

# PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU

Nanda Kurnia Agusmawati<sup>1\*</sup>, Fitwatul Khoiriyah<sup>2</sup>, Abu Tholib<sup>3</sup>

<sup>1,2,3</sup>Universitas Nurul Jadid; Jl. PP Nurul Jadid, Dusun Tj. Lor, Karanganyar, Kec. Paiton, Kabupaten Probolinggo, Jawa Timur 67291; Telp. 08883077077

*Riwayat artikel:*

*Received: 2 Juli 2023*

*Accepted: 30 Juli 2023*

*Published: 1 Agustus 2023*

**Keywords:**

Prediksi, Emas; LSTM; GRU; Metrik Evaluasi.

**Correspondent Email:**

nandakurnia382@gmail.com

© 2023 JITET (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY NC)

**Abstrak.** Prediksi harga emas sangat penting karena menjadi acuan bagi para investor untuk menentukan strategi yang tepat dalam berinvestasi. Tren metode prediksi dalam beberapa tahun terakhir adalah deep learning, yang merupakan subbidang machine learning dan populer dalam menangani masalah prediksi time-series. Dalam penelitian ini, kami membandingkan performa dua metode deep learning, yaitu Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dalam memprediksi harga Emas. Hasil dalam penelitian ini menunjukkan bahwa metode GRU lebih akurat dibanding metode LSTM dalam memprediksi harga Emas, meskipun dalam perhitungan metrik evaluasi didapatkan nilai eror LSTM lebih rendah. Hasil model LSTM terbaik yang diujikan memiliki nilai MAE sebesar 0.0389, RMSE sebesar 0.0475, dan MAPE sebesar 5.2047%, serta model GRU terbaik dari hasil pengujian memiliki nilai MAE 0.0447, RMSE 0.0545, dan MAPE 6.0688%. Dari hasil penelitian ini, kami menemukan bahwa GRU adalah metode yang lebih efektif dan akurat untuk memprediksi harga Emas dibanding LSTM.

**Abstract.** Gold price prediction is critical because it serves as a guide for investors in determining the best investment strategy. Deep learning, a popular subfield of machine learning for dealing with time-series prediction problems, has been a recent trend in prediction methods. In this study, we compared the performance of two deep learning methods in predicting gold prices: Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU). The results of this study show that the GRU method outperforms the LSTM method in predicting gold prices, despite the fact that the LSTM error value is lower when calculating the evaluation metric. The best LSTM model examined had an MAE value of 0.0389, RMSE of 0.0475, and MAPE of 5.2047%, while the best GRU model had an MAE value of 0.0447, RMSE of 0.0545, and MAPE of 6.0688%. According to the results of this study, GRU is a more effective and accurate method for predicting gold prices than LSTM.

## 1. PENDAHULUAN

Emas adalah salah satu jenis logam mulia yang menjadi komoditas berharga di seluruh dunia. Emas menjadi aset yang digunakan dalam produksi perhiasan dan juga aset keuangan karena dapat digunakan sebagai penyimpanan nilai [1]. Banyak orang yang

menjadikan emas untuk melestarikan kekayaan dari generasi ke generasi [2].

Sebagai logam mulia, emas memiliki performa luar biasa yang mampu bertahan di tengah krisis ekonomi dunia, dimana performa produk keuangan lainnya melemah [3]. Akan tetapi, harga emas juga naik turun dan tidak terkendali. Ada banyak faktor yang memengaruhi harga emas, diantaranya adalah

nilai tukar dolar, inflasi, permintaan dan penawaran, serta kebijakan moneter [3], [4]. Dengan perubahan harga emas yang naik turun mengikuti perubahan waktu, mendorong untuk perlu dilakukannya suatu peramalan guna memprediksi harga emas di masa selanjutnya dan menjadi acuan bagi para investor untuk mengambil langkah yang tepat dalam berinvestasi.

