

PENERAPAN LSTM DAN GRU UNTUK PREDIKSI HARGA CABAI MERAH DI KOTA JAWA TIMUR

Maggie Lim¹, Teny Handayani^{2*}

^{1,2} Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara, Jakarta

Received: 9 Maret 2025
Accepted: 29 Maret 2025
Published: 14 April 2025

Keywords:

Cabai Merah;
Gated Recurrent Unit;
Long Short-Term Memory;
Prediksi Harga.

Correspondent Email:

tenyh@fti.untar.ac.id

Abstrak. Fluktuasi harga cabai merah di Jawa Timur, yang dipengaruhi oleh berbagai faktor seperti musim tanam, cuaca, dan permintaan pasar, menjadi perhatian penting dalam menjaga stabilitas ekonomi. Dalam penelitian ini, digunakan dua algoritma Recurrent Neural Networks (RNN), yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), untuk memprediksi harga cabai merah di Jawa Timur. Pengujian dilakukan dengan menggunakan dua skenario data latih, yaitu 70% dan 80%, dengan jumlah epoch tetap sebanyak 50. Hasil pengujian menunjukkan bahwa LSTM memberikan hasil yang lebih baik pada skenario 80% data latih, dengan nilai Mean Absolute Error (MAE) sebesar 1458,764, Root Mean Squared Error (RMSE) 2596,010, dan koefisien determinasi (R^2) 0,978. Sementara itu, GRU menunjukkan sedikit keunggulan pada 70% data latih, dengan MAE 1742,027, RMSE 2820,462, dan R^2 0,969. Secara keseluruhan, LSTM lebih optimal pada jumlah data latih yang lebih besar, sedangkan GRU lebih stabil pada data latih yang lebih kecil. Penelitian ini menyarankan pemilihan algoritma berdasarkan jumlah data latih yang tersedia untuk prediksi harga cabai merah yang lebih akurat.

Abstract. The price fluctuation of red chili in East Java, influenced by various factors such as planting seasons, weather, and market demand, is a critical concern in maintaining economic stability. This study uses two recurrent neural network (RNN) algorithms, namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), to predict the price of red chili in East Java. The testing was conducted using two training data scenarios, 70% and 80%, with a fixed number of epochs of 50. The results showed that LSTM performed better with the 80% training data scenario, with a Mean Absolute Error (MAE) of 1458.764, Root Mean Squared Error (RMSE) of 2596.010, and a coefficient of determination (R^2) of 0.978. Meanwhile, GRU showed a slight advantage with the 70% training data scenario, with MAE of 1742.027, RMSE of 2820.462, and R^2 of 0.969. Overall, LSTM is more optimal with a larger amount of training data, while GRU performs more stably with smaller training data. This study suggests selecting the appropriate algorithm based on the available training data to achieve more accurate red chili price predictions.

1. PENDAHULUAN

Jawa Timur adalah salah satu provinsi yang terletak di bagian timur Pulau Jawa, Indonesia. Dengan luas wilayah yang mencakup berbagai jenis topografi, mulai dari dataran rendah

hingga pegunungan, provinsi ini memiliki peran yang penting dalam perekonomian di negara Indonesia. Berdasarkan data dari Badan Pusat Statistik Jawa Timur (BPS), jumlah penduduk provinsi ini pada tahun 2022 mencapai sekitar

41.149.974 jiwa, menjadikannya salah satu provinsi dengan populasi terbesar di Indonesia [1]. Keberagaman sumber daya alam dan demografis ini turut mendukung posisi strategis Jawa Timur sebagai pusat ekonomi dan perdagangan, baik di tingkat regional maupun nasional.

Secara geografis, Jawa Timur memiliki iklim tropis. Terdapat dua musim, yaitu musim hujan dari Oktober hingga Maret dan musim kemarau dari April hingga September [2]. Kondisi iklim ini memengaruhi pola pertanian di wilayah ini, terutama dalam menentukan masa tanam dan panen berbagai komoditas pertanian [3]. Jawa Timur dikenal sebagai salah satu lumbung pangan utama Indonesia, dengan komoditas unggulan seperti padi, jagung, cabai merah, dan bawang merah. Cabai merah, khususnya, merupakan bahan utama dalam masakan tradisional Indonesia, menjadikannya komoditas penting dengan permintaan yang tinggi sepanjang tahun [4].

