

## MODEL PREDIKSI HARGA BITCOIN MENGGUNAKAN ALGORITMA SBI-GRU DAN SBI-LSTM

Aryajaya Alamsyah

Program Studi Teknik Informatika, Universitas Indraprasta PGRI  
aryajayaalamsyah@gmail.com

*Submitted December 21, 2025; Revised April 1, 2026; Accepted April 5, 2026*

### Abstrak

Masalah utama penelitian ini adalah volatilitas harga *bitcoin* yang cenderung tinggi. Berdasarkan hasil observasi kami diketahui bahwa volatilitas harga *bitcoin* berkisar antara 35% hingga 85% sehingga investasi *bitcoin* cenderung berisiko yang cukup signifikan. Oleh karena itu, tujuan penelitian ini untuk membuat model prediksi harga *bitcoin* yang mampu mengikuti pola volatilitas tersebut. Kami membuat model prediksi harga *bitcoin* berbasis Neural Network (NN) dengan menggunakan algoritma *Stacked-Bidirectional Gated Recurrent Unit* (SBI-GRU) dan *Stacked-Bidirectional Long Short-Term Memory* (SBI-LSTM). Kedua algoritma tersebut sudah sesuai dan terbukti mampu memprediksi harga *bitcoin*. Selanjutnya, Kami juga menggunakan *hyperparameter tuning* untuk meningkatkan hasil akurasi model prediksi ini. Adapun parameter tuning yang digunakan adalah *epoch*, *batch size*, dan *optimizer*. Hasil penelitian kami menunjukkan bahwa model prediksi ini mampu memprediksi harga *bitcoin* beserta pola volatilitasnya. Adapun tolak ukurnya adalah jika menggunakan model SBI-GRU memiliki nilai MAPE sebesar 0,0254 dan nilai koefisien korelasi sebesar 0,9975. Selanjutnya, model SBI-LSTM memiliki nilai MAPE sebesar 0,0333 dan nilai koefisien korelasi sebesar 0,9963. Interpretasi dari hasil tersebut adalah kedua model prediksi baik menggunakan metode SBI-GRU dan SBI-LSTM mampu memprediksi harga *bitcoin* dengan sangat baik. Nilai MAPE kurang dari 0,05 membuat model prediksi menjadi akurat sedangkan koefisien korelasi mencapai 0,99 membuat model mampu mengikuti pola volatilitasnya.

**Kata Kunci :** *Bitcoin*, SBI-GRU, SBI-LSTM.

### Abstract

*The main issue in this study is the high volatility of bitcoin prices. Based on our observations, we found that bitcoin price volatility ranges from 35% to 85%, making bitcoin investments quite risky. Therefore, the purpose of this study is to create a bitcoin price prediction model that can follow this volatility pattern. We created a neural network (NN)-based Bitcoin price prediction model using the Stacked-Bidirectional Gated Recurrent Unit (SBI-GRU) and Stacked-Bidirectional Long Short-Term Memory (SBI-LSTM) algorithms. Both algorithms are suitable and have been proven capable of predicting Bitcoin prices. Furthermore, we also used hyperparameter tuning to improve the accuracy of this prediction model. The tuning parameters used were epoch, batch size, and optimizer. Our research results show that this prediction model is capable of predicting bitcoin prices and their volatility patterns. The benchmarks are as follows: the SBI-GRU model has a MAPE value of 0.0254 and a correlation coefficient of 0.9975. Meanwhile, the SBI-LSTM model has a MAPE value of 0.0333 and a correlation coefficient of 0.9963. The interpretation of these results is that both prediction models, using the SBI-GRU and SBI-LSTM methods, are able to predict bitcoin prices very well. A MAPE value of less than 0.05 makes the prediction model accurate, while a correlation coefficient of 0.99 means that the model is able to follow the volatility pattern.*

**Key Words :** *Bitcoin*, SBI-GRU, SBI-LSTM.

### 1. PENDAHULUAN

Masalah utama penelitian adalah volatilitas harga *bitcoin* (BTC-USD) cenderung tinggi. Kami juga mengamati harga *bitcoin* selama periode yang panjang, yaitu dari 1 Januari

2015 hingga 30 April 2024. Hasil observasi menunjukkan bahwa volatilitas atau fluktuasi harga cenderung tinggi. Tingkat volatilitas tersebut berkisar antara 35% hingga 85% seperti yang tertera pada Gambar 2. Selain

itu, selama periode tersebut, tercatat harga penutupan terendah sebesar \$178 dolar di tanggal 14 Januari 2015 sedangkan harga penutupan terendah sebesar \$73.083 dolar di tanggal 13 Maret 2024. Hasil pencatatan tersebut menunjukkan bahwa harga *bitcoin* naik hingga 40.951%. Meskipun investasi *bitcoin* menawarkan potensi yang menarik, namun volatilitasnya juga membawa resiko yang cukup signifikan.

