



MODEL *DEEP LEARNING* LSTM DAN GRU UNTUK PREDIKSI VALUTA ASING

Santi Amalia*, Oni Soesanto, Hermei Lissa

Jurusan Matematika Fakultas MIPA Universitas Lambung Mangkurat

Jl. A. Yani KM. 36, Banjarbaru 70714, Kalimantan Selatan

*email : santiiiamaliaaaa@gmail.com

ABSTRACT

Currency exchange rates are one of the most important variables in macroeconomics because changes in exchange rates can affect economic stability and activity. The uncertainty of exchange rates is an important problem in finance, so accurate predictions are needed to design strategic steps in dealing with foreign exchange fluctuations. This research aims to explain the process of implementing the LSTM and GRU deep learning models in predicting foreign exchange against the Rupiah and US Dollar exchange rates and analyzing the evaluation results and prediction results of the LSTM and GRU models. The data used is the daily closing price of the USD/IDR exchange rate for the period August 29, 2014, to August 28, 2024, obtained from the global financial platform investing.com, totaling 2,554 data points. Predictions are made for a one-step forward horizon ($t+1$) with a chronological data division scheme of 80% as training data and 20% as testing data. Before the model training process, the data is normalized using the Z-score normalization method to improve data stability against outliers and aid the model learning process. The results showed that the LSTM and GRU models were able to learn historical data patterns well during the training and testing processes. During testing, the LSTM model produced an MAE of 0,133; RMSE of 0,159; and R^2 of 0.932. After denormalization, the LSTM model has a mean prediction error (MAE) of approximately Rp65 and a RMSE of approximately Rp89 relative to the actual value. Meanwhile, the GRU model produced an MAE of 0.102; RMSE of 0.124; and R^2 of 0.958. The denormalization results show that the GRU model has an average prediction error (MAE) of approximately Rp54 and an RMSE of approximately Rp70 relative to the actual value. The evaluation results show that the GRU model performs better than the LSTM model because it produces a smaller error value and the R^2 value that is closest to 1.

Keywords: LSTM, GRU, Prediction, Foreign Exchange

ABSTRAK

Nilai tukar mata uang merupakan salah satu variabel penting dalam ekonomi makro karena perubahan nilai tukar dapat memengaruhi stabilitas dan aktivitas ekonomi. Ketidakpastian nilai tukar ini merupakan permasalahan yang penting dalam bidang keuangan, sehingga diperlukan prediksi yang akurat untuk merancang langkah strategis dalam menghadapi fluktuasi valuta asing. Penelitian ini bertujuan untuk menjelaskan proses pengimplementasian model *deep learning* LSTM dan GRU dalam memprediksi valuta asing terhadap nilai tukar Rupiah dan US Dolar serta menganalisis hasil evaluasi dan hasil prediksi model LSTM dan GRU. Data yang digunakan berupa harga penutupan harian nilai tukar USD/IDR periode 29 Agustus 2014 hingga 28 Agustus 2024 yang diperoleh dari platform finansial global investing.com sebanyak 2554 data. Prediksi dilakukan untuk horizon satu langkah ke depan ($t+1$) dengan skema pembagian data secara kronologis sebesar 80% sebagai *data training* dan 20% sebagai *data testing*. Sebelum proses pelatihan model, data dinormalisasi menggunakan metode Z-score normalization untuk meningkatkan stabilitas data terhadap outlier dan membantu proses pembelajaran model. Hasil penelitian menunjukkan bahwa model LSTM dan GRU mampu mempelajari pola historis data dengan baik selama proses *training* dan *testing*. Pada proses pengujian, model LSTM menghasilkan nilai MAE sebesar 0,133; RMSE

sebesar 0,159; dan R^2 sebesar 0,932. Setelah dilakukan denormalisasi, model LSTM memiliki rata-rata kesalahan prediksi (MAE) sekitar Rp65 dan RMSE sekitar Rp89 terhadap nilai aktual. Sementara itu, model GRU menghasilkan nilai MAE sebesar 0,102; RMSE sebesar 0,124; dan R^2 sebesar 0,958. Hasil denormalisasi menunjukkan bahwa model GRU memiliki rata-rata kesalahan prediksi sekitar (MAE) Rp54 dan RMSE sekitar Rp70 terhadap nilai aktual. Berdasarkan hasil evaluasi, model GRU memberikan performa yang lebih optimal dibandingkan model LSTM karena menghasilkan nilai error yang lebih kecil serta nilai R^2 yang lebih mendekati 1.