Harga cabai merah di Jawa Timur, seperti di wilayah lainnya, dipengaruhi oleh berbagai faktor, seperti musim tanam, masa panen, serta momen tertentu seperti hari raya keagamaan yang memicu lonjakan permintaan [5] [6]. Fluktuasi harga cabai merah juga dipengaruhi oleh faktor-faktor eksternal lainnya, termasuk kebijakan pemerintah, cuaca ekstrem, dan biaya distribusi yang dapat mempengaruhi pasokan ke pasar [7]. Kenaikan harga cabai merah tidak hanya berimbas pada inflasi, namun memengaruhi daya beli masyarakat, terutama mereka yang berada di bawah garis kemiskinan [8]. Oleh karena itu, analisis dan prediksi harga cabai merah secara regional sangat penting.

Penelitian ini bertujuan menerapkan model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk memprediksi harga cabai merah di Jawa Timur menggunakan data historis dari Januari 2020 hingga November 2024. Model tersebut dibandingkan untuk mengevaluasi keakuratan prediksinya, sehingga dapat merekomendasikan model terbaik yang diharapkan mampu mendukung pengelolaan stabilitas harga pangan.

2. TINJAUAN PUSTAKA

Long Short-Term Memory (LSTM)

Salah satu jenis jaringan saraf tiruan berbasis Recurrent Neural Network (RNN) adalah Algoritma Long Short-Term Memory (LSTM). LSTM diciptakan untuk menyelesaikan masalah vanishing gradient pada set data berulang. [9]. LSTM menggunakan mekanisme gating yang terdiri dari tiga komponen utama yaitu input gate, forget gate, dan output gate. Input gate menyaring informasi baru yang akan disimpan, forget gate membuang informasi yang tidak relevan, dan output gate mengontrol informasi yang akan diteruskan ke hidden state berikutnya [10]. Pendekatan ini memungkinkan LSTM untuk menyimpan informasi jangka panjang dan melupakan informasi yang tidak berguna.

LSTM bekerja dengan memproses data urut waktu (time series) dalam bentuk window tertentu untuk memprediksi nilai di masa depan, seperti harga cabai merah pada hari mendatang. Data sebelumnya digunakan untuk menginformasikan prediksi nilai saat ini dengan mempertahankan pola temporal yang kompleks. Ini menjadikan LSTM sangat efektif dalam menangani masalah prediksi pada data yang dipengaruhi oleh faktor-faktor musiman dan fluktuasi pasar [11]. Rumus LSTM dapat dilihat pada persamaan (1-5).

$$i_t = \sigma(W_i \cdot [h_t - 1, x_t] + b_i) \quad (1)$$

$$f_t = \sigma(W_f \cdot [h_t - 1, x_t] + b_f) \quad (2)$$

$$o_t = \sigma(W_o \cdot [h_t - 1, x_t] + b_o) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$h_t = o_t * \tanh(C_t) \quad (5)$$

Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) adalah jenis jaringan saraf tiruan berbasis Recurrent Neural Network (RNN) yang digunakan untuk menangani data time series [12]. GRU dikembangkan sebagai alternatif lebih sederhana dari Long Short-Term Memory (LSTM) dengan menggunakan dua gate utama yaitu reset gate dan update gate [13]. Reset gate mengontrol informasi mana yang perlu dilupakan dari waktu sebelumnya, sementara update gate menentukan seberapa banyak

informasi baru yang akan dimasukkan ke dalam status saat ini [14]. Selain itu, masalah hilangnya gradien (vanishing gradient) dapat diatasi dengan baik dengan GRU [15]. Pendekatan ini memungkinkan GRU untuk menangkap hubungan jangka panjang dan jangka pendek tanpa memerlukan struktur memory cell seperti LSTM.

Jika dibandingkan dengan LSTM, GRU memiliki lebih sedikit parameter, menjadikannya lebih cepat dalam pelatihan dan lebih efisien untuk dataset kecil, dengan risiko overfitting yang lebih rendah [16] [17]. Meskipun lebih sederhana, GRU tetap dapat memberikan hasil yang kompetitif dalam prediksi time series, termasuk peramalan harga komoditas seperti cabai merah. Rumus GRU data dilihat pada persamaan (6-9).

$$z_t = \sigma(W_z \cdot [h_t - 1, x_t] + b_z) \quad (6)$$

$$r_t = \sigma(W_r \cdot [h_t - 1, x_t] + b_r) \quad (7)$$

$$\hat{h}_t = \tanh(W_h \cdot [r_t * h_{t-1}, x_t] + b_h) \quad (8)$$

$$h_t = (1 - z_t) * \hat{h}_t + z_t * h_{t-1} \quad (9)$$

Mean Absolute Error (MAE)