Pembuatan model prediksi merupakan salah satu solusi untuk masalah volatilitas harga *bitcoin*. Sehingga kami membaca beberapa penelitian tentang cara memprediksi harga *bitcoin* dengan *neural network*, seperti yang tersaji pada Tabel 1.

Berdasarkan hasil penelitian sebelumnya, diketahui bahwa pendekatan *neural network* dengan metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) mampu memprediksi harga *bitcoin* [1]-[5]. Keunggulan metode ini (LSTM dan GRU) adalah mampu memprediksi dengan akurat meskipun data tidak terdistribusi normal, data tidak linier, data tidak stasioner, dan terdapat pencilan [6].

Walaupun, metode LSTM dan GRU sudah cukup akurat untuk prediksi harga *bitcoin*. Akan tetapi menambahkan teknik *Stacked Bidirectional* dan *Hyperparameter Tuning* dapat meningkatkan performa model. Hasil penelitian [7] menunjukkan bahwa *stacked-bidirectional* dapat meningkatkan performa sebesar 2% sedangkan hasil penelitian [8] menunjukkan bahwa *hyperparameter tuning* dapat meningkatkan performa sebesar 17%. Beberapa hasil penelitian [9]-[14] tentang *stacked bidirectional* dan *hyperparameter tuning* lainnya seperti pada Tabel 1.

Peningkatan performa dapat terjadi karena *stacked bidirectional* dapat mempelajari dan memprediksi data deret waktu yang sangat abstrak. Sedangkan *hyperparameter tuning* mencari dan menentukan parameter terbaik untuk model prediksi tersebut.

Oleh karena itu, tujuan penelitian ini untuk menciptakan model prediksi harga *bitcoin* dengan metode SBI-LSTM dan SBI-GRU. Sehingga model prediksi tersebut mampu mengikuti pola volatilitasnya.

**Tabel 1. Studi Literatur Sejenis**

Ref	Data Penelitian	Periode Waktu	Hyperparameter Tuning	Algoritma
[9]	<ul style="list-style-type: none"> <li>• Cryptocurrency</li> <li>• Stock Price</li> </ul>	2014 – 2023	Number of hidden layers, number of nodes, activation function, optimizers, batch size, epoch, time window.	<ul style="list-style-type: none"> <li>• AE-LSTM</li> <li>• AE-GRU</li> </ul>
[10]	<i>Stock Price</i>	2012 – 2020	Number of hidden layers, dropout rate, optimizers, learning rate, batch size, epoch	LSTM
[11]	<i>Stock Price</i>	2010 – 2024	Number of hidden layers, number of nodes, dropout rate, optimizers, learning rate, batch size, epoch.	LSTM
[12]	<i>Stock Price</i>	2018 – 2023	Number of nodes, dropout rate, optimizers, learning rate, batch size, epoch	LSTM
[13]	<i>Stock Price</i>	2006 – 2020	Number of nodes, optimizers, learning rate, batch size, epoch, timestep.	LSTM
[14]	<i>Cryptocurrency</i>	2012 – 2021	Activation function, optimizers, learning rate, batch size, epoch	DCNN-GRU

## 2. METODE PENELITIAN

Penelitian ini dilakukan melalui beberapa tahap seperti pengumpulan data, eksplorasi data analisis, praproses data, analisis deret waktu, pembagian data, pembuatan model prediksi, evaluasi model. Tahap penelitian yang kami lakukan seperti pada Gambar 1.

### Pengumpulan Data

Penelitian kami menggunakan data *bitcoin* dari *Yahoo Finance*. Data tersebut tersedia di <https://uk.finance.yahoo.com/quote/BTC-USD/>. Data *bitcoin* merupakan data deret waktu dengan format data harian. Data ini memiliki atribut *date*, *open*, *high*, *low*, dan

close. Saat Kami mengunduh data *bitcoin*, data tersebut memiliki periode waktu dari 1 Januari 2015 hingga 30 April 2024.

### Ekspolarasi Data dan Analisis

Eksplorasi data dan analisis dilakukan untuk melihat beberapa karakteristik data bitcoin seperti visualisasi data untuk melihat pola tren dan musiman, identifikasi *outlier* dan *missing value*, observasi volatilitas harga.

