

Perbandingan Metode GARCH, LSTM, GRU, dan CNN pada Peramalan Volatilitas Kurs

Adeline Vinda Septani^{1*}, Farit Mochamad Afendi², Anang Kurnia³

^{1,2,3}Departemen Statistika IPB University Bogor Indonesia

e-mail: 2809adelinevinda@apps.ipb.ac.id

Diajukan: 22 Desember 2024, Diperbaiki: 8 Januari 2025, Diterima: 14 Januari 2025

Abstrak

Volatilitas kurs merupakan salah satu aspek penting dalam analisis data deret waktu di bidang ekonomi dan keuangan. Penelitian ini bertujuan membandingkan kinerja empat metode, yaitu *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), dan *Convolutional Neural Network* (CNN), dalam memprediksi volatilitas kurs Rupiah terhadap Dollar Amerika. Data yang digunakan adalah kurs harian dari Januari 2015 hingga Maret 2024. Evaluasi dilakukan dengan menghitung *Root Mean Square Error* (RMSE) dan persentase nilai aktual dalam selang kepercayaan 95% pada data *training* dan *testing*. Hasil penelitian menunjukkan bahwa LSTM memiliki nilai RMSE terkecil, yaitu 0.0000250 pada data *testing*, menandakan akurasi yang tinggi dalam menangkap pola *non-linear* dan fluktuasi jangka panjang. GRU mencatat persentase nilai aktual dalam selang kepercayaan tertinggi, sebesar 92.39% pada data *testing*, menunjukkan konsistensi prediksi yang lebih baik dibandingkan metode lain. Sementara itu, GARCH menunjukkan performa kompetitif tetapi kurang robust pada data *testing*. CNN memiliki performa terendah dengan RMSE tinggi dan persentase data dalam selang kepercayaan rendah. Secara keseluruhan, GRU menjadi metode terbaik karena mampu memberikan keseimbangan optimal antara akurasi prediksi dan konsistensi, menjadikannya alat yang andal untuk memodelkan volatilitas kurs dalam situasi volatilitas tinggi, sehingga digunakan untuk peramalan volatilitas kurs 30 hari ke depan. Temuan ini memberikan kontribusi dalam memilih metode yang sesuai untuk memodelkan volatilitas kurs, terutama di tengah ketidakpastian pasar global.

Kata Kunci: *Convolutional Neural Network (CNN), Gated Recurrent Unit (GRU), Generalized Autoregressive Conditional Heteroscedasticity (GARCH), Long Short-Term Memory (LSTM), Volatilitas*

Abstract

Exchange rate volatility is a crucial aspect of time series analysis in the fields of economics and finance. This study aims to compare the performance of four methods: Generalized Autoregressive Conditional Heteroscedasticity (GARCH), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and Convolutional Neural Network (CNN) in predicting the volatility of the Rupiah against the US Dollar. The data used consists of daily exchange rates from January 2015 to March 2024. Evaluation is conducted by calculating the Root Mean Square Error (RMSE) and the percentage of actual values within the 95% confidence interval for both training and testing data. The results indicate that LSTM achieves the lowest RMSE, at 0.0000250 on the testing data, demonstrating high accuracy in capturing nonlinear patterns and long-term fluctuations. GRU records the highest percentage of actual values within the confidence interval, at 92.39% on the testing data, indicating better predictive consistency compared to other methods. Meanwhile, GARCH exhibits competitive performance but lacks robustness in the testing data. CNN performs the worst, with high RMSE and a low percentage of data within the confidence interval. Overall, GRU emerges as the best method, providing an optimal balance between prediction accuracy and consistency, making it a reliable tool for modeling exchange rate volatility in highly volatile conditions. Consequently, GRU is used for forecasting exchange rate volatility for the next 30 days. These findings

contribute to the selection of appropriate methods for modeling exchange rate volatility, particularly amid global market uncertainty.

Keywords: *Convolutional Neural Network (CNN), Gated Recurrent Unit (GRU), Generalized Autoregressive Conditional Heteroscedasticity (GARCH), Long Short-Term Memory (LSTM), Volatility*

1 Pendahuluan

Volatilitas merupakan salah satu aspek penting dalam analisis data deret waktu, terutama pada bidang ekonomi dan keuangan. Volatilitas mengukur tingkat fluktuasi harga atau nilai suatu aset dalam periode tertentu, dan mencerminkan risiko yang terkait dengan aset tersebut [1]. Tingkat volatilitas yang tinggi menggambarkan pasar yang tidak stabil, sehingga dapat meningkatkan ketidakpastian dalam peramalan pergerakan harga [2]. Hal ini menjadi penting dalam kaitannya dengan nilai tukar mata uang pada pasar keuangan, di mana perubahan nilai tukar dapat dipengaruhi oleh faktor ekonomi global, kebijakan moneter, hingga kondisi politik. Faktor-faktor tersebut akan menyebabkan volatilitas menjadi tinggi, dan bahkan ekstrem. Kondisi ini membuat model peramalan konvensional untuk analisis data deret waktu seperti Autoregressive Integrated Moving Average (ARIMA) yang didasarkan pada asumsi homogenitas ragam sisaan (homoskedastisitas) menjadi suatu keterbatasan. Ketika volatilitas tinggi terjadi, ARIMA tidak mampu menangani fluktuasi tersebut, menyebabkan hasil peramalan menjadi kurang akurat [3]. Salah satu cara yang dapat digunakan untuk menangani data yang memiliki volatilitas tinggi adalah dengan cara memodelkan ragamnya [4].

Generalized Autoregressive Conditional Heteroscedasticity (GARCH) adalah salah satu analisis data deret waktu yang dapat digunakan untuk memodelkan ragam sehingga volatilitas tinggi dapat diakomodir. GARCH merupakan pengembangan dari *Autoregressive Conditional Heteroscedasticity (ARCH)* yang memiliki kemampuan untuk meramalkan volatilitas dengan memasukkan informasi ragam dari periode sebelumnya ke dalam model, di samping bergantung pada kuadrat *error* pada periode sebelumnya [5]. GARCH banyak digunakan dalam memodelkan volatilitas harga saham, nilai tukar, dan komoditas, serta mampu menangkap dinamika volatilitas yang lebih kompleks. Selain metode GARCH, pendekatan baru yang adaptif dan efisien untuk meramalkan data sekuensial, seperti data volatilitas dapat dilakukan dengan penggunaan *deep learning* [6].

Deep learning adalah salah satu cabang dari *machine learning* yang berfokus pada model berbasis jaringan saraf tiruan (*artificial neural networks*) dengan banyak lapisan (*deep neural networks*). Model ini mencoba meniru cara kerja otak manusia dalam memproses data dan mengenali pola-pola yang kompleks [7]. *Deep learning* sering digunakan dalam berbagai bidang, salah satunya yaitu analisis data deret waktu. Dalam konteks analisis volatilitas, *deep learning*

dapat membantu meramalkan fluktuasi harga dengan cukup akurat, karena kemampuannya menangkap pola-pola tersembunyi dalam data yang tidak bisa ditangkap oleh model peramalan konvensional [8]. Dua arsitektur *deep learning* yang umum digunakan untuk analisis data deret waktu adalah *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU).

LSTM dan GRU adalah jenis *Recurrent Neural Networks* (RNN) yang dirancang untuk mengatasi kelemahan RNN standar, terutama masalah "vanishing gradient" yang terjadi ketika memproses data sekuensial dengan rentang panjang [9]. LSTM dan GRU memiliki mekanisme memori yang memungkinkan mereka mempertahankan informasi dari periode sebelumnya, sehingga cocok untuk data deret waktu dengan volatilitas yang dinamis, seperti harga saham atau nilai tukar mata uang. LSTM menggunakan struktur memori yang lebih kompleks dengan adanya tiga gerbang utama (*input*, *output*, dan *forget gate*), sedangkan GRU adalah versi yang lebih sederhana dan efisien, namun tetap mampu menangkap pola penting dalam data deret waktu [10].