Kata kunci: LSTM, GRU, Prediksi, Valuta Asing

Received: 25 July 2025, Accepted: 24 May 2026, Published: 9 June 2026

PENDAHULUAN

Nilai tukar mata uang merupakan salah satu variabel ekonomi makro yang penting, karena fluktuasinya dapat memengaruhi stabilitas serta aktivitas ekonomi. Ketidakstabilan nilai tukar dapat berdampak pada aliran modal dan perdagangan, mengingat transaksi ekonomi internasional melibatkan penggunaan mata uang domestik dan mata uang asing (Mokodongan *et al.*, 2018). Dolar Amerika Serikat (USD) menjadi mata uang yang paling banyak digunakan dalam perdagangan internasional dan cadangan devisa dunia sehingga pergerakan nilai tukar Rupiah terhadap USD menjadi perhatian penting dalam perekonomian Indonesia (Lee, 2018). Berdasarkan data dari Bank Indonesia, nilai tukar Rupiah terhadap Dolar AS terus mengalami fluktuasi dan cenderung melemah dari tahun ke tahun (Arifin & Mayasya, 2018). Fluktuasi tersebut semakin meningkat pada periode pasca pandemi COVID-19 akibat ketidakpastian ekonomi global dan kondisi pasar keuangan internasional. Oleh karena itu, untuk menjaga kestabilan ekonomi dan mengambil langkah strategis dalam menghadapi fluktuasi yang terjadi terhadap valuta asing diperlukan sebuah prediksi yang akurat.

Prediksi merupakan sebuah proses sistematis dalam melakukan perkiraan tentang kejadian yang mungkin akan terjadi di masa mendatang dengan mengacu pada data dari masa lalu dan saat ini. Prediksi tidak dapat memberikan jawaban yang pasti melainkan berusaha untuk menghasilkan jawaban yang paling mendekati dengan kejadian sebenarnya di masa depan (Srisulistiowati *et al.*, 2021). Dalam bidang keuangan, prediksi nilai tukar menjadi penting karena dapat membantu pemerintah, investor, maupun pelaku ekonomi dalam mengurangi risiko ketidakpastian pasar. Seiring berkembangnya teknologi komputasi, metode prediksi berbasis *Machine Learning* dan *Deep Learning* mulai banyak digunakan karena mampu mempelajari pola data *time series* yang kompleks. *Deep Learning* merupakan salah satu cabang *Machine Learning* yang menggunakan arsitektur jaringan saraf berlapis untuk mempelajari representasi data secara mendalam dan mampu menghasilkan performa prediksi yang baik pada data sequential maupun nonlinear (Ayyadevara, 2018).

Salah satu metode *Deep Learning* yang banyak digunakan pada data *time series* adalah *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Model *Deep Learning* seperti LSTM dan GRU banyak digunakan pada data *time series* karena mampu mempelajari dependensi jangka panjang pada data sequential (Brownlee, 2018). LSTM merupakan sebuah evolusi dari arsitektur RNN, arsitektur LSTM memiliki sel memori yang berfungsi menyimpan informasi, dan mekanisme pembaruannya dilakukan melalui *forget gate*, *input gate*, dan *output gate*. Sementara itu, struktur GRU memiliki kinerja yang hampir mirip dengan LSTM namun hanya menggunakan dua *gate*, yaitu *reset gate* dan *update gate* (Giarsyani, N., 2020). Kemampuan kedua metode tersebut dalam mempelajari pola historis menjadikannya sesuai untuk digunakan dalam prediksi nilai tukar mata uang yang memiliki pola fluktuatif dan nonlinear.

Beberapa penelitian sebelumnya menunjukkan bahwa model *Deep Learning* memiliki performa yang baik dalam prediksi data keuangan dan *time series*. Arfan & Lussiana ETP (2019) melakukan penelitian menggunakan LSTM pada data harga saham di Indonesia. Dari hasil analisis, model LSTM mampu memberikan prediksi harga saham periode 2017 hingga 2019 dengan nilai MSE sebesar 0,0015. Penelitian terhadap model LSTM yang dilakukan oleh Yusuf (2022) untuk prediksi indeks harga saham gabungan (IHSG) menghasilkan model terbaik dengan nilai RMSE yang paling kecil pada *epoch* sejumlah 50. Penelitian Fischer dan Krauss (2018) menunjukkan bahwa model LSTM mampu memberikan performa prediksi yang baik pada data financial market karena dapat menangkap pola nonlinear dan hubungan temporal dalam data *time series*. Penelitian yang dilakukan oleh Arwansyah *et al.* (2022) prediksi terhadap *dataset time series* salah satunya adalah data *Exchange Rate*. Hasilnya menyatakan bahwa model GRU menghasilkan prediksi yang lebih akurat dibandingkan dengan model ARIMA, RNN, dan LSTM. Selain itu, Aji (2019) menggunakan model GRU untuk prediksi harga Bitcoin dan menghasilkan nilai Mean Absolute Percentage Error (MAPE) sebesar 5,43%.