### Analisis Deret Waktu

Kami melakukan analisis deret waktu untuk menguji sifat stasioneritas dan autokorelasi terhadap data penelitian (data *bitcoin*). Uji stasioneritas dilakukan dengan dua metode, yaitu *Phillip Perron* dengan persamaan (2) [15], dan *Augmented Dickey Fuller* dengan persamaan (2) [15].

$$\Delta y_t = \alpha + \beta_t + y_{t-1} + \varepsilon_t \quad (1)$$

$$\Delta y_t = \alpha + \beta_t + y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-1} + \varepsilon_t \quad (2)$$

### Praproses Data

Kami menerapkan normalisasi dengan *min-max scaler* seperti pada persamaan (3) dan transformasi *supervised learning time series* seperti pada *pseudocode* (1). Sehingga data *bitcoin* menjadi lebih terstruktur.

$$Normalization = a + \frac{(x - \min(x)) * (b - a)}{\max(x) - \min(x)} \quad (3)$$

```
# function supervised learning time series
def create_dataset(look_back, dataset):

    # declare variable X and Y
    dataX = []
    dataY = []

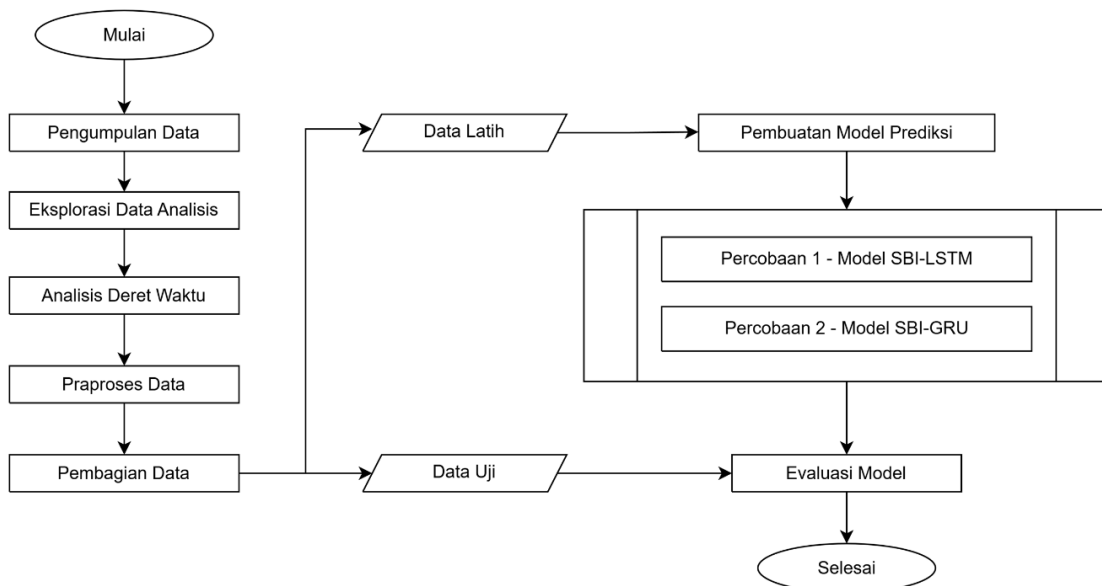
    # looping for create supervised learning
    for i in range(look_back, len(dataset)):
        dataX.append(dataset[i-look_back:i, 0])
        dataY.append(dataset[i, 0])

    # return value X and Y
    return np.array(dataX), np.array(dataY)
```

Pseudocode 1. Supervised learning time series

### Pembagian Data

Pembagian data dilakukan untuk membagi data menjadi data latih dan data uji. Proses pembagian data menggunakan metode *split validation* dengan persentase data latih 80% dan data uji 20%.



Gambar 1. Tahapan Penelitian

### Model Prediksi Bitcoin

Model prediksi bitcoin dibuat menggunakan metode LSTM dan GRU. Berdasarkan hasil penelitian [1]-[5] membuktikan bahwa kedua ini metode memberikan hasil optimal.

Pembuatan model LSTM berdasarkan hasil penelitian [16]. Metode ini terbagi menjadi empat bagian utama yaitu *forget gate* pada persamaan 4, *input gate* pada persamaan 5, *memori cell* pada persamaan 7 dan 8, *output gate* pada persamaan 9. Keunggulan utama dari metode LSTM adalah hasil prediksinya cenderung lebih optimal.

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (7)$$

$$O_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (9)$$

Sementara, model GRU dibuat berdasarkan hasil penelitian [17] [18]. Metode ini terbagi tiga bagian utama yaitu *update gate* dengan persamaan 10, *reset gate* dengan persamaan 11, *hidden state* dengan persamaan 12, 13. Keunggulan utama dari metode GRU adalah waktu komputasinya cenderung lebih baik dari pada metode LSTM.

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (10)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (11)$$

$$\hat{h}_t = \phi(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (12)$$

$$h_t = \phi(1 - z_t) \odot h_{t-1} + z_t \odot \hat{h}_t \quad (13)$$

Kami ingin model prediksi bitcoin memiliki hasil yang optimal. Oleh karena itu, model prediksi ini dilakukan beberapa penyesuaian *hyperparameter tuning*. Adapun *parameter tuning* adalah *epoch*, *batch size*, *optimizer*.

