



# Prediksi Harga Emas Dunia Menggunakan Deep Learning GRU dengan Optimasi Nadam

Ismail Saputra R. Harmain<sup>1\*</sup>, Nurwan<sup>2</sup>, Isran K. Hasan<sup>1</sup>, Djihad Wungguli<sup>2</sup>, and Nisky Imansyah Yahya<sup>2</sup>

<sup>1</sup>Program Studi Statistika, Jurusan Matematika, Universitas Negeri Gorontalo, Gorontalo, Indonesia

<sup>2</sup>Program Studi Matematika, Jurusan Matematika, Universitas Negeri Gorontalo, Gorontalo, Indonesia

## Abstrak

Volatilitas harga emas yang tinggi menuntut adanya metode prediksi yang andal untuk mendukung pengambilan keputusan investasi. Penelitian ini mengimplementasikan algoritma *Gated Recurrent Unit* (GRU) berbasis *deep learning* yang dioptimalkan menggunakan *Nesterov-Accelerated Adaptive Moment Estimation* (Nadam) untuk memprediksi harga emas harian. Model terbaik diperoleh dengan nilai *Mean squared Error* (MSE) sebesar 0.00012 pada data univariat dan 0.00027 pada data multivariat. *Mean Absolute Percentage Error* (MAPE) yang diperoleh masing-masing sebesar 1.107% untuk data univariat dan 1.59% untuk data multivariat. Hasil tersebut mengindikasikan bahwa model GRU dengan optimasi Nadam memiliki performa prediksi yang tinggi, baik pada data deret waktu tanpa penambahan fitur maupun dengan penambahan fitur.

**Kata Kunci:** Analisis *Time Series*, *Deep Learning*, emas, GRU, Nadam.

## Abstract

High volatility in gold prices necessitates a reliable prediction method to support investment decision-making. This study implements the Gated Recurrent Unit (GRU) deep learning algorithm, optimized using Nesterov-Accelerated Adaptive Moment Estimation (Nadam), to forecast daily gold prices. The best model was obtained with a Mean squared Error (MSE) value of 0.00012 on univariate data and 0.00027 multivariate data.. The Mean Absolute Percentage Error (MAPE) values were 1.107% for univariate data and 1.59% for multivariate data. These findings suggest that the GRU model with Nadam optimization demonstrates high predictive performance, both on time-series data without additional features and with added features.

**Keywords:** Deep Learning, Gated Recurrent Unit, Gold, Nadam, Time Series Analysis.

Copyright © 2025 by Authors, Published by JRMM Group. This is an open access article under the CC BY-SA License (<https://creativecommons.org/licenses/by-sa/4.0>)

## 1 Pendahuluan

Investasi merupakan kegiatan menanamkan modal pada suatu instrumen finansial atau proyek nyata dengan harapan memperoleh imbal hasil yang lebih tinggi dibandingkan dengan tingkat inflasi [1]. Didunia investasi dan perdagangan, logam mulia emas adalah salah satu komoditas

\*Corresponding author. E-mail: [ismailsaputraharmain@gmail.com](mailto:ismailsaputraharmain@gmail.com)

paling penting di dunia dan memiliki peran penting dalam investasi. Emas juga dianggap sebagai asset investasi yang lumayan stabil sebab cenderung tidak terlalu berpengaruh terhadap fluktuasi ekonomi [2]. Fluktuasi harga emas adalah hal yang wajar, namun investor tetap tertarik karena emas dianggap sebagai aset yang aman dan stabil dalam jangka panjang. Permintaan yang konsisten, terutama saat terjadi ketidakpastian ekonomi, serta kemampuannya sebagai lindung nilai terhadap inflasi, membuat emas menjadi pilihan investasi yang menarik [3]. Terlepas dari keuntungan tersebut perlu diketahui bahwa harga emas sangat volatil. Biaya penyimpanan, serta spread antara harga beli dan jual membuat para investor perlu melakukan analisis teknikal sebelum memutuskan untuk berinvestasi dalam emas [4].

Analisis teknikal adalah sebuah metode peramalan gerak harga saham, indeks atau instrumen keuangan lainnya dengan menggunakan grafik dari data historis (masa lalu) [5]. Contoh dari analisis teknikal sendiri yaitu analisis runtun waktu (*time series*). Berdasarkan tipe datanya *time series* dibagi menjadi dua, yaitu *univariat* dan *multivariat*. *time series univariat* yaitu kumpulan data mengukur satu variabel sedangkan *time series multivariat* adalah kumpulan data yang mengukur beberapa variabel secara simultan pada setiap titik waktu [6]. Analisis *time series* dapat dilakukan dengan menggunakan pendekatan berbasis *Machine learning* dan *deep learning*.