Metode prediksi saat ini telah banyak dikembangkan dengan menggunakan machine learning (pembelajaran mesin). Hal ini karena machine learning memiliki performa yang jauh luar biasa dibanding dengan metode tradisional statistik. Salah satu subbagian dari machine learning adalah deep learning, yang telah diterapkan untuk masalah *time-series* dalam berbagai bidang, termasuk dalam prediksi harga [5]–[9]. Dalam penelitian Makala dan Li [4], digunakan model ARIMA dan SVM untuk memprediksi harga emas dan didapatkan hasil bahwa SVM (Poly) ditemukan memiliki kinerja yang jauh lebih baik dibandingkan SVM (RBF) dan model ARIMA lainnya. Pada penelitian lain yang dilakukan oleh Prasetyo, dkk. [10], menggunakan Long Short-Term Memory (LSTM) untuk memprediksi harga emas berdasarkan data dari gold.org, dan digunakan untuk memprediksi harga emas dalam rentang waktu 1-3 hari ke depan. Akan tetapi ditemukan kelemahan, yaitu model yang telah dibangun kurang akurat untuk melakukan prediksi harga emas dalam jangka waktu yang lebih panjang, yaitu 24 hari ke depan.

Setelah dilakukan diskusi terkait latar belakang dan penelitian tersebut, penelitian ini akan berfokus untuk mengukur performa model LSTM dan GRU dalam memprediksi harga emas, dimana keduanya merupakan model deep learning populer saat ini dan merupakan pembaruan dari metode-metode deep learning terdahulu. Nantinya, kedua model tersebut dibandingkan menggunakan tiga metrik evaluasi, yaitu MAE, RMSE, dan MAPE. Penelitian ini bertujuan untuk memperoleh model dengan performa paling baik, sehingga


dapat digunakan dalam prediksi harga emas yang akan datang.

## 2. TINJAUAN PUSTAKA

### a. Long Short-Term Memory (LSTM)

LSTM adalah salah satu arsitektur dari RNN (Recurrent Neural Network) yang dirancang untuk mengatasi permasalahan pada RNN, yaitu ledakan gradien (*exploding gradient*) dan hilangnya gradien (*vanishing gradient*) saat mempelajari data yang disimpan dalam memori jangka panjang. Sehingga LSTM cocok digunakan untuk kasus prediksi dan klasifikasi yang ada hubungannya dengan waktu.

Model LSTM terdiri dari lapisan input (*input layer*), lapisan tersembunyi (*hidden layers*), dan lapisan output (*output layers*). Pada tiap blok terdapat beberapa *memory cell* yang melekat dan tiga unit pengali, yaitu *input*, *output* dan *forget gates*. Dari komponen ini, LSTM berisi tiga *gates* dan sebuah *memory cell* yang mampu melupakan atau menghafal informasi untuk menentukan berapa banyak informasi yang harus ditransfer ke sel berikutnya.



Gambar 1. Arsitektur LSTM

Formula LSTM:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_t, x_t] + b_C) \quad (3)$$

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


$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

### b. Gated Recurrent Unit (GRU)

LSTM memiliki banyak varian, dan Gated Recurrent Unit (GRU) adalah salah satu varian yang populer dari LSTM [11]. GRU

dimunculkan oleh Cho [12] pada tahun 2014. Kelebihan GRU adalah proses komputasi yang lebih sederhana dibanding LSTM, namun memiliki akurasi yang setara dan cukup efektif dalam mengurangi permasalahan hilangnya gradien (*vanishing gradient*) [13]. GRU merupakan sel dengan kandungan 2 gate dan 3 fungsi aktivasi. Gate dan fungsi yang minim ini akan mempercepat proses pengolahan data yang umumnya sangat besar, sehingga kemampuan GRU dirancang untuk menjadi lebih baik dari LSTM terutama untuk dataset yang jumlahnya kecil [14].



Gambar 2. Arsitektur GRU

Formula GRU:

$$r = \sigma(W_r \cdot x_t + U_r \cdot h(t-1) + b_r) \tag{1}$$

$$z = \sigma(W_z \cdot x_t + U_z \cdot h(t-1) + b_z) \tag{2}$$

$$\tilde{h} = \tanh(W_h \cdot x_t + r * U_h \cdot h(t-1) + b_h) \tag{3}$$

$$h = z * h(t-1) + (1 - z) * \tilde{h} \tag{4}$$

**c. Evaluation Metrics**

Metrik evaluasi digunakan untuk mengukur performa dari prediksi model. Pada model *time-series*, evaluasi dapat dilakukan dengan menghitung error yang dibuat pada model. Ada beberapa metrik yang dipakai dalam evaluasi model *time-series*, diantaranya adalah Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE) yang akan digunakan dalam penelitian ini.

