

# Perbandingan Algoritma LSTM, Bi-LSTM, GRU, dan Bi-GRU untuk Prediksi Harga Saham Berbasis Deep Learning

Muthia Tshamaroh\*, Inggih Permana, Febi Nur Salisah, Fitriani Muttakin, M Afdal

Sains dan Teknologi, Sistem Informasi, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia  
 Email: <sup>1\*</sup>12150321164@students.uin-suska.ac.id, <sup>2</sup>inggihpermana@uin-suska.ac.id, <sup>3</sup>febinursalisah@uin-suska.ac.id,  
<sup>4</sup>fitrianimuttakin@uin-suska.ac.id, <sup>5</sup>m.afdal@uin-suska.ac.id

Email Penulis Korespondensi: 12150321164@students.uin-suska.ac.id

Submitted: 30/04/2025; Accepted: 31/05/2025; Published: 01/06/2025

**Abstrak**—Prediksi harga saham menjadi komponen penting dalam pengambilan keputusan investasi. Penelitian ini bertujuan untuk membandingkan performa empat model deep learning, yaitu LSTM, Bi-LSTM, GRU, dan Bi-GRU, dalam memprediksi harga saham, guna menemukan model yang paling optimal untuk implementasi sistem prediksi harga saham yang akurat. Data historis lima tahun diolah melalui proses normalisasi, windowing, serta dibagi menjadi data latih, data validasi, dan data uji. Pelatihan model dilakukan dengan berbagai konfigurasi batch size, timestep, dan tiga jenis optimizer (Adam, SGD, RMSprop). Evaluasi performa menggunakan metrik MSE, RMSE, MAE, dan  $R^2$ . Hasil menunjukkan bahwa model Bi-GRU dengan konfigurasi optimizer Adam, batch size 8, dan timestep 21 memberikan performa terbaik dengan MSE sebesar 0.0003, RMSE 0.0169, MAE 0.0129, dan  $R^2$  0.9438. Model ini menunjukkan kemampuan tinggi dalam mengenali pola kompleks dan ketergantungan temporal jangka panjang, serta lebih akurat dibanding model lainnya. Temuan ini mendukung implementasi sistem prediktif yang dapat membantu investor dan perusahaan dalam pengambilan keputusan strategis berbasis data.

**Kata Kunci:** Prediksi Harga Saham; Deep Learning; LSTM; GRU; Bi-GRU; Bi-LSTM

**Abstract**—Stock price prediction is an important component in making investment decisions. This study aims to compare the performance of four deep learning models, namely LSTM, Bi-LSTM, GRU, and Bi-GRU, in predicting stock prices, in order to find the most optimal model for the implementation of an accurate stock price prediction system. Five years of historical data undergoes normalization, windowing, and is separated into training data, validation data, and test data. Model training is conducted with different settings of batch size, timestep, and three kinds of optimizers (Adam, SGD, RMSprop). Performance assessment employs MSE, RMSE, MAE, and  $R^2$  measurements. The findings indicate that the Bi-GRU model utilizing Adam optimizer settings, a batch size of 8, and a timestep of 21 yields the highest performance, achieving an MSE of 0.0003, an RMSE of 0.0169, an MAE of 0.0129, and an  $R^2$  of 0.9438. This model demonstrates a strong capability to identify intricate patterns and long-term temporal relationships, outperforming other models in accuracy. The results advocate for the establishment of a predictive system that aids investors and firms in making strategic decisions based on data.

**Keywords:** Stock Price Prediction; Deep Learning; LSTM; GRU; Bi-GRU; Bi-LSTM

## 1. PENDAHULUAN

Investor membutuhkan strategi investasi yang efektif untuk meminimalkan risiko portofolio sekaligus memaksimalkan keuntungan [1]. Saham adalah salah satu aset pasar keuangan yang paling diminati, dipilih oleh banyak investor karena potensinya memberikan imbal hasil yang tinggi [2]. Saham mencerminkan kepemilikan atau penyertaan dalam suatu perusahaan atau perseroan terbatas yang dimiliki oleh individu atau organisasi [3].

Fluktuasi harga saham yang cepat dalam jangka pendek menuntut sistem informasi yang andal dalam mengelola dan menganalisis data keuangan. Meskipun berbagai teknik telah dikembangkan untuk meramalkan harga saham di masa depan, teknik-teknik ini masih menghadapi tantangan, tantangan utama berkaitan dengan kompleksitas pola data dan ketergantungan jangka panjang [4]. Oleh karena itu, penggunaan sistem informasi berbasis deep learning menjadi solusi inovatif dalam meningkatkan efisiensi dan akurasi prediksi harga saham.

Sistem informasi memiliki peran penting dalam dunia keuangan, terutama dalam mengolah data pasar saham secara real-time dan memberikan wawasan yang lebih mendalam bagi pengambil keputusan. Dengan kemampuannya dalam mengenali pola yang kompleks dan memproses volume data yang besar, teknologi deep learning menawarkan pendekatan yang lebih canggih dibandingkan metode konvensional. Deep learning memungkinkan sistem informasi untuk mengoptimalkan analisis data keuangan, meningkatkan efisiensi prediksi, dan mendukung sistem keuangan digital yang lebih cerdas dan responsif [5].