Meskipun penelitian terkait LSTM dan GRU pada data *time series* telah banyak dilakukan, sebagian besar penelitian sebelumnya berfokus pada prediksi saham, cryptocurrency, dan indeks pasar modal. Penelitian mengenai perbandingan performa model LSTM dan GRU pada data nilai tukar Rupiah terhadap USD dengan data harian jangka panjang masih relatif terbatas, khususnya pada periode volatilitas tinggi pasca pandemi. Selain itu, beberapa penelitian sebelumnya lebih berfokus pada implementasi satu model tanpa melakukan analisis komparatif performa model secara mendalam. Oleh karena itu, kebaruan penelitian ini berupa analisis komparatif implementasi model LSTM dan GRU pada prediksi nilai tukar USD/IDR menggunakan data *time series* harian periode 2014–2024 untuk mengevaluasi kemampuan kedua model dalam menangkap pola fluktuasi nilai tukar.


Penelitian ini bertujuan untuk menjelaskan proses pengimplementasian model LSTM dan GRU dalam memprediksi valuta asing terhadap nilai tukar

Rupiah dan US Dolar. Selain itu, juga akan dilakukan analisis performa model menggunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi R^2 . Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan metode prediksi berbasis *Deep Learning* pada data *time series* keuangan serta menjadi referensi dalam pengambilan keputusan yang berkaitan dengan pergerakan nilai tukar valuta asing. dan hasil prediksi dari model LSTM dan GRU dalam memprediksi valuta asing terhadap nilai tukar Rupiah dan US Dolar.

TINJAUAN PUSTAKA

Long Short Term Memory (LSTM)

LSTM termasuk salah satu varian dari metode RNN, pada LSTM dapat mengingat informasi jangka panjang dan dapat menghindari permasalahan *long-term* pada RNN (Olah, 2015). LSTM pertama kali dikembangkan oleh Hochreiter dan Schmidhuber pada tahun 1997. Arsitektur jaringannya terdiri dari lapisan LSTM yang bekerja secara berulang. Berbeda dengan RNN yang hanya mengalirkan informasi ke depan melalui antar neuron, LSTM mampu mengakses kembali informasi dari neuron sebelumnya. Arsitektur LSTM terlihat pada Gambar 1.



Gambar 1. Arsitektur LSTM (Olah, 2015)

Arsitektur LSTM yaitu sebagai berikut:

a. *Forget Gate* (f_t)

Pada *forget gate*, input berupa nilai h_{t-1} dan x_1 diproses untuk menghasilkan *output* berupa nilai antara 0 dan 1 untuk dikirim pada *cell state* (Olah, 2015). Terdapat rumus yang diuraikan pada persamaan berikut:

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

Nilai *weight* diperoleh dalam rentang tertentu yang dihitung pada persamaan berikut:

$$W = \left(-\frac{1}{\sqrt{d}}, \frac{1}{\sqrt{d}} \right) \quad (2)$$

b. *Input Gate* (i_t)

Bagian pertama adalah sigmoid *layer* atau biasa disebut *input gate* merupakan nilai yang akan diperbarui. Hal ini diuraikan pada persamaan berikut:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

Selanjutnya tanh *layer* akan menghasilkan $\tilde{C}_t$ yang akan ditambahkan ke *cell state* (Olah, 2015). Diuraikan pada persamaan berikut:

$$\tilde{C}_t = \tanh(W_{\tilde{C}_t} \cdot [h_{t-1}, x_t] + b_{\tilde{C}_t}) \quad (4)$$

Bagian kedua adalah *output* dari *input gate layer* dan tanh *layer* akan digabungkan untuk memperbaharui *cell state* (Olah, 2015). Diformulasikan pada persamaan berikut:

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (5)$$

c. *Output Gate* (o_t)

Persamaan pada *output gate* yang diuraikan sebagai berikut:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

Kemudian nilai *output* orde t diuraikan sebagai berikut:


$$h_t = o_t \times \tanh(C_t) \quad (7)$$

dengan:

σ	: fungsi sigmoid
$\tanh$	: fungsi tanh
x_t	: nilai <i>input</i> pada orde ke t
b	: nilai bias
W	: <i>weight</i>
d	: jumlah data
$\tilde{C}_t$	: nilai baru yang akan ditambahkan ke <i>cell state</i>
C_t	: <i>cell state</i>
h_t	: nilai <i>output</i> orde t

Gated Recurrent Unit (GRU)

GRU pertama kali dikenalkan oleh Cho pada tahun 2014 dengan tujuan untuk mengatasi permasalahan *vanishing gradient problem* yang sering terjadi pada RNN. Dalam hal operasi, GRU dan LSTM bekerja dengan cara yang sama tetapi GRU *cell* menggunakan satu *hidden state* yang menggabungkan *forget gate* dan *input gate* menjadi *update gate*. Selain itu, GRU juga menggabungkan *hidden* dan *cell states* menjadi satu *state*. Oleh karena itu, GRU disebut sebagai varian LSTM yang disederhanakan (ArunKumar *et al.*, 2022). Arsitektur pada GRU dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur GRU (ArunKumar *et al.*, 2022)

Persamaan-persamaan yang digunakan dalam GRU dapat diuraikan sebagai berikut:

a. *Reset gate* (r_t)

$$r_t = \sigma(U_r x_t + W_r h_{t-1} + b_r) \quad (8)$$

b. *Update gate* (z_t)