### Evaluasi Model

Kami menghitung koefisien korelasi (R) dan *Absolute Percentage Error* (MAPE) untuk menentukan performa model prediksi harga *bitcoin*. Nilai R dihitung dengan persamaan 16 [19] sedangkan MAPE dihitung dengan persamaan 17 [20].

$$R = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (16)$$

$$MAPE = \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (17)$$

Selain itu, kami melakukan evaluasi model untuk membandingkan kinerja SBI-LSTM dengan SBI-GRU dengan uji normalitas dan uji hipotesis. Uji normalisasi menggunakan *ShapiroWilk* dan uji hipotesis menggunakan uji tindependen sesuai persamaan 18 dan 19 [19]. Semua pengujian ini bertujuan untuk membuktikan bahwa kedua model tersebut memiliki performa yang sama-sama unggul.

$$w = \frac{(\sum_{i=1}^n a_i x_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (18)$$

$$t = \frac{\bar{X}_1 + \bar{X}_2}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \quad (19)$$

## 3. HASIL DAN PEMBAHASAN

### Pengumpulan Data


Penelitian ini menggunakan data sekunder, khususnya data *bitcoin* dari *yahoo finance* dengan periode waktu dari 1 Januari 2015 sampai 30 April 2025, seperti pada Tabel 2. Data ini termasuk kedalam data deret waktu dengan format data harian.

Tabel 2. Data Bitcoin

Date	Open	High	Low	Close
2014-01-01	320,43	320,43	314,00	314,25
2014-01-02	314,08	315,84	313,57	315,03
2014-01-03	314,85	315,15	281,08	281,08
...	....	....	....	....
2024-04-28	63.423,52	64.321,48	62.793,60	63.113,23
2024-04-29	63.106,36	64.174,88	61.795,46	63.841,12
2024-04-30	63.839,42	64.703,33	59.120,07	60.636,86

### Ekspolarasi Data Analisis

Hasil ekspolarasi data analisis menunjukkan volatilitas berkisar 35% hingga 65%, seperti pada Gambar 2 sehingga harga bitcoin sulit diprediksi.




**Gambar 2. Volatilitas Harga Bitcoin**

Visualisasi deret waktu menunjukkan bahwa fluktuasi harga *bitcoin* cenderung semakin tinggi sejak tahun 2020. Pada tahun tersebut harga *bitcoin* terendah sebesar \$4.900 dolar, sebelum meningkat drastis hingga \$67.000 dolar. Namun sepanjang tahun 2021 sampai akhir tahun 2023, harga *bitcoin* cenderung turun. Sejak awal tahun 2024, harga *bitcoin* kembali meningkat menjadi \$77.500 dolar.




**Gambar 3. Visualisasi Deret Waktu**

Visualisasi *boxplot* menunjukkan bahwa data *bitcoin* memiliki pencilan, jika harga *bitcoin* melebihi \$65.00 maka dianggap pencilan.



**Gambar 4. Visualisasi Boxplot**

Visualisasi histogram, seperti pada Gambar 5 menunjukkan bahwa data tidak terdistribusi secara normal. Sebaran data lebih condong ke kanan. Hal ini menunjukkan bahwa lebih banyak data *bitcoin* dengan harga dibawah \$20.000 dolar.



**Gambar 5. Visualisasi Histogram**

Oleh karena itu, dapat disimpulkan bahwa data *bitcoin* memiliki volatilitas yang tinggi, terdapat pencilan, tidak terdistribusi normal. Sehingga pendekatan *neural network* sudah sesuai untuk penelitian ini.

**Analisis Deret Waktu**

Hasil pengujian menggunakan metode DW menghasilkan nilai 1,9985. Artinya data ini tidak mengandung gejala autokorelasi.

Kemudian, hasil pengujian dengan metode ADF dan PP menghasilkan *p-value* sebesar 0,2033 dan 0,3949. Hasil *p-value* lebih kecil dari 0,05 dapat disimpulkan bahwa data ini tidak stasioner.

**Tabel 3. Hasil Analisis Deret Waktu**

Metode	Lag	P-Value	Critical values		
			1%	5%	10%
ADF	60	0,2033	-3,9614	-3,4118	-3,1278
PP	60	0,3949	-3,9614	-3,4118	-3,1278

**Praproses Data**

Hasil normalisasi data *min-max scaler* pada Gambar 6, sehingga rentang nilai berubah menjadi 0 hingga 1.



**Gambar 6. Hasil Normalisasi Data**


Selanjutnya, hasil *supervised learning time series* seperti pada tabel 4. Proses ini perlu dilakukan untuk memberikan pengetahuan kepada model prediksi tentang urutan data.