Dalam beberapa tahun terakhir, pasar saham mengalami perkembangan pesat dengan meningkatnya kebutuhan akan analisis data yang lebih akurat. PT Bank Syariah Indonesia Tbk (BSI), yang resmi beroperasi pada 1 Februari 2021, merupakan bank syariah terbesar di Indonesia hasil penggabungan tiga bank syariah yaitu BRI Syariah, Bank Syariah Mandiri, dan BNI Syariah [6]. Sejak peresmiannya, PT BSI Tbk menghadapi tantangan fluktuasi yang mempengaruhi pendapatan perusahaan dan investor [7]. Oleh karena itu, diperlukan sistem informasi yang dapat mengelola data pasar saham secara efektif dan memberikan prediksi yang lebih presisi.

Berbagai penelitian telah menunjukkan keunggulan teknologi deep learning dalam memprediksi saham dibandingkan metode konvensional. Beberapa di antaranya studi oleh Sujatna, dkk. [8], mengeksplorasi model gabungan LSTM-GRU untuk memprediksi harga saham PT Bank Syariah Indonesia Tbk, menunjukkan bahwa susunan empat stack LSTM-GRU (LGLG) pada epoch 750 memberikan akurasi terbaik dengan nilai MSE sebesar 63,44. Pendekatan lain oleh Seabe, dkk. [9], membandingkan kinerja LSTM, GRU, dan Bi-LSTM dalam memprediksi

harga kripto, di mana Bi-LSTM menghasilkan prediksi paling akurat dengan nilai MAPE masing-masing sebesar 0.036 untuk BTC, 0.041 untuk LTC, dan 0.124 untuk ETH.

Selain itu, model CNN-BiLSTM juga digunakan oleh Mushliha [10], untuk memprediksi harga saham bank syariah lainnya seperti Bank Syariah Indonesia, BTPN Syariah dan Panin Dubai Syariah, menghasilkan nilai MAPE yang rendah (0,629%-2,376%) dan menunjukkan kemampuan tinggi dalam ekstraksi fitur dan pola temporal data. Penelitian lain oleh Tuan [11], berfokus pada analisis data nasabah menggunakan deep learning untuk menentukan kelayakan deposito. Model BiLSTM dengan akurasi 90,05% pada epoch 50 menjadi yang paling efektif dalam mengidentifikasi nasabah potensial berdasarkan berbagai atribut.

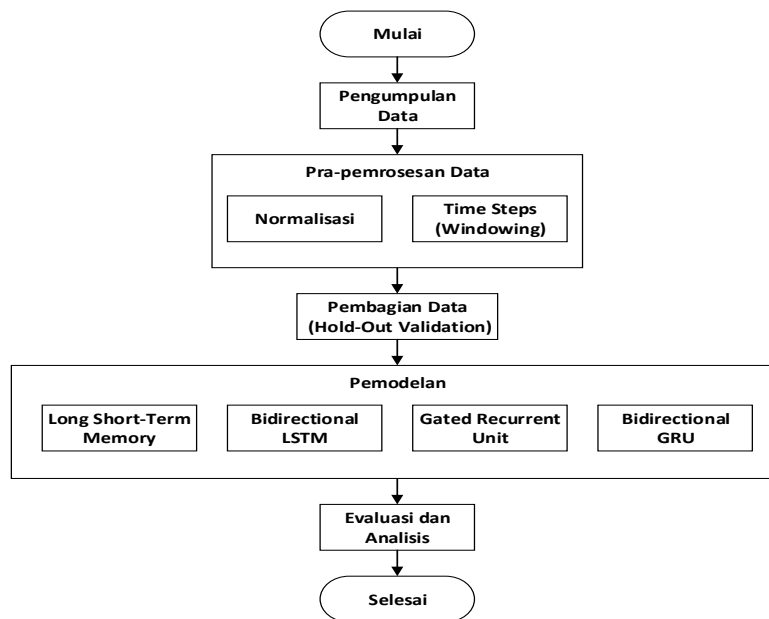
Sebagai tambahan, studi oleh Khalis Sofi, dkk. [12], menunjukkan bahwa algoritma Gated Recurrent Unit (GRU) memiliki performa terbaik dibandingkan dengan Linear Regression dan Long-Short Term Memory (LSTM) dalam memprediksi harga saham. Hal ini dibuktikan dengan nilai RMSE, MSE, dan MAE dari GRU yang paling rendah, yaitu RMSE sebesar 0.034, MSE sebesar 0.001, dan MAE sebesar 0.024.

Teknologi deep learning dalam prediksi saham juga menawarkan berbagai keunggulan dibandingkan metode konvensional [13]. Pertama, model berbasis deep learning dapat memproses data dalam jumlah besar secara cepat dan efisien, memungkinkan analisis real-time yang lebih akurat [5]. Kedua, deep learning mampu mengidentifikasi pola yang tidak dapat ditangkap oleh model statistik tradisional, sehingga meningkatkan kemampuannya dalam mengantisipasi pergerakan pasar. Ketiga, penggunaan algoritma optimasi dalam proses pelatihan model memungkinkan untuk menyesuaikan parameter secara adaptif, meningkatkan akurasi prediksi secara signifikan [14].

