaluasi Model

Evaluasi model dilakukan menggunakan metrik RMSE dan metrik akurasi klasifikasi. RMSE dipilih untuk melihat seberapa jauh kesalahan hasil prediksi dibandingkan dengan data aktual. Sedangkan akurasi klasifikasi dipilih untuk membedakan jenis-jenis kabut. Perbedaan jenis kabut ditentukan berdasarkan keilmuan meteorologi sesuai indikator pembentukan kabut yang telah dijelaskan pada Tabel 1.

2.4.1 RMSE

RMSE merupakan tingkat kesalahan hasil regresi, artinya semakin kecil nilai RMSE, maka hasil regresi akan semakin akurat. Cara menghitung RMSE adalah dengan mengurangi nilai aktual dengan nilai prediksi, kemudian dikuadratkan (Wonda dan Pratama, 2023). RMSE dilakukan pada tahap validasi dan tahap *testing*. Rumus RMSE dijelaskan pada Persamaan (1).

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

Dimana n adalah jumlah sampel data uji, y_i adalah nilai aktual pada titik waktu i , dan $\hat{y}_i$ adalah nilai hasil prediksi. Sedangkan i adalah waktu.

2.4.2 Akurasi

Akurasi merupakan rasio prediksi benar (positif dan negatif) dengan keseluruhan data. Akurasi adalah persentase data yang diklasifikasikan dengan benar dari keseluruhan data (Alwi Aliu dan Fitrianto, 2023). Nilai akurasi klasifikasi diperoleh dengan membandingkan data klasifikasi aktual dan data klasifikasi prediksi yang masing-masing dihasilkan melalui pemetaan data aktual dan data hasil prediksi ke dalam kategori kejadian kabut berdasarkan tabel indikator pembentukan kabut.

Tabel 1 menguraikan bahwa kejadian kabut tebal terbentuk ketika nilai *dew point depression* ($T-T_d$) ≤ 3 °C yang disertai dengan kecepatan angin lemah ≤ 4 knot, sehingga menekan *visibility* hingga < 1.000 meter. Kondisi kabut tipis juga membutuhkan indikator ambang batas suhu dan angin yang sama ($T-T_d \leq 3$ °C dan kecepatan angin ≤ 4 knot), namun *visibility* masih terlihat lebih jauh, yakni pada rentang 1.000 meter hingga 5.000 meter. Sebaliknya, apabila *visibility* tercatat > 5.000 meter, maka kondisi tersebut secara operasional diklasifikasikan sebagai Tidak Kabut, terlepas dari kondisi parameter *dew point depression* maupun kecepatan angin pada saat itu. Pembagian *Confusion Matrix* klasifikasi untuk kabut tipis, tidak kabut, dan kabut tebal dapat disajikan pada Tabel 5. Di mana data vertikal adalah data aktual dan data horizontal adalah data prediksi.

Tabel 5. Matriks Konfusi Klasifikasi

		Kabut Tipis Prediksi	Tidak Kabut Prediksi	Kabut Tebal Prediksi
Aktual	Kabut Tipis	a	b	c
Aktual	Tidak Kabut	d	e	f
Aktual	Kabut Tebal	g	h	i

Adapun data pada Tabel 5 kemudian dihitung akurasi. Akurasi tersebut menggunakan rumus seperti yang dijelaskan pada Persamaan (2).

$$Akurasi = \frac{a+e+i}{a+b+c+d+e+f+g+h+i} \quad (2)$$

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan pada penelitian ini meliputi: hasil pra-pemrosesan dataset yang siap digunakan untuk *training* model, hasil RMSE berupa nilai kesalahan prediksi terhadap data aktual, dan hasil akurasi untuk klasifikasi jenis kabut yang diprediksi.