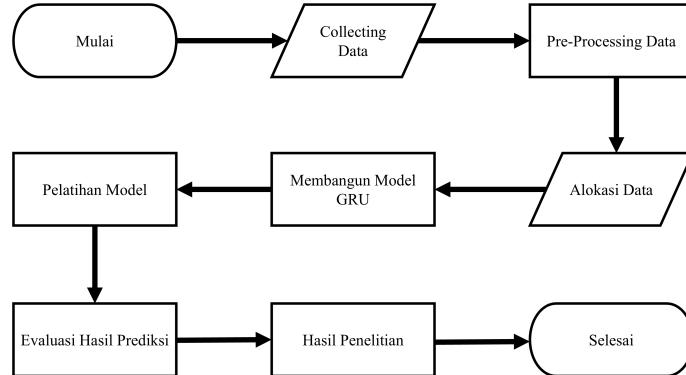
Penelitian terdahulu telah melakukan analisis *time series* berbasis *deep learning* untuk memprediksi harga emas dunia. Penelitian [7] melakukan memprediksi harga emas dengan menggunakan *Radial Basis Function Neural Network* (RBFNN). Namun, hasil pengujian menunjukkan performa yang tidak optimal, yaitu nilai *Mean Squared Error* (MSE) yang relative besar. Hasil ini mengindikasikan bahwa model tersebut memiliki keterbatasan signifikan dalam menghasilkan prediksi yang akurat. Oleh karena itu, diperlukan metode *deep learning* yang lebih unggul untuk memprediksi harga emas. Penelitian lainnya dilakukan oleh [8] telah berhasil membuktikan efektivitas metode *Long Short-Term Memory* (LSTM) dengan optimasi *Nesterov-Accelerated Adaptive Moment Estimation* (Nadam) dalam memprediksi harga komoditas emas. Hasil yang diperoleh menunjukkan performa yang sangat baik, dengan nilai *Mean squared Error* (MSE) sebesar 0,0003 *Root Mean squared Error* (RMSE) sebesar 0,026071 dan *R-squared* sebesar 0,9804 pada data pengujian. Namun, penelitian tersebut belum mengeksplorasi perbandingan dengan arsitektur *deep learning* lain yang juga mumpuni, seperti *Gated Recurrent Unit* (GRU). GRU merupakan varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi permasalahan vanishing gradient. Arsitektur GRU lebih ringkas dibandingkan dengan LSTM, yang juga merupakan modifikasi dari RNN [9]. Secara spesifik, model LSTM menggunakan tiga *gate* (yaitu *input gate*, *forget gate*, dan *output gate*) untuk mengontrol aliran informasi. Sementara itu, model GRU menyederhanakan mekanisme ini dengan hanya menggunakan dua *gate* (*update gate* dan *reset gate*). Meskipun memiliki arsitektur yang lebih sederhana dan jumlah *gate* yang lebih sedikit, namun model GRU mampu memberikan tingkat akurasi prediksi yang setara dengan model LSTM [10]. Penelitian yang paling mendekati yaitu penelitian yang dilakukan oleh [11] yaitu membahas Prediksi Harga Emas Menggunakan Data *Yahoo Finance* menggunakan *deep learning Gated Recurrent Unit* (GRU) dengan optimasi *Adaptive Moment Estimation* (Adam). Hasil penelitian menunjukkan performa yang baik, dengan nilai *Mean Squared Error* (MSE) sebesar 0,0003 dan *Mean Absolute Error* (MAE) sebesar 0,0128. Meskipun model GRU telah terbukti efektif, dalam penelitian tersebut, masih belum melakukan eksplorasi terhadap penggunaan *optimizer* lain yang berpotensi memberikan performa yang lebih baik. Penelitian ini bertujuan untuk menggunakan arsitektur model GRU yang sama, namun dengan fokus pada penggantian dan pengujian *optimizer*. Secara spesifik, penelitian ini akan menguji Nadam (Nesterov-accelerated Adaptive Moment Estimation), sebuah *optimizer* yang merupakan pengembangan dari Adam, dengan harapan dapat mengoptimalkan performa model GRU dalam prediksi harga emas.

Berdasarkan beberapa penelitian sebelumnya yang telah dilakukan untuk memprediksi harga emas. Penelitian ini mengusulkan penggunaan *Gated Recurrent Unit* (GRU) dengan penambahan optimasi *Nesterov-Accelerated Adaptive Moment Estimation* (Nadam). Optimasi Nadam

merupakan pengembangan dari algoritma Adaptive Moment Estimation (ADAM) yang mengintegrasikan komponen momentum dari Nesterov Accelerated Gradient (NAG) [12]. Penambahan optimasi Nadam pada model deep learning mampu memberikan akurasi terbaik dibandingkan optimasi Adam dan Adamax [8]. Sebagai titik awal, hasil dari penelitian [8] dan [11] akan digunakan sebagai tolak ukur dari efektivitas GRU-Nadam. Keterbaruan Penelitian juga akan melakukan analisis *multivariate* dengan menggunakan harga perak dan harga minyak *West Texas Intermediate* (WTI) sebagai fitur tambahan dalam memprediksi harga emas. Penelitian ini diharapkan dapat digunakan pada pendekatan inovatif dalam meramalkan harga emas dengan mengadopsi *deep learning* GRU dan mengoptimalkannya menggunakan algoritma Nadam. Hasil penelitian ini diharapkan memberikan kontribusi baru dalam pengembangan model prediksi berbasis *deep learning* yang lebih akurat dan efisien.

## 2 Metode

Penelitian ini akan melakukan percobaan terhadap proses prediksi GRU dengan menerapkan algoritma Nadam sebagai algoritma optimasi. Alur dari tahapan penelitian ini dapat dilihat pada ilustrasi [Gambar 1](#).



**Gambar 1:** Tahapan penelitian

### 2.1 Pengumpulan Data

Data pada penelitian ini dikumpulkan dari situs Investing.com<sup>1</sup>. Data yang dikumpulkan berupa data history harga Emas harian dengan periode waktu dimulai dari tanggal 04 Januari 2000 sampai dengan 29 November 2024.

### 2.2 Pre-processing Data

Pre-Processing data merupakan tahap awal yang penting dalam menyiapkan data sebelum digunakan dalam perancangan model prediksi. Dalam penelitian ini, proses pra-pemrosesan dilakukan melalui dua tahap, yaitu pembersihan data dan normalisasi menggunakan teknik min-max scaling. Tujuan dari tahapan ini adalah untuk mengurangi tingkat kesalahan saat pengujian model prediktif serta membantu model dalam mengenali pola data secara lebih efisien.. Adapun perhitungan min-max scaling dilakukan dengan [Pers. 1](#).