Pada MAE, setiap nilai diambil nilai absolutnya, sehingga nilai negatif hilang. Untuk evaluasi model peramalan, MAE lebih intuitif dalam memberikan rata-rata error dari keseluruhan data [15].

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


RMSE merupakan besarnya tingkat kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat.

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

MAPE digunakan untuk mengukur nilai error dari prediksi dalam bentuk persentase, dengan menghitung rata-rata nilai absolut dan kemudian dikalikan dengan 100%..

$$MAPE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \times 100\%$$

**3. METODE PENELITIAN**



Gambar 3. Diagram Alur (Flowchart) Penelitian

Alur dari penelitian yang dilakukan yaitu, pada langkah pertama, kami mengumpulkan dataset Daily Gold Price Historical Data dari Kaggle [16]. Setelah itu, dilakukan *preprocessing data* agar data lebih siap untuk dilatih. Data hasil *preprocess* lalu *displit* menjadi data training sebanyak 80% dan data testing sebanyak 20%. Lalu dilakukan training model LSTM dan GRU pada data training dengan beberapa macam *hyperparameter*. Selain itu, performa model juga diukur menggunakan *evaluation metrics*, yaitu MAE, RMSE, dan MAPE. Kemudian, dilakukan evaluasi dan analisis untuk mendapatkan performa model yang paling baik

dan akurat dalam memprediksi harga emas, sehingga model dapat digunakan untuk memprediksi harga emas yang akan datang.

### 3.1 Dataset

Dataset yang digunakan diperoleh dari Kaggle [16], dengan judul Daily Gold Price Historical Data. Data dalam dataset ini adalah data harian mulai dari 4 Januari 2000 hingga 2 September 2022 (8277 hari) dengan total 5703 data. Dataset ini memiliki 7 atribut, yaitu Date, Open, High, Low, Close, Volume, dan Currency.

Tabel 1. Sampel Dataset Emas

Date	Open	High	Low	Close	Volume	Currency
2000-01-04	289.5	289.5	280.0	283.7	21621	USD
2000-01-05	283.7	285.0	281.0	282.1	25448	USD
2000-01-06	281.6	282.8	280.2	282.4	19055	USD
2000-01-07	282.5	284.5	282.0	282.9	11266	USD
2000-01-10	282.4	283.9	281.8	282.7	30603	USD

Tabel di atas menunjukkan sampel dari lima data teratas pada dataset emas. Kolom "Date" adalah tanggal observasi data, kolom "Open" adalah harga pada saat pembukaan di tanggal tersebut, kolom "High" adalah harga tertinggi pada tanggal tersebut, kolom "Low" untuk harga terendah di tanggal tersebut, kolom "Close" untuk harga saat penutupan pasar di tanggal tersebut, kolom "Volume" adalah volume transaksi pada tanggal tersebut, serta kolom "Currency" adalah mata uang pasar yang digunakan untuk observasi data. Fitur yang akan digunakan untuk melatih model dalam penelitian ini adalah atribut "Close".

### 3.2 Preprocessing dan Split Data

Pada tahap *preprocessing* data, dilakukan normalisasi pada data menggunakan MinMax Scaler, dengan tujuan untuk meminimalisir redundansi dan mencegah anomali pada data.

Data yang telah *dipreprocess* kemudian *displit* menjadi data training sebanyak 80% dan data testing sebanyak 20%. Data training digunakan dalam training model, sedangkan data testing digunakan untuk tahap prediksi.

### 3.3 Training Model LSTM dan GRU

Selanjutnya, dilakukan training pada masing-masing model (LSTM dan GRU) menggunakan data training dalam beberapa *hyperparameter* (batch dan epoch). Tujuannya adalah untuk menemukan metode training yang paling baik dengan performa paling bagus. Masing-masing model ditraining dalam dua batch, yaitu batch 32 dan batch 64, dengan epoch sebesar 50, 100, 200, 400, dan 600 pada masing-masing batch.