3.1 Hasil Pra-pemrosesan Dataset

Dataset penelitian berasal dari data METAR Stasiun Meteorologi Budiarto yang mencakup periode September 2015 hingga Januari 2026, dengan total 153.838 baris data. Setelah melalui tahapan *data cleaning*, penanganan *missing value*, normalisasi menggunakan *Min-Max Scaling*, serta pembentukan data deret waktu menggunakan metode *Sliding Window* 9–1, diperoleh dataset yang siap digunakan untuk proses pelatihan model *Deep Learning*. Jumlah *sequence sliding window* 9–1 sebanyak 153.829 *sequence*. Konfigurasi *Sliding Window* 9–1 menghasilkan data berupa sembilan urutan pengamatan meteorologi sebelumnya yang digunakan untuk memprediksi kondisi kabut pada waktu berikutnya. Pendekatan ini dipilih karena pembentukan kabut merupakan fenomena atmosfer yang berlangsung secara bertahap, sehingga informasi historis memiliki kontribusi penting terhadap kondisi saat prediksi dilakukan.

Tabel 6. Dataset *Sliding Window* 9-1

Input	Output
[Suhu Udara, Suhu Titik Embun, Kecepatan Angin, Visibility]	[Suhu Udara, Suhu Titik Embun, Kecepatan Angin, Visibility]
Input 1:	
[[23 23 0 1700]	
[25 23 0 2500]	
[27 22 0 3700]	
[28 22 2 4500]	
[29 22 3 6000]	
[30 21 4 7000]	
[31 20 3 9000]	
[32 18 4 9999]	
[33 18 7 9999]	
Input 2:	
[[25 23 0 2500]	
[27 22 0 3700]	
[28 22 2 4500]	
[29 22 3 6000]	
[30 21 4 7000]	
[31 20 3 9000]	
[32 18 4 9999]	
[33 18 7 9999]	
[33 18 5 9999]	
	Output 1:
	[[33 18 5 9999]]
	Output 2:
	[[32 18 4 9999]]

Tabel 6 menunjukkan proses pembentukan dataset menggunakan teknik *sliding window* dengan konfigurasi 9-1, yaitu sembilan data pengamatan sebelumnya digunakan sebagai *input* untuk memprediksi satu data pengamatan berikutnya sebagai *output*. Setiap data pengamatan terdiri atas empat parameter meteorologi, yaitu kolom satu berisi data suhu udara, kolom dua berisi data suhu titik embun, kolom tiga berisi data kecepatan angin, dan kolom empat berisi data *visibility*. Pada *Input* 1, model menerima sembilan data berurutan mulai dari pengamatan pertama hingga kesembilan, kemudian memprediksi data pada pengamatan ke-10 sebagai *Output* 1. Selanjutnya, pada *Input* 2, jendela data bergeser satu langkah sehingga terdiri atas pengamatan kedua hingga kesepuluh, dengan target prediksi berupa pengamatan ke-11 sebagai *Output* 2. Proses pergeseran jendela ini dilakukan secara berulang hingga seluruh data

historis digunakan untuk membentuk dataset pelatihan model. Representasi tersebut memungkinkan model mempelajari perubahan parameter atmosfer secara temporal, termasuk penurunan suhu udara, mendekatnya suhu terhadap titik embun, perubahan kecepatan angin, serta penurunan *visibility* yang umumnya mendahului terbentuknya kabut.


Tabel 7. Pembagian Waktu Dataset

proses	waktu	input waktu 1	input waktu 9
training	awal	01/09/2015 00:00	01/09/2015 04:00
training	akhir	16/08/2021 01:00	16/08/2021 14:00
validasi	awal	16/08/2021 02:00	16/08/2021 15:00
validasi	akhir	21/03/2024 20:00	22/03/2024 00:00
testing	awal	21/03/2024 20:30	22/03/2024 01:00
testing	akhir	09/02/2026 01:30	09/02/2026 05:30

Tabel 7 menjelaskan rincian pembagian rentang waktu secara kronologis (waktu awal dan akhir) untuk tiga tahapan utama, yaitu fase *training*, validasi, dan *testing*, berdasarkan dua variasi masukan ("input waktu 1" dan "input waktu 9"). Data keseluruhan yang digunakan mencakup periode dari September 2015 hingga Februari 2026, yang dipotong secara berurutan, di mana bagian data paling awal (September 2015 – Agustus 2021) dialokasikan untuk melatih model (*training*), data selanjutnya (Agustus 2021 – Maret 2024) untuk evaluasi penyesuaian (validasi), dan bagian data terbaru (Maret 2024 – Februari 2026) digunakan untuk pengujian akhir (*testing*). Struktur ini memastikan bahwa model dievaluasi menggunakan data di masa depan yang belum pernah dilihat sebelumnya.