Penelitian ini mengembangkan model prediksi harga saham PT Bank Syariah Indonesia Tbk (BSI) dengan pendekatan komprehensif yang membandingkan empat algoritma deep learning: LSTM, Bi-LSTM, GRU, dan Bi-GRU. Tidak hanya berfokus pada satu model, penelitian ini juga mengevaluasi performa masing-masing algoritma menggunakan metrik evaluasi seperti MSE, RMSE, MAE, dan  $R^2$ , serta mengoptimalkan model melalui metode pelatihan dengan algoritma optimasi seperti Adam, SGD, dan RMSprop. Dengan mengintegrasikan arsitektur bidirectional, penelitian ini dirancang untuk menangkap pola data yang lebih kompleks dan jangka panjang, memberikan inovasi signifikan dalam pengembangan prediksi harga saham BSI [10]. Penelitian ini berkontribusi pada literatur yang ada dengan menghadirkan model prediksi yang lebih akurat untuk menghadapi tantangan fluktuasi harga saham yang dinamis dan semakin kompleksnya dinamika pasar. Hasil dari penelitian ini diharapkan memberikan wawasan berharga bagi perusahaan dan investor dalam mengambil keputusan yang lebih tepat, melalui prediksi harga saham BSI yang lebih kuat dan akurat.

## 2. METODOLOGI PENELITIAN

Proses penelitian ini mengikuti sejumlah tahapan yang sistematis mulai dari pengumpulan data hingga evaluasi model. Tahapan berturut-turut dari proses tersebut dapat dilihat secara menyeluruh pada Gambar 1.



**Gambar 1.** Metodologi Penelitian

### 2.1 Pengumpulan Data

Data historis yang digunakan dalam penelitian ini selama lima tahun terakhir, dari 1 Februari 2020 hingga 1 Februari 2025, untuk merepresentasikan berbagai kondisi pasar. Dataset Yahoo! Finance mencakup 1200 data berisi harga penutupan, harga pembukaan, harga tertinggi, dan harga terendah saham PT. Bank Syariah Indonesia Tbk [15].

## 2.2 Pra-pemrosesan Data

### 2.2.1 Normalisasi

Normalisasi data menggunakan metode penskalaan min-max dari sklearn library's yang mengubah nilai asli menjadi nilai berskala dalam interval tertentu [16]. Dalam upaya mengoptimalkan akurasi prediksi, dataset dinormalisasi melalui percobaan dengan interval [0,1]. Rumus normalisasi yang digunakan adalah sebagai berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

$x'$  adalah nilai setelah normalisasi, sedangkan  $x$  mewakili nilai aktual data yang akan dinormalisasi. Nilai minimum dari data aktual ditandai dengan  $x_{min}$ , dan nilai maksimum data aktual ditunjukkan dengan  $x_{max}$ .

### 2.2.2 Time Steps (Windowing)

Windowing adalah teknik untuk membentuk struktur baru dari suatu data dengan mengubah data time series menjadi data cross-sectional dengan tetap memperhatikan urutan dan pola dalam data aslinya [17]. Teknik windowing dengan pendekatan sliding window membagi dataset menjadi segmen-segmen yang saling tumpang tindih, masing-masing terdiri dari sejumlah time step tertentu untuk menangkap pola dan ketergantungan temporal.

## 2.3 Pembagian Data

Dengan rasio 80:10:10, data dibagi menjadi tiga bagian, di mana 80% pertama digunakan untuk melatih model, 10% digunakan untuk validasi model, sementara 10% sisanya digunakan untuk pengujian hasil prediksi model.

## 2.4 Long Short-Term Memory (LSTM)

LSTM adalah jenis jaringan saraf berulang (Recurrent Neural Network) dengan arsitektur khusus yang dirancang untuk mengatasi masalah seperti hilangnya dan meledaknya gradien, yang umum terjadi pada RNN tradisional [18]. LSTM terkenal karena kemampuannya mempertahankan dan memanfaatkan memori jangka panjang dalam data berurutan [19]. LSTM terdiri dari tiga gerbang *gate* utama yaitu input gate, forget gate, dan output gate, yang masing-masing memiliki fungsi khusus dalam mengatur aliran data.

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (5)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \odot \tanh(c_t) \quad (7)$$

Berikut ini terdapat enam persamaan formal yang terkait dengan proses gating dalam sel LSTM: Sel saat ini memiliki forget gate  $f_t$ , input gate  $i_t$  nilai output gate  $o_t$ , status sel saat ini  $C_t$  status kandidat sel (keadaan sel berikutnya), serta bobot jaringan  $W_f$ ,  $W_i$ ,  $U_a$ , dan  $U_G$ . Variabel bias pada jaringan adalah  $b_Z$ ,  $b_i$ ,  $b_a$ , dan  $b_n$ . Keadaan tersembunyi saat ini dilambangkan dengan  $h_t$ , keadaan tersembunyi sebelumnya dengan  $h_{t-1}$ , dan nilai input baru dengan  $x_t$  [20].