Pada GRU, *forget gate* dan *input gate* dikombinasikan menjadi *update gate* pada persamaan berikut:

$$z_t = \sigma(U_z x_t + W_z h_{t-1} + b_z) \quad (9)$$

c. Kandidat aktivasi ($\tilde{h}_t$)

$$\tilde{h}_t = \tanh(U_{\tilde{h}} x_t + W_{\tilde{h}} (h_{t-1} \times r_t) + b_{\tilde{h}}) \quad (10)$$

d. Nilai aktivasi (h_t)

$$h_t = (1 - z_t) \times \tilde{h}_t + z_t \times h_{t-1} \quad (11)$$

dengan:


σ	: fungsi sigmoid
$\tanh$	: fungsi tanh
U	: nilai bobot
x_t	: nilai input
W	: nilai bobot
b	: nilai bias

METODE PENELITIAN

Penelitian ini menggunakan data kuantitatif nilai tukar mata uang Rupiah (IDR) terhadap Dolar AS (USD) yang diperoleh melalui website *investing.com*. Data yang digunakan ialah data harian nilai tukar mata uang IDR terhadap USD mulai dari 29 Agustus 2014 sampai dengan 28 Agustus 2024 dengan jumlah data sebanyak 2554. Peneliti menggunakan metode LSTM dan GRU dengan

menggunakan bahasa pemrograman python. Adapun tahapan dalam melakukan pengolahan data menggunakan metode tersebut sebagai berikut:

- 1) Melakukan *preprocessing* data.
- 2) Melakukan pembagian data menjadi *data training* (80%) dan *data testing* (20%).
- 3) Melakukan normalisasi data menggunakan metode *Z-score normalization*.
- 4) Membuat simulasi kalkulasi numerik dari implementasi model LSTM.
- 5) Membuat model LSTM dengan bantuan bahasa pemrograman python.
- 6) Membuat simulasi kalkulasi numerik dari implementasi model GRU.
- 7) Membuat model GRU dengan bantuan bahasa pemrograman python.
- 8) Melakukan pengukuran akurasi model LSTM dan GRU menggunakan RMSE, MAE dan R^2 .
- 9) Melakukan denormalisasi data.
- 10) Menganalisis hasil prediksi model LSTM dan GRU.




Gambar 3. Flowchart Penelitian

HASIL DAN PEMBAHASAN

Karakteristik Data

Penelitian ini menggunakan data harga penutupan (*Price*) nilai tukar IDR terhadap USD pada periode 29 Agustus 2014 hingga 28 Agustus 2024 dengan rentang periode perhari sebanyak 2554 data. Visualisasi data awal untuk melihat pola pergerakan harga penutupan (*Price*) nilai tukar IDR terhadap USD dalam bentuk grafik dapat dilihat pada Gambar 3.



Gambar 4. Grafik Data Harga Penutupan Nilai Tukar IDR terhadap USD

Data yang digunakan dalam penelitian ini dibagi menjadi *data training* (80%) dan *data testing* (20%) bertujuan untuk digunakan proses *training* dan proses *testing*. Normalisasi data pada penelitian ini menggunakan metode *Z-score normalization*. Berikut tabel hasil normalisasi data disajikan pada Tabel 1.

Tabel 1. Normalisasi Data

<i>Date</i>	<i>Price Hasil Normalisasi</i>
29/08/2014	-3,052
01/09/2014	-3,015
02/09/2014	-2,971
03/09/2014	-2,947
04/09/2014	-2,948
⋮	⋮
22/08/2024	2,436
23/08/2024	2,281
26/08/2024	2,197
27/08/2024	2,288
28/08/2024	2,190

Implementasi Model

Pada bagian ini dijelaskan langkah-langkah implementasi model LSTM dan GRU. Penjelasan lebih lanjut mengenai setiap model adalah sebagai berikut.

a. Model LSTM

Berikut contoh kalkulasi numerik LSTM pada *data training*. Dalam kalkulasi numerik LSTM pertama adalah menghitung *weight* menggunakan Persamaan (2). Perhitungan *weight* dengan jumlah data sebanyak 2041 sehingga diketahui nilai $d = 2041$.

$$W = \left[-\frac{1}{\sqrt{2041}}, \frac{1}{\sqrt{2041}} \right]$$

$$W = [-0,022; 0,022]$$

Perhitungan hari ke-1 pada tanggal 29 Agustus 2014.

