

Analisis Komparatif Prediksi Kelembaban di Kota Bandung Menggunakan Metode *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU)

MUHAMMAD ARIEF BUDIMAN*,
MUHAMMAD RIZKY DARMAWAN, MUHAMMAD NOVRIZAL AKMAL, DAN HERLINA
NAPITUPULU

DEPARTEMEN MATEMATIKA, FMIPA, UNIVERSITAS PADJADJARAN, JALAN IR. SOEKARNO KM. 21
JATINANGOR, SUMEDANG, 45363, INDONESIA

Abstrak

Kelembaban udara memiliki pengaruh yang signifikan pada berbagai sektor industri, terutama yang bergantung pada kondisi lingkungan, seperti tekstil dan farmasi. Kota Bandung sebagai salah satu kota industri juga sangat dipengaruhi oleh tingkat kelembaban udaranya. Oleh karena itu, peramalan kelembaban udara penting untuk mendukung pengambilan keputusan yang tepat. Dalam penelitian ini, dilakukan analisis komparatif dua metode pemodelan berbasis *Recurrent Neural Network* (RNN), yaitu *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), untuk memprediksi kelembaban udara di Kota Bandung. Data yang digunakan dalam penelitian ini adalah data kelembaban udara dari 1 Juli 2019 hingga 1 Juli 2024, yang diambil dari sumber data sekunder di situs web NASA. Proses pemodelan dilakukan dengan menggunakan Google Colab, dan akurasi model diukur dengan dua metrik utama, yaitu *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Squared Error* (RMSE). Hasil penelitian menunjukkan bahwa model GRU menghasilkan kinerja yang lebih baik dibandingkan LSTM, dengan konfigurasi 1 *layer* dan 25 *node*. Nilai MAPE yang diperoleh adalah 2,831% dan RMSE sebesar 0,579. Sementara itu, LSTM optimal pada penggunaan 1 *layer* dengan 75 *node* dan memiliki nilai MAPE sebesar 2,929% serta RMSE sebesar 0,593. Dari segi efisiensi waktu, GRU juga unggul dengan waktu pengoperasian yang lebih pendek, yaitu 2525,489 detik, dibandingkan dengan LSTM yang membutuhkan waktu 3410,316 detik. Oleh karena itu, GRU merupakan pilihan yang lebih baik dalam memprediksi kelembaban udara, baik dari segi akurasi maupun efisiensi waktu.

Kata kunci: Kelembaban, *Long Short Term Memory*, *Gated Recurrent Unit*

Abstract

Air humidity has a significant influence on various industrial sectors, particularly those that depend on environmental conditions, such as the textile and pharmaceutical industries. Bandung City, as one of the major industrial areas in Indonesia, is also strongly affected by air humidity levels. Therefore, accurate air humidity forecasting is essential to support effective decision-making processes. In this study, a comparative analysis of two Recurrent Neural Network (RNN)-based modeling approaches, namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), is conducted to predict air humidity in Bandung City. The data used in this research consist of air humidity records from July 1, 2019, to July 1, 2024, obtained from secondary data sources from the NASA website. The modeling process is implemented using Google Colab, and model performance is evaluated using two main accuracy metrics, namely Mean Absolute Percentage Error (MAPE) and Root Mean Squared Error (RMSE). The results indicate that the GRU model outperforms the LSTM model in terms of predictive performance, with an optimal configuration of one layer and 25 nodes. The GRU model achieves a MAPE value of 2.831% and an RMSE of 0.579. Meanwhile, the optimal LSTM configuration consists of one layer with 75 nodes, resulting in a MAPE of 2.929% and an RMSE of 0.593. In terms of computational efficiency, the GRU model also demonstrates superior performance, requiring a shorter computation time of 2525.489 seconds compared to 3410.316 seconds for the LSTM model. Therefore, GRU is considered a more suitable approach for air humidity prediction, offering both higher accuracy and better computational efficiency.