## 2.5 Bidirectional Long Short-Term Memory (Bi-LSTM)

Varian perbaikan dari algoritma LSTM disebut BiLSTM, yang menggabungkan fungsi ideal RNN dan LSTM dua arah. BiLSTM mencapai hal ini dengan menggabungkan dua keadaan tersembunyi, memungkinkan pemrosesan data dari arah maju dan mundur secara bersamaan [21]. Pemrosesan arah mundur memungkinkan pengenalan karakteristik dan pola tersembunyi dalam data yang biasanya terlewatkan oleh LSTM biasa [22].

$$\vec{h}_t = f(w_1 x_t + w_2 \vec{h}_{t-1}) \quad (7)$$

$$\overleftarrow{h}_t = f(w_3 x_t + w_3 \overleftarrow{h}_{t+1}) \quad (8)$$

$$O_t = g(w_4 \vec{h}_t + w_6 \overleftarrow{h}_t) \quad (9)$$

Enam matriks bobot independen yang dilambangkan sebagai  $w_i$  ( $1, 2, \dots, 6$   $i = \dots$ ) memiliki fungsi sebagai berikut:  $w_1$   $w_3$   $w$  mewakili bobot input-to-hidden untuk lapisan depan dan belakang;  $w_2$   $w_5$ ,  $w$  mewakili bobot hidden-to-hidden; sedangkan  $w_4$ ,  $w_6$  mewakili bobot hidden-to-output untuk arah maju dan mundur. Dalam model BiLSTM, dua nilai  $h_t$  disimpan di lapisan tersembunyi:  $h_t \rightarrow$  for forward untuk perhitungan maju dan  $h_t$  for backward untuk perhitungan mundur. Keluaran dari lapisan maju dan mundur ini kemudian digabungkan untuk menghasilkan nilai final output [23].

## 2.6 Gated Recurrent Unit (GRU)

GRU digunakan untuk memprediksi hasil time series dengan memanfaatkan data historis terkini. Dibandingkan dengan LSTM, GRU menawarkan struktur yang lebih sederhana dan efisien, sambil tetap mempertahankan kinerja LSTM. Meskipun kinerja sel GRU dan LSTM serupa, GRU menyederhanakan proses dengan menggabungkan input gate dan forget gate serta menyatukan sel dan status tersembunyi, sehingga mengurangi jumlah gate menjadi dua yaitu update gate dan reset gate [24].

$$Z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (10)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (11)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_c) \quad (12)$$

$$h_t = (1 - Z_t) \odot h_{t-1} + Z_t \odot \tilde{h}_t \quad (13)$$

$W$  merujuk pada bobot, sedangkan  $b$  merupakan suku bias.  $r_t$  adalah reset gate,  $z_t$  berfungsi sebagai update gate,  $\tilde{h}_t$  mewakili status kandidat, dan  $h_t$  adalah output dalam persamaan algoritma GRU.

## 2.7 Bidirectional Gated Recurrent Unit (Bi-GRU)

Dua GRU yang dihubungkan ke output layer yang sama namun berorientasi ke arah yang berlawanan membentuk Bi-GRU. Dengan demikian, setiap titik dalam rangkaian input dapat mengakses informasi dari masa lalu dan masa depan secara bersamaan, memungkinkan output layer untuk memanfaatkan lebih banyak informasi berurutan [25].

$$\vec{h}_t^1 = f\left(w_{xh^1} \vec{x}_t + w_{h^1 h^2} \vec{h}_{t-1}^1 + b_{h^1}^1\right) \quad (14)$$

$$\overleftarrow{h}_t^1 = f\left(w_{xh^1} \overleftarrow{x}_t + w_{h^1 h^1} \overleftarrow{h}_{t-1}^1 + b_{h^1}^1\right) \quad (15)$$

$$\vec{h}_t^2 = f\left(w_{h^1 h^2} \vec{h}_t^1 + w_{h^1 h^2} \vec{h}_{t-1}^2 + b_{h^2}^1\right) \quad (16)$$

$$\overleftarrow{h}_t^2 = f\left(w_{h^1 h^2} \overleftarrow{h}_t^1 + w_{h^2 h^2} \overleftarrow{h}_{t+1}^2 + b_{h^2}^2\right) \quad (17)$$

$$y_t = g\left(w_{h^2 y} \vec{h}_t^2 + w_{h^2 y} \overleftarrow{h}_t^2 + b_y\right) \quad (18)$$

Vektor keluaran dari lapisan tersembunyi lapisan depan pada lapisan pertama dan kedua jaringan saraf Bi-GRU pada waktu  $t$  dinyatakan sebagai  $\vec{h}_t^1 \in \mathbb{R}^H$  dan  $\overleftarrow{h}_t^1 \in \mathbb{R}^H$ , dengan  $H$  menyatakan jumlah unit dalam sel GRU. Demikian pula, vektor keluaran dari lapisan tersembunyi lapisan belakang pada lapisan pertama dan kedua Bi-GRU adalah  $\vec{h}_t^2 \in \mathbb{R}^H$  dan  $\overleftarrow{h}_t^2 \in \mathbb{R}^H$ , di mana  $x_t$  adalah input jaringan saraf pada waktu  $t$  dan  $n$  adalah jumlah label. Fungsi  $(\cdot)$  mewakili fungsi aktivasi, dan fungsi  $(x) = \text{exi} \sum nk = \text{exk}$  menunjukkan proses dalam jaringan saraf GRU. Bobot dan bias yang perlu dipelajari masing-masing dinyatakan dengan variabel  $w$  dan  $b$  [26].