Diketahui $h_0 = 0$; $x_1 = -3,052$; $C_0 = 0$; $W = 0,022$; $b_f = 1$; $b_i = 0,5$; $b_{\tilde{c}_t} = 0$; dan $b_o = 0,1$

Langkah 1 menghitung *forget gate* menggunakan Persamaan (1).

$$f_1 = \sigma([0,022 \times 0 + 0,022 \times (-3,052)] + 1)$$

$$f_1 = \sigma(0,933)$$

$$f_1 = 0,718$$

Langkah 2 menghitung *input gate* menggunakan Persamaan (3).

$$i_1 = \sigma([0,022 \times 0 + 0,022 \times (-3,052)] + 0,5)$$

$$i_1 = \sigma(0,433)$$

$$i_1 = 0,607$$

Perhitungan *tanh layer* menggunakan Persamaan (4)

$$\tilde{C}_1 = \tanh([0,022 \times 0 + 0,022 \times (-3,052)] + 0)$$

$$\tilde{C}_1 = \tanh(-0,067)$$

$$\tilde{C}_1 = -0,067$$

Perhitungan *cell state* menggunakan Persamaan (5)

$$C_1 = 0,718 \times 0 + 0,607 \times (-0,067)$$

$$C_1 = -0,040$$

Langkah 3 menghitung *output gate* menggunakan Persamaan (6).

$$o_1 = \sigma([0,022 \times 0 + 0,022 \times (-3,052)] + 0,1)$$

$$o_1 = \sigma(0,033)$$

$$o_1 = 0,508$$

Perhitungan nilai output menggunakan Persamaan (7)


$$h_1 = 0,508 \times \tanh(-0,040)$$

$$h_1 = -0,020$$

Setiap langkah perhitungan di atas dilakukan pada setiap *time step* dengan menghasilkan informasi baru yaitu nilai C_t dan h_t . Nilai tersebut dibawa ke *time step* berikutnya dan nilai h_t disimpan sebagai *output* dari *time step* tersebut. Langkah perhitungan ini akan berlangsung pada proses *training* hingga

memperoleh model yang paling optimal, sehingga model tersebut akan digunakan pada proses *testing*.

Uraian di atas merupakan contoh kalkulasi numerik LSTM dan untuk selanjutnya menggunakan komputasi dengan bahasa pemrograman Python. Grafik visualisasi perbandingan nilai aktual dan nilai *output* yang dihasilkan oleh model LSTM dapat dilihat pada Gambar 5.



Gambar 5. Grafik Perbandingan Nilai Aktual dan Nilai Prediksi Model LSTM pada (a) Proses *Training* dan (b) Proses *Testing*

Dapat dilihat pada Gambar 5 secara visual hasil prediksi saat proses *training* dan *testing* dari model LSTM memiliki performa yang baik. Hal ini dikarenakan secara garis besar pola nilai prediksi yang terbentuk dapat mengikuti pola nilai aktual.

b. Model GRU

Proses implementasi model GRU untuk prediksi valuta asing terhadap nilai tukar IDR dan USD adalah sebagai berikut:

1. Inisialisasi bobot menggunakan inisialisasi random normal pada bobot.
2. GRU juga memiliki nilai bias. Nilai dari bobot dan bias menggunakan nilai *random* normal dengan rentang -1 sampai dengan 1. Berikut contoh inisialisasi nilai bobot dan bias adalah $U_z = -0,112$; $W_z = -0,187$; $U_r = -0,228$; $W_r = -0,967$; $U_{\tilde{h}} = 1$; $W_{\tilde{h}} = -0,554$; $V_{out} = 1$; $b_z = 0,418$; $b_r = 0,102$; $b_{\tilde{h}} = 0,089$; dan $b_{out} = -0,063$
3. Contoh kasus menggunakan sampel data harga penutupan (*price*) yang telah dinormalisasi yaitu $x_1 = -3,052$ dan $x_2 = -3,015$
4. Proses dimulai dengan menghitung nilai *update gate* pada *time step* pertama. Perhitungan *update gate* menggunakan Persamaan (9):

$$z_1 = \sigma((-0,112 \times (-3,052)) + (-0,187 \times 0) + 0,418)$$

$$z_1 = \sigma(0,760)$$

$$z_1 = 0,681$$
5. Perhitungan dilanjutkan dengan menghitung nilai *reset gate* pada *time step* pertama. Perhitungan *reset gate* menggunakan Persamaan (8):

$$r_1 = \sigma((-0,228 \times (-3,052)) + (0,967 \times 0) + 0,102)$$

$$r_1 = \sigma(0,798)$$

$$r_1 = 0,690$$

6. Langkah berikutnya adalah menghitung kandidat aktivasi ($\tilde{h}_t$). Perhitungan kandidat aktivasi menggunakan Persamaan (10):

$$\tilde{h}_1 = \tanh((1 \times (-3,052)) + (-0,554(0 \times 0,690)) + 0,089)$$

$$\tilde{h}_1 = \tanh(-2,963)$$

$$\tilde{h}_1 = -0,995$$


7. Pada setiap *time step*, nilai aktivasi (h_t) digunakan sebagai *output* dari GRU. Perhitungan nilai aktivasi menggunakan Persamaan (11):

$$h_1 = (1 - 0,681) \times (-0,995) + 0,681 \times 0$$

$$h_1 = -0,317$$

8. Kemudian nilai aktivasi (h_t) tersebut digunakan dalam *time step* berikutnya.

Uraian di atas merupakan contoh kalkulasi numerik GRU dan untuk selanjutnya menggunakan komputasi dengan bahasa pemrograman Python. Grafik visualisasi perbandingan nilai aktual dan nilai *output* yang dihasilkan oleh model GRU dapat dilihat pada Gambar 6.