### 3.4 Model Prediksi dan Hasil Evaluasi Matrik

Setelah proses training pada model selesai, selanjutnya dilakukan prediksi pada model dengan menggunakan data testing. Kemudian, data testing (aktual) dan data hasil prediksi dibandingkan dan diukur nilai erornya menggunakan matrik evaluasi MAE, RMSE, dan MAPE.

### 3.5 Evaluasi dan Analisis

Hasil dari matrik evaluasi kemudian dianalisis dan dipetakan dalam grafik untuk mengetahui model dengan batch dan epoch mana yang memberikan hasil prediksi paling mendekati nilai aktual, serta akan diukur nilai akurasi.

## 4. HASIL DAN PEMBAHASAN

Setelah dilakukan tahapan-tahapan seperti dalam metode penelitian, pada bagian ini akan dipaparkan hasil dari training model dan prediksi yang didapat. Berikut adalah kombinasi *hyperparameter* yang kami gunakan dalam melatih model.

Tabel 2. Kombinasi Penggunaan *Hyperparameter*

No	Batch Size	Epochs	No	Batch Size	Epochs	MAE	RMSE	MAPE
1	32	50	1	32	50	0.048	0.0616	6.1143%
2	32	100	2	32	100	0.0438	0.0556	5.6844%
3	32	200	3	32	200	0.0406	0.0500	5.3637%
4	32	400	4	32	400	0.0389	0.0475	5.2047%
5	32	600	5	32	600	0.0391	0.0476	5.27%
6	64	50	6	64	50	0.1792	0.1983	22.823%
7	64	100	7	64	100	0.0557	0.0713	6.9775%
8	64	200	8	64	200	0.0428	0.0541	5.5788%
9	64	400	9	64	400	0.0409	0.0511	5.3824%
10	64	600	10	64	600	0.0412	0.0510	5.4386%

Variasi kombinasi dari batch size dan epochs di atas diterapkan pada masing-masing model LSTM dan GRU untuk kemudian digunakan untuk melatih data training. Setelah model ditraining, dilakukan evaluasi performa model menggunakan data testing yang dibandingkan dengan hasil prediksi model dengan harga aktual.



Gambar 4. Harga Emas Harian dalam 8277 hari

Gambar 4 menunjukkan data harga emas harian dalam 8277 hari yang dihitung mulai tanggal 4 Januari 2000 sampai 2 September 2022. Untuk mengetahui mana hyperparameter yang paling optimal untuk model LSTM dan GRU, dilakukan eksperimen dengan melatih model menggunakan data harga emas harian yang ditunjukkan pada gambar 4 tersebut. Hasil pengukuran performa model dengan variasi kombinasi hyperparameter yang telah ditentukan, ditunjukkan pada tabel berikut.

Tabel 3. Hasil evaluasi MAE, RMSE, dan MAPE

**LSTM Model**

GRU Model		
MAE	RMSE	MAPE
0.0484	0.0602	6.3139%
0.0447	0.0545	6.0688%
0.0449	0.0548	6.1123%
0.0450	0.0549	6.1207%
0.0450	0.0549	6.1274%
0.1391	0.1573	17.6552%
0.0503	0.0631	6.5006%
0.0449	0.0548	6.1057%
0.0450	0.0549	6.117%
0.0451	0.0552	6.148%

Dari hasil percobaan training model menggunakan dataset harga emas harian dengan kombinasi hyperparameter pada model yang telah ditentukan, ditemukan bahwa model dengan hasil metrik evaluasi terendah didapat oleh model LSTM dengan batch size 32 dan epoch 400, dengan nilai hasil MAE 0.0389, RMSE 0.0475, dan MAPE 5.2047%.




Gambar 5. Nilai Aktual vs Prediksi pada Harga Emas menggunakan LSTM

Pada gambar 5, nilai aktual ditunjukkan dengan garis berwarna merah, dan nilai prediksi LSTM ditunjukkan dengan garis warna biru. Gambar 5 membandingkan harga aktual dan harga prediksi pada data testing emas menggunakan model LSTM dengan batch size 32 dan epoch 400. Nilai metrik evaluasi dari model ini menghasilkan MAE 0.0389, RMSE 0.0475, dan MAPE 5.2047%. Hasil model LSTM ini nantinya akan dibandingkan dengan model GRU yang memprediksi dataset yang sama.