**Tabel 4. Hasil *Supervised Learning Time Series***

Date	Lag-1	Lag-2	Lag-3	Lag-4	Lag-5	Lag-6	Lag-7	...	Lag-60	Target
2014-01-01	0,00187	0,00188	0,00141	0,00118	0,00132	0,00148	0,00159	...	0,00113	0,00134
2014-01-02	0,00188	0,00141	0,00118	0,00132	0,00148	0,00159	0,00144	...	0,00134	0,00142
2014-01-03	0,00141	0,00118	0,00132	0,00148	0,00159	0,00144	0,00154	...	0,00142	0,00130
...	...	...	...	...	...	...	...	...	...	...
2024-04-28	0,85490	0,83698	0,85402	0,84838	0,86399	0,93481	0,87268	...	0,86744	0,86324
2024-04-29	0,83698	0,85402	0,84838	0,86399	0,93481	0,87268	0,90431	...	0,86324	0,87323
2024-04-30	0,85402	0,84838	0,86399	0,93481	0,87268	0,90431	0,91553	...	0,87323	0,82928

### Pembagian Data

Hasil pembagian data menggunakan metode *split validation* dengan persentase data latih 80% dan data uji 20% seperti pada Gambar 7. Data *bitcoin* yang kami unduh memiliki dimensi data sebesar 3.408 baris x 5 kolom. Setelah dilakukan pembagian data, jumlah data latih sebanyak 2.726 baris dan data uji sebanyak 682 baris.



**Gambar 7. Hasil pembagian data**

### Model Prediksi *Bitcoin*

Tahap awal dalam membuat model prediksi *bitcoin* adalah menentukan parameter, pada Tabel 5. Adapun parameter yang digunakan adalah *epoch*, *batch size* dan *optimizer*,

**Tabel 5. *Hyperparameter Tuning***

Parameter tuning	Inisialisasi parameter
Epoch	25, 50
Batch Size	8, 16, 24, 32
Optimizer	Adam, Adamax, RMSprop.

Tahap awal dalam membuat model prediksi *bitcoin* adalah menentukan arsitektur *neural network* untuk metode SBI-LSTM dan SBI-GRU seperti pada Tabel 6. Arsitektur dari kedua metode tersebut dibuat sama yaitu 1 *input layer*, 2 *hidden layer*, 1 *dropout layer*, dan 1 *input layer*. Hal ini sengaja dilakukan untuk meminimalisir perbedaan bias anatara model SBI-LSTM dan SBI-GRU.

*Hidden layer* bersifat *stacked-bidirectional* untuk meningkatkan performa. Selanjutnya, *dropout layer* digunakan untuk mengurangi *overfitting*.

Berdasarkan hasil *parameter tuning*, seperti pada Tabel 5, maka model prediksi ini akan menghasilkan 48 kombinasi model prediksi. Pencarian model terbaik dilakukan dengan *naive search*, artinya kami mencoba semua kombinasi tersebut. Adapun kriteria model terbaik diukur menggunakan R, MAPE, dan waktu komputasi.

Hasil pencarian model prediksi terbaik dan dilakukan pengukuran nilai R seperti pada Tabel 6, nilai MAPE pada Tabel 7, dan nilai waktu komputasi pada Tabel 8. Hasil Tabel 6 diketahui bahwa seluruh kombinasi pada menciptakan model prediksi yang baik. Hal ini dibuktikan dengan nilai R lebih dari 0,9. Artinya semua model dapat mengikuti pola volatilitas *bitcoin*.

Hasil penilaian MAPE membuktikan bahwa tidak semua model memiliki performa yang baik. Karena beberapa model memiliki nilai MAPE diatas 0,05 (5%). Hasil penilaian ini menghasilkan pola, dimana hasil SBI-GRU cenderung lebih baik dari SBI-LSTM. Hasil SBI-LSTM yang memiliki galat kurang dari 0,05 berjumlah 10 model. Namun, hasil SBI-GRU yang memiliki galat kurang dari 0,05 berjumlah 12 model. Model prediksi terbaik untuk SBI-LSTM menggunakan parameter seperti jumlah *epoch* 50, jumlah *batch size* 8, *optimizer adam*. Model ini menghasilkan nilai MAPE sebesar 0,0277. Model prediksi terbaik SBI-GRU menggunakan parameter seperti jumlah *epoch* 50, jumlah *batch size* 2, dan *optimizer adam*. Model ini memiliki

nilai MAPE sebesar 0,0221. Perbedaan nilai MAPE antara kedua model sebesar 0,0056 (0,56%) atau kurang dari 1%. Perbedaan ini masih dalam batas toleransi *error*.

Hasil penilaian waktu komputasi digunakan untuk mengukur efisiensi waktu saat model prediksi diimplementasikan, seperti Tabel 8. Hasil penilaian ini memiliki beberapa pola, seperti SBI-LSTM cenderung lebih lambat jika dibandingkan SBI-GRU. Penambahan jumlah *batch size* akan menurunkan waktu komputasi sedangkan penambahan jumlah *epoch* akan meningkat waktu komputasi.