Selain itu, *Convolutional Neural Networks* (CNN), yang umumnya digunakan dalam pengenalan gambar, juga dapat diterapkan dalam analisis data deret waktu [11]. CNN memiliki kemampuan untuk mengekstrak fitur-fitur penting dari data sekuensial dengan menggunakan filter yang melibatkan lapisan konvolusi. Ketika digunakan dalam analisis volatilitas, CNN dapat membantu menangkap pola lokal yang signifikan dalam fluktuasi harga, yang mungkin terlewat oleh model peramalan lainnya [12].

Berbagai penelitian sebelumnya telah menunjukkan efektivitas model *deep learning* dalam memprediksi volatilitas. Penelitian pada data saham yang membandingkan tiga metode, yaitu LSTM, LGBM, dan CNN, menunjukkan bahwa CNN lebih unggul dalam memprediksi realisasi volatilitas semua saham individual [13]. Penelitian serupa juga dilakukan dengan membandingkan metode GARCH dan LSTM pada data saham, dan hasilnya menunjukkan bahwa LSTM lebih baik dalam memprediksi volatilitas saham tersebut [14] [15]. Selain itu, studi tentang volatilitas harga perdagangan karbon di Hubei dan Guangdong yang membandingkan beberapa metode, termasuk GARCH, LSTM, dan GRU, menemukan bahwa GRU memberikan hasil prediksi yang lebih akurat dibandingkan model lainnya [16]. Penelitian yang mereka lakukan yaitu dengan membandingkan dua atau lebih metode untuk membandingkan

Dalam konteks nilai tukar mata uang, volatilitas sering kali tinggi dan sulit diprediksi. Nilai tukar Dollar Amerika terhadap Rupiah, misalnya, sering kali menunjukkan volatilitas yang signifikan. Volatilitas ini dapat berdampak langsung pada perdagangan internasional, daya saing ekonomi, dan stabilitas ekonomi nasional [17]. Prediksi yang akurat terhadap volatilitas kurs dapat membantu dalam pengambilan keputusan strategis, baik oleh pemerintah, pelaku pasar, maupun

perusahaan multinasional. Fluktuasi kurs yang tidak terduga dapat memengaruhi biaya impor dan ekspor, menciptakan risiko yang lebih besar dalam transaksi lintas negara [18].

Pandemi COVID-19 juga telah memberikan pengaruh besar terhadap volatilitas kurs global. Ketidakpastian ekonomi yang disebabkan oleh gangguan rantai pasokan, kebijakan *lockdown*, serta perubahan sentimen pasar menyebabkan volatilitas kurs meningkat secara signifikan [19]. Dollar Amerika terhadap Rupiah mengalami fluktuasi tajam selama pandemi, memperlihatkan volatilitas yang tinggi akibat ketidakpastian global. Perubahan ini sangat sulit diramalkan menggunakan model-model konvensional, karena perubahan yang terjadi selama pandemi melampaui asumsi stabilitas data. Dalam situasi ini, penggunaan model prediksi yang lebih adaptif seperti GARCH, LSTM, CNN, dan GRU menjadi sangat relevan untuk memodelkan volatilitas kurs selama krisis.

Penelitian ini bertujuan untuk membandingkan kinerja empat metode, yaitu GARCH, CNN, LSTM, dan GRU, dalam memprediksi volatilitas kurs antara Dollar Amerika dan Rupiah. Perbandingan keempat metode sekaligus tersebut merupakan perbandingan yang baru pertama kali dilakukan untuk menilai keunggulan dalam peramalan volatilitas. Melalui penelitian ini, diharapkan dapat memberikan kontribusi baru dengan mengevaluasi keempat metode tersebut secara bersamaan, dan ditemukan metode yang paling efektif untuk memprediksi volatilitas kurs yang tinggi dan fluktuatif, terutama dalam konteks ketidakpastian pasar global pasca pandemi COVID-19. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi bagi pengambilan keputusan yang lebih baik di sektor keuangan, terutama dalam menghadapi risiko yang terkait dengan fluktuasi nilai tukar.

2 Metode Penelitian

2.1 Return

Return adalah hasil yang didapatkan dari suatu investasi [20]. [21] menjelaskan bahwa return digunakan karena ada dua alasan. Pertama, return aset memberikan informasi investasi dengan skala peluang yang bebas. Kedua, data return lebih mudah dikelola daripada harga. Secara matematis, return dihitung dengan rumus:

$$R_t = \ln \left\{ \frac{y_t}{y_{t-1}} \right\} \quad (1)$$

dengan R_t merupakan return kurs ke- t , y_t merupakan kurs pada waktu ke- t , dan y_{t-1} merupakan kurs pada waktu ke- $(t-1)$.

2.2 Metode GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*)

GARCH digunakan saat residual tidak memenuhi homoskedastisitas. Model ini lebih fleksibel dibanding ARCH dan mampu mengakomodasi kondisi volatilitas dari ragam sisaan dan dapat menghasilkan ramalan dari ragamnya. Berikut persamaan umum model ARCH(q) [22].

$$\varepsilon_t = \sigma_t v_t \quad (2)$$

dengan

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 \quad (3)$$

Persamaan umum model GARCH (p,q) adalah sebagai berikut.

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (4)$$

dengan v_t menyebar bebas stokastik identik, $v_t \sim bsi(0,1)$, $\alpha_0 > 0$, $\alpha_i \geq 0$, $i = 1, 2, \dots, q$, $\beta_j \geq 0$, $j = 1, 2, \dots, p$ dan $\sum_{i=1}^{\max(p,q)} (\alpha_i + \beta_j) < 1$

2.3 Metode LSTM (*Long Short-Term Memory*)

LSTM diperkenalkan oleh Hochreiter dan Schmidhuber tahun 1997 untuk mengatasi masalah vanishing gradient pada RNN [23]. LSTM menggunakan tiga gerbang: *forget*, *input*, dan *output gates*. Adapun persamaan dalam struktur LSTM adalah sebagai berikut [24]:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t * \tanh(C_t) \quad (10)$$

dimana f_t merupakan *forget gate*, i_t merupakan *input gate*, o_t merupakan *output gate*, C_t merupakan *memory cell*, h_t merupakan *hidden state*, W dan b yaitu bobot matriks dan bias vektor, x_t yaitu nilai masukan untuk waktu saat ini (t), σ adalah fungsi aktivasi sigmoid, $*$ mengindikasikan *matrix multiplication*, dan \tanh merupakan fungsi aktivasi yang dapat disesuaikan dengan kebutuhan maupun karakteristik dari permasalahan yang akan diselesaikan.

2.4 Metode GRU (*Gated Recurrent Unit*)

GRU diperkenalkan pertama kali oleh Kyunghyun Cho dan kawan kawan tahun 2014. Metode ini merupakan pengembangan dari LSTM yang lebih sederhana namun efektif dalam mengatasi masalah vanishing gradient [25]. Ada beberapa komponen dalam *Gated Recurrent Unit*, yaitu *update gate* z_t , *reset gate* r_t , *new memory* \hat{h}_t , dan *current state* h_t [26].

Persamaan pada struktur *Gated Recurrent Unit* (GRU) adalah sebagai berikut:

$$r_{(t)} = \sigma(W_r \cdot x_{(t)} + U_r h_{(t-1)} + b_r) \quad (11)$$

$$\hat{h}_{(t)} = \tanh(U_h(r_{(t)} \odot h_{(t-1)}) + W_h x_{(t)} + b_h) \quad (12)$$

$$z_{(t)} = \sigma(W_z x_{(t)} + U_z h_{(t-1)} + b_z) \quad (13)$$

$$h_{(t)} = (1 - z_{(t)}) \odot h_{(t-1)} \oplus z_{(t)} \odot \hat{h}_{(t)} \quad (14)$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (15)$$

$$h_t = o_t * \tanh(C_t) \quad (16)$$

dimana W dan b yaitu bobot matriks dan bias vektor dari *forget gate*, x_t yaitu nilai masukan untuk waktu saat ini (t), σ adalah fungsi aktivasi sigmoid, \odot mengindikasikan *element-wise multiplication*.