3.2 Evaluasi Training

Dalam proses training, dihasilkan validasi *loss* pada model TST yang lebih rendah daripada model GRU lihat Gambar 3 (a) dan Gambar 3 (b). Pada Gambar 3 (a), training model GRU berhenti pada epoch 94 dari 200 epoch yang sudah di-*setting*, sehingga model terbaik pada epoch 74 dengan validasi *loss* sebesar 0,926889.


Gambar 3. (a) Grafik *Training Loss* dan Validasi *Loss* GRU 9-1; (b) Grafik *Training Loss* dan Validasi *Loss* TST 9-1

Pada Gambar 3 (b), training model TST berhenti di epoch 11 dari 200 epoch yang sudah di-*setting*, sehingga model terbaik diperoleh epoch 31 dengan validasi *loss* sebesar 0,315635.

3.3 Hasil RMSE

Hasil RMSE kedua model GRU dan TST dapat dilihat pada Tabel 8. RMSE TST lebih kecil daripada RMSE GRU (yang ditandai *). Hal ini membuktikan bahwa model TST lebih baik daripada model GRU. Kesalahan model GRU dua kali lipat dari model TST. Dengan demikian, dapat disimpulkan bahwa model TST mampu menghasilkan prediksi yang lebih akurat dibandingkan model GRU. Perbedaan tersebut menunjukkan bahwa kemampuan TST dalam memanfaatkan hubungan temporal jangka panjang memberikan keuntungan yang signifikan pada data meteorologi.


Pada proses pembentukan kabut, perubahan suhu, titik embun, angin, serta *visibility* sering kali saling memengaruhi dalam rentang waktu yang cukup panjang. Informasi tersebut dapat dipertahankan lebih baik melalui mekanisme *self-attention* pada model TST dibandingkan dengan mekanisme sekuen pada model GRU. Adapun hasil perbandingan RMSE dapat dilihat pada Tabel 8.

Tabel 8. Hasil RMSE GRU dan TST

RMSE	GRU	TST
<i>Sliding Window</i> 9-1	0.883981	0.452427 (*)

3.4 Hasil Akurasi

Setelah memperoleh hasil prediksi, nilai tersebut dikonversi ke dalam kategori operasional berdasarkan batas visibilitas yang telah ditetapkan. Rincian dan visualisasi dari hasil pengujian tersebut disajikan secara terpisah untuk setiap arsitektur yang diuji. Pembagian serta pemetaan hasil *Confusion Matrix* ini dapat dilihat pada Gambar 4 (a) untuk model GRU dan Gambar 4 (b) untuk model TST. Melalui visualisasi tersebut, perbandingan performa klasifikasi antara kedua model dapat dianalisis secara lebih objektif.



Gambar 4. *Confusion Matrix* Klasifikasi (a) GRU 9-1 (b) TST 9-1

Berdasarkan *Confusion Matrix*, terlihat bahwa model TST menghasilkan jumlah prediksi yang benar (*true positive* dan *true negative*) yang lebih tinggi dibandingkan dengan GRU. Kesalahan klasifikasi (*false positive* dan *false negative*) juga mengalami penurunan sehingga distribusi prediksi menjadi lebih seimbang. Kemampuan tersebut sangat penting dalam sistem prediksi kabut karena kesalahan dalam mendeteksi kejadian kabut (*false negative*) dapat menyebabkan prakiraan kabut kurang menjadi akurat dalam memberikan peringatan dini terhadap kondisi berbahaya bagi aktivitas penerbangan. Sebaliknya, jumlah *false positive* yang rendah juga membantu mengurangi peringatan palsu (*false alarm*) sehingga informasi prakiraan menjadi lebih terpercaya. Untuk hasil akurasi GRU dan TST dapat dilihat pada Tabel 9.