Kombinasi parameter terbaik dari SBI-GRU membutuhkan waktu komputasi 102,8 detik sedangkan SBI-LSTM membutuhkan waktu 422,8 detik. Sehingga perbedaan waktunya sebesar 320,01 detik atau dapat disimpulkan model SBI-GRU lebih efisien 75,68% jika dibandingkan dengan SBI-GRU.

Kami membuat visualisasi dari pengukuran nilai R, MAPE, dan waktu komputasi untuk mempermudah dalam memahami hasilnya. Visualisasi tersebut seperti pada Gambar 9, 10 dan 11.

**Tabel 6. Pengukuran Nilai Koefisien Korelasi untuk SBI-LSTM dan SBI-GRU**


Epoch	Batch Size	SBI-LSTM-RNN			SBI-GRU-RNN		
		Optimizers			Optimizers		
		Adam	Adamax	RMSprop	Adam	Adamax	RMSprop
25	8	0.9863	0.9949	0.9972	0.9904	0.9960	0.9973
	16	0.9970	0.9950	0.9974	0.9958	0.9971	0.9974
	24	0.9898	0.9927	0.9973	0.9971	0.9961	0.9972
	32	0.9938	0.9933	0.9967	0.9974	0.9962	0.9976
50	8	<b>0.9964</b>	0.9969	0.9961	0.9921	0.9963	0.9956
	16	0.9973	*0.9962	0.9972	0.9962	*0.9975	0.9975
	24	0.9928	0.9948	0.9974	<b>0.9976</b>	0.9969	0.9976
	32	0.9952	0.9948	0.9976	0.9974	0.9968	0.9974

**Tabel 7. Pengukuran Nilai MAPE untuk SBI-LSTM dan SBI-GRU**


Epoch	Batch Size	SBI-LSTM-RNN			SBI-GRU-RNN		
		Optimizers			Optimizers		
		Adam	Adamax	RMSprop	Adam	Adamax	RMSprop
25	8	0.1651	0.0326	0.0729	0.0612	0.0778	0.0741
	16	0.0417	0.0437	0.0543	0.0867	0.0310	0.0434
	24	0.1371	0.0954	0.0639	0.0876	0.0526	0.0398
	32	0.1331	0.1231	0.0628	0.0718	0.1003	0.0485
50	8	<b>0.0277</b>	0.0567	0.0498	0.1130	0.0806	0.0543
	16	0.0382	*0.0351	0.0429	0.0442	*0.0264	0.0364
	24	0.1069	0.0675	0.0431	<b>0.0221</b>	0.0403	0.0345
	32	0.1003	0.0879	0.0407	0.0289	0.0718	0.0336

**Tabel 8. Pengukuran Nilai Waktu Komputasi untuk SBI-LSTM dan SBI-GRU**


Epoch	Batch Size	SBI-LSTM-RNN			SBI-GRU-RNN		
		Optimizers			Optimizers		
		Adam	Adamax	RMSprop	Adam	Adamax	RMSprop
25	8	218.33	218.26	220.78	191.76	193.59	218.82
	16	106.54	115.05	115.70	97.73	103.690	105.46
	24	63.94	62.66	63.47	58.12	58.93	64.46
	32	52.32	52.03	53.63	47.40	49.75	52.48
50	8	<b>422.87</b>	407.07	438.98	381.27	350.73	386.48
	16	209.77	*202.06	228.93	199.56	*180.55	205.39
	24	112.71	116.62	127.99	<b>102.86</b>	105.74	123.64
	32	91.83	90.36	101.81	84.60	80.60	93.03



Gambar 9. Visualisasi Hasil Pengukuran Nilai R untuk SBI-LSTM Dan SBI-GRU



Gambar 10. Visualisasi Hasil Pengukuran Nilai MAPE untuk SBI-LSTM Dan SBI-GRU



Gambar 11. Visualisasi Hasil Pengukuran Nilai Waktu Komputasi untuk SBI-LSTM Dan SBI-GRU

### Evaluasi Model

Selanjutnya, kami membuktikan perbedaan performa SBI-LSTM dan SBI-GRU dengan perhitungan statistika untuk membuktikan perbedaannya secara empiris. Apakah terjadi perbedaan performa secara nyata atau tidak memiliki perbedaan.

Oleh karena itu, model prediksi terbaik dari SBI-LSTM dan SBI-GRU diulang sebanyak 30 kali untuk melihat konsistensi dari hasil *hyperparameter tuning*, pada Tabel 9. Hasil tersebut menunjukkan bahwa model prediksi sudah konsisten karena perbedaannya kurang dari 1% dan masih dalam batas toleransi.