$$x'_i = \frac{x_i - \min_x}{\max_x - \min_x} \quad (1)$$

<sup>1</sup><https://www.investing.com/commodities/gold-historical-data>

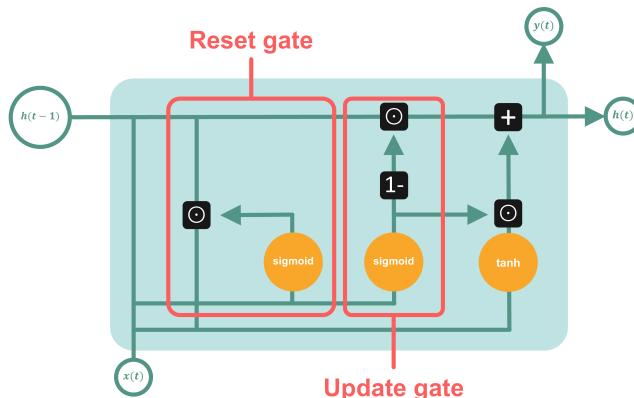
dengan  $x_i$  merupakan data asli yang akan dinormalisasi, sedangkan  $x'_i$  adalah hasil data setelah dilakukan normalisasi. Adapun  $\min_x$  dan  $\max_x$  masing-masing merepresentasikan nilai minimum dan maksimum dari keseluruhan data.

### 2.3 Alokasi Data

Alokasi data pada penelitian ini mengikuti rasio 60:20:20, 70:15:15, dan 80:10:10. Hal ini berarti pada rasio 60:20:20 dataset akan dibagi menjadi 60% data latih, 20% data validasi dan 20% data uji. Hal ini berarti pada rasio 70:15:15 dataset akan dibagi menjadi 70% data latih, 15% data validasi dan 15% data uji. Hal ini berarti pada rasio 80:10:10 dataset akan dibagi menjadi 80% data latih, 10% data validasi dan 10% data uji.

### 2.4 Gated Recurrent Unit

GRU merupakan varian dari *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi permasalahan vanishing gradient. Arsitektur GRU lebih ringkas dibandingkan dengan LSTM, yang juga merupakan modifikasi dari RNN [9]. Sebagai salah satu pengembangan dari *Recurrent Neural Network* (RNN), *Gated Recurrent Unit* (GRU) pertama kali dikemukakan oleh [13]. Algoritma ini sebanding dengan *Long Short-Term Memory* (LSTM), namun dengan arsitektur yang lebih sederhana. GRU mengimplementasikan mekanisme gerbang, yang terdiri dari gerbang pembaruan (*Update Gate*) dan gerbang reset (*Reset Gate*). Gambaran arsitektur GRU dapat dilihat pada [Gambar 7](#).



**Gambar 2:** Arsitektur GRU

Persamaan GRU dapat dilihat pada [Pers. 2](#) sampai [Pers. 5](#) [14]:

$$z_t = \sigma(w^{(z)}x_t + u^{(z)}h_{t-1} + b) \quad (2)$$

$$r_t = \sigma(w^{(r)}x_t + u^{(r)}h_{t-1} + b) \quad (3)$$

$$\tilde{h}_t = \tanh(wx_t + r_t \odot uh_{t-1}) \quad (4)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \tilde{h}_t \quad (5)$$

dengan

$$\sigma = \frac{1}{(1 + e^{-x})}$$

$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

dimana  $x_t$  merupakan vektor input pada waktu ( $t$ ),  $h_t$  adalah vektor output,  $\tilde{h}_t$  merepresentasikan kandidat hidden state,  $z_t$  adalah vektor update gate, dan  $r_t$  merupakan vektor reset gate. Sementara itu,  $w$  dan  $u$  menyatakan matriks bobot,  $b$  adalah vektor bias, serta  $\sigma$  dan  $\tanh$  masing-masing merupakan fungsi aktivasi dengan  $e$  adalah bilangan euler.

## 2.5 Nesterov-accelerated Adaptive Moment Estimation (Nadam)

Nadam merupakan algoritma optimasi yang menggabungkan keunggulan dari Nesterov Accelerated Gradient (NAG) dan Adaptive Moment Estimation (ADAM) [12]. Nadam beroperasi dengan melakukan pembaruan bobot secara adaptif guna meredam fluktuasi gradien, sehingga mampu mempercepat proses pelatihan serta meningkatkan tingkat akurasi model. Adapun algoritma Nadam dapat dilihat pada [Alg. 1](#).

---

**Algoritma 1** Optimisasi nesterov-accelerated adaptive moment estimation (nadam)

---

**Require:**  $\alpha_0, \dots, \alpha_T; \mu_0, \dots, \mu_T; \nu; \epsilon : \text{Hyperparameters}$

$m_0; n_0 \leftarrow 0$ (vektor moment pertama/kedua)

- 1: **while**  $\theta_t$  belum konvergen **do**
  - 2:    $\mathbf{g}_t \leftarrow \nabla_{\theta_{t-1}} f_t(\theta_{t-1})$
  - 3:    $\mathbf{m}_t \leftarrow \mu_t \mathbf{m}_{t-1} + (1 - \mu_t) g_t$
  - 4:    $\mathbf{n}_t \leftarrow \nu \mathbf{n}_{t-1} + (1 - \nu) g_t^2$
  - 5:    $\hat{\mathbf{m}} \leftarrow (\mu_{t+1} \mathbf{m}_t / (1 - \Pi_{i=1}^{t+1} \mu_i)) + ((1 - \mu_t) g_t / (1 - \Pi_{i=1}^t \mu_i))$
  - 6:    $\hat{\mathbf{n}} \leftarrow \nu \mathbf{n}_{t-1} / (1 - \nu^t)$
  - 7:    $\theta_t \leftarrow \theta_{t-1} - \frac{\alpha_t}{\sqrt{\hat{\mathbf{n}}_t + \epsilon}} \hat{\mathbf{m}}_t$
  - 8: **end while**
  - 9: **return**  $\theta_t$
- 

## 2.6 Pelatihan Model

Proses pelatihan akan menggunakan Nadam untuk melakukan estimasi bobot dan bias. Setelah proses pelatihan kemudian akan dipilih model terbaik dari beberapa konfigurasi hyperparameter. Pemilihan model terbaik ditentukan berdasarkan nilai *Mean squared Error* (MSE) terkecil. Adapun perhitungan MSE dapat dilihat pada [Pers. 6](#).

$$MSE = \sum_{t=1}^n \frac{(\hat{Y}_t - Y_t)^2}{n} \quad (6)$$

dengan  $\hat{Y}_t$  adalah data hasil prediksi dan  $Y_t$  merupakan data aktual. Sedangkan  $n$  adalah banyak data.