2.5 Metode CNN (Convolutional Neural Network)

CNN, yang diperkenalkan oleh Lecun tahun 1998, lebih sering digunakan pada data citra, namun juga efektif untuk prediksi data deret waktu. Keunggulannya adalah efisiensi dalam pembelajaran berkat fitur *local perception* dan *weight sharing*. Dari sisi struktur, CNN utamanya terdiri dari dua bagian, yaitu layer konvolusi (*convolutional*) dan layer penyatuan (*pooling*) [27]. Dalam hal ini, setiap layer konvolusi berisi sejumlah kernel konvolusi, yang rumus penghitungannya ditunjukkan adalah sebagai berikut:

$$l_t = \tanh(x_t * k_t + b_t) \quad (17)$$

dengan l_t merupakan nilai keluaran setelah proses konvolusi, \tanh merupakan fungsi aktivasi yang umum digunakan, x_t merupakan vektor masukan, k_t merupakan nilai bobot dari kernel konvolusi, dan b_t merupakan bias dari kernel konvolusi ($b_t = 0$ apabila tidak menggunakan bias). Kemudian akan dilanjutkan dengan lapisan penyatuan dengan tujuan utama melakukan reduksi kembali terhadap jumlah fitur yang diekstraksi.

2.6 Ukuran Kebaikan Model

Penilaian kualitas suatu model sering kali melibatkan beberapa ukuran evaluasi untuk memberikan gambaran yang komprehensif. Dalam konteks ini, terdapat dua unsur utama yang digunakan sebagai ukuran kebaikan model, yaitu Root Mean Square Error (RMSE) dan persentase nilai aktual yang masuk ke dalam selang kepercayaan.

1. Root Mean Square Error (RMSE)

RMSE merupakan salah satu ukuran yang digunakan untuk menilai seberapa dekat prediksi model terhadap nilai sebenarnya [28]. Semakin kecil nilai RMSE, semakin baik model tersebut dalam merepresentasikan data. Persamaan RMSE dapat ditulis sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^T (\hat{\sigma}_i - \sigma_i)^2}{T}} \quad (18)$$

dengan $i = 1, 2, \dots, T$, σ_i yaitu nilai volatilitas dan korelasi sebenarnya, $\hat{\sigma}_i$ yaitu nilai prediksi dari volatilitas pada periode ke- t untuk masing-masing model, dan T yaitu banyaknya periode waktu.

RMSE dipilih sebagai ukuran kebaikan model karena lebih sensitif terhadap kesalahan prediksi besar dibandingkan ukuran lain seperti MAE, dengan memberikan penalti lebih tinggi pada error yang besar. Selain itu, RMSE memiliki satuan yang sama dengan data asli, sehingga lebih mudah diinterpretasikan dalam konteks volatilitas nilai tukar. Dibandingkan dengan MAPE, RMSE lebih sesuai untuk data dengan distribusi normal dan tidak terpengaruh oleh nilai aktual mendekati nol, seperti pada data volatilitas kurs dan harga CPO yang memiliki nilai nol. Keunggulan lainnya adalah kemampuannya menangkap variabilitas data dengan lebih baik, menjadikannya metrik yang ideal untuk mengevaluasi model prediksi volatilitas yang dinamis.

2. Selang Kepercayaan

Selain RMSE, penggunaan selang kepercayaan menjadi penting untuk menilai keandalan model dalam memprediksi data [29]. Selang kepercayaan membantu mengevaluasi seberapa besar persentase nilai aktual yang masuk ke dalam rentang prediksi dengan tingkat kepercayaan tertentu, misalnya 95%. Model dengan persentase nilai aktual yang mendekati nilai *confidence interval* dianggap lebih baik. Rumus selang kepercayaan adalah:

$$SK(1 - \alpha)\% = \bar{x} \pm Z_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \quad (19)$$

dengan \bar{x} adalah rata-rata dari data volatilitas, di mana dalam konteks ini diasumsikan $\bar{x} = 0$, $Z_{\frac{\alpha}{2}}$ adalah nilai kritis distribusi normal standar, σ merupakan ukuran penyebaran data yang dapat berubah-ubah akibat sifat heteroskedastisitas data.

Adapun perhitungan persentase nilai yang masuk ke selang dihitung sebagai berikut :

$$Persentase = \frac{\text{Jumlah nilai aktual dalam selang}}{\text{Total nilai}} \times 100\% \quad (20)$$

3. Kombinasi RMSE dan Selang Kepercayaan

Penentuan ukuran kebaikan model mempertimbangkan kedua unsur ini secara bersamaan. RMSE memberikan informasi tentang akurasi rata-rata prediksi, sedangkan persentase nilai aktual yang masuk ke dalam selang kepercayaan mencerminkan keandalan model dalam memprediksi data. Gabungan dari kedua aspek ini memberikan pendekatan evaluasi yang lebih lengkap untuk memastikan model yang terbaik dipilih, baik dari segi akurasi maupun keandalan.

2.7 Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini adalah data empiris sekunder nilai kurs atau nilai tukar mata uang Rupiah Indonesia (IDR) atas Dollar Amerika (USD). Data tersebut menggunakan data kurs tengah yang merupakan perhitungan rata-rata dari kurs jual dan kurs beli yang bersumber

dari <https://www.bi.go.id/>. Periode data berupa harian dari bulan Januari 2015 – Maret 2024, sehingga perubahan nilai kurs menjadi lebih fluktuatif.

2.8 Tahapan Analisis

Beberapa tahapan analisis yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Eksplorasi Data

Eksplorasi data bertujuan untuk memahami karakteristik dan pola data kurs yang digunakan dalam pemodelan. Pada tahapan ini, akan ditampilkan visualisasi data dan statistik deskriptif dari data histori kurs dan data volatilitas kurs.

2. Pra-pemrosesan Data Pemodelan

Pra-pemrosesan data bertujuan untuk menyiapkan data agar sesuai untuk dimasukkan ke dalam model. Pada tahapan ini, dilakukan normalisasi atau standarisasi data pada metode LSTM, GRU, dan CNN untuk memastikan kestabilan dalam proses pelatihan. Selain itu, dilakukan pembagian data ke dalam empat kelompok menggunakan metode *Sliding Window Cross-Validation*. Pendekatan ini memungkinkan evaluasi model yang lebih *robust* dengan memanfaatkan data secara berulang melalui pemisahan data ke dalam kelompok *training* dan *testing* dengan rentang waktu yang bergeser secara bertahap. Dalam setiap kelompok, data dibagi dengan persentase 80% untuk *training* dan 20% untuk *testing*.

Keunggulan metode *Sliding Window Cross-Validation* ini adalah menjaga urutan waktu yang penting dalam analisis deret waktu, sehingga hasil evaluasi mencerminkan performa model dalam kondisi data dunia nyata. Tahap pertama pemisahan data ini bertujuan untuk menentukan kombinasi model dan *hyperparameter* terbaik bagi metode GARCH, LSTM, GRU, dan CNN. Performa model diukur berdasarkan rata-rata RMSE dari keempat kelompok data, sehingga diperoleh model serta *hyperparameter* yang optimal untuk setiap metode.

Setelah model dan *hyperparameter* terbaik ditentukan, dilakukan pemisahan data kedua pada seluruh dataset nilai tukar dengan membaginya menjadi 80% untuk *training* dan 20% untuk *testing*. Pemisahan ini bertujuan untuk mengevaluasi dan membandingkan metode yang telah ditentukan sebelumnya menggunakan data penuh, sehingga dapat diperoleh metode terbaik berdasarkan performa prediksi pada data yang belum pernah dilihat model sebelumnya.

Dengan demikian, dua tahap pemisahan data ini memungkinkan seleksi optimal *hyperparameter* serta model terbaik terlebih dahulu sebelum dilakukan evaluasi akhir terhadap metode yang paling efektif dalam memprediksi nilai tukar. Hal ini memastikan bahwa model yang diterapkan pada data penuh telah diuji dan disesuaikan dengan konfigurasi terbaik, sehingga menghasilkan prediksi yang lebih akurat dan andal.