Gambar 6. Grafik Perbandingan Nilai Aktual dan Nilai Prediksi Model GRU pada (a) Proses *Training* dan (b) Proses *Testing*

Secara visual hasil prediksi saat proses *testing* dan *training* dari model GRU menunjukkan performa yang baik, karena pola nilai prediksi yang terbentuk secara garis besar mampu mengikuti pola nilai aktual.

Pada Gambar 6(a) nilai aktual ditunjukkan oleh garis warna biru dan nilai prediksi dari model GRU ditunjukkan oleh garis warna hijau. Dapat dilihat pada Gambar 6(a) secara visual hasil prediksi saat proses *training* dari model GRU memiliki performa yang baik. Hal ini dikarenakan secara garis besar pola nilai prediksi yang terbentuk dapat mengikuti pola nilai aktual. Setelah selesai dilakukan proses *training*. Selanjutnya akan dilanjutkan ketahap proses *testing*. Grafik visualisasi perbandingan nilai aktual dan hasil prediksi yang dihasilkan oleh model GRU pada proses *testing* dapat dilihat pada Gambar 6(b). Pada Gambar 6(b) nilai

aktual ditunjukkan oleh garis warna merah dan nilai prediksi dari model GRU ditunjukkan oleh garis warna hijau. Secara visual hasil prediksi saat proses *testing* dari model GRU menunjukkan performa yang baik, karena pola nilai prediksi yang terbentuk secara garis besar mampu mengikuti pola nilai aktual. Meskipun demikian, garis nilai prediksi cenderung berada dibawah garis nilai aktual yang mengindikasikan adanya selisih diantara kedua garis tersebut. Oleh karena itu, perlu dilakukan evaluasi model GRU untuk menghitung selisih kesalahan (*error*) antara nilai prediksi dan nilai aktual.

Perbandingan Model LSTM dan GRU

Dalam penelitian ini, perbandingan model LSTM dan GRU dilakukan dengan menganalisis akurasi model menggunakan RMSE, MAE, dan R^2 . Pada proses *testing* diperoleh hasil pengukuran akurasi model LSTM dan GRU yang dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pengukuran Akurasi Model LSTM DAN GRU

Model	RMSE	MAE	R^2
LSTM	0,159	0,133	0,932
GRU	0,124	0,102	0,958

Pada Tabel 2 menunjukkan bahwa model GRU yang paling optimal karena menghasilkan nilai RMSE dan MAE terkecil yaitu RMSE sebesar 0,124 dan MAE sebesar 0,102. Serta model GRU juga menghasilkan nilai R^2 yang paling mendekati 1 yaitu sebesar 0,958. RMSE merupakan salah satu cara yang digunakan untuk menguji keakuratan hasil prediksi data kuantitatif dari suatu model, semakin rendah nilai RMSE yang didapatkan maka semakin akurat prediksinya. *Mean Absolute Error* (MAE) merupakan ukuran kesalahan absolut antara data yang diprediksi dan data asli, nilai MAE dapat berkisar dari 0 hingga ∞ . Semakin kecil nilai MAE maka semakin baik modelnya. R-Squared (R^2) atau biasa juga dikenal sebagai *coefficient of determination* merupakan ukuran statistik untuk mempelajari korelasi antara nilai aktual dan data hasil prediksi. R^2 dapat bernilai antara 0 sampai dengan 1 dimana semakin nilai R^2 mendekati 1 maka model yang ada semakin cocok dengan dataset. (Chicco *et al.*, 2021)

Selanjutnya untuk melihat nilai prediksi dari model LSTM dan GRU perlu dilakukan denormalisasi data untuk mengembalikan data yang telah dinormalisasi ke skala aslinya. Perbandingan nilai aktual (*Price*) dan nilai prediksi dari model LSTM dan GRU pada proses *testing* dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan Nilai Aktual dan Nilai Prediksi Model LSTM dan GRU

<i>Date</i>	<i>Price</i>	LSTM	GRU
29/08/2022	14895	14880,78	14880
30/08/2022	14840	14893,703	14893,755
31/08/2022	14840	14846,206	14843,221
01/09/2022	14880	14846,206	14843,221
02/09/2022	14895	14880,78	14880,001
⋮	⋮	⋮	⋮
22/08/2024	15595	15395,753	15423,599
23/08/2024	15485	15495,769	15527,498
26/08/2024	15425	15400,09	15428,114
27/08/2024	15490	15348,122	15373,93
28/08/2024	15420	15404,427	15432,63

Pada Tabel 3 terlihat bahwa nilai aktual dan nilai prediksi memiliki selisih yang kecil, menunjukkan bahwa nilai prediksi hampir mendekati nilai aktual. Hal ini didukung dengan nilai RMSE, MAE dan R^2 yang diperoleh. Grafik visualisasi perbandingan nilai aktual dan nilai prediksi yang dihasilkan oleh model LSTM dan GRU pada proses *testing* dapat dilihat pada Gambar 7.