Keywords: *Air Humidity, Long Short Term Memory, Gated Recurrent Unit*

1. PENDAHULUAN

Menurut berita di situs Antaranews [2], dilaporkan bahwa perubahan iklim akan mempengaruhi tingkat kelembaban udara, yang akan menyebabkan berbagai penyakit terkait kekebalan seperti demam dan gejala pilek seperti batuk dan pilek. Kelembaban udara adalah jumlah uap air yang terkandung dalam suatu ruang udara. Uap air ini merupakan gas yang tidak terlihat dan tidak berbau, terbentuk dari proses penguapan air [3]. Perubahan kelembaban udara dapat memiliki efek yang berbeda tergantung pada wilayahnya. Misalnya, di Bandung, tingkat kelembaban cenderung tinggi selama musim hujan dan lebih rendah selama musim kemarau, bervariasi dari tahun ke tahun.

Kota Bandung, kota dengan populasi 2,5 juta orang, merupakan kota dengan populasi terbesar ketiga di Indonesia setelah Jakarta dan Surabaya. Ibu kota Jawa Barat terletak 151,7 km dari Jakarta. Menurut Badan Pusat Statistik [4], kelembaban di Kota Bandung cenderung normal dibandingkan dengan Kota Bogor yang hampir selalu mengalami hujan. Grafik kelembaban kota Bandung dalam lima tahun terakhir dapat dilihat pada Gambar 1

Menurut SSE [12], kelembaban udara yang tinggi dapat mempengaruhi proses produksi di sektor industri, terutama untuk industri yang tinggi. Kelembaban udara yang tinggi juga dapat berdampak pada pertumbuhan jamur, pembusukan, dan korosi peralatan industri. Oleh karena itu, prediksi kelembaban udara diperlukan sebagai upaya optimalisasi sektor industri yang berdampak pada kesejahteraan masyarakat.



GAMBAR 1. Grafik kelembaban udara relatif kota Bandung 1 Juli 2019 – 1 Juli 2024 (<https://power.larc.nasa.gov/data-access-viewer/>)

Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) adalah bagian dari Recurrent Neural Networks (RNN) yang sering digunakan dalam pemrosesan urutan, seperti natural language processing, prediksi urutan, dan tugas lain yang melibatkan data berurutan [5]. LSTM sering digunakan dalam kasus di mana perlu menyimpan informasi untuk jangka waktu yang sangat lama. Sementara itu, GRU lebih disukai dalam aplikasi di mana kecepatan merupakan faktor penting, dan seringkali memberikan kinerja yang sama atau bahkan lebih baik daripada LSTM dalam beberapa kasus. Oleh karena itu, LSTM dan GRU cocok dalam melakukan peramalan data berbasis waktu [11].

Berdasarkan riset [1] menggunakan metode LSTM dan GRU untuk memprediksi harga emas dengan mempertimbangkan besaran *Epoch*. Penelitian [6] menggunakan metode LSTM dan GRU untuk memprediksi curah hujan. Pada penelitian ini digunakan metode LSTM dan GRU untuk memprediksi nilai kelembaban spesifik data pada 2 meter di Kota Bandung. Metode yang digunakan untuk memprediksi satu tahun ke depan adalah metode yang memiliki nilai MAPE berdasarkan jumlah layernya.


2. METODE PENELITIAN

Bagian ini berisi kajian teori yang digunakan dan sumber data yang digunakan pada penelitian ini.

2.1. Kelembaban Udara. Berdasarkan Glosarium Meteorologi, kelembaban didefinisikan sebagai jumlah uap air di udara atau tekanan uap yang diamati terhadap tekanan uap jenuh untuk suhu yang diamati dan dinyatakan dalam persen. Menurut [8], ada tiga jenis kelembaban udara, yaitu:

- (1) Kelembaban absolut, yang massa total uap air per satuan volume udara dinyatakan dalam satuan (g/m^3).
- (2) Kelembaban spesifik, yang merupakan rasio antara massa uap air dan massa udara lembab dalam satuan volume udara tertentu dalam satu unit (g/kg).
- (3) Kelembaban relatif atau kelembaban relatif, yang merupakan rasio antara tekanan uap air aktual dan tekanan uap air pada saturasi, dinyatakan dalam persen.