## 2.7 Evaluasi Hasil Prediksi

Model yang telah mempelajari pola dari data training ini kemudian diuji performanya dengan melakukan prediksi terhadap data latih. Kemudian data hasil prediksi dari model tersebut dilakukan denormalisasi. Adapun denormalisasi dapat dilakukan dengan [Pers. 7](#) [15].

$$x_i = x'_i(\max_x - \min_x) + \min_x \quad (7)$$

dengan  $x_i$  merupakan data asli yang telah didenormalisasikan, sedangkan  $x'_i$  adalah hasil data setelah dilakukan normalisasi. Adapun  $\min_x$  dan  $\max_x$  masing-masing merepresentasikan nilai minimum dan maksimum dari keseluruhan data.

Keluaran dari proses ini adalah harga emas sebelum normalisasi yang selanjutnya akan dievaluasi akurasinya menggunakan Mean Absolute Percentage Error (MAPE) dengan membandingkannya terhadap nilai harga aktual atau data uji. Adapun persamaan yang digunakan untuk menghitung MAPE dapat dilihat pada Pers. 8 [16].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (8)$$

dengan  $\hat{Y}_t$  adalah data hasil prediksi dan  $Y_t$  merupakan data aktual. Sedangkan  $n$  adalah banyak data. Nilai MAPE dapat diinterpretasikan kedalam beberapa kriteria yang dapat dilihat pada tabel 1.

**Tabel 1:** Kriteria Nilai MAPE

Hasil MAPE	Kriteria
< 10%	Hasil peramalan sangat baik
10% – 20%	Hasil peramalan baik
20% – 50%	Hasil peramalan cukup baik
> 50%	Hasil peramalan buruk

## 2.8 Lingkungan Pemrograman

Seluruh tahapan analisis data serta visualisasi menggunakan *tools Google Collaboratory* dan Bahasa pemrograman *python* dengan detail spesifikasi pada tabel 2.

**Tabel 2:** Spesifikasi Sistem

Perangkat Lunak	Spesifikasi
Browser	Google Chrome
Tools	Google Collaboratory
Bahasa Pemrograman	Python 3.11.13
Framework	Tensorflow 2.19.0
API	Keras 3.10.0
Library	Pandas 2.2.2 Numpy 2.0.2 Matplotlib 3.10.5 Scikit-learn 1.7.1

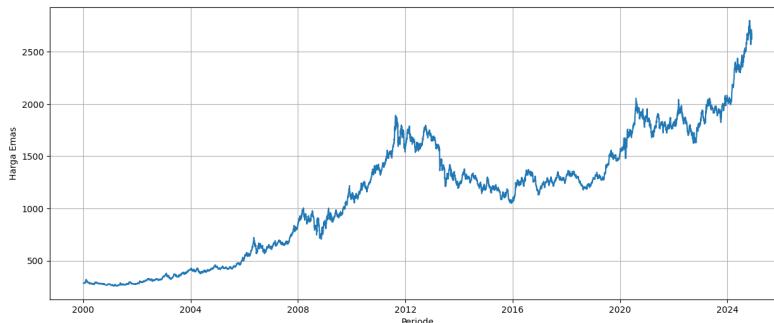
## 3 Hasil dan Pembahasan

Data harga emas yang diunduh berjumlah 8847 baris data, dengan kolom-kolom yang mencakup “Date”, “Price”, “Open”, “High”, “Low”, dan “Change%”. Dalam penelitian ini, hanya kolom “Date” dan “Price” yang akan digunakan. Set data penelitian dapat dilihat pada gambar 3.

Tahap awal ini melibatkan pembersihan dataset yang masih dalam format aslinya. Proses *cleaning* data dalam penelitian ini difokuskan untuk urutan data yang konsisten dalam skala harian, dengan mempertahankan data hanya untuk lima hari kerja dalam seminggu. Untuk mengatasi data yang hilang pada hari Sabtu, Minggu, atau hari kerja kosong lainnya, nilai harga akan diimputasi menggunakan harga pada hari kerja sebelumnya (*forward fill*). Dataset harga emas yang siap digunakan pada penelitian ini sebanyak 6499 baris data, dengan periode waktu dimulai dari tanggal 04 Januari 2000 sampai dengan 29 November 2024. Data tersebut selanjutnya disajikan dalam bentuk Plot *time series* pada gambar 3.

**Tabel 3:** Dataset Harga Emas

Date	Price	Open	High	Low	Vol.	Change%
29/11/2024	2,681.0	2,660.6	2,690.5	2,644.1	180.76K	0.61%
27/11/2024	2,664.8	2,658.3	2,683.4	2,652.2	169.46K	1.15%
26/11/2024	2,634.4	2,638.7	2,655.5	2,618.5	2.72K	0.14%
25/11/2024	2,630.6	2,728.0	2,735.5	2,629.5	2.57K	-3.46%
22/11/2024	2,724.9	2,683.6	2,728.3	2,683.6	0.82K	1.41%
⋮	⋮	⋮	⋮	⋮	⋮	⋮
01/11/2000	284.4	282.4	285.3	281.9	13.50K	0.60%
01/10/2000	282.7	282.4	283.9	281.8	30.60K	-0.07%
01/07/2000	282.9	282.5	284.5	282.0	11.27K	0.18%
01/06/2000	282.4	281.6	282.8	280.2	19.06K	0.11%
01/05/2000	282.1	283.7	285.0	281.0	25.45K	-0.56%
01/04/2000	283.7	289.5	289.5	280.0	21.62K	-2.04%



**Gambar 3:** Plot Time series Pergerakan Harga Emas Januari 2000-November 2024

Plot Harga emas di atas mengindikasikan adanya tren kenaikan harga emas dalam jangka panjang. Namun jika diamati lebih detail, harga emas setiap bulannya menunjukkan fluktuasi yang cukup signifikan, mengindikasikan volatilitas harga dalam jangka pendek.