Tabel 9. Pengujian konsistensi model SBI-LSTM dan SBI-GRU sebanyak 30 kali

Percobaan	SBI-LSTM			SBI-GRU		
	R	MAPE	Waktu	R	MAPE	Waktu
1	0,9963	0,0315	205,30	0,9975	0,0235	180,44
2	0,9962	0,0365	210,97	0,9975	0,0230	190,84
3	0,9963	0,0470	215,56	0,9975	0,0297	186,80
4	0,9960	0,0432	207,76	0,9974	0,0215	183,21
5	0,9967	0,0256	217,82	0,9975	0,0211	189,79

Percobaan	SBI-LSTM			SBI-GRU		
	R	MAPE	Waktu	R	MAPE	Waktu
6	0,9962	0,0337	204,01	0,9975	0,0288	182,70
7	0,9963	0,0307	202,44	0,9975	0,0219	177,83
8	0,9960	0,0315	207,36	0,9975	0,0254	183,91
9	0,9965	0,0284	218,46	0,9975	0,0223	189,62
10	0,9962	0,0335	213,85	0,9975	0,0258	190,82
11	0,9967	0,0278	220,31	0,9975	0,0212	189,43
12	0,9964	0,0302	209,40	0,9975	0,0208	187,73
13	0,9960	0,0410	211,03	0,9974	0,0287	178,69
14	0,9964	0,0358	219,04	0,9970	0,0349	187,64
15	0,9962	0,0353	200,15	0,9975	0,0270	173,42
16	0,9961	0,0338	206,28	0,9975	0,0257	184,49
17	0,9962	0,0335	205,13	0,9975	0,0287	181,92
18	0,9961	0,0390	207,26	0,9975	0,0272	189,23
19	0,9965	0,0288	202,82	0,9975	0,0303	178,35
20	0,9962	0,0382	217,27	0,9974	0,0239	184,16
21	0,9963	0,0350	209,24	0,9975	0,0247	184,58
22	0,9963	0,0327	218,15	0,9975	0,0285	187,49
23	0,9965	0,0266	225,26	0,9974	0,0230	182,33
24	0,9965	0,0294	202,21	0,9973	0,0269	181,93
25	0,9965	0,0302	211,82	0,9975	0,0270	181,08
26	0,9961	0,0333	206,71	0,9975	0,0222	182,44
27	0,9965	0,0262	212,06	0,9975	0,0198	187,18
28	0,9966	0,0307	200,93	0,9975	0,0221	175,36
29	0,9963	0,0336	201,54	0,9975	0,0269	179,48
30	0,9963	0,0352	215,59	0,9974	0,0301	186,33
<b>Terendah</b>	0.9960	0.0256	200.15	0.9970	0.0198	173.42
<b>Rata-rata</b>	0.9967	0.0470	225.26	0.9975	0.0349	190.84
<b>Tertinggi</b>	0.9963	0.0333	210.19	0.9975	0.0254	183.97

Setelah pengujian konsistensi selesai, maka dilakukan perhitungan statistika dengan uji normalitas dan uji t. Hal ini dilakukan untuk menguji perbedaan performa, apakah terjadi perbedaan atau tidak ada secara empiris.

Hasil pengujian perbedaan performa seperti pada Tabel 10. Hasil tersebut membuktikan bahwa konsistensi model mengikuti kaidah distribusi normal karena *p-value* dari kedua model lebih dari 0,05. Walaupun pengujian konsistensi memiliki perbedaan kurang dari 1%, namun secara empiris terjadi perbedaan performa karena nilai *p-value* uji t kurang dari 0,05.

**Tabel 10. Pengujian statistika**

Uji Statistika	SBI-LSTM		SBI-GRU	
	MAPE	Waktu	MAPE	Waktu
Uji shapiro-wilk	0.1851	0.2764	0.2042	0.2895
Uji t independent	0.0000	0.0000	0.0000	0.0000

#### 4. SIMPULAN

Hasil penelitian ini dapat kesimpulan bahwa model prediksi *bitcoin* dapat mengikuti pola volatilitas. Hal ini dibuktikan dengan model terbaik SBI-LSTM dan SBI-GRU memiliki nilai MAPE kurang dari 0,05 (5%) dan nilai R lebih dari 0,99.