Tabel 1. Pembagian Data Kurs Menjadi 4 Kelompok Data Menggunakan Sliding Window Cross-Validation

Kelompok data	Rentang waktu
1	Januari 2015 s.d. Juni 2017
2	Juli 2017 s.d. Desember 2019
3	Januari 2020 s.d. Juni 2022
4	Juli 2022 s.d. Maret 2024

3. Pemodelan dan *Fine-Tuning Hyperparameter*

Tahapan ini melibatkan penerapan dan pelatihan masing-masing metode, yaitu GARCH, LSTM, GRU, dan CNN untuk memprediksi volatilitas kurs dengan *fine-tuning hyperparameter* untuk mencapai performa terbaik

- Metode GARCH

Empat variasi model GARCH yang digunakan dalam penelitian ini yaitu GARCH(1,1), GARCH(1,2), GARCH(1,3), dan GARCH(1,4).

- Metode LSTM, GRU, dan CNN

Model dikembangkan dengan menyesuaikan berbagai *hyperparameter* seperti *optimizer*, *activation function*, *dropout*, *jumlah layer*, *learning rate*, dan lain sebagainya.

Berikut adalah *hyperparameter* yang diaplikasikan dalam metode LSTM.

Tabel 2. *Hyperparameter Model LSTM*

<i>Hyperparameter</i>	Nilai
<i>Optimizer</i>	Adam, RMSprop, SGD
<i>Activation</i>	Relu, linear, swish, sigmoid, tanh
Banyak <i>layer</i>	1
<i>Dropout</i>	0.15
Banyak neuron	[20, 100]
<i>Learning rate</i>	0.001
<i>Epochs</i>	10

Berikut adalah *hyperparameter* yang diaplikasikan dalam metode GRU.

Tabel 3. *Hyperparameter Model GRU*

<i>Hyperparameter</i>	Nilai
<i>Learning rate</i>	[0.01, 0.0001]
<i>Unit layer</i>	[32, 512]
<i>Epochs</i>	[1, 10]
<i>Batch size</i>	32
<i>Dropout</i>	0.2
<i>Optimizer</i>	Adam
<i>Activation</i>	relu

Berikut adalah *hyperparameter* yang diaplikasikan dalam metode CNN.

Tabel 4. *Hyperparameter Model CNN*

<i>Hyperparameter</i>	<i>Nilai</i>
<i>Kernel size</i>	2
Banyak <i>filter</i>	[32, 64]
<i>Optimizer</i>	Adam
<i>Activation</i>	Relu, sigmoid
<i>Hidden Dropout</i>	[0.05, 0.2]
<i>Convolutional Dropout</i>	[0.05, 0.2]
<i>Convolution layer number</i>	[1, 5]
<i>Hidden Layer Number</i>	[1, 5]
<i>Layer unit</i>	[50, 100]
<i>Learning Rate</i>	0.0001
<i>Epochs</i>	10
<i>Batch size</i>	16
<i>Pool Size</i>	2

Dalam penelitian ini, optimasi *hyperparameter* dilakukan menggunakan *Randomized Search Cross-Validation (RandomizedSearchCV)* untuk menentukan kombinasi terbaik. Pemilihan nilai *hyperparameter* yang bersifat kontinu dilakukan dengan fungsi ‘*randint*’ dari *scipy.stats*, memungkinkan eksplorasi arsitektur model yang lebih fleksibel dibandingkan pendekatan diskret.

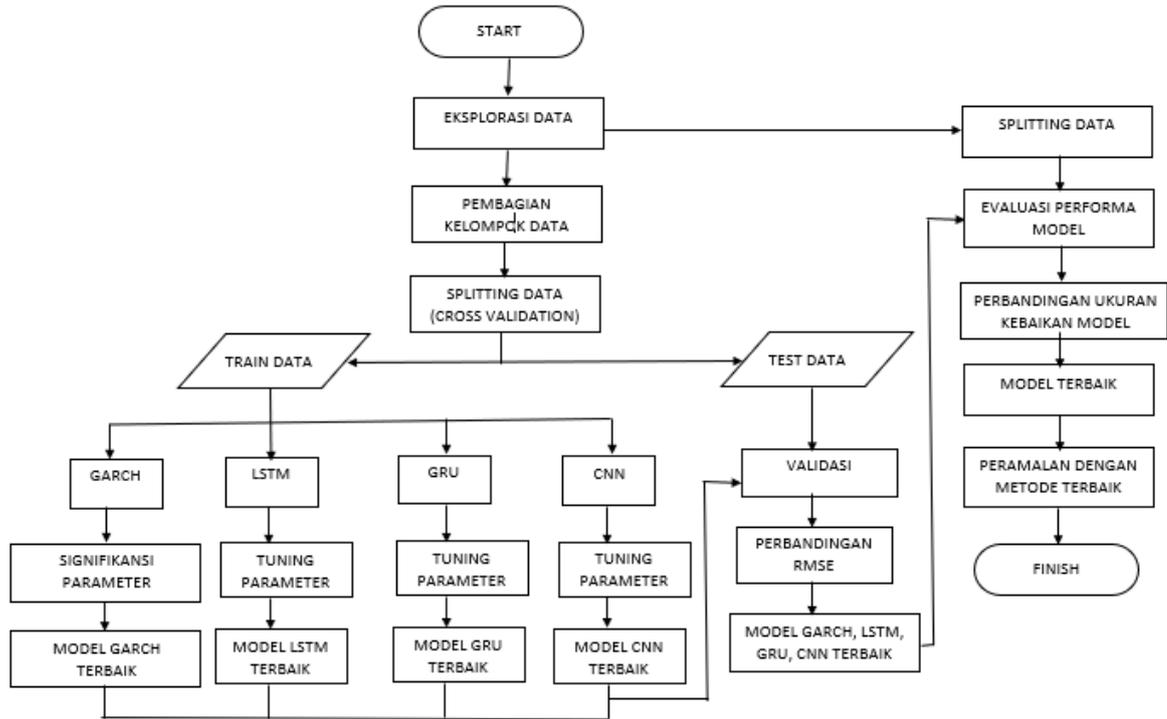
Proses optimasi memanfaatkan validasi silang *TimeSeriesSplit* untuk memastikan evaluasi yang lebih akurat pada data deret waktu, dengan pemilihan kombinasi terbaik berdasarkan nilai *Mean Squared Error (MSE)* terendah. Untuk meningkatkan reproduibilitas hasil, nilai *random seed* dikontrol pada *numpy* dan *TensorFlow*, memastikan hasil yang konsisten dalam setiap proses pelatihan model.

Fine-tuning dilakukan menggunakan *Randomized Search*, yang lebih efisien dibandingkan *grid search* karena dapat mengurangi waktu komputasi sambil tetap mengeksplorasi berbagai kombinasi secara acak. Pendekatan ini memungkinkan pencarian konfigurasi optimal dengan lebih cepat, meningkatkan efektivitas optimasi model.

4. Evaluasi Performa Model

Tahapan ini akan dilakukan penerapan model dengan kombinasi *hyperparameter model* terbaik dengan menggunakan data *training* dan *testing* keseluruhan untuk keempat metode yang digunakan. Kemudian dilakukan perhitungan RMSE dan pembuatan selang kepercayaan keempat metode, baik data *training* maupun *testing*, dan akan dibandingkan serta dipilih metode yang terbaik berdasarkan nilai RMSE dan persentase nilai aktual dalam selang kepercayaan keempat metode dengan data *testing*.