Data tersebut kemudian dialokasikan menjadi data latih, data validasi, dan data uji pada masing masing rasio pembagian data. Data latih akan digunakan model untuk mempelajari pola data. Data validasi akan digunakan saat proses training dan akan menjadi tolak ukur apakah model mengalami *overfitting* dan *underfitting* dan digunakan untuk menentukan model terbaik berdasarkan nilai MSE terkecil. Sedangkan data uji akan digunakan untuk menguji akurasi prediksi model. Adapun hasil pembagian data set dapat dilihat pada tabel 4.

**Tabel 4:** Hasil Alokasi Data

Alokasi	Data latih	Data validasi	Data Uji
60:20:20	3913	1293	1293
70:15:15	4559	970	970
80:10:10	5207	646	646

Model GRU yang digunakan dalam penelitian ini terdiri dari empat lapisan, yaitu satu lapisan input, dua lapisan tersembunyi, dan satu lapisan *dense* (output). Lapisan output akan memiliki satu neuron, sementara jumlah *neuron* atau *unit* pada tiga lapisan lainnya mengikuti yang tertera pada tabel 5. Adapun *time step* yang diterapkan dalam penelitian ini adalah sebanyak 5, yang berarti model akan memanfaatkan 5 data sebelumnya untuk memprediksi nilai data berikutnya. Saat proses pelatihan, penelitian ini menggunakan *batch size* sebanyak 32, 64, dan 128, serta menggunakan *epoch* sebanyak 100. Lebih jelasnya konfigurasi model dapat dilihat pada tabel 5.

**Tabel 5:** Konfigurasi Hyperparameter

<i>Hyperparameter</i>	Banyak
<i>Layer</i>	4
<i>Neuron/Unit</i>	32; 64
<i>Drop_rate</i>	0,2
<i>Batch_size</i>	32; 64; 128
<i>epoch</i>	100

Konfigurasi tersebut selanjutnya di uji coba pada setiap rasio alokasi data, model dengan nilai MSE terkecil adalah model terbaik dan akan digunakan ke tahap selanjutnya. Hasil pelatihan dapat dilihat pada tabel 6, tabel 7 dan tabel 8.

**Tabel 6:** Hasil Pelatihan Model GRU Alokasi Data 60:20:20

<i>Hyperparameter</i>			MSE
epoch	Unit	Batch Size	
100	32	32	0.00039
		64	0.00029
		128	0.00034
	64	32	0.00025
		64	0.00016
		128	0.00022

Berdasarkan Tabel 6, hasil pelatihan dengan alokasi data 60:20:20 secara jelas menunjukkan efektivitas dari konfigurasi model dengan 64 *unit* dan *batch size* 64. Model ini berhasil mencapai nilai MSE terkecil sebesar 0.00016. Nilai MSE yang sangat rendah ini mengimplikasikan bahwa model ini merupakan kandidat optimal untuk digunakan dalam pengujian lebih lanjut atau penerapan, karena mampu memberikan prediksi yang paling akurat di antara semua konfigurasi yang diuji pada alokasi 60:20:20.

**Tabel 7:** Hasil Pelatihan Model GRU Alokasi Data 70:15:15

<i>Hyperparameter</i>			MSE
epoch	Unit	Batch Size	
100	32	32	0.00039
		64	0.00032
		128	0.00031
	64	32	0.00028
		64	0.00013
		128	0.00025

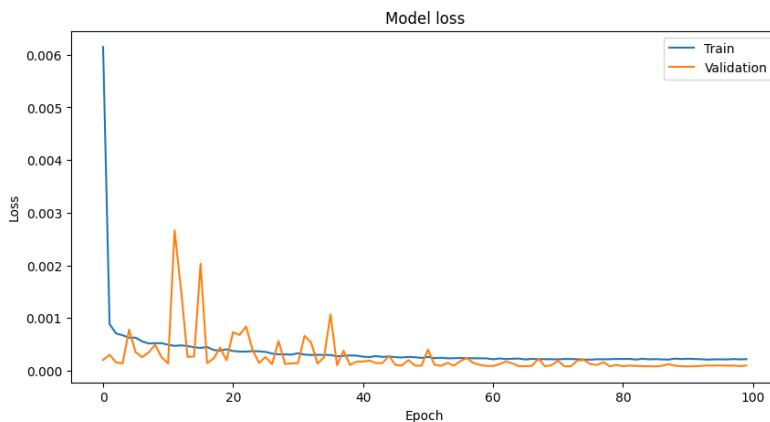
Pada Tabel 7, hasil pelatihan dengan alokasi data 70:15:15 menunjukkan bahwa konfigurasi 64 *unit* dan *batch size* 64 merupakan model dengan performa paling optimal. Model ini berhasil mencapai nilai MSE terkecil sebesar 0.00013. Nilai ini menunjukkan efektivitas model dalam meminimalkan kesalahan prediksi dan menegaskan kemampuannya untuk menangkap pola data dengan akurasi tinggi.