2.2. Long Short Term Memory (LSTM). Long Short Term Memory (LSTM) adalah salah satu jenis Machine Learning Approach-based Recurrent Neural Network yang dapat memprediksi kondisi mesin saat ini dengan menggunakan percikan mesin pemrosesan data skala besar. Menurut [13], LSTM adalah jenis khusus dari Neural Network. LSTM dirancang untuk mengatasi masalah gradien yang menghilang yang sering terjadi pada RNN saat memproses data waktu yang panjang. [9] menjelaskan bahwa dengan memanfaatkan memori sel yang ditingkatkan, LSTM dapat menyimpan informasi untuk jangka waktu yang lebih lama. Struktur sel dalam LSTM dapat dilihat pada Gambar 2



GAMBAR 2. Struktur sel LSTM [14]

Gambar 2 menunjukkan arsitektur LSTM, di mana terdapat tiga gerbang, yaitu gerbang *forget* (f_t), gerbang *input* (i_t), dan gerbang *output* (o_t). Gerbang *forget* adalah persamaan yang menentukan unsur yang harus "forget" oleh sel LSTM. Persamaan gerbang *forget* dapat dilihat dalam persamaan (1) berikut:

$$f_t = \sigma(\mathbf{W}_{f_h} \mathbf{h}_{t-1}, \mathbf{W}_{f_x} \mathbf{x}_t, \mathbf{b}_f) \quad (1)$$

Gerbang *input* adalah persamaan yang menentukan elemen baru yang harus disimpan oleh sel LSTM. Persamaan gerbang *input* dapat dilihat dalam persamaan (2) berikut:

$$i_t = \sigma(\mathbf{W}_{i_h} \mathbf{h}_{t-1}, \mathbf{W}_{i_x} \mathbf{x}_t, \mathbf{b}_i) \quad (2)$$

Status sel kandidat, persamaan ini digunakan untuk menghitung kandidat nilai baru untuk status sel yang akan ditambahkan. Persamaan dapat dilihat dalam persamaan (3) berikut:

$$\tilde{C}_t = \tanh(\mathbf{W}_{c_h} \mathbf{h}_{t-1}, \mathbf{W}_{c_x} \mathbf{x}_t, \mathbf{b}_c) \quad (3)$$

Status sel baru adalah persamaan untuk menentukan nilai baru dari keadaan sel. Persamaan dapat dilihat dalam persamaan (4) berikut:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

Gerbang *output*, fungsi untuk mengontrol status sel yang akan dikirim ke $\mathbf{h}_t$. Persamaan keluaran gerbang dapat dilihat dalam persamaan (5) berikut:

$$o_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t], \mathbf{b}_o) \quad (5)$$


Hidden state, adalah nilai keluaran akhir LSTM. Persamaan dapat dilihat dalam persamaan (6) berikut:

$$\mathbf{h}_t = o_t \cdot \tanh(C_t) \quad (6)$$

Dengan $\mathbf{x}_t$ adalah nilai input, $\mathbf{W}$ adalah bobot, $\mathbf{b}$ adalah bias, $\mathbf{h}_{t-1}$ adalah output pada waktu $t-1$, C_{t-1} adalah keadaan sel memori di sel sebelumnya, dan $\mathbf{h}_t$ merupakan *output* akhir.

2.3. Gated Recurrent Unit (GRU). *Gated Recurrent Unit (GRU)* adalah salah satu variasi dari *Recurrent Neural Network* yang dibuat untuk menghindari masalah ketergantungan jangka panjang. GRU dapat mengingat informasi jangka panjang seperti *Recurrent Neural Network*, GRU juga terdiri dari beberapa pemrosesan berulang. Performa GRU mirip dengan LSTM, namun GRU hanya terdiri dari dua gerbang, yaitu gerbang *reset* (r_t) dan gerbang *update* (u_t) [15]. Sistemika GRU dapat divisualisasikan pada Gambar 3 berikut:

Gerbang *pembaruan* adalah fungsi yang menentukan berapa banyak nilai yang akan dibawa oleh *hidden state* lama ke *hidden state* baru di t . Berikut persamaan untuk memperbarui gerbang:



GAMBAR 3. Struktur sel GRU [10]

$$u_t = \sigma(\mathbf{W}_{h_u} \mathbf{h}_{t-1} + \mathbf{W}_{x_u} \mathbf{x}_t + \mathbf{b}_u) \quad (7)$$

Gerbang *reset* mengontrol besarnya pengaruh keadaan *hidden* sebelumnya pada kandidat keadaan *hidden* baru. Persamaan gerbang reset dapat dilihat dalam persamaan (8) berikut:

$$r_t = \sigma(\mathbf{W}_{r_h} \mathbf{h}_{t-1} + \mathbf{W}_{x_r} \mathbf{x}_t + \mathbf{b}_r) \quad (8)$$

Hidden state kandidat adalah nilai sementara yang digunakan untuk menghitung *hidden state* baru ($\mathbf{h}_t$). Persamaannya dapat dilihat sebagai berikut:

$$\hat{\mathbf{h}}_t = \tanh(\mathbf{W}_{h_h} (r_t \odot \mathbf{h}_{t-1}) + \mathbf{W}_{x_h} \mathbf{x}_t + \mathbf{b}_h) \quad (9)$$

Keadaan *hidden* akhir adalah nilai akhir yang telah dikendalikan oleh fungsi-fungsi di atas, persamaannya dapat dilihat sebagai berikut:

$$\mathbf{h}_t = (1 - u_t) \odot \mathbf{h}_{t-1} + u_t \odot \hat{\mathbf{h}}_t \quad (10)$$

Simbol $\odot$ adalah operator produk Hadamard yang mengalikan elemen dalam baris dan kolom yang sama dari dua matriks dengan ukuran yang sama.

2.4. Sumber Data. Sumber data yang digunakan dalam penelitian ini menggunakan data sekunder yang dapat diakses di situs resmi NASA (<https://power.larc.nasa.gov/data-access-viewer/>). Data yang digunakan adalah kelembaban spesifik data pada 2 meter dari 1 Juli 2019–1 Juli 2024. Alasan pemilihan data ini adalah data ini mengukur jumlah uap air di atmosfer, khususnya pada ketinggian yang relevan bagi aktivitas manusia, ekosistem, dan proses permukaan bumi. Kemudian data masuk ke tahap *data preprocessing*, yaitu pengecekan nilai yang hilang, membersihkan data, dan mengoreksi format. Data yang diperoleh dapat dilihat pada Tabel 1.

TABEL 1. Data Kelembaban Kota Bandung dari 1 Juli 2019–1 Juli 2024

Waktu	Kelembaban (g/Kg)
01/07/2019	13,73
02/07/2019	13,61
03/07/2019	13,98
...	...
29/06/2024	17,15
30/06/2024	16,85
01/07/2024	–999

Tidak terdapat data yang hilang pada data yang diperoleh. Adapun data pada tanggal 1 Juli 2024 memiliki nilai anomali, sehingga harus dihilangkan.

3. HASIL DAN PEMBAHASAN

Pada bagian ini dibahas mengenai hasil beserta pembahasannya.

3.1. Prediksi Nilai Kelembaban dengan LSTM. LSTM yang digunakan dalam penelitian ini merupakan metode terbaik dari metode LSTM dengan banyak *layer* sebanyak 1, 2, 3, 4, 5, dan 6 serta jumlah *node* 25, 50, 75, dan 100. Kualifikasi metode terbaik dilihat dari nilai RMSE dan MAPE yang diperoleh dari masing-masing elemen.