5. Peramalan Data Volatilitas Kurs Berdasarkan Model Terbaik

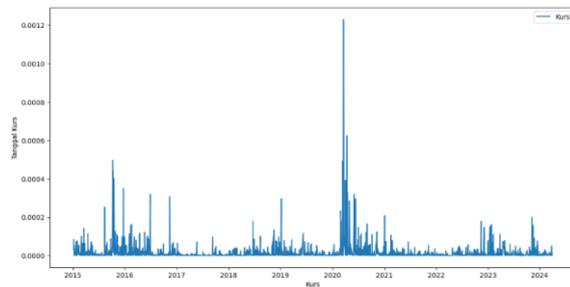
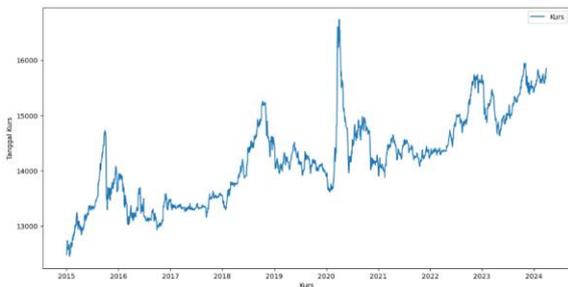


Gambar 1. Flowchart Tahapan Analisis

3 Hasil dan Pembahasan

3.1 Eksplorasi Data

Data harian pada nilai kurs rupiah atas Dollar AS dari bulan Januari 2015 sampai bulan Maret 2024 adalah sebanyak 2270 pengamatan. Data ini akan dilakukan pengeksplorasian dengan menggunakan plot *time series* untuk mengetahui informasi awal, seperti pola pergerakan nilai kurs. Selain eksplorasi data harian kurs, eksplorasi juga dilakukan pada data volatilitas kurs yang didapatkan dari perhitungan *squared return* kurs harian.



Gambar 2. Plot time series data harian kurs Gambar 3. Plot time series data volatilitas kurs

Gambar 1 menunjukkan plot perkembangan nilai kurs rupiah atas dollar AS harian dengan periode waktu. Perkembangan nilai kurs dari periode 2015-2024 secara umum mengalami peningkatan, namun cukup berfluktuasi. Pada gambar juga dapat dilihat bahwa tidak ada pola

musiman, tetapi jelas terlihat terdapat perbedaan variansi. Nilai kurs rupiah atas dollar AS tertinggi terjadi pada tanggal 2 April 2020 yaitu Rp16.741. Peningkatan kurs yang sangat tinggi dan pelemahan signifikan ini terjadi sekitar satu bulan setelah terjadinya pandemi COVID-19 di Indonesia, yang memicu kepanikan di pasar keuangan global dan mengakibatkan gejolak ekonomi yang besar.

Sementara itu, Gambar 2 menunjukkan plot volatilitas nilai kurs rupiah atas dollar AS harian pada periode waktu yang sama. Dari gambar tersebut, terlihat bahwa volatilitas kurs relatif rendah dan stabil dari tahun 2015 hingga 2019. Namun, pada awal tahun 2020, volatilitas mengalami lonjakan yang signifikan, bersamaan dengan dampak pandemi COVID-19 yang meluas. Lonjakan kurs dan peningkatan volatilitas yang terjadi bersamaan ini memperlihatkan pola yang sejalan pada kedua gambar, menandakan bahwa krisis akibat pandemi menjadi pemicu utama ketidakstabilan di pasar keuangan pada tahun 2020. Dengan demikian, kedua gambar ini menunjukkan bahwa pandemi COVID-19 tidak hanya menyebabkan peningkatan nilai kurs tetapi juga mengakibatkan fluktuasi yang lebih besar dalam nilai tukar rupiah terhadap dolar AS.

3.2 Pemodelan

Setelah melakukan eksplorasi data, tahapan selanjutnya yang dilakukan yaitu memodelkan data volatilitas kurs dengan menggunakan metode GARCH, LSTM, GRU, dan CNN pada 4 kelompok data. Kelompok data ini masing-masingnya dibagi ke dalam data *training* dan *testing*.

Model GARCH yang diterapkan pada data volatilitas kurs terdapat 4 model, yaitu GARCH (1,1), GARCH (1,2), GARCH (1,3), dan GARCH (1,4). Ketiga metode yang lain, yaitu metode LSTM, GRU, dan CNN menggunakan 10 kombinasi *hyperparameter* model. Setelah dilakukan analisis keempat metode tersebut, maka didapatkan model GARCH dan kombinasi *hyperparameter* terbaik dengan rata-rata RMSE terendah.

Model GARCH (1,1) terbaik baik dari data *testing* yang memiliki nilai RMSE terkecil dibandingkan dengan ketiga model lainnya. Nilai RMSE *testing* adalah sebesar 0.0000134268. Model GARCH ini juga memiliki semua parameter signifikan yang sudah dilakukan pengujian sebelumnya.

Kombinasi *hyperparameter model* terbaik untuk metode LSTM pada volatilitas kurs data *testing* adalah dengan kombinasi *optimizer RMSprop*, *neuron* sebanyak 40, dan *activation linear* dengan rata-rata RMSE modelnya sebesar 0.0345 yang lebih kecil dibandingkan dengan kombinasi lain. Berdasarkan hal ini, maka kombinasi *hyperparameter model* yang akan diterapkan pada data *training* dan *testing* volatilitas kurs keseluruhan dalam pengevaluasian model adalah kombinasi terbaik pada data *testing* yaitu *optimizer RMSprop*, *neuron* sebanyak 40, dan *activation linear*.

Kombinasi *hyperparameter model* terbaik untuk metode GRU pada volatilitas kurs data *testing* adalah kombinasi *unit layer* sebanyak 64, *learning rate* sebesar 0.0001 dengan rata-rata RMSE modelnya sebesar 0.0394 yang lebih kecil dibandingkan dengan kombinasi lain. Berdasarkan hal ini, maka kombinasi *hyperparameter model* untuk metode GRU yang akan diterapkan pada data *training* dan *testing* volatilitas kurs keseluruhan dalam pengevaluasian model adalah kombinasi terbaik pada data *testing* yaitu *unit layer* sebanyak 64, *learning rate* sebesar 0.0001.

Kombinasi *hyperparameter model* terbaik untuk metode CNN pada volatilitas kurs data *testing* adalah kombinasi *convolutional dropout* sebesar 0.104228, *hidden dropout* sebesar 0.128298, *filter* sebanyak 38, *convolutional layer* sebanyak 4, *hidden layer* sebanyak 5, dan *layer unit* sebanyak 58 dengan rata-rata RMSE modelnya sebesar 0.0364 yang lebih kecil dibandingkan dengan kombinasi lain. Berdasarkan hal ini, maka kombinasi *hyperparameter model* untuk metode GRU yang akan diterapkan pada data *training* dan *testing* volatilitas kurs keseluruhan dalam pengevaluasian model adalah kombinasi terbaik pada data *testing* yaitu kombinasi *convolutional dropout* sebesar 0.104228, *hidden dropout* sebesar 0.128298, *filter* sebanyak 38, *convolutional layer* sebanyak 4, *hidden layer* sebanyak 5, dan *layer unit* sebanyak 58.

3.3 Evaluasi Performa Model

Setelah didapatkan model GARCH terbaik dan kombinasi *hyperparameter model* terbaik untuk metode LSTM, GRU, CNN, maka tahapan selanjutnya adalah menerapkan model/kombinasi terbaik tersebut ke dalam data volatilitas kurs keseluruhan yang terbagi menjadi data *training* dan *testing*. Metode yang memiliki kinerja terbaik pada peramalan volatilitas kurs ditentukan dari nilai RMSE yang paling kecil dan persentase terbesar actual berada dalam selang kepercayaan.