Tabel 9. Hasil Akurasi GRU dan TST

Akurasi	GRU	TST
<i>Sliding Window</i> 9-1	72,97%	88,21 % (*)

Selanjutnya dilakukan evaluasi menggunakan metrik akurasi. Hasil evaluasi menunjukkan bahwa model TST memperoleh tingkat akurasi sebesar 88,21% yang lebih tinggi dibandingkan dengan model GRU. Nilai tersebut menunjukkan bahwa sebagian besar kejadian kabut berhasil diklasifikasikan dengan benar berdasarkan prediksi *visibility*. Peningkatan akurasi tersebut sekaligus memperkuat hasil evaluasi RMSE yang sebelumnya menunjukkan bahwa TST memiliki tingkat kesalahan prediksi numerik yang lebih rendah. Dengan demikian, keunggulan model TST tidak hanya terlihat pada hasil regresi *visibility*, tetapi juga berdampak langsung pada peningkatan ketepatan klasifikasi kejadian kabut.

3.5 Pembahasan

Keunggulan model TST dengan akurasi 88,21% dibandingkan GRU yang hanya mencapai 72,97% karena TST memiliki arsitektur *self-attention*. Untuk memprediksi tren pembentukan kabut, model kecerdasan buatan harus mampu menganalisis kondisi parameter meteorologi hingga 4,5 jam sebelumnya dengan memanfaatkan metode *sliding window* 9-1. Model GRU kurang bisa menangkap anomali parameter meteorologi, sehingga hasil akurasinya rendah. Sebaliknya, keunggulan mekanisme *self-attention* memungkinkan model TST untuk membaca sembilan waktu tersebut secara paralel. Melalui *multi-head attention*, TST secara matematis membandingkan dan memberikan bobot korelasi langsung dari data awal hingga akhir tanpa terkendala batasan urutan. Hal ini membuat model TST mampu mengidentifikasi fenomena langka secara akurat dan tidak terjebak dalam dominasi kelas mayoritas yang tidak seimbang (*imbalanced data*).

Keberhasilan model GRU dan TST dalam penelitian ini memperjelas *gap* penelitian pada berbagai studi terdahulu. Pada penelitian pertama yang dilakukan oleh Kurniawan dan Abdul Aziz (2024) dengan lokasi Bandara Radin Inten II, prediksi kabut menggunakan model Random Forest dengan akurasi sebesar 69,44%, karena keterbatasan pendekatan machine learning dalam memodelkan data kabut yang kompleks secara berurutan. Penelitian kedua oleh Dewita dan Alfiandy (2024) di Bandara Zainuddin Abdul Majid pada Januari 2024, mencoba mengatasi masalah



kejadian kabut tersebut dengan menggunakan metode dikotonomi *threshold* dari *Numerical Weather Prediction* (NWP) menghasilkan akurasi 87%, namun metode ini sangat bergantung pada penetapan batas ambang yang statis dan masih memerlukan campur tangan observasi manual. Penelitian ketiga yang dilakukan oleh Wiujianna dkk. (2025) di Bandara Ruteng telah mengambil langkah maju dengan menerapkan *deep learning* melalui model RNN dan LSTM, di mana meskipun mampu menghasilkan performa yang baik, model tanpa *attention mechanism* terbukti rentan mengalami *overfitting* serta kesulitan menangani data berutuan yang panjang akibat masalah degradasi atau *vanishing gradient*, sehingga penelitian ini menjadi rekomendasi untuk model time-series menggunakan metode *attention mechanism* agar lebih akurat. Sejalan dengan itu, penelitian keempat oleh Sharma dkk. (2024) yang menguji GRU dan LSTM untuk prediksi kabut di berbagai bandar udara India Utara menunjukkan model tersebut stabil, tingkat akurasi dan kinerja regresinya cenderung terus menurun seiring dengan bertambahnya jumlah kategori klasifikasi kabut yang diprediksi.