Gambar 6. Nilai Aktual vs Prediksi pada Harga Emas menggunakan GRU

Pada gambar 6, nilai aktual ditunjukkan oleh garis merah dan nilai prediksi dari GRU ditunjukkan oleh garis hijau. Gambar 6 menunjukkan perbandingan harga prediksi Emas dengan harga aktual pada dataset menggunakan model GRU dengan batch size 32 dan epochs 400. Hasil perhitungan metrik evaluasi dari model ini yaitu MAE 0.0450, RMSE 0.0549, dan MAPE 6.1207%. Sebelumnya model LSTM menghasilkan MAE 0.0389, RMSE 0.0475, dan MAPE 5.2047 untuk memprediksi harga Emas menggunakan batch size dan epochs yang sama. Untuk memprediksi harga Emas ini, LSTM memperoleh nilai yang lebih rendah dibanding GRU.



Gambar 7. Nilai Aktual vs Prediksi pada Harga Emas menggunakan LSTM dan GRU

Pada gambar 7, nilai aktual ditunjukkan oleh garis merah, nilai prediksi LSTM ditunjukkan oleh warna biru, dan nilai prediksi GRU ditunjukkan oleh warna hijau. Gambar 7 menunjukkan perbandingan hasil prediksi harga Emas menggunakan model LSTM dan GRU dengan nilai aktual untuk 1081 hari dengan batch size 32 dan epochs 400. Gambar tersebut juga menunjukkan hasil prediksi dari model GRU untuk memprediksi harga 1081 hari lebih baik dari pada model LSTM, yang mana hasil prediksi model GRU lebih mendekati nilai aktual.

No.	Data Test (Aktual)	Prediction Result LSTM	Prediction Result GRU
1.	1290.9	1326.7	1303.6
2.	1292.0	1325.2	1300.4
3.	1289.6	1323.7	1297.9
4.	1304.4	1322.1	1295.9
5.	1303.7	1320.5	1295.4

Berdasarkan percobaan yang telah dilakukan terhadap dataset Emas, kami menemukan bahwa model GRU lebih baik untuk memprediksi harga Emas dibanding LSTM model. LSTM model tidak dapat memberikan nilai harga yang mendekati nilai aktual, walaupun dengan hasil metrik evaluasi yang lebih kecil dibanding GRU. Hasil metrik evaluasi terbaik dari LSTM adalah dari batch 32 dan epochs 400, dengan hasil MAE 0.0389, RMSE 0.0475, dan MAPE 5.2047%. Sedangkan hasil metrik evaluasi terbaik dari GRU diperoleh dari batch size 32 dan epochs 100

dengan hasil MAE 0.0447, RMSE 0.0545, dan MAPE 6.0688%.

## 5. KESIMPULAN

Berdasarkan hasil penelitian yang telah kami lakukan, didapat kesimpulan sebagai berikut.

- a. Setelah dilakukan perbandingan metrik evaluasi dari kedua model, penelitian ini mengindikasikan bahwa model LSTM lebih baik dibanding model GRU dalam memprediksi harga emas dengan hasil metrik evaluasi MAE 0.0389, RMSE 0.0475, dan MAPE 5.2047%, sedangkan model GRU yang memiliki performa paling baik menggunakan batch size 32 dan epochs 100, yang memiliki hasil MAE 0.0447, RMSE 0.0545, dan MAPE 6.0688% pada dataset Emas.
- b. Sedangkan prediksi terburuk dari LSTM adalah pada batch size 64 epoch 50, dengan hasil MAE 0.1792, RMSE 0, 1983, dan MAPE 22.823%. Sedangkan prediksi terburuk LSTM didapat pada batch size 64 dan epoch 50 dengan hasil MAE 0.1391, RMSE 0.1573, dan MAPE 17.6552%.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini, khususnya kepada Bapak Abu Tholib selaku pembimbing, serta teman-teman yang telah mendukung selama penelitian dan penulisan ini.