Berdasarkan Tabel 8, hasil pelatihan dengan alokasi data 80:10:10 menghasilkan model terbaik secara keseluruhan dengan konfigurasi 64 *unit* dan *batch size* 64. Model ini mencapai nilai MSE terendah yaitu 0.00012. Nilai ini tidak hanya menunjukkan akurasi yang sangat tinggi, tetapi juga secara signifikan lebih rendah dibandingkan MSE pada alokasi data 60:20:20 (0.00016) dan 70:15:15 (0.00013) yang telah dibahas sebelumnya. Hasil ini menegaskan bahwa pembagian data 80:10:10 merupakan alokasi yang paling optimal untuk model ini, memungkinkan model untuk mempelajari pola data dengan akurasi maksimal dan meminimalkan kesalahan prediksi.

**Tabel 8:** Hasil Pelatihan Model GRU Alokasi Data 80:10:10

Hyperparameter			MSE
epoch	Unit	Batch Size	
100	32	32	0.00086
		64	0.00032
		128	0.00029
	64	32	0.00052
		64	0.00012
		128	0.00015

Hasil ini juga menunjukkan nilai MSE yang diperoleh lebih kecil dari nilai MSE pada penelitian sebelumnya. Pada penelitian [11] yaitu prediksi harga emas menggunakan GRU optimasi Adam memperoleh nilai MSE sebesar 0.0003. Pada penelitian [8] yaitu prediksi harga emas menggunakan LSTM optimasi Nadam memperoleh nilai MSE sebesar 0.0003. Berdasarkan perbandingan tersebut dapat disimpulkan bahwa GRU dengan optimasi Nadam lebih unggul dari kedua kombinasi pada penelitian sebelumnya. Grafik hasil pelatihan model terbaik dapat dilihat pada gambar 4.



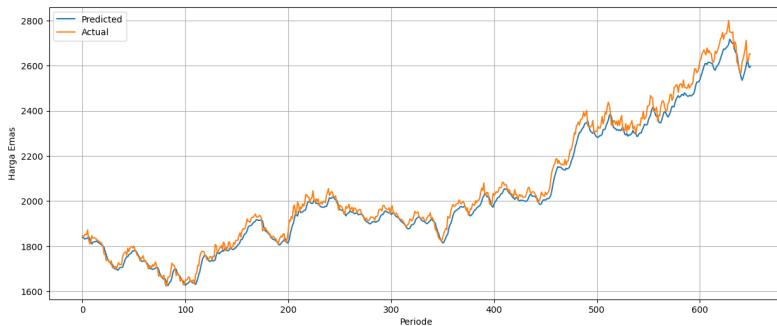
**Gambar 4:** Hasil pelatihan Model Terbaik

Gambar 4 menunjukkan grafik hasil pelatihan model terbaik, di mana kesalahan pada data latih menurun tajam di awal dan terus berkurang hingga *epoch* ke-100. Sebaliknya, kesalahan validasi berfluktuasi hingga sekitar *epoch* ke-40, dengan puncak pada *epoch* ke-12, dan kembali turun pada akhir pelatihan. Grafik ini juga menggambarkan efektivitas algoritma optimasi Nadam dalam menyesuaikan parameter-parameter model seperti bobot, bias, dan *learning rate* selama pelatihan sehingga mencapai nilai kesalahan yang kecil.

Model terbaik kemudian digunakan untuk memprediksi data uji. Hasil prediksi kemudian dilakukan denormalisasi untuk mengembalikan ke skala awal sehingga diperoleh hasil prediksi harga emas dengan skala data sebenarnya. Grafik perbandingan data hasil prediksi dan data aktual disajikan pada Gambar 5.

Berdasarkan grafik yang ditampilkan, terlihat bahwa pola data prediksi yang berwarna jingga sangat mirip dengan pola data aktual. Hal ini mengindikasikan bahwa model yang digunakan menunjukkan kinerja yang baik dalam memprediksi harga emas dunia. Berdasarkan data yang diperoleh, nilai *Mean Absolute Percentage Error* (MAPE) tercatat sebesar 1,107%. Nilai tersebut menunjukkan bahwa hasil prediksi harga emas menggunakan model GRU termasuk dalam kategori sangat baik, mengingat MAPE berada di bawah ambang batas 10%.

Penelitian ini juga melakukan pengujian performa model pada data deret waktu multivariat dengan menambahkan variabel pendukung berupa harga komoditas lain, yakni harga minyak



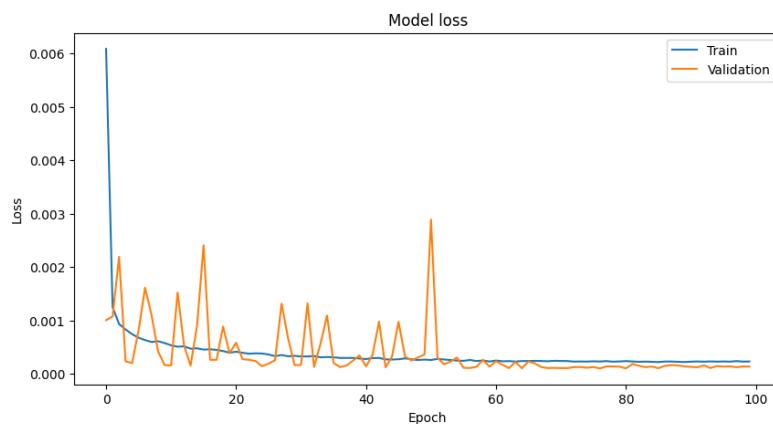
**Gambar 5:** Perbandingan Hasil Prediksi dengan Data Aktual

*West Texas Intermediate (WTI)* dan harga perak, yang juga diperoleh dari situs [investing.com](https://www.investing.com/commodities)<sup>2</sup>. Rentang waktu yang digunakan tetap konsisten dengan data harga emas, yaitu dari 04 Januari 2000 hingga 29 November 2024. Hasil pelatihan model dengan rasio alokasi data sebesar 80:10:10 disajikan pada [Tabel 9](#).