Kelemahan utama dari keempat penelitian terdahulu, yaitu belum adanya pemanfaatan model berbasis *self-attention* yang dirancang secara spesifik untuk mengatasi keterbatasan memori jangka panjang pada pemrosesan data cuaca penerbangan. Penelitian ini berhasil mengisi *gap* tersebut dengan membuktikan bahwa implementasi teknik *sliding window* 9-1 tidak hanya meningkatkan akurasi model secara keseluruhan, tetapi juga memperlihatkan perbedaan performa yang signifikan antara model rekuren dan transformer. Dengan kemampuan memproses data secara paralel, model TST terbukti jauh lebih unggul dalam menangkap anomali kejadian kabut secara berurutan, menjadikannya solusi yang lebih *robust*.

4. KESIMPULAN

Kesimpulan pada riset ini adalah secara empiris bahwa pemodelan *Time Series Transformer* (TST) secara fundamental lebih unggul daripada *Gated Recurrent Unit* (GRU) untuk model prediksi kabut di Bandar Udara Budiarto. Dengan metode *Sliding Window* 9-1, arsitektur TST berhasil menghasilkan RMSE sebesar 0,4524 dan mampu mengklasifikasikan kategori pembentukan kabut dengan tingkat akurasi yang sangat tinggi, yaitu 88,21%. Kinerja tersebut menunjukkan bahwa TST mampu mempelajari pola temporal yang kompleks secara lebih efektif dibandingkan dengan GRU. Keunggulan ini didukung oleh mekanisme *self-attention* yang mampu menangkap hubungan antardata dalam rentang waktu yang panjang tanpa mengalami penurunan performa akibat ketergantungan pada urutan waktu. Hasil penelitian ini juga mengindikasikan bahwa pendekatan berbasis TST memiliki potensi besar untuk diterapkan dalam prediksi fenomena kabut yang memerlukan ketelitian tinggi. Meskipun demikian, batasan penelitian ini adalah pengujian model yang masih dilakukan melalui pengembangan model secara *offline*, sehingga belum sepenuhnya merepresentasikan kondisi operasional di lapangan. Oleh karena itu, penelitian selanjutnya disarankan untuk mengembangkan model TST dengan konfigurasi *Sliding Window* 9-1 ke dalam Sistem Peringatan Dini (*Early Warning System*) yang terintegrasi dan mampu beroperasi secara *real-time*. Selain itu, evaluasi terhadap data multimusim dan berbagai kondisi meteorologis juga perlu dilakukan untuk menguji ketahanan (*robustness*) model. Implementasi tersebut diharapkan dapat menjadi bagian dari *decision support system* (sistem pendukung keputusan) bagi pengelola lalu lintas udara dalam meningkatkan keselamatan penerbangan, khususnya untuk meminimalkan risiko kecelakaan pada penerbangan latihan dengan aturan terbang *Visual Flight Rules* (VFR). Sebagai kontribusi dalam penelitian ini menggunakan data kabut yang panjang dengan metode *sliding window* 9-1 yang diimplementasikan pada model GRU dan model TST. Hasil dari penelitian ini dapat memutakhirkan layanan prakiraan cuaca penerbangan, yang mengubah transisi dari metode analisis prediksi kabut yang masih manual menjadi sistem peringatan dini cerdas yang berjalan otomatis, dan memiliki tingkat akurasi yang tinggi.