## 2.8 Optimizer

Skenario pelatihan yang digunakan meliputi variasi pembagian data, penggunaan dua hidden layer masing-masing dengan 100 unit, optimizer Adam dengan learning rate 0,001, SGD dengan learning rate 0,01 dan RMSprop dengan learning rate 0,001, serta 100 epoch.

## 2.9 Metrik Pengukuran Performa

Metrik seperti Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan R-Squared ( $R^2$ ) akan digunakan untuk menguji serta mengevaluasi model yang dilatih, dengan tujuan menentukan model yang optimal. Model dengan nilai terendah pada metrik-metrik ini akan dipilih untuk memprediksi harga saham PT. Bank Syariah Indonesia Tbk pada periode berikutnya.

$$MAE = \frac{1}{T} \sum_{t=1}^T |P_t - \hat{Z}_t| \quad (19)$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (P_t - \hat{Z}_t)^2} \quad (20)$$

$$MSE = \frac{1}{T} \sum_{t=1}^T (P_t - \hat{Z}_t)^2 \quad (21)$$

$$R^2 = 1 - \frac{\sum_{t=1}^T (P_t - \hat{Z}_t)^2}{\sum_{t=1}^T (Z_t - \bar{Z})^2} \quad (22)$$

Nilai antisipasi pada waktu  $t$  dilambangkan dengan  $P_t$  dan nilai observasi pada waktu  $t$  diwakili oleh  $Z_t$  [27].

### 3. HASIL DAN PEMBAHASAN

Untuk menemukan model terbaik dalam memprediksi harga saham menggunakan algoritma LSTM, Bi-LSTM, GRU dan Bi-GRU, dilakukan serangkaian eksperimen. Berbagai parameter diuji, termasuk batch size (8, 16, dan 32), optimizer (Adam, SGD, dan RMSprop), time step (14, 21, 28) serta learning rate (0.01 untuk SGD dan 0.001 untuk Adam dan RMSprop). Dengan memanfaatkan callback (checkpoint), setiap model dilatih selama 100 epoch untuk mengevaluasi kinerjanya.

#### 3.1 Hasil Evaluasi Model dengan Algoritma LSTM

Untuk mengetahui performa model LSTM dalam memprediksi harga saham, dilakukan serangkaian pengujian menggunakan berbagai konfigurasi parameter. Hasil dari pemodelan LSTM dapat dilihat pada Tabel 1.

**Tabel 1.** Hasil Evaluasi Model LSTM

Optimizer	Batch Size	Timestep	MSE	RMSE	MAE	R <sup>2</sup>
Adam	8	14	0.0003	0.0172	0.0132	0.9427
		21	0.0003	0.0172	0.0134	0.9411
		28	0.0003	0.0175	0.0133	0.9407
	16	14	0.0003	0.0151	0.0132	0.9328
		21	0.0003	0.0151	0.0131	0.9363
		28	0.0004	0.0148	0.0147	0.9218
	32	14	0.0004	0.015	0.0146	0.9144
		21	0.0004	0.0147	0.0145	0.9182
		28	0.0004	0.0146	0.0149	0.9127
SGD	8	14	0.0015	0.0134	0.0297	0.6658
		21	0.0015	0.0132	0.0297	0.6707
		28	0.0015	0.0131	0.0299	0.6658
	16	14	0.0016	0.0135	0.0298	0.6641
		21	0.0017	0.0131	0.0321	0.6247
		28	0.0017	0.0129	0.0315	0.6386
	32	14	0.0019	0.0134	0.0332	0.5955
		21	0.0019	0.0131	0.0338	0.5915
		28	0.002	0.013	0.0346	0.576
RMSprop	8	14	0.0004	0.0151	0.0141	0.919
		21	0.0004	0.0149	0.0149	0.9126
		28	0.0004	0.0156	0.0152	0.9084
	16	14	0.0005	0.015	0.0156	0.9026
		21	0.0005	0.0149	0.0156	0.9022
		28	0.0004	0.0152	0.0153	0.904
	32	14	0.0005	0.015	0.0164	0.8882
		21	0.0006	0.0147	0.0171	0.8811
		28	0.0006	0.0147	0.0183	0.8703

Berdasarkan percobaan yang dilakukan pada Tabel 1, model LSTM dengan optimizer Adam, batch size 8, dan timestep 14 menunjukkan performa terbaik dibandingkan konfigurasi LSTM lainnya. Model ini menghasilkan MSE sebesar 0.0003, RMSE 0.0172, MAE 0.0132, dan R<sup>2</sup> 0.9427.