Metode untuk mengukur tingkat akurasi model dalam melakukan peramalan atau forecasting adalah Mean Absolute Error (MAE) [18]. Nilai Mean Absolute Error yang lebih rendah menunjukkan bahwa hasil prediksi semakin mendekati nilai sebenarnya [19]. MAE dinyatakan melalui rumus berikut:

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

Di mana n mewakili jumlah data, f_i adalah nilai hasil prediksi, dan y_i merupakan nilai aktual. MAE memberikan gambaran rata-rata besarnya kesalahan absolut yang terjadi, sehingga menjadi metrik evaluasi yang intuitif dan mudah diinterpretasikan.

Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah metode yang digunakan untuk mengukur perbedaan antara nilai prediksi yang dihasilkan oleh model dan nilai yang diamati. RMSE cocok digunakan ketika terdapat outlier yang perlu dideteksi [20]. Nilai RMSE memiliki rentang 0 hingga ∞ [21]. Semakin rendah nilai RMSE, semakin tinggi akurasi model dalam melakukan peramalan atau forecasting. Rumus

RMSE dapat dilihat pada persamaan 11, di mana n merupakan jumlah data, Y_t adalah nilai aktual, dan $\hat{Y}_t$ adalah nilai hasil prediksi [22].

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (11)$$


R-Squared (R^2)

R-Squared (R^2) adalah proporsi varians dalam variabel dependen yang dapat dijelaskan oleh variabel independen [23]. R-Squared digunakan untuk mengevaluasi sejauh mana suatu model mampu memprediksi hasil. Nilai koefisien determinasi berkisar antara 0 dan 1, dimana nilai 0 mewakili tingkat terendah, sedangkan nilai 1 menunjukkan tingkat tertinggi [24]. Rumus R-Squared dapat dilihat pada persamaan 7, di mana m merupakan jumlah data, X_i adalah nilai aktual, Y_i adalah nilai prediksi, dan $\bar{Y}$ adalah nilai rata-rata dari Y_i .

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (12)$$

3. METODE PENELITIAN

Penelitian ini bertujuan untuk memprediksi harga cabai merah di Provinsi Jawa Timur menggunakan metode Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Data yang digunakan merupakan harga cabai merah (dalam rupiah), dengan periode data dari Januari 2020 hingga November 2024, yang diperoleh dari situs Bank Indonesia <https://www.bi.go.id/hargapangan/TabelHarga/PedagangBesarDaerah>. Data ini melalui beberapa tahapan, seperti preprocessing untuk menangani data yang hilang (missing values) [25], normalisasi menggunakan Min-Max Scaling, serta pembagian data menjadi training serta testing. Tujuan dari proses ini adalah untuk memastikan bahwa data yang digunakan berkualitas tinggi dan siap untuk diproses oleh model prediksi. Diagram alur dari penelitian dapat dilihat pada Gambar 1.




Gambar 1 Diagram Alir Penelitian

Model LSTM dan GRU dilatih menggunakan data pelatihan dengan parameter tertentu yang disesuaikan untuk mengoptimalkan kinerja prediksi. Hasil prediksi model kemudian diuji menggunakan data pengujian dan dikembalikan ke skala aslinya (denormalisasi) agar lebih mudah diinterpretasikan. Metrik evaluasi yang digunakan untuk menilai kinerja model meliputi Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan R-squared (R^2). MAE mengukur rata-rata selisih absolut antara nilai aktual dan prediksi. RMSE mengukur akar kuadrat dari rata-rata selisih kuadrat antara nilai aktual dan prediksi, sedangkan R^2 digunakan untuk mengukur seberapa baik model menjelaskan variasi pada data. Hasil evaluasi ini akan digunakan untuk menentukan algoritma terbaik antara LSTM dan GRU dalam memprediksi harga cabai merah.


4. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil pengujian serta perbandingan antara dua model yang digunakan dalam penelitian ini, yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), dalam memprediksi harga cabai merah di Jawa Timur. Pengujian dilakukan dengan


berbagai variasi ukuran data latih dan unit model untuk memperoleh hasil yang optimal.