## DAFTAR PUSTAKA

- [1] S. S. Sharma, "Can consumer price index predict gold price returns?," *Economic Modelling*, vol. 55, pp. 269–278, Jun. 2016, doi: 10.1016/j.econmod.2016.02.014.
- [2] F.-C. Yuan, C.-H. Lee, and C. Chiu, "Using Market Sentiment Analysis and Genetic Algorithm-Based Least Squares Support Vector Regression to Predict Gold Prices.," *IJCIS*, vol. 13, no. 1, p. 234, 2020, doi: 10.2991/ijcis.d.200214.002.
- [3] X. Yang, "The Prediction of Gold Price Using ARIMA Model," in *Proceedings of the 2nd International Conference on Social Science, Public Health and Education (SSPHE 2018)*, Sanya, China: Atlantis Press, 2019. doi: 10.2991/ssphe-18.2019.66.
- [4] D. Makala and Z. Li, "Prediction of gold price with ARIMA and SVM," *J. Phys.: Conf. Ser.*, vol. 1767, no. 1, p. 012022, Feb. 2021, doi: 10.1088/1742-6596/1767/1/012022.
- [5] M. Owen, V. Vincent, R. Br Ambarita, and E. Indra, "Implementasi Metode Long Short Term Memory Untuk Memprediksi Pergerakan Nilai Harga Emas," *Teknikom*, vol. 5, no. 1, p. 96, Jun. 2022, doi: 10.37600/teknikom.v5i1.507.
- [6] M. Yanto, S. Sanjaya, Y. Yulasmi, D. Guswandi, and S. Arlis, "Implementation multiple linear regression in neural network predict gold price," *IJECS*, vol. 22, no. 3, p. 1635, Jun. 2021, doi: 10.11591/ijeecs.v22.i3.pp1635-1642.
- [7] A. Moghar and M. Hamiche, "Stock Market Prediction Using LSTM Recurrent Neural Network," *Procedia Computer Science*, vol. 170, pp. 1168–1173, 2020, doi: 10.1016/j.procs.2020.03.049.
- [8] D. M. Gunarto, S. Sa'adah, and D. Q. Utama, "Predicting Cryptocurrency Price Using RNN and LSTM Method," *SISFOKOM*, vol. 12, no. 1, pp. 1–8, Mar. 2023, doi: 10.32736/sisfokom.v12i1.1554.
- [9] B. Yang, S. Sun, J. Li, X. Lin, and Y. Tian, "Traffic flow prediction using LSTM with feature enhancement," *Neurocomputing*, vol. 332, pp. 320–327, 2019, doi: https://doi.org/10.1016/j.neucom.2018.12.016.
- [10] V. R. Prasetyo, S. Axel, J. T. Soebroto, D. Sugiarto, S. A. Winatan, and S. D. Njudang, "Gold Price Prediction Based on Gold.org Data Using the Long Short Term Memory Method," *SISTEMASI*, vol. 11, no. 3, p. 623, Sep. 2022, doi: 10.32520/stmsi.v11i3.1999.
- [11] B. Prijono, "Pengenalan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) – RNN Bagian 2," *Pengenalan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) – RNN Bagian 2*. <https://indoml.com/2018/04/13/pengenalan-long-short-term-memory-lstm-dan-gated-recurrent-unit-gru-rnn-bagian-2/>
- [12] K. Cho *et al.*, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation." arXiv, Sep. 02, 2014. Accessed: May 15, 2023. [Online]. Available: <http://arxiv.org/abs/1406.1078>
- [13] Y. Karyadi, "Prediksi Kualitas Udara Dengan Metoda LSTM, Bidirectional LSTM, dan

- GRU,” *JATISI*, vol. 9, no. 1, pp. 671–684, Mar. 2022, doi: 10.35957/jatisi.v9i1.1588.
- [14] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. Etp, “Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19,” *JEPIN*, vol. 7, no. 2, p. 133, Aug. 2021, doi: 10.26418/jp.v7i2.47411.
- [15] A. A. Suryanto, “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.
- [16] B. Senkal, “Daily Gold Price Historical Data.” [Online]. Available: <https://www.kaggle.com/datasets/psycon/daily-gold-price-historical-data>