REFERENCES

- Alwi Aliu, M., & Fitrianto, A. (2023). Pemodelan Regresi Logistik Ordinal Backward dengan Imputasi K-Nearest Neighbour pada Indeks Pembangunan Manusia di Indonesia Tahun 2021. *Jurnal Statistika Dan Aplikasinya*, 7(1).
Antaranews. (2022). Akibat kabut, tujuh penerbangan di Pekanbaru terganggu. <https://www.antaranews.com/berita/3112713/akibat-kabut-tujuh-penerbangan-di-pekanbaru-terganggu>.
BMKG. (2024). *Peraturan Badan Meteorologi, Klimatologi, Dan Geofisika Republik Indonesia, Nomor 6 Tahun 2024 Tentang Penyediaan Dan Penyebaran Aerodrome Forecast*.
BMKG. (2025). *Kep 26 KB I 2025 Tentang Stasiun Meteorologi Penanggung Jawab Penyediaan Dan Penyebaran Metar*.
Chen, Q. (2025). *Comparing Different Transformer Model Structures for Stock Prediction*. <http://arxiv.org/abs/2504.16361>
D. F. Laksana. (2021). Rancangan Aplikasi E-Sched Untuk Personel Penerbangan Sebagai Upaya Pemerataan Traffic Di Bandar Udara Budiarto Curug. *Politeknik Penerbangan Surabaya*.
Dewita, A., & Alfiandy, S. (2024). Kajian Awal : Prediksi Kabut Berdasarkan Data Observasi di Wilayah Bandara Zainuddin Abdul Majid. *Buletin GAW Bariri*, 5(2), 60–69. <https://doi.org/10.31172/bgb.v5i2.135>
El-Saieed, A. M. (2025). An Adaptive Transformer Model for Long-Term Time-Series Forecasting of Temperature and Radiation in Photovoltaic Energy Generation. *Applied Computational Intelligence and Soft Computing*, 2025(1). <https://doi.org/10.1155/acis/6671565>
Hue Dinh Thi Hong. (2021). *Fog Prediction Using Deep Learning Models*. Texas A&M University.



- Imam Sonhaji. (2022). Peran Politeknik Penerbangan Iindonesia (PPI) Curug Pada Pengembangan Aerowisata Provinsi Banten. *Jurnal Manajemen Dirgantara Vol.15, No.1, Juli 2022*. <https://doi.org/10.56521/manajemen-dirgantara.v15i1.574>
- Kişmıroğlu, C., & Isik, O. (2025). Temperature Prediction Using Transformer–LSTM Deep Learning Models and Sarimax from a Signal Processing Perspective. *Applied Sciences (Switzerland)*, 15(17). <https://doi.org/10.3390/app15179372>
- Kurniawan, A., & Abdul Aziz, R. (2024). Prediksi Kabut Bandar Udara di Indonesia Menggunakan Neural Network dan Radom Forest. *Building of Informatics, Technology and Science (BITS)*, 6(2), 746–757. <https://doi.org/10.47065/bits.v6i2.5544>
- Liu, G. (2024). *Predicting Winter Fog over Complex Terrain using Machine Learning*. University of Utah.
- Shankar, A., Kumar, A., & Sinha, V. (2024). Machine Learning Approach in the Prediction of Fog: An Early Warning System. *Mausam*, 75(4), 1039–1050. <https://doi.org/10.54302/mausam.v75i4.5919>
- Sharma, S., Bajaj, K., Deshpande, P., Bhattacharya, A., & Tripathi, S. (2024). *Short-Term Fog Forecasting using Meteorological Observations at Airports in North India*. <https://mesonet.agron.iastate.edu/>
- Wikipedia. (2025, February 4). *Musibah Bandar Udara Tenerife*. https://Id.Wikipedia.Org/Wiki/Musibah_bandar_udara_Tenerife. https://id.wikipedia.org/wiki/Musibah_bandar_udara_Tenerife
- Wiujianna, A., Setio Pribadi, F., Djuniadi, D., & Sunarno, S. (2025). *Komputika: Jurnal Sistem Komputer Prediksi Kabut Menggunakan RNN dan LSTM dengan Attention Mechanism di Bandara Ruteng*. 14(1), 87–93. <https://doi.org/10.34010/8e86yg15>
- WMO. (1992). *World Meteorological Organization International Meteorological Vocabulary*.
- Wonda, D., & Pratama, I. (2023). *Implementasi Data Mining Menggunakan Neural Network Untuk Prediksi Penjualan (Studi Kasus: Burjo Burneo Seturan Raya)*.
- Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., & Zhang, W. (2021). *Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting*. <http://arxiv.org/abs/2012.07436>