**Gambar 7.** Grafik Perbandingan Nilai Aktual dan Nilai Prediksi Model LSTM dan GRU pada Proses *Testing*

Hasil Prediksi Model LSTM dan GRU

Berdasarkan proses *training* dan *testing* pada model LSTM dan GRU yang telah dilakukan sebelumnya, sehingga diperoleh prediksi harga penutupan (*price*) valuta asing untuk periode harian pada 29 Agustus 2024. Hasil prediksi model LSTM dan GRU dapat dilihat pada Tabel 4.

Tabel 4. Hasil Prediksi Model LSTM dan GRU

<i>Date</i>	<i>Price Hasil Prediksi LSTM</i>	<i>Price Hasil Prediksi GRU</i>
29/08/2024	15433,189	15439,565

Berdasarkan Tabel 4 terlihat bahwa hasil prediksi harga penutupan (*price*) yang dihasilkan oleh model LSTM sebesar 15433,189 dan model GRU sebesar 15439,565. Selisih prediksi yang relatif kecil antara kedua model menunjukkan bahwa model LSTM maupun GRU mengindikasikan bahwa kedua model mampu mengikuti pola pergerakan nilai tukar USD/IDR dengan cukup baik dalam memprediksi pergerakan harga valuta asing terhadap Rupiah untuk periode tersebut. Hal tersebut juga didukung oleh hasil evaluasi model yang menghasilkan nilai RMSE dan MAE yang rendah serta nilai R^2 yang mendekati 1 (Chicco *et al.*, 2021).

Penelitian ini dilakukan untuk membandingkan performa model *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD/IDR) menggunakan data *time series* harian periode 2014–2024. Tahapan penelitian dimulai dari *preprocessing* data yang meliputi pengurutan data berdasarkan waktu, seleksi variabel harga penutupan (*price*), pemeriksaan *missing values* dan *outlier*, serta normalisasi data menggunakan metode *Z-score normalization*. Normalisasi dilakukan untuk membantu proses pembelajaran model agar data berada pada rentang yang lebih stabil sehingga proses *training* menjadi lebih optimal.

Data kemudian dibagi menjadi *data training* sebesar 80% dan *data testing* sebesar 20%. Pembagian data secara kronologis dilakukan untuk mempertahankan karakteristik data *time series* sehingga model mempelajari pola historis pada periode sebelumnya dan melakukan prediksi terhadap data pada periode berikutnya. Selanjutnya dilakukan proses *training* dan *testing* pada model LSTM dan GRU untuk mengevaluasi kemampuan model dalam mengikuti pola pergerakan nilai tukar USD/IDR. Hasil penelitian menunjukkan bahwa kedua model mampu mengikuti pola historis data dengan cukup baik. Hal ini terlihat dari hasil prediksi yang mendekati nilai aktual serta nilai evaluasi RMSE dan MAE yang relatif kecil. Namun demikian, model GRU menghasilkan performa prediksi yang lebih baik dibandingkan model LSTM. Nilai *error* yang lebih rendah menunjukkan bahwa model GRU memiliki kemampuan yang lebih baik dalam mempelajari pola fluktuasi nilai tukar USD/IDR pada *data testing*.

Performa GRU yang lebih baik diduga dipengaruhi oleh arsitekturnya yang lebih sederhana dibandingkan LSTM. GRU hanya menggunakan dua *gate*, yaitu *update gate* dan *reset gate*, sehingga jumlah parameter yang dipelajari menjadi lebih sedikit. Struktur tersebut memungkinkan proses pelatihan menjadi lebih efisien dan membantu model beradaptasi terhadap pola data *time series* yang fluktuatif dan nonlinear. Karakteristik data nilai tukar USD/IDR yang dinamis

menyebabkan model dengan struktur yang lebih sederhana dapat memberikan generalisasi yang lebih baik pada *data testing*.

Hasil penelitian ini sejalan dengan penelitian Arwansyah *et al.* (2022) yang menyatakan bahwa model GRU memiliki performa yang lebih baik dibandingkan beberapa model *time series* lainnya pada data *exchange rate*. Dengan demikian, penggunaan model *Deep Learning* seperti LSTM dan GRU dapat menjadi alternatif dalam prediksi nilai tukar karena mampu menangkap hubungan temporal pada data historis.

KESIMPULAN

Penelitian ini berhasil mengimplementasikan model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) untuk prediksi nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD/IDR) menggunakan data *time series* harian. Berdasarkan hasil evaluasi, kedua model mampu menghasilkan prediksi yang mendekati data aktual, dengan model GRU menunjukkan performa yang lebih baik dibandingkan model LSTM.