Tabel 5. Penentuan Metode Terbaik pada Data Volatilitas Kurs

Data	Metode	Nilai RMSE
<i>Training</i>	GARCH	0.0000632
	LSTM	0.0000533
	GRU	0.0000561
	CNN	0.04952
<i>Testing</i>	GARCH	0.0000259
	LSTM	0.0000250
	GRU	0.0000256
	CNN	0.02191

Tabel 6. Persentase Data Aktual Berada Dalam Selang Kepercayaan

Data	Metode	Persentase
<i>Training</i>	GARCH	90.04
	LSTM	84.40
	GRU	89.88
	CNN	59.85
<i>Testing</i>	GARCH	78.52
	LSTM	83.67
	GRU	92.39
	CNN	63.31

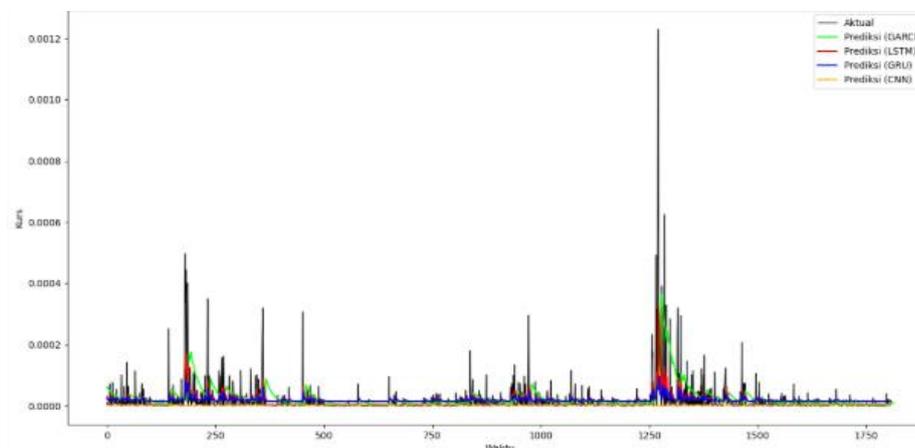
Tabel 5 menunjukkan bahwa metode yang memiliki RMSE terkecil untuk data *training* dan *testing* adalah metode LSTM dengan nilai RMSE masing-masingnya yaitu 0.0000533 dan 0.0000250. Nilai RMSE yang kecil pada data *testing* ini menunjukkan bahwa model LSTM memiliki tingkat *error* prediksi yang paling rendah, sehingga lebih akurat dalam menangkap pola volatilitas kurs dibandingkan metode lainnya seperti GARCH, GRU, dan CNN. Namun, selisih nilai RMSE antara LSTM, GRU dan GARCH cukup kecil, menunjukkan bahwa ketiga metode ini memiliki kemampuan yang hampir setara dalam memprediksi volatilitas kurs. Sebagai contoh, RMSE GRU untuk data *testing* sebesar 0.0000256. Untuk GARCH, nilai RMSE data *testing* sebesar 0.0000259. Perbedaan kecil ini menandakan bahwa ketiga metode mampu menangkap pola volatilitas kurs dengan baik, meskipun LSTM sedikit lebih unggul karena kemampuannya dalam menangani pola *non-linear* dan fluktuasi jangka panjang. Selain itu, metode CNN menunjukkan performa yang kurang optimal dengan nilai RMSE yang jauh lebih tinggi dibandingkan ketiga metode lainnya. Hal ini konsisten dengan kekurangan arsitektur CNN yang lebih cocok untuk pengenalan pola spasial daripada data sekuensial seperti volatilitas kurs. CNN tidak memiliki mekanisme internal untuk menangkap ketergantungan jangka panjang dalam data temporal, sehingga hasil prediksinya cenderung kurang akurat.

Tabel 6 memberikan sudut pandang tambahan untuk menentukan metode terbaik dengan melihat persentase data aktual yang masuk ke dalam selang kepercayaan. Dari tabel ini, metode GRU mencatat persentase tertinggi dan paling dekat dengan tingkat kepercayaan yang digunakan yaitu 95% dibandingkan model lainnya, baik pada data *training* maupun *testing*. Persentase untuk GRU pada data *training* adalah 89.88%, sedangkan pada data *testing* adalah 92.39%. Nilai ini lebih tinggi dibandingkan metode LSTM, yang mencatat persentase sebesar 84.40% pada data *training* dan 83.67% pada data *testing*, serta metode GARCH (90.04% pada *training* dan 78.52% pada *testing*). Tingginya persentase GRU menunjukkan bahwa model ini lebih sering

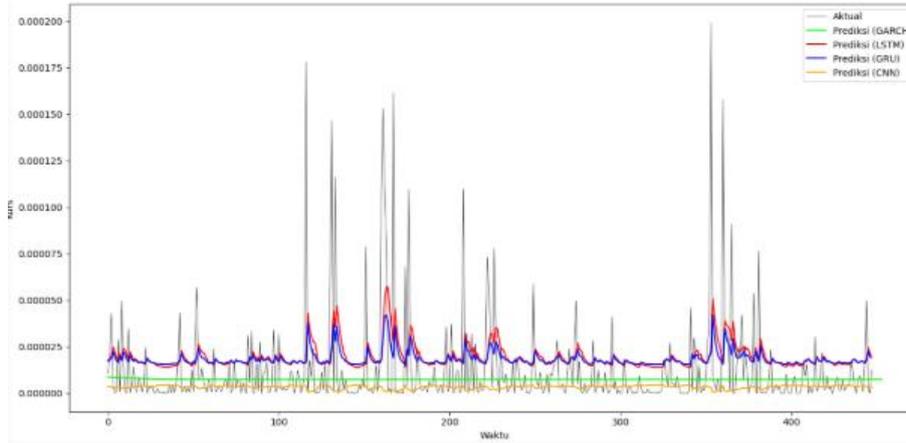
menghasilkan prediksi yang berada dalam selang kepercayaan, sehingga lebih konsisten dibandingkan metode lainnya. Sebaliknya, metode CNN kembali mencatat performa yang terendah dalam Tabel 6, dengan persentase hanya 59.85% pada data *training* dan 63.31% pada data *testing*. Hal ini sejalan dengan nilai RMSE yang tinggi pada CNN, menegaskan bahwa metode ini tidak cocok untuk memprediksi volatilitas kurs.

Secara keseluruhan, kombinasi hasil dari Tabel 5 dan Tabel 6 menunjukkan bahwa metode terbaik untuk memprediksi volatilitas kurs adalah GRU. Meskipun LSTM mencatat nilai RMSE terkecil pada data *testing*, nilai RMSE GRU sangat mendekati LSTM dan tidak menunjukkan perbedaan signifikan. Di sisi lain, GRU unggul secara signifikan dalam persentase data aktual yang berada dalam selang kepercayaan, yang mencerminkan konsistensi prediksi yang lebih baik dibandingkan dengan LSTM dan metode lainnya. Oleh karena itu, GRU dapat dianggap sebagai metode terbaik secara keseluruhan karena mampu memberikan keseimbangan antara akurasi prediksi (RMSE kecil) dan konsistensi (persentase selang kepercayaan tinggi).

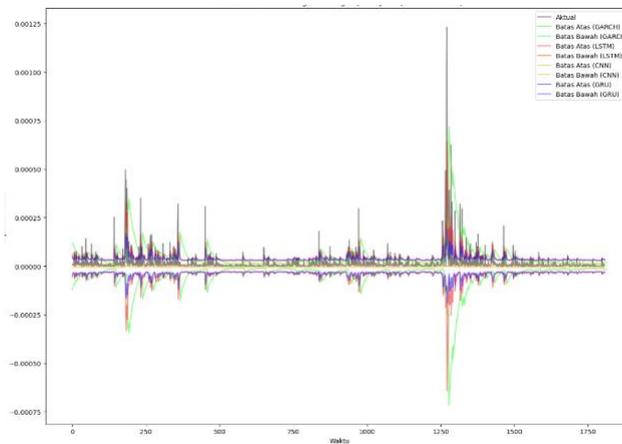
Visualisasi perbandingan kinerja metode berdasarkan RMSE ditampilkan pada Gambar 3 (data *training*) dan Gambar 4 (data *testing*). Sementara itu, visualisasi aktual dan selang kepercayaan keempat metode ditampilkan pada Gambar 5 (data *training*) dan Gambar 6 (data *testing*), yang mendukung kesimpulan bahwa GRU lebih unggul dibandingkan metode lainnya.