#### 3.2 Hasil Evaluasi Model dengan Algoritma Bi-LSTM

Untuk mengetahui performa model Bi-LSTM dalam memprediksi harga saham, dilakukan serangkaian pengujian menggunakan konfigurasi parameter yang berbeda. Rincian lengkap hasil pemodelan Bi-LSTM dapat dilihat pada Tabel 2.

**Tabel 2.** Hasil Evaluasi Model Bi-LSTM

Optimizer	Batch Size	Timestep	MSE	RMSE	MAE	R <sup>2</sup>
Adam	8	14	0.0003	0.0177	0.0138	0.9385
		21	0.0003	0.0151	0.013	0.9362
		28	0.0005	0.0161	0.017	0.9003
	16	14	0.0003	0.0147	0.0134	0.9298
		21	0.0003	0.0144	0.0137	0.9256
		28	0.0004	0.015	0.0137	0.9234
	32	14	0.0004	0.0146	0.0142	0.9176
		21	0.0004	0.0144	0.0143	0.918
		28	0.0005	0.015	0.0157	0.9027



Optimizer	Batch Size	Timestep	MSE	RMSE	MAE	R <sup>2</sup>
SGD	8	14	0.0011	0.0136	0.0251	0.7544
	8	21	0.0015	0.0128	0.0297	0.6837
	8	28	0.0013	0.0131	0.0275	0.7212
	16	14	0.0017	0.0133	0.0313	0.6405
	16	21	0.0018	0.0127	0.033	0.6211
	16	28	0.0019	0.0125	0.0342	0.6012
	32	14	0.0016	0.0133	0.0308	0.6529
	32	21	0.0019	0.0127	0.0345	0.5924
	32	28	0.0022	0.0125	0.038	0.5274
RMSprop	8	14	0.0004	0.015	0.0145	0.915
	8	21	0.0004	0.0149	0.014	0.92
	8	28	0.0004	0.0148	0.0137	0.9221
	16	14	0.0004	0.0147	0.0145	0.9141
	16	21	0.0004	0.0149	0.0151	0.9061
	16	28	0.0005	0.0149	0.0163	0.8973
	32	14	0.0005	0.0147	0.0153	0.9016
	32	21	0.0005	0.0149	0.0156	0.8991
	32	28	0.0004	0.0148	0.0153	0.9042

Berdasarkan analisis pemodelan Bi-LSTM pada tabel 2, model paling efektif diperoleh dengan optimizer Adam, batch size 8, dan timestep 21. Model ini mencapai MSE sebesar 0.0003, RMSE 0.0151, MAE 0.013, dan R<sup>2</sup> 0.9362.

### 3.3 Hasil Evaluasi Model dengan Algoritma GRU

Model GRU dievaluasi untuk menentukan konfigurasi terbaik untuk memprediksi harga saham. Tabel 3 menampilkan hasil pemodelan GRU pada data uji.

**Tabel 3.** Hasil Evaluasi Model GRU

Optimizer	Batch Size	Timestep	MSE	RMSE	MAE	R <sup>2</sup>
Adam	8	14	0.0003	0.0186	0.0135	0.9413
	8	21	0.0003	0.0187	0.0136	0.9407
	8	28	0.0003	0.0185	0.0133	0.9429
	16	14	0.0003	0.017	0.013	0.9422
	16	21	0.0003	0.0174	0.0133	0.9409
	16	28	0.0004	0.0189	0.0141	0.9380
	32	14	0.0003	0.0171	0.0132	0.9419
	32	21	0.0003	0.0181	0.0139	0.9398
	32	28	0.0003	0.0185	0.0137	0.9417
SGD	8	14	0.0008	0.0155	0.0204	0.8484
	8	21	0.0008	0.0156	0.0203	0.8476
	8	28	0.0008	0.0154	0.0206	0.8447
	16	14	0.0009	0.0153	0.0212	0.8364
	16	21	0.0008	0.0153	0.021	0.8412
	16	28	0.0008	0.0153	0.021	0.839
	32	14	0.0008	0.0153	0.0212	0.8389
	32	21	0.0009	0.0152	0.0215	0.8338
	32	28	0.0009	0.0152	0.0217	0.8321
RMSprop	8	14	0.0003	0.0169	0.0134	0.9355
	8	21	0.0004	0.0175	0.0142	0.9294
	8	28	0.0004	0.0167	0.0146	0.9271
	16	14	0.0004	0.0169	0.014	0.9283
	16	21	0.0004	0.0175	0.0149	0.9211
	16	28	0.0004	0.0174	0.015	0.9206
	32	14	0.0004	0.0168	0.015	0.9175
	32	21	0.0004	0.0169	0.0148	0.918
	32	28	0.0004	0.017	0.0147	0.9186

Seperti terlihat pada Tabel 3, model dengan optimizer Adam, batch size 16, dan timestep 14 menunjukkan kinerja terbaik. Model ini mencapai MSE sebesar 0.0003, RMSE 0.017, MAE 0.013, dan R<sup>2</sup> 0.9422 menjadikannya konfigurasi yang paling terbaik.