Hasil penelitian menunjukkan bahwa pendekatan *Deep Learning* memiliki potensi untuk digunakan dalam prediksi nilai tukar karena mampu mempelajari pola historis dan karakteristik nonlinear pada data *time series* keuangan. Penelitian ini diharapkan dapat memberikan kontribusi sebagai referensi dalam pengembangan model prediksi nilai tukar berbasis *Deep Learning* serta mendukung pengambilan keputusan pada bidang ekonomi dan keuangan.

Namun demikian, penelitian ini masih memiliki keterbatasan karena hanya menggunakan satu variabel berupa harga penutupan (*closing price*) tanpa mempertimbangkan variabel eksternal lainnya. Selain itu, penelitian hanya menggunakan satu pasangan mata uang dan satu skema pembagian *data training-testing* sehingga hasil model masih berpotensi dipengaruhi oleh kondisi data pada periode tertentu.

Penelitian selanjutnya dapat dikembangkan dengan menambahkan variabel makroekonomi, menerapkan metode validasi *walk-forward cross validation*, melakukan prediksi multi-horizon, serta mengembangkan *interval prediction* agar model menjadi lebih adaptif dan interpretatif terhadap perubahan kondisi ekonomi global.

REFERENSI

- Aji, H. W. (2019). Prediksi Harga Bitcoin Dengan Menggunakan Metode Gated Recurrent Unit (Gru). *Skripsi ULM*, 112035.
- Arfan, A., & Lussiana ETP. (2019). Prediksi Harga Saham di Indonesia Menggunakan Algoritma Long Short-Term Memory. *Seminar Nasional Teknologi Informasi dan Komunikasi STIK (SeNTIK)*, 3(1), 2581–2327.

- Arifin, S., & Mayasya, S. (2018). Faktor - Faktor yang Mempengaruhi Nilai Tukar Rupiah terhadap Dolar Amerika Serikat. *Jurnal Ekonomi-Qu*, 8(1), 82–96. <https://doi.org/10.35448/jequ.v8i1.4965>
- ArunKumar, K. E., Kalaga, D. V., Mohan Sai Kumar, C., Kawaji, M., & Brenza, T. M. (2022). Comparative Analysis of Gated Recurrent Units (GRU), Long Short-Term Memory (LSTM) Cells, Autoregressive Integrated Moving Average (ARIMA), Seasonal Autoregressive Integrated Moving Average (SARIMA) for Forecasting COVID-19 Trends. *Alexandria Engineering Journal*, 61(10), 7585–7603. <https://doi.org/10.1016/j.aej.2022.01.011>
- Arwansyah, A., Suryani, S., SY, H., Usman, U., Ahyuna, A., & Alam, S. (2022). *Time series* Forecasting Menggunakan Deep Gated Recurrent Units. *Digital Transformation Technology*, 4(1), 410–416. <https://doi.org/10.47709/digitech.v4i1.4141>
- Ayyadevara, V. K. (2018). *Pro Machine Learning Algorithms*. Apress. https://doi.org/10.1007/978-1-4842-3564-5_10
- Brownlee, J. (2018). *Deep learning for Time Series Forecasting*. Machine Learning Mastery.
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The Coefficient of Determination R-squared is More Informative than SMAPE, MAE, MAPE, MSE and RMSE in Regression Analysis Evaluation. *PeerJ Computer Science*, 7, 1–18. <https://doi.org/10.7717/peerj-cs.623>
- Fischer, T., & Krauss, C. (2018). Deep learning with Long Short-Term Memory Networks for Financial Market Predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Giarsyani, N. (2020). Komparasi Algoritma Machine Learning dan Deep Learning untuk Named Entity Recognition: Studi Kasus Data Kebencanaan. *Indonesian Journal of Applied Informatics*, 4(2), 138. <https://doi.org/10.20961/ijai.v4i2.41317>
- Lee, K. (2018). Systematic Exchange Rate Variation: Where Does the Dollar Factor Come from? *International Review of Economics & Finance*, 56, 288–307. <https://doi.org/10.1016/j.iref.2017.10.030>
- Mokodongan, Z. Z. ., Rotinsulu, T. O., & Mandeij, D. M. (2018). Analisis Fluktuasi Tingkat Kurs Rupiah (Idr) terhadap Dollar Amerika (Usd) Pada sistem Kurs Mengambang Bebas di Indonesia Dalam Periode 2007.1-2014.4. *Jurnal Berkala Ilmiah Efisiensi*, 18(2), 135–145.
- Olah, C. (2015). *Understanding LSTM Networks*.
- Srisulistiwati, D. B., Khaerudin, M., & Rejeki, S. (2021). Sistem Informasi Prediksi Penjualan Alat Tulis Kantor dengan Metode Fp-Growth (Studi Kasus Toko Koperasi Sekolah Bina Mulia). *Jurnal Sistem Informasi Universitas Suryadarma*, 8(2). <https://doi.org/10.35968/jsi.v8i2.739>
- Yusuf, A. (2022). Prediksi Indeks Harga Saham Gabungan (IHSG) Menggunakan Long Short-Term Memory. *Jurnal Epsilon*, 15, 124–132.