#### DAFTAR PUSTAKA

- [1] N. Nafisah, Y. Yamasari, and E. Yohannes, "A Performance Comparison of LSTM and GRU Architectures for Forecasting Daily Bitcoin Price Volatility," *J. Inf. Eng. Educ. Technol.*, vol. 9, no. 2, pp. 156–167, 2025.
- [2] Ferdiansyah, S. H. Othman, R. Zahilah Raja Md Radzi, D. Stiawan, Y. Sazaki, and U. Ependi, "A LSTM-Method for Bitcoin Price

- Prediction: A Case Study Yahoo Finance Stock Market,” *Int. Conf. Electr. Eng. Comput. Sci.*, pp. 206–210, 2019, doi: 10.1109/ICECOS47637.2019.8984499.
- [3] M. Alfarizi and D. Lestarini, “Predicting Cryptocurrency Prices Using Machine Learning: A Case Study on Bitcoin,” *J. Appl. Informatics Comput.*, vol. 9, no. 6, pp. 3612–3621, 2025.
- [4] M. Aswadi and U. Ependi, “Predicting Bitcoin and Ethereum Prices Using the Long Short-Term Memory (LSTM) Model,” *J. Inf. Syst. Informatics*, vol. 7, no. 3, pp. 3046–3061, 2025, doi: 10.51519/journalisi.v7i3.1228.
- [5] R. Satria Andromeda and N. A. S. Winarsih, “Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga Close Cryptocurrency,” *Sist. J. Sist. Inf.*, vol. 14, no. 1, p. 366, 2025, doi: 10.32520/stmsi.v14i1.4880.
- [6] J. Brownlee, “Develop Deep Learning Models On Theano And TensorFlow Using Keras,” *J. Chem. Inf. Model.*, vol. 53, no. 9, pp. 1689–1699, 2019.
- [7] I. P. B. Priadinata, I. G. I. Sudipa, N. P. S. Meinarni, I. M. L. Radhitya, and I. K. D. G. Supartha, “Comparative Analysis of LSTM, GRU, and Bi-LSTM Deep Learning Models for Time Series Cryptocurrency Price Forecasting,” *Sinkron*, vol. 9, no. 3, pp. 1024–1035, 2025, doi: 10.33395/sinkron.v9i3.14795.
- [8] N. Buslim, I. L. Rahmatullah, B. A. Setyawan, and A. Alamsyah, “Comparing Bitcoin’s Prediction Model Using GRU, RNN, and LSTM by Hyperparameter Optimization Grid Search and Random Search,” *2021 9th Int. Conf. Cyber IT Serv. Manag. CITSM 2021*, 2021, doi: 10.1109/CITSM52892.2021.9588947.
- [9] J. Dip Das, R. K. Thulasiram, C. Henry, and A. Thavaneswaran, “Encoder–Decoder Based LSTM and GRU Architectures for Stocks and Cryptocurrency Prediction,” *J. Risk Financ. Manag.*, vol. 17, no. 5, 2024, doi: 10.3390/jrfm17050200.
- [10] E. Ismanto and V. Vitriani, “RETRACTED: LSTM Network Hyperparameter Optimization for Stock Price Prediction Using the Optuna Framework,” *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 9, no. 1, pp. 22–35, 2023, doi: 10.26555/jiteki.v9i1.24944.
- [11] V. Deswal and D. Kumar, “Hyperparameter Tuning of the LSTM model for Stock Price Prediction,” *Int. J. Intell. Syst. Appl. Eng.*, vol. 2024, no. 4, pp. 705–712, 2024, [Online]. Available: [www.ijisae.org](http://www.ijisae.org)
- [12] B. Gülmez, “Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm,” *Expert Syst. Appl.*, vol. 227, no. May, p. 120346, 2023, doi: 10.1016/j.eswa.2023.120346.
- [13] H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, “Predicting stock market index using LSTM,” *Mach. Learn. with Appl.*, vol. 9, no. February, p. 100320, 2022, doi: 10.1016/j.mlwa.2022.100320.
- [14] C. Y. Kang, C. P. Lee, and K. M. Lim, “Cryptocurrency Price Prediction with Convolutional Neural Network and Stacked Gated Recurrent Unit,” *Data*, vol. 7, no. 11, 2022, doi: 10.3390/data7110149.
- [15] M. Joseph, *Modern Time Series Forecasting with Python: Explore industry-ready time series*

- forecasting using modern machine learning and deep learning*, Packt Publishing, 2022.
- [16] N. Sizykh, S. Dandamaev and D. Sizykh, "Application of the Method of Multivariate Multi-stage Forecasting Based on the LSTM Deep Learning Model for Bitcoin Price Time Series," *2023 16th International Conference Management of large-scale system development (MLSD)*, 2023, pp. 1-5, doi: 10.1109/MLSD58227.2023.10304008.
- [17] K. Cho *et al.*, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, pp. 1724–1734, 2014, doi: 10.3115/v1/d14-1179.
- [18] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," pp. 1–9, 2014, [Online]. Available: <http://arxiv.org/abs/1412.3555>
- [19] J. Brownlee, *Statistical Methods for Machine Learning*. 2019.
- [20] J. Brownlee, *Introduction to Time Series Forecasting with Python*. Machine Learning Mastery, 2017.