TABEL 2. Hasil Perhitungan RMSE dan MAPE pada LSTM dengan Berbagai Layer dan Node


Layer	Node	RMSE	MAPE
1	25	0,641	3,224
1	50	0,638	3,111
1	75	0,593	2,929
1	100	0,724	3,635
2	25	0,759	3,887
2	50	0,641	3,168
2	75	0,780	3,901
2	100	0,674	3,297
3	25	0,726	3,644
3	50	0,901	4,709
3	75	0,937	4,935
3	100	0,669	3,326
4	25	0,773	3,869
4	50	0,290	7,105
4	75	0,733	3,664
4	100	0,822	4,173
5	25	0,060	5,500
5	50	0,034	5,416
5	75	0,787	3,949
5	100	0,860	4,358
6	25	0,810	4,038
6	50	0,896	4,596
6	75	0,766	3,847
6	100	0,780	3,902

Pada Tabel 2, hasil perhitungan RMSE dan MAPE diberikan untuk beberapa variasi nilai layer dan node. Berdasarkan RMSE dan MAPE terkecil, metode LSTM terbaik adalah metode dengan 1 layer dan 75 node. Waktu yang digunakan untuk mendapatkan LSTM adalah 3410,316 detik. Grafik LSTM disajikan pada Gambar 4

Skor MAPE yang diperoleh dengan menggunakan metode LSTM terbaik adalah 2,929. Artinya, nilai MAPE kurang 10, sehingga metode ini dikatakan sangat baik dalam mencocokkan data kelembaban. Nilai RMSE dengan metode ini adalah 0,593 dari nilai aktual.

3.2. Prediksi Nilai Kelembaban dengan GRU. Pada bagian ini, dilakukan percobaan numerik untuk menentukan model terbaik menggunakan metode GRU menggunakan layer sebanyak 1, 2, 3, 4, 5, dan 6 dan banyak node 25, 50, 75, dan 100. Kualifikasi metode terbaik dilihat dari nilai metrik evaluasi, yaitu RMSE dan MAPE dengan nilai terkecil.

Tabel 3 mewakili hasil GRU dengan berbagai layer dan node. Berdasarkan RMSE dan MAPE, metode GRU terbaik adalah model dengan total layer 1 dan node 25. Waktu yang



GAMBAR 4. Prediksi nilai kelembaban menggunakan LSTM


TABEL 3. Hasil Perhitungan RMSE dan MAPE pada GRU dengan Berbagai Layer dan Node

Layer	Node	RMSE	MAPE
1	25	0,580	2,831
1	50	0,583	2,845
1	75	0,582	2,840
1	100	0,585	2,858
2	25	0,615	3,020
2	50	0,628	3,093
2	75	0,630	3,111
2	100	0,621	3,050
3	25	0,666	3,281
3	50	0,659	3,254
3	75	0,677	3,358
3	100	0,660	3,260
4	25	0,692	3,451
4	50	0,685	3,404
4	75	0,701	3,509
4	100	0,687	3,431
5	25	0,709	3,536
5	50	0,702	3,509
5	75	0,705	3,518
5	100	0,700	3,500
6	25	0,949	4,600
6	50	0,715	3,583
6	75	0,769	3,813
6	100	0,730	3,645

digunakan untuk mendapatkan model GRU terbaik adalah 2525,489 detik. Berikut adalah grafik model GRU terbaik yang dapat dilihat pada Gambar 5

Nilai MAPE yang diperoleh menggunakan metode GRU adalah 2,831. Artinya, nilai MAPE kurang dari 10, sehingga metode ini termasuk dalam kategori akurasi yang sangat baik dalam mencocokkan data. Nilai RMSE dengan metode ini adalah 0,579 dari nilai aktual.


3.3. Perbandingan Metode LSTM dan GRU. Dalam penelitian ini, metode terbaik dalam hal akurasi untuk memprediksi nilai kelembaban di Kota Bandung ditentukan berdasarkan nilai MAPE dan RMSE terkecil. Di sisi lain, dalam hal efisiensi waktu, kedua metode ini dibandingkan berdasarkan waktu penghentian kode eksekusi program. Sehingga prediksi yang digunakan adalah prediksi terbaik dari segi waktu dan akurat dari segi hasil. Berikut ini adalah ringkasan perbandingan kedua metode yang dapat dilihat pada Tabel 4