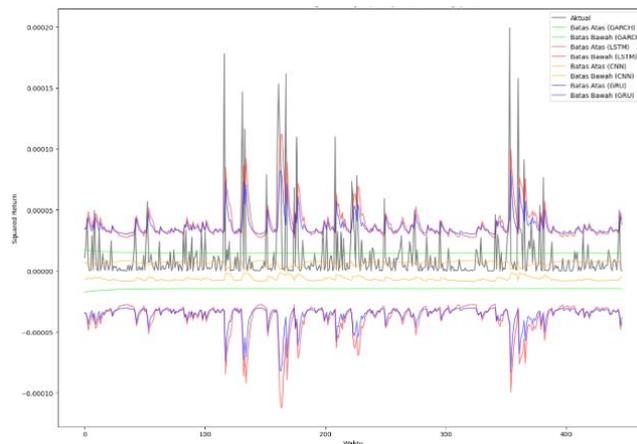
Gambar 4. Perbandingan Kinerja Data Training



Gambar 5. Perbandingan Kinerja Data *Testing*



Gambar 6. Selang Kepercayaan Data *Training*

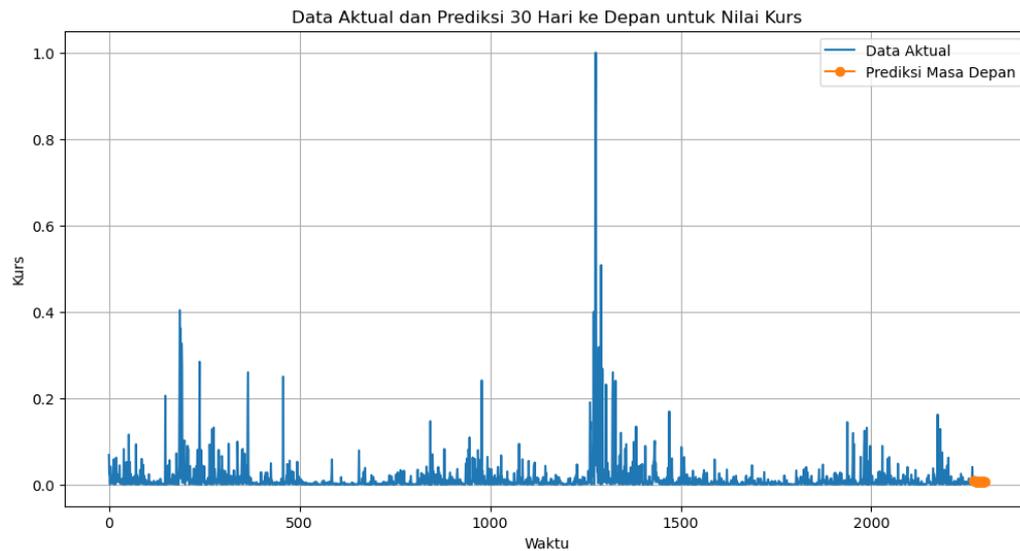


Gambar 7. Selang Kepercayaan Data *Testing*

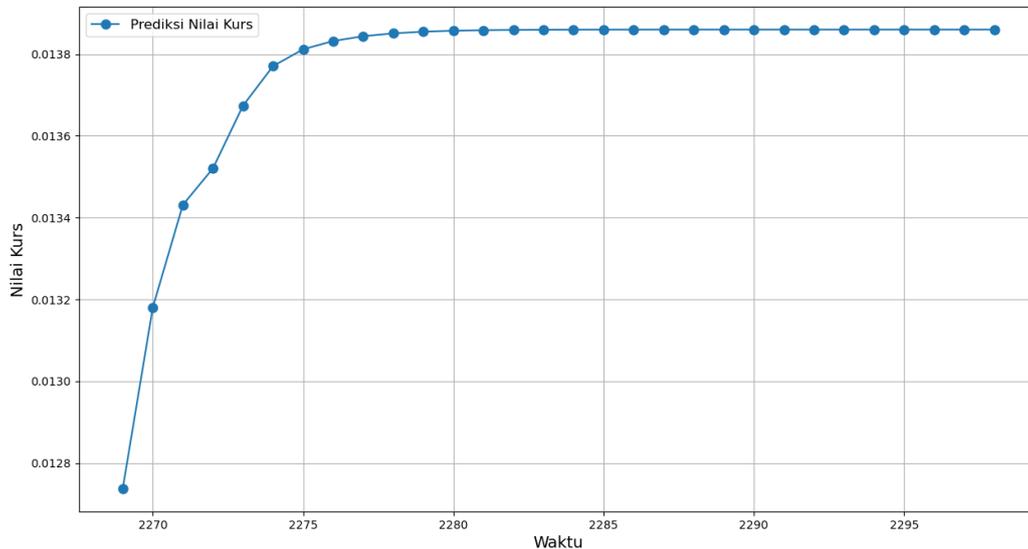
3.4 Peramalan Data Volatilitas Kurs Berdasarkan Metode Terbaik

Peramalan volatilitas kurs dilakukan menggunakan metode terbaik yang telah diidentifikasi pada tahapan sebelumnya, yaitu GRU. Pemilihan GRU sebagai metode terbaik didasarkan pada kinerja model yang unggul dalam menghasilkan nilai RMSE paling rendah dan persentase nilai

aktual dalam selang kepercayaan paling tinggi, baik untuk data *training* maupun data *testing*, yang menunjukkan kemampuan prediksi yang akurat dan stabil. Pada model GRU ini, kombinasi *hyperparameter* terbaik yang digunakan adalah kombinasi kombinasi *unit layer* sebanyak 64, *learning rate* sebesar 0.0001. Peramalan ini dilakukan untuk 30 hari ke depan yang dapat dilihat pada Gambar 8 dan 9. Gambar 8 menunjukkan data aktual kurs hingga titik waktu terakhir dan hasil prediksi volatilitas kurs untuk periode 30 hari ke depan yang diwakili oleh garis *orange*. Sedangkan Gambar 9 menunjukkan pola prediksi volatilitas kurs untuk periode 30 hari ke depan.



Gambar 8. Peramalan Volatilitas Kurs 30 Hari ke Depan



Gambar 9. Pola Peramalan Volatilitas Kurs 30 Hari ke Depan

4 Simpulan

1. LSTM memiliki performa terbaik dalam memprediksi volatilitas kurs Rupiah terhadap Dollar Amerika dengan nilai RMSE terkecil pada data pelatihan. Hal ini menandakan bahwa LSTM sangat baik dalam menangkap pola non-linear dan fluktuasi jangka panjang dalam volatilitas kurs.
2. GRU unggul dalam hal persentase data aktual dalam selang kepercayaan, dengan nilai tertinggi di antara semua metode, yaitu 89.88% pada data *training* dan 92.39% pada data *testing*. Ini menunjukkan bahwa GRU lebih konsisten dalam menghasilkan prediksi yang berada dalam rentang toleransi.
3. GARCH memiliki performa yang kompetitif pada data *training*, tetapi menunjukkan penurunan pada data *testing*, dengan nilai persentase selang kepercayaan yang lebih rendah (78.52%) dibandingkan dengan GRU dan LSTM. Hal ini menunjukkan bahwa GARCH kurang *robust* pada data *testing*.
4. CNN menunjukkan performa terendah dibandingkan metode lainnya, dengan nilai RMSE yang tinggi dan persentase data dalam selang kepercayaan yang sangat rendah. Hal ini menunjukkan bahwa CNN tidak cocok untuk data sekuensial seperti volatilitas kurs karena kurang mampu menangkap pola temporal yang dinamis.
5. Metode terbaik secara keseluruhan untuk memprediksi volatilitas kurs adalah GRU, karena memiliki kombinasi yang optimal antara akurasi prediksi (RMSE kecil, mendekati LSTM) dan konsistensi (persentase selang kepercayaan tertinggi). Meskipun LSTM memiliki RMSE terkecil, keunggulan GRU dalam menangkap pola volatilitas secara konsisten membuatnya lebih dapat diandalkan dalam aplikasi nyata.