### 3.4 Hasil Evaluasi Model dengan Algoritma Bi-GRU

Model Bi-GRU diuji untuk menentukan kinerja terbaiknya dalam memprediksi harga saham. Rincian lengkap hasil pemodelan Bi-GRU dapat dilihat pada Tabel 4.

**Tabel 4.** Hasil Evaluasi Model Bi-GRU

Optimizer	Batch Size	Timestep	MSE	RMSE	MAE	R <sup>2</sup>
Adam	8	14	0.0003	0.015	0.0124	0.9412
	8	21	0.0003	0.0169	0.0129	0.9438
	8	28	0.0003	0.0149	0.013	0.9369
	16	14	0.0003	0.0152	0.0125	0.9418
	16	21	0.0003	0.0155	0.0126	0.9406
	16	28	0.0003	0.0152	0.0127	0.9393
	32	14	0.0003	0.0154	0.0133	0.9342
	32	21	0.0003	0.0173	0.0134	0.9383
	32	28	0.0003	0.0152	0.0129	0.9362
SGD	8	14	0.0009	0.0136	0.0224	0.8085
	8	21	0.0007	0.014	0.019	0.8527
	8	28	0.0007	0.0141	0.0189	0.8558
	16	14	0.0009	0.0136	0.0227	0.8088
	16	21	0.0009	0.0135	0.0226	0.8074
	16	28	0.0007	0.0136	0.0196	0.8473
	32	14	0.0012	0.0134	0.0264	0.7459
	32	21	0.001	0.013	0.0248	0.7837
	32	28	0.0012	0.0129	0.027	0.7429
RMSprop	8	14	0.0003	0.0151	0.0133	0.9287
	8	21	0.0003	0.0148	0.0136	0.9282
	8	28	0.0003	0.0152	0.0132	0.9299
	16	14	0.0003	0.015	0.0131	0.9297
	16	21	0.0003	0.0148	0.0135	0.927
	16	28	0.0004	0.015	0.0138	0.9236
	32	14	0.0004	0.0154	0.0156	0.9053
	32	21	0.0004	0.0149	0.0138	0.921
	32	28	0.0004	0.0149	0.0143	0.9158

Pada Tabel 4 terlihat bahwa model Bi-GRU paling efektif diperoleh dengan optimizer Adam, batch size 8, dan timestep 21. Model ini mencapai MSE sebesar 0.0003, RMSE 0.0169, MAE 0.0129, dan R<sup>2</sup> 0.9438.

### 3.5 Evaluasi dan Analisis

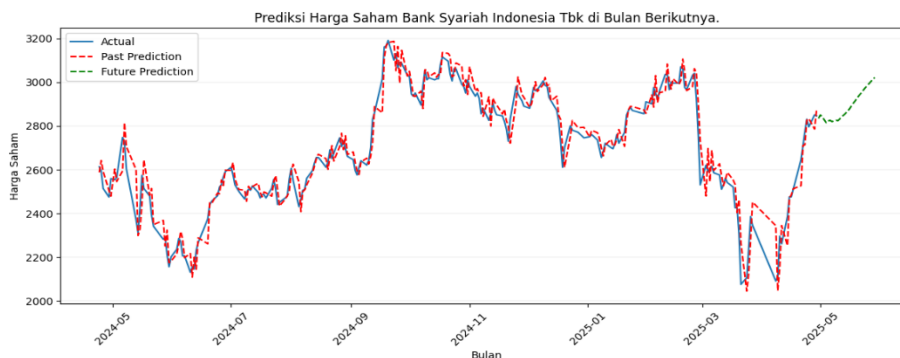
Berdasarkan hasil analisis pengujian, model Bi-GRU dengan pengoptimal Adam, batch size 8, dan timestep 21 menunjukkan performa terbaik karena memiliki kombinasi nilai MAE terendah dan R<sup>2</sup> tertinggi.



**Gambar 2.** Prediksi Harga Saham pada Data Uji

Meskipun nilai RMSE-nya sedikit lebih tinggi dibandingkan model lain, selisihnya relatif kecil dan tidak cukup signifikan untuk mengungguli keunggulan Bi-GRU pada metrik-metrik lainnya. Model ini mencapai MSE sebesar 0.0003, RMSE 0.0169, MAE 0.0129, dan R<sup>2</sup> 0.9438. Hasil prediksi model Bi-GRU pada data uji dapat dilihat pada Gambar 2.

Pada Gambar 2, garis penuh mewakili harga saham aktual, dan garis putus-putus mewakili hasil prediksi model Bi-GRU. Pola grafik menunjukkan bahwa model tersebut mampu mengidentifikasi tren pergerakan harga saham dengan kesalahan minimal. Model Bi-GRU yang terpilih sebagai yang terbaik akan diterapkan untuk memprediksi harga saham di masa depan pada Mei 2025. Hasil prediksi menunjukkan bahwa harga saham Bank Syariah Indonesia Tbk diperkirakan akan mengalami kenaikan. Grafik prediksi model Bi-GRU dapat dilihat pada Gambar 3.