GAMBAR 5. Prediksi nilai kelembaban menggunakan GRU

TABEL 4. Perbandingan Performa Model Terbaik LSTM dan GRU

Model Terbaik	Layer	Node	MAPE (%)	RMSE	Waktu Kode Berjalan (detik)
LSTM	1	75	2,929	0,593	3410,316
GRU	1	25	2,831	0,579	2525,489




GAMBAR 6. Grafik perbandingan prediksi nilai kelembaban dengan metode LSTM (Biru) dan GRU (Hijau)

Gambar 6 adalah visualisasi perbandingan hasil prediksi antara metode terbaik LSTM dan GRU. Meskipun metode LSTM menggunakan lebih banyak node, nilai MAPE yang dihasilkan tidak lebih baik dari metode GRU yang hanya 25 node. Dari hasil tersebut, metode GRU dapat mencapai nilai prediksi yang lebih akurat dibandingkan metode LSTM. Hal ini sesuai dengan fakta bahwa nilai MAPE dan RMSE dari metode GRU lebih kecil daripada metode LSTM.

Secara teori, GRU lebih efektif dalam memprediksi kelembaban spesifik karena memiliki struktur yang sederhana, sehingga cocok dengan sifat data meteorologis. Data kelembaban antara tahun 2019 hingga 2024 menunjukkan pola musiman dan tren tahunan yang stabil, sehingga tidak memerlukan model yang kompleks untuk menggambarkan ketergantungan jangka panjang. GRU dengan dua gerbang, yaitu *update* dan *reset gate*, mampu menangkap pola berulang tersebut secara efisien. Sementara itu, LSTM yang memiliki struktur lebih rumit dengan tiga gerbang cenderung kurang optimal. Jumlah parameter yang lebih sedikit pada GRU mengurangi risiko terjadinya *overfitting* dan mempercepat proses konvergensi, sehingga menghasilkan akurasi yang lebih baik (MAPE sebesar 2,831% dibandingkan 2,929%) serta waktu komputasi yang lebih singkat (2525 detik dibandingkan 3410 detik).

3.4. Prediksi Kelembaban dengan Metode Terbaik. Metode terbaik untuk memprediksi nilai kelembaban di kota Bandung adalah GRU dengan *layer* 1 dan *node* 25. Prediksi dibuat untuk memperkirakan nilai kelembaban di Kota Bandung sehingga masyarakat Bandung dapat mempersiapkan kemungkinan nilai kelembaban yang akan terjadi. Berikut ini adalah data

prediksi untuk satu tahun ke depan (1 Juli 2024 hingga 30 Juni 2025) menggunakan metode GRU yang disajikan pada Gambar 7,



GAMBAR 7. Grafik prediksi menggunakan metode GRU terbaik untuk satu tahun ke depan

Gambar 7 menunjukkan prediksi nilai kelembaban kota Bandung menggunakan metode GRU dengan layer 1 dan node 25. Grafik ini menampilkan nilai kelembaban data asli (garis biru) dan prediksi GRU yang berdekatan (garis merah) dalam periode pelatihan. Hal ini menandakan bahwa metode GRU mampu mempelajari pola dengan baik. Setelah itu, prediksi kelembaban untuk 1 Juli 2024 hingga 30 Juni 2025 ditampilkan dengan garis hijau. Hasil ini memberikan gambaran tentang bagaimana kelembaban dapat berubah di masa depan, dengan pola fluktuasi yang konsisten dengan data tren sebelumnya. Hasil prediksi ini diharapkan dapat meningkatkan kesadaran akan kelembaban, khususnya masyarakat Kota Bandung. Dengan mengetahui tren kelembaban di tahun depan, diharapkan pemerintah dan masyarakat dapat melakukan langkah preventif untuk mengantisipasi potensi kekeringan atau lonjakan kelembaban yang dapat mempengaruhi produktivitas dan kesejahteraan masyarakat.