**Tabel 9:** Hasil Pelatihan Model GRU Data Multivariat

Hyperparameter			MSE
epoch	Unit	Batch Size	
100	32	32	0.00176
		64	0.00106
		128	0.00061
	64	32	0.00144
		64	<b>0.00027</b>
		128	0.00034

Berdasarkan [Tabel 9](#), model yang dilatih menggunakan data deret waktu multivariat mencapai performa terbaik dengan konfigurasi 64 *unit* dan *batch size* 64. Konfigurasi ini menghasilkan nilai MSE terkecil sebesar 0.00027. Nilai MSE yang rendah ini menunjukkan kemampuan model dalam memprediksi data multivariat dengan akurasi yang tinggi. Hasil ini membuktikan bahwa konfigurasi arsitektur 64 *unit* dan *batch size* 64 secara optimal mampu menangkap kompleksitas dan interdependensi antarvariabel dalam data deret waktu tersebut, sehingga menghasilkan kesalahan prediksi yang minimal.



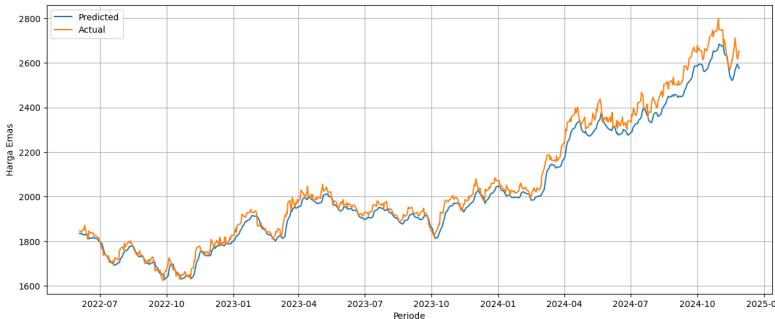
**Gambar 6:** Hasil Pelatihan Model Multivariat

[Gambar 6](#) menunjukkan grafik pelatihan dari model dengan kinerja terbaik, yang memperlihatkan penurunan signifikan pada nilai kesalahan data latih sejak awal pelatihan hingga

<sup>2</sup><https://www.investing.com/commodities>

mencapai *epoch* ke-100. Sementara itu, kesalahan pada data validasi menunjukkan pola fluktuatif hingga sekitar epoch ke-50 sebelum akhirnya mengalami stabilisasi hingga akhir proses pelatihan. Pola ini mengindikasikan bahwa algoritma optimasi Nadam mampu secara efektif menyesuaikan parameter-parameter penting model, seperti bobot, bias, dan *learning rate*, selama proses pelatihan berlangsung.

Hasil prediksi kemudian dilakukan denormalisasi untuk mengembalikan ke skala awal sehingga diperoleh hasil prediksi harga emas dengan skala data sebenarnya. Grafik perbandingan data hasil prediksi dan data aktual disajikan pada Gambar 7



Gambar 7: Perbandingan Hasil Prediksi dengan Data Aktual Model Multivariat

Berdasarkan grafik yang ditampilkan, terlihat bahwa pola prediksi yang ditunjukkan oleh garis berwarna jingga sangat mendekati pola data aktual. Hal ini menunjukkan bahwa model yang diterapkan memiliki performa yang baik dalam memprediksi harga emas dunia, terutama setelah penambahan variabel fitur. Dari hasil prediksi yang diperoleh, nilai *Mean Absolute Percentage Error* (MAPE) mencapai 1.59%. Nilai tersebut menandakan bahwa akurasi model GRU berada dalam kategori sangat baik, karena MAPE masih berada di bawah ambang batas toleransi sebesar 10%.

## 4 Kesimpulan

Penelitian berfokus pada prediksi harga emas menggunakan *deep learning Gated Recurrent Unit* (GRU) yang dioptimalkan dengan algoritma *Nesterov Accelerated Adaptive Moment Estimation* (Nadam). Analisis menggunakan 6.499 data historis harian harga emas dimulai dari 04 Januari 2000 hingga 29 November 2024. Berdasarkan hasil evaluasi, GRU terbukti mampu dalam memprediksi data deret waktu, mampu menangkap pola historis jangka pendek dan panjang. Penambahan Nadam sebagai algoritma optimasi membuat kinerja pelatihan GRU lebih unggul dari kinerja GRU-Adam dan LSTM-Nadam pada penelitian terdahulu. Nilai MSE yang diperoleh dari GRU-Nadam sebesar 0.00012, dimana nilai ini lebih kecil dari nilai MSE pada kedua kombinasi tersebut yaitu 0.0003. Model juga berhasil memprediksi data multivariat dengan menambahkan harga minyak mentah WTI dan perak, menghasilkan nilai MAPE 1.59%. Namun dapat dilihat pada grafik, nilai prediksi di akhir periode mulai menjauh dari nilai data aktual. Untuk penelitian mendatang, disarankan eksplorasi lebih lanjut pada penyesuaian jumlah *hidden layer*, *epoch*, *batch size*, penambahan *dropout* dan untuk meningkatkan akurasi.

## Pernyataan Kontribusi Penulis (CRediT)

**Ismail Saputra R. Harmain:** Konseptualisasi, Metodologi, Penulisan–Draf Awal, perangkat lunak, visualisasi, Analisis Formal, Investigasi, Sumber Data, Kurasi Data, Penulisan–Draf Awal, Penulisan–Telaah dan Penyuntingan. **Nurwan:** Penulisan–Draf Awal, Metodologi dan Validasi. **Isran K. Hasan:** Penulisan–Draf Awal, Metodologi, Perangkat lunak dan Validasi. **Djihad**

**Wungguli:** Penulisan–Telaah dan Penyuntingan, Metodologi, Validasi, dan Supervisi. **Nisky Imansyah Yahya:** Penulisan–Telaah dan Penyuntingan, Metodologi, Validasi, dan Supervisi.

## Deklarasi Penggunaan AI atau Teknologi Berbasis AI

Penelitian ini menggunakan bantuan Model Google Gemini versi 2.5 dalam penyusunan draf awal dan koreksi struktur kalimat.