5 Saran

Penelitian ini masih terbatas pada analisis data historis tanpa mempertimbangkan faktor eksternal yang berpotensi memengaruhi volatilitas harga, seperti kondisi ekonomi makro, kebijakan perdagangan, atau peristiwa global. Untuk pengembangan lebih lanjut, disarankan agar model prediksi tidak hanya mengandalkan data historis, tetapi juga memasukkan variabel eksternal yang relevan. Dengan demikian, model dapat lebih akurat dalam menangkap dampak dari faktor eksternal terhadap volatilitas harga serta meningkatkan kualitas prediksi yang dihasilkan.

6 Daftar Pustaka

- [1] P. A. Supriati and N. L. P. Wiagustini, “PENGARUH VOLUME PERDAGANGAN TERHADAP VOLATILITAS (Studi pada Bursa Efek Indonesia dan New York Stock Exchange),” *E-Jurnal Manaj. Univ. Udayana*, vol. 8, no. 4, p. 2438, 2019, doi: 10.24843/ejmunud.2019.v08.i04.p20.
- [2] L. K. Sari, N. A. Achsani, and B. Sartono, “Pemodelan Volatilitas Return Saham: Studi Kasus Pasar Saham Asia Modelling Volatility of Return Stock Index: Evidence from Asian Countries,” *J. Ekon. dan Pembang. Indones.*, vol. 18, no. 1, pp. 35–52, 2017.
- [3] L. Aulia, S. Salsabilla, W. Sulistijanti, and A. M. Mardiyah, “Analisis Volatilitas Return Saham PT . Bumi Serpong Damai Tbk . Menggunakan Metode,” vol. 02, no. 02, 2021.
- [4] D. H. Ratnasari, Tarno, and H. Yasin, “Peramalan Volatilitas Menggunakan Model Generalized Autoregressive Conditional Heteroscedasticity in Mean (GARCH-M),” *J. Gaussian*, vol. 3, no. 4, pp. 655–662, 2014, [Online]. Available: <http://ejournal-s1.undip.ac.id/index.php/gaussian>
- [5] S. N. Brilliantya, “Model EGARCH dan TGARCH untuk Mengukur Volatilitas Asimetris Return Saham,” vol. 9, pp. 356–363, 2022.
- [6] A. Casolaro, V. Capone, G. Iannuzzo, and F. Camastra, “Deep Learning for Time Series Forecasting: Advances and Open Problems,” *Inf.*, vol. 14, no. 11, 2023, doi: 10.3390/info14110598.
- [7] M. Ferian, R. Akbari, B. Rahayudi, and L. Muflikhah, “Implementasi Deep Learning menggunakan Algoritma EfficientDet untuk Sistem Deteksi Kelayakan Penerima Bantuan Langsung Tunai berdasarkan Citra Rumah di Wilayah Kabupaten Kediri,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 4, pp. 1817–1825, 2023.
- [8] F. T. Nosa, “Analisis Peramalan Harga Kopi Robusta London dengan Menggunakan Recurrent Neural Network-Long Short Term Memory (RNN-LSTM),” vol. 9, pp. 356–363, 2022.
- [9] A. Arwansyah, S. Suryani, H. SY, U. Usman, A. Ahyuna, and S. Alam, “Time Series Forecasting Menggunakan Deep Gated Recurrent Units,” *Digit. Transform. Technol.*, vol. 4, no. 1, pp. 410–416, 2022, doi: 10.47709/digitech.v4i1.4141.
- [10] E. Nur Cahyo and E. Susanti, “Analisis Time Series Untuk Deep Learning Dan Prediksi Data Spasial Seismik: Studi Literatur,” *J. Teknol.*, vol. 15, no. 2, pp. 124–136, 2023, doi: 10.34151/jurtek.v15i2.3581.
- [11] A. P. Wibawa, A. B. P. Utama, H. Elmunsyah, U. Pujianto, F. A. Dwiyanto, and L.

- Hernandez, "Time-series analysis with smoothed Convolutional Neural Network," *J. Big Data*, vol. 9, no. 1, 2022, doi: 10.1186/s40537-022-00599-y.
- [12] R. Reisenhofer, X. Bayer, and N. Hautsch, "HARNet: A Convolutional Neural Network for Realized Volatility Forecasting," *SSRN Electron. J.*, no. 2009, pp. 1–22, 2022, doi: 10.2139/ssrn.4116642.
- [13] J. Li, "The Comparison of LSTM, LGBM, and CNN in Stock Volatility Prediction," 2022. [Online]. Available: <https://www.kaggle.com/c/optiver-realized-volatility->
- [14] R. Liu, Y. Jiang, and J. Lin, "Forecasting the Volatility of Specific Risk for Stocks with LSTM," *Procedia Comput. Sci.*, vol. 202, pp. 111–114, 2022, doi: 10.1016/j.procs.2022.04.015.
- [15] Y. Wang, M. Liu, Z. Bao, and S. Zhang, "Short-term load forecasting with multi-source data using gated recurrent unit neural networks," *Energies*, vol. 11, no. 5, 2018, doi: 10.3390/en11051138.
- [16] J. Hao, X. Bao, S. Guan, and G. Jiang, "Transfer Prediction for the Price Volatility of Carbon Trading with Hybrid Gated Recurrent Unit," 2023, [Online]. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4523090
- [17] F. Zahroh, Z. Zainuri, and R. Purtomo, "Pengaruh Volatilitas Nilai Tukar terhadap Volume Perdagangan Internasional di ASEAN-3," *e-Journal Ekon. Bisnis dan Akunt.*, vol. 6, no. 1, p. 28, 2019, doi: 10.19184/ejeba.v6i1.11071.
- [18] Kholid Mawardi, "Dampak Nilai Tukar Mata Uang Terhadap Perdagangan Internasional," *Maret*, vol. 2, no. 1, pp. 88–102, 2023, [Online]. Available: <https://doi.org/10.58192/ocean.v2i2.959>
- [19] K. Benzid, Lamia; Chebbi, "Impact of Covid-19 Virus on Exchange Rate Volatility: Evidence Through GARCH Model," *SSRN Electron. J.*, 2020.
- [20] J. Hartono, "Teori portofolio dan analisis investasi," 2022.
- [21] J. Y. Campbell, A. W. Lo, and A. C. MacKinlay, "The econometrics of financial markets," *Econom. Financ. Mark.*, pp. 1–611, 2012, doi: 10.1017/s1365100598009092.
- [22] R. F. Engle, "Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation," *Econom. J. Econom. Soc.*, pp. 987–1007, 1982.
- [23] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE Trans. neural networks*, vol. 5, no. 2, pp. 157–166, 1994.
- [24] M. K. Wisyaldin, G. M. Luciana, and H. Pariaman, "Pendekatan LSTM untuk Memprediksi Kondisi Motor 10 kV pada PLTU Batubara," *Kilat*, vol. 9, no. 2, pp. 311–318, 2020, [Online]. Available:

<http://jurnal.itpln.ac.id/kilat/article/view/997%0Ahttps://jurnal.itpln.ac.id/kilat/article/download/997/775>

- [25] Anishnama, "Understanding Gated Recurrent Unit (GRU) in Deep Learning," *Mediu. Publ. Amerika*, 2018, [Online]. Available: <https://medium.com/@anishnama20/understanding-gated-recurrentunit-gru-in-deep-learning-2e54923f3e2>
- [26] Kostadinov, "Understanding GRU Networks," *Mediu. Publ. Amerika*, 2017, [Online]. Available: <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>
- [27] S. A. K. Tareen and F. K. Tareen, "Convolutional Neural Networks for Beginners," *SSRN Electron. J.*, 2023, doi: 10.2139/ssrn.4566310.
- [28] R. J. Hyndman and G. Athanasopoulos, "Forecasting : Principles and Practice".
- [29] M. D. Petty, "Calculating and using confidence intervals for model validation," *Fall Simul. Interoperability Work. 2012, 2012 Fall SIW*, pp. 37–45, 2012.