4. SIMPULAN

Kelembaban udara adalah jumlah uap air yang terkandung dalam suatu ruang udara. Kelembaban udara yang tinggi dapat mempengaruhi proses produksi di sektor industri, terutama untuk industri yang sangat bergantung pada kondisi lingkungan seperti tekstil, farmasi, atau makanan. Prediksi nilai kelembaban udara sangat penting untuk pengambilan keputusan di masa depan. Dalam penelitian ini, data kelembaban udara di kota Bandung digunakan sejak 1 Juli 2019 hingga 1 Juli 2024. Metode yang digunakan adalah metode Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Berdasarkan hasil yang diperoleh, metode terbaik adalah metode Gated Recurrent Unit (GRU) dengan banyak layer 1 dan banyak node 25. Karena metode GRU terbaik memiliki nilai MAPE 2,831, RMSE 0,579 dan waktu kode berjalan 2525,489 detik.

DAFTAR PUSTAKA

- [1] Agusmawati, N. K., Khoiriyah, F., & Tholib, A., 2023, Prediksi harga emas menggunakan metode LSTM dan GRU, *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, Volume 11, Issue 3, <https://doi.org/10.23960/jitet.v11i3.3250>.
- [2] Antaranews, 2024, Perubahan kelembaban saat pancaroba timbulkan kerentanan pada penyakit, *Antara News*, <https://www.antaranews.com>.
- [3] Astuti, R., et al., 2023, Pengaruh kelembaban udara terhadap kualitas udara dalam ruangan dan kesehatan manusia, *Jurnal Kesehatan Masyarakat*, Volume 14, Issue 2.
- [4] Badan Pusat Statistik, 2024, Penduduk Kota Bandung berdasarkan kelompok umur dan jenis kelamin, *Badan Pusat Statistik Kota Bandung*, <https://bandungkota.bps.go.id>.
- [5] Cahyania, J., Mujahidin, S., & Fiqara, T. P., 2023, Implementasi metode Long Short Term Memory (LSTM) untuk memprediksi harga bahan pokok nasional, *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, Volume 11, Issue 2, Pages 346-352.

- [6] Carnegie, M. D. A., & Chairani, 2023, Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi curah hujan, *Jurnal Media Informatika Budidarma*, Volume 7, Issue 3. doi:10.30865/mib.v7i3.6213
- [7] Guesmi, M., & Mebarki, N., 2022, Deep learning: Activation functions and their impact on performance, *International Journal of Computer Applications*, Volume 181, Issue 29, Pages 1-9, <https://doi.org/10.5120/ijca2021921857>.
- [8] Lakitan, B., 1994, *Dasar-Dasar Klimatologi*, RajaGrafindo Persada.
- [9] Namini, S. S., Tavakoli, N., & Namin, A. S., 2019, The performance of LSTM and BiLSTM in forecasting time series, Paper presented at the IEEE International Conference on Big Data.
- [10] Rolangon, A., Weku, A., & Sandag, G., 2023, Perbandingan algoritma LSTM untuk analisis sentimen pengguna Twitter terhadap layanan rumah sakit saat pandemi Covid-19, *TeIKa*, Volume 13, Issue 1, Pages 31-40, <https://doi.org/10.36342/teika.v13i01.3063>.
- [11] Sofi, K., Sunge, A. S., Riady, S. R., & Kamalia, A. Z., 2021, Perbandingan algoritma linear regression, LSTM, dan GRU dalam memprediksi harga saham dengan model time series, In 3rd SEMINASTIKA 2021.
- [12] SSE, 2024, Impact of humidity, *SSE*, <https://sse.co.th/impact-of-humidity/>.
- [13] Yadav, S., 2018, Intro to recurrent neural networks LSTM — GRU, Retrieved July 22, 2024, from <https://www.kaggle.com/code/thebrownviking20/intro-to-recurrent-neural-networks-lstm-gru/notebook>.
- [14] Yang, C., Zhai, J., & Tao, G., 2020, Deep learning for price movement prediction using convolutional neural network and long short-term memory, *Mathematical Problems in Engineering*, Volume 2020, Pages 1–13. <https://doi.org/10.1155/2020/2746845>
- [15] Zaman, L., Sumpeno, S., & Hariadi, M., 2019, Analisis kinerja LSTM dan GRU sebagai model generatif untuk tari remo, *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, Volume 8, Issue 2, Pages 142-150.