## Deklarasi Konflik Kepentingan

Penulis menyatakan tidak ada konflik kepentingan

## Ketersediaan Data

Dataset yang dianalisis dalam studi ini tersedia secara terbuka dan dapat digunakan oleh publik. Dataset harga emas, harga perak, dan harga Minyak WTI dapat diakses di repository investing.com<sup>3 4 5</sup>.

## Daftar Pustaka

- [1] S. Adiningtyas and L. Hakim, “Pengaruh pengetahuan investasi, motivasi, dan uang saku terhadap minat mahasiswa berinvestasi di pasar modal syariah dengan risiko investasi sebagai variabel intervening,” *Jurnal Ilmiah Ekonomi Islam*, vol. 8, no. 1, pp. 474–482, 2022. DOI: <https://doi.org/10.29040/jiei.v8i1.4609>.
- [2] D. I. Enjellina, “Analisis dampak kenaikan harga emas terhadap stabilitas moneter di indonesia,” *Jurnal Ilmiah Ekonomi Dan Manajemen*, vol. 3, no. 6, pp. 239–245, 2025. DOI: <https://www.ejurnal.kampusakademik.co.id/index.php/jiem/article/view/5072>.
- [3] R. R. A.-A. Siagian, “Persepsi masyarakat indonesia terhadap kenaikan harga emas sebagai instrumen investasi jangka panjang: Sebuah tinjauan literatur,” *Future Academia: The Journal of Multidisciplinary Research on Scientific and Advanced*, vol. 3, no. 1, pp. 72–79, 2025. DOI: <https://doi.org/10.61579/future.v3i1.298>.
- [4] F. Kesarditama, H. Haryadi, and Y. V. Amzar, “Pengaruh inflasi, nilai tukar rupiah per dollar amerika, harga minyak mentah dunia dan indeks harga saham gabungan terhadap harga emas di indonesia,” *E-Journal Perdagangan Industri Dan Moneter*, vol. 8, no. 2, pp. 55–64, 2020. DOI: <https://doi.org/10.22437/pim.v8i2.8269>.
- [5] T. Hutapea, “Analysis of volatility of the return of composite stock price index using arch/garch model, january 2015-september 2024,” *Jurnal Kewirausahaan, Akuntansi dan Manajemen Tri Bisnis*, vol. 7, no. 1, pp. 81–99, 2025. DOI: <https://doi.org/10.59806/jkamtb.v7i1.498>.
- [6] A. G. A. Savada, G. F. Nama, T. Yulianti, and M. Mardiana, “Peramalan data ekonomi menggunakan model hybrid vector autoregressive-long short term memory,” *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 11, no. 1, pp. 91–104, 2025. DOI: <https://doi.org/10.28932/jutisi.v11i1.10066>.
- [7] S. Khotijah, L. Sarifah, and A. Fuaddiyah, “Prediksi harga emas menggunakan metode radial basis function neural network (rbfnn),” *Jurnal Sains Matematika dan Statistika*, vol. 10, no. 1, pp. 20–30, 2024. DOI: <http://dx.doi.org/10.24014/jsms.v10i1.20890>.

<sup>3</sup><https://www.investing.com/commodities/gold-historical-data>

<sup>4</sup><https://www.investing.com/commodities/crude-oil-historical-data>

<sup>5</sup><https://www.investing.com/commodities/silver-historical-data>

- [8] W. F. Hidayat, K. Handayani, Y. Malau, R. A. Purnama, and A. Setiadi, “Prediksi harga komoditi emas menggunakan metode long short-term memory dengan penambahan optimalisasi,” *Jurnal Infortech*, vol. 6, no. 2, pp. 156–162, 2024. DOI: <https://doi.org/10.31294/infortech.v6i2.24440>.
- [9] A. Nilsen, “Perbandingan model rnn, model lstm, dan model gru dalam memprediksi harga saham-saham lq45,” *Jurnal Statistika dan Aplikasinya*, vol. 6, no. 1, pp. 137–147, 2022.
- [10] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical evaluation of gated recurrent neural networks on sequence modeling,” *arXiv*, 2014. Available online.
- [11] I. Sudiatmika, I. Putra, and W. W. Artana, “The implementation of gated recurrent unit (gru) for gold price prediction using yahoo finance data: A case study and analysis,” *Brilliance: Research Of Artificial Intelligence*, vol. 4, no. 1, pp. 176–184, 2024. DOI: <10.47709/brilliance.v4i1.3865>.
- [12] T. Dozat, “Incorporating nesterov momentum into adam,” 2016. Available online.
- [13] K. Cho, B. Van Merriënboer, D. Bahdanau, and Y. Bengio, “On the properties of neural machine translation: Encoder-decoder approaches,” *arXiv*, 2014. DOI: <https://doi.org/10.48550/arXiv.1409.1259>.
- [14] M. Ridwan, K. Sadik, and F. M. Afendi, “Comparison of arima and gru models for high-frequency time series forecasting.,” *Scientific Journal of Informatics*, vol. 10, no. 3, pp. 389–400, 2023. Available online.
- [15] U. I. Arfianti, D. C. R. Novitasari, N. Widodo, M. Hafiyusholeh, and W. D. Utami, “Sunspot number prediction using gated recurrent unit (gru) algorithm,” *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 15, no. 2, pp. 141–152, 2021. DOI: <https://doi.org/10.22146/ijccs.63676>.
- [16] R. S. Al-Khowarizmi, M. K. Nasution, and M. Elveny, “Sensitivity of mape using detection rate for big data forecasting crude palm oil on k-nearest neighbor,” *Int. J. Electr. Comput. Eng*, vol. 11, no. 3, pp. 2696–2703, 2021. DOI: <http://doi.org/10.11591/ijece.v11i3. pp2696-2703>.