Gambar 2 Grafik data aktual vs data training eksperimen ke-1




Gambar 3 Grafik data aktual vs data training eksperimen ke-2




Gambar 4 Grafik data aktual vs data training eksperimen ke-3




Gambar 5 Grafik data aktual vs data training eksperimen ke-4




Gambar 8 Grafik data aktual vs data training eksperimen ke-7




Gambar 6 Grafik data aktual vs data training eksperimen ke-5




Gambar 9 Grafik data aktual vs data training eksperimen ke-8



Gambar 7 Grafik data aktual vs data training eksperimen ke-6



Gambar 10 Grafik data aktual vs data training eksperimen ke-9



Gambar 11 Grafik data aktual vs data training eksperimen ke-10

Tabel 1 menunjukkan hasil pengujian algoritma LSTM dengan berbagai kombinasi data latih dan unit model. Pengujian ini dilakukan dengan dua skenario, yaitu menggunakan 70% dan 80% data latih untuk melatih model, dengan jumlah epoch tetap sebanyak 50. Hasil ini menunjukkan bahwa model dengan unit 64 dan 80% data latih memberikan hasil terbaik dengan nilai MAE dan RMSE yang lebih rendah, serta nilai R^2 yang lebih tinggi, menunjukkan akurasi yang lebih baik. Hal ini menunjukkan bahwa penggunaan lebih banyak data latih dapat meningkatkan kemampuan model dalam memprediksi harga cabai merah.

Tabel 1 Hasil Pengujian Algoritma LSTM

Data Latih	Eksperimen ke	Model Unit	Epoch	MAE	RMSE	R^2
70%	1	32	50	1178,032	2481,215	0,976
	2	64	50	971,023	2423,177	0,977
	3	128	50	1512,334	2596,618	0,973
	4	256	50	3247,767	3765,681	0,944
	5	512	50	2079,625	2868,153	0,967
80%	6	32	50	1328,388	2618,292	0,977
	7	64	50	958,971	2457,530	0,980
	8	128	50	1838,431	2695,217	0,976
	9	256	50	1522,068	2637,050	0,977
	10	512	50	1645,961	2571,963	0,978

Tabel 2 Hasil Pengujian Algoritma GRU

Data Latih	Eksperimen ke	Model Unit	Epoch	MAE	RMSE	R^2
70%	1	32	50	1457,447	2749,775	0,970
	2	64	50	1791,769	2808,339	0,969
	3	128	50	1344,816	2661,791	0,972
	4	256	50	2062,414	2976,409	0,965
	5	512	50	2053,690	2905,996	0,967
80%	6	32	50	1098,141	2660,817	0,977
	7	64	50	1154,124	2645,193	0,977
	8	128	50	2264,752	3181,245	0,967
	9	256	50	2204,769	3162,978	0,967
	10	512	50	1517,225	2691,704	0,976

Tabel 3 Rata-rata Algoritma LSTM dan GRU

Data Latih	Metode	MAE	RMSE	R ²
70%	LSTM	1797,756	2826,969	0,967
	GRU	1742,027	2820,462	0,969
80%	LSTM	1458,764	2596,010	0,978
	GRU	1647,802	2868,387	0,973

Tabel 2 menunjukkan hasil pengujian untuk algoritma GRU dengan kondisi serupa, menggunakan variasi data latih dan unit model. Model GRU juga diuji dengan dua skenario data latih, yaitu 70% dan 80%, dan dilatih dengan 50 epoch. Dari hasil ini, terlihat bahwa model GRU dengan unit 64 dan data latih 80% juga memberikan hasil yang cukup baik, meskipun secara umum, nilai MAE dan RMSE sedikit lebih tinggi dibandingkan LSTM. Meskipun demikian, GRU masih menunjukkan kinerja yang kompetitif dengan nilai R² yang cukup tinggi, yang menunjukkan kemampuannya dalam memprediksi harga cabai merah.

Tabel 3 menunjukkan rata-rata hasil pengujian algoritma LSTM dan GRU dengan dua skenario penggunaan data latih, yaitu 70% dan 80%. Secara umum, algoritma GRU memiliki nilai MAE yang lebih rendah dibandingkan LSTM pada data latih 70%, tetapi LSTM menunjukkan performa lebih baik dengan MAE dan RMSE yang lebih rendah serta nilai R² yang lebih tinggi pada data latih 80%. Hasil ini menunjukkan bahwa LSTM cenderung lebih optimal ketika jumlah data latih lebih besar, sedangkan GRU menunjukkan kinerja yang kompetitif pada skenario dengan data latih yang lebih kecil.

5. KESIMPULAN

Kesimpulannya, berdasarkan hasil pengujian yang dilakukan pada algoritma LSTM dan GRU dengan dua skenario data latih 70% dan 80%, kedua algoritma memiliki kelebihan dan kekurangan yang bergantung pada jumlah data latih yang digunakan. Pada skenario 80% data latih, LSTM menunjukkan performa yang lebih baik dengan nilai MAE sebesar 1458,764, RMSE 2596,010, dan R² 0,978, yang menunjukkan akurasi prediksi yang lebih baik dibandingkan GRU, yang memiliki

MAE 1647,802, RMSE 2868,387, dan R² 0,973. Sebaliknya, pada 70% data latih, GRU sedikit lebih unggul dengan MAE 1742,027, RMSE 2820,462, dan R² 0,969, meskipun perbedaan ini tidak signifikan dibandingkan LSTM yang menghasilkan MAE 1797,756, RMSE 2826,969, dan R² 0,967. Secara umum, LSTM lebih optimal ketika jumlah data latih yang digunakan lebih banyak, sementara GRU memberikan kinerja yang lebih stabil pada data latih yang lebih sedikit. Pemilihan algoritma yang tepat harus disesuaikan dengan jumlah data latih yang tersedia dan tujuan akurasi yang diinginkan dalam aplikasi prediksi harga cabai merah.

UCAPAN TERIMA KASIH

DAFTAR PUSTAKA

- [1] M. K. Sholihin, "Pengaruh Upah Minimum Dan Tingkat Pengangguran Terhadap Jumlah Penduduk Miskin Di Provinsi Jawa Timur," *GEMAH RIPAH: Jurnal Bisnis*, vol. 1, no. 01, pp. 1–7, Dec. 2021, Accessed: Nov. 29, 2024. [Online]. Available: <https://aksiologi.org/index.php/gemahripah/article/view/134>
- [2] B. Sayaka, N. Wahida, T. Sudaryanto, and S. Wahyuni, "Upaya Petani Dan Pemerintah Menghadapi Bencana Kekeringan," *Forum penelitian Agro Ekonomi*, vol. 40, no. 1, p. 25, Dec. 2022, doi: 10.21082/fae.v40n1.2022.25-38.
- [3] A. Hidayat, "Dampak Perubahan Iklim Terhadap Pertanian Dan Strategi Adaptasi Yang Diterapkan Oleh Petani," May 2023, doi: 10.31219/OSF.IO/MW5GE.
- [4] S. A. Wulandari, "Fluktuasi Harga Cabai Merah Di Masa Pandemi Covid 19 Di Kota Jambi," *Jurnal MeA (Media Agribisnis)*, vol. 5, no. 2, pp. 112–120, Oct. 2020, Accessed: Nov. 29, 2024. [Online]. Available:

- <https://mea.unbari.ac.id/index.php/MEA/article/view/82>
- [5] B. G. Hendratri, J. Iswanto, A. Tohawi, Subekan, and A. Y. Dianto, "Pengaruh Fluktuasi Harga Cabai Rawit dan Dampaknya pada Daya Beli Konsumen di Pasar Wage Nganjuk.," *Jurnal Kolaboratif Sains*, vol. 6, no. 11, pp. 1595–1600, Nov. 2023, doi: 10.56338/JKS.V6I11.4651.
 - [6] M. R. Susila, "Pengaruh Hari Raya Idul Fitri Terhadap Inflasi Di Indonesia Dengan Pendekatan Arimax (Variasi Kalender)," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 14, no. 3, pp. 369–378, Oct. 2020, doi: 10.30598/BAREKENGVOL14ISS3PP369-378.
 - [7] A. M. Windhy and A. S. Jamil, "Peramalan Harga Cabai Merah Indonesia: Pendekatan ARIMA," *AGRIEKSTENSIA : Jurnal Penelitian Terapan Bidang Pertanian*, vol. 20, no. 1, pp. 90–106, Jul. 2021, doi: 10.34145/AGRIEKSTENSIA.V20I1.1502.
 - [8] A. N. Putri and A. K. Wardhani, "Penerapan Metode Single Moving Average Untuk Peramalan Harga Cabai Rawit Hijau," *Indonesian Journal of Technology, Informatics and Science (IJTIS)*, vol. 2, no. 1, pp. 37–40, Dec. 2020, Accessed: Nov. 29, 2024. [Online]. Available: <https://jurnal.umk.ac.id/index.php/ijtis/article/view/5653>
 - [9] A. Winata, M. D. Lauro, and T. Handhayani, "Analysis and Prediction of Foodstuffs Prices in Tasikmalaya Using ELM and LSTM," *Sistemasi: Jurnal Sistem Informasi*, vol. 12, no. 3, pp. 874–887, Sep. 2023, doi: 10.32520/STMSI.V12I3.3145.
 - [10] H. Yurdoğlu and Ö. Güleç, "A Case Study For Preventing Electricity Over-Consumption Using Deep Learning In Textile Industry," *Journal of Engineering Sciences and Design*, vol. 11, no. 4, pp. 1383–1397, Dec. 2023, doi: 10.21923/JESD.1308899.
 - [11] H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, "Predicting stock market index using LSTM," *Machine Learning with Applications*, vol. 9, p. 100320, Sep. 2022, doi: 10.1016/J.MLWA.2022.100320.
 - [12] T. Handhayani, C. Tanudy, and J. Hendryli, "Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit," *JURNAL FASILKOM*, vol. 13, no. 3, pp. 480–488, Dec. 2023, doi: 10.37859/JF.V13I3.6185.
 - [13] M. Oni, M. D. Lauro, A. Winata, and T. Handhayani, "Analysis And Forecasting of Foodstuffs Prices in Bandung Using Gated Recurrent Unit," *Jurnal Esensi Infokom : Jurnal Esensi Sistem Informasi dan Sistem Komputer*, vol. 7, no. 2, pp. 15–21, Oct. 2023, doi: 10.55886/INFOKOM.V7I2.651.
 - [14] A. Lawi, H. Mesra, and S. Amir, "Implementation of Long Short-Term Memory and Gated Recurrent Units on grouped time-series data to predict stock prices accurately," *J Big Data*, vol. 9, no. 1, pp. 1–19, Dec. 2022, doi: 10.1186/S40537-022-00597-0/FIGURES/16.
 - [15] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "Prediksi Harga Emas Menggunakan Metode LSTM Dan GRU," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/JITET.V11I3.3250.
 - [16] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. ETP, "Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 7, no. 2, p. 133, Aug. 2021, doi: 10.26418/JP.V7I2.47411.
 - [17] S. Nosouhian, F. Nosouhian, and A. Kazemi Khoshouei, "A Review of Recurrent Neural Network Architecture for Sequence Learning: Comparison between LSTM and GRU," Jul. 2021, doi: 10.20944/PREPRINTS202107.0252.V1.
 - [18] T. O. Hodson, "Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not," *Geosci Model Dev*, vol. 15, no. 14, pp. 5481–5487, Jul. 2022, doi: 10.5194/GMD-15-5481-2022.
 - [19] A. A. Suryanto and A. Muqtadir, "Penerapan Metode Mean Absolute Error (MEA) Dalam Algoritma Regresi Linear Untuk Prediksi Produksi Padi," *SAINTEKBU*, vol. 11, no. 1, pp. 78–83, Feb. 2019, doi: 10.32764/SAINTEKBU.V11I1.298.
 - [20] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput Sci*, vol. 7, pp. 1–24, Jul. 2021, doi: 10.7717/PEERJ-CS.623/SUPP-1.
 - [21] R. Ahmed, V. Sreeram, Y. Mishra, and M. D. Arif, "A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization," *Renewable and Sustainable Energy Reviews*, vol. 124, p. 109792, May 2020, doi: 10.1016/J.RSER.2020.109792.
 - [22] M. Čalasan, S. H. E. Abdel Aleem, and A. F. Zobaa, "On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function," *Energy Convers Manag*, vol. 210, p. 112716, Apr.

- 2020, doi:
10.1016/J.ENCONMAN.2020.112716.
- [23] F. Rustam *et al.*, “COVID-19 Future Forecasting Using Supervised Machine Learning Models,” *IEEE Access*, vol. 8, pp. 101489–101499, 2020, doi: 10.1109/ACCESS.2020.2997311.
- [24] J. Kaliappan, K. Srinivasan, S. Mian Qaisar, K. Sundararajan, C. Y. Chang, and C. Suganthan, “Performance Evaluation of Regression Models for the Prediction of the COVID-19 Reproduction Rate,” *Front Public Health*, vol. 9, p. 729795, Sep. 2021, doi: 10.3389/FPUBH.2021.729795/BIBTEX.
- [25] G. Huang, “Missing data filling method based on linear interpolation and lightgbm,” *J Phys Conf Ser*, vol. 1754, no. 1, p. 012187, Feb. 2021, doi: 10.1088/1742-6596/1754/1/012187.