**Gambar 3.** Prediksi Harga Saham di Bulan Berikutnya

Pada Gambar 3 terlihat bahwa model Bi-GRU memprediksi adanya tren kenaikan harga saham PT Bank Syariah Indonesia Tbk untuk periode Mei 2025. Garis penuh dalam grafik merepresentasikan nilai aktual hingga titik prediksi, sementara garis putus-putus menunjukkan hasil proyeksi dari model. Pola grafik memperlihatkan kenaikan harga saham yang relatif stabil, yang mengindikasikan potensi keuntungan bagi investor. Temuan ini menegaskan bahwa model Bi-GRU tidak hanya menunjukkan akurasi yang baik pada data uji sebelumnya, tetapi juga mampu memberikan proyeksi pergerakan harga yang andal untuk masa depan.

Hasil penelitian ini menegaskan bahwa Bi-GRU mengungguli model LSTM, Bi-LSTM, dan GRU. Temuan ini sesuai dengan penelitian Sofi, dkk. [12] yang menunjukkan bahwa GRU mengungguli Linear Regression dan LSTM dalam memprediksi saham, dengan RMSE 0,034 dan MAE 0,024. Penelitian ini menunjukkan bahwa dengan mengoptimalkan konfigurasi parameter dan menggunakan arsitektur bidirectional, Bi-GRU mampu mengungguli GRU tradisional dengan nilai RMSE yang lebih rendah (0,0169) dan MAE yang lebih kecil (0,0129).

Keunggulan Bi-GRU dalam penelitian ini disebabkan oleh kemampuannya memproses informasi sekuensial dalam dua arah (maju dan mundur), sehingga memungkinkan pengenalan pola kompleks dan ketergantungan jangka panjang dalam data harga saham. Adam merupakan optimizer terbaik untuk kasus ini, dengan MAE terendah dan  $R^2$  tertinggi. RMSprop dapat menjadi alternatif, namun hasilnya sedikit kurang optimal dibandingkan Adam. Sementara itu, SGD menunjukkan performa terburuk dan tidak disarankan karena error yang lebih tinggi serta ketidakstabilan dalam pelatihan. Selain itu, penggunaan batch size yang lebih kecil pada model cenderung meningkatkan akurasi prediksi.

Dengan keunggulan model Bi-GRU, penelitian ini berkontribusi secara signifikan dalam meningkatkan akurasi prediksi harga saham, khususnya untuk pasar saham syariah Indonesia. Implementasi model ini dapat membantu investor dan perusahaan dalam mengambil keputusan yang lebih tepat berdasarkan data prediktif yang andal. Selain itu, hasil penelitian ini menegaskan bahwa pemilihan arsitektur deep learning dan optimasi parameter memainkan peran penting dalam menentukan kualitas prediksi.

## 4. KESIMPULAN

Hasil analisis menunjukkan bahwa model deep learning memiliki performa yang baik dalam memprediksi harga saham PT. Bank Syariah Indonesia Tbk. Di antara keseluruhan, model Bi-GRU menunjukkan efektivitas tertinggi berdasarkan hasil pengujian, dengan nilai MSE sebesar 0.0003, RMSE sebesar 0.0169, MAE sebesar 0.0129, dan  $R^2$  sebesar 0.9438. Penggunaan algoritma optimasi Adam terbukti secara signifikan meningkatkan kinerja model arsitektur dibandingkan dengan optimasi lainnya seperti RMSprop dan SGD. Berdasarkan keunggulan tersebut, model Bi-GRU dipilih untuk melakukan prediksi harga saham PT. Bank Syariah Indonesia Tbk selama 30 hari ke depan. Hasil prediksi menunjukkan potensi kenaikan harga saham, yang dapat dimanfaatkan oleh perusahaan untuk menyusun strategi ekspansi dan mempertahankan keberlangsungan bisnis dalam jangka panjang. Penelitian ini memberikan kontribusi penting bagi organisasi dan investor yang memiliki keterkaitan dengan saham PT. Bank Syariah Indonesia Tbk, dengan menyediakan data prediktif yang akurat serta mendukung perumusan strategi investasi yang lebih efektif.

## REFERENCES

- [1] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. ETP, "Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19," *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 2, p. 133, 2021, doi: 10.26418/jp.v7i2.47411.
- [2] R. Moerdianto, A. S. U. Anto, Y. P. Gazali, Kartini, and Y. Rura, "Pengaruh Return On Asset Dan Earning Per Share Terhadap Harga Saham Perusahaan Sektor Energi Yang Terdaftar Di Bursa Efek Indonesia.," *J. Ekon. Dan Bisnis*, vol. 11, no. 4, pp. 251–259, 2022, doi: 10.34308/eqien.v11i04.1237.
- [3] S. Kusmawaningsih, R. Saputri, and A. Khoirudin, "Analisis Harga Saham Dalam Perspektif Ekonomi Islam," *J. Iqtishaduna Econ. Doctrin.*, vol. 6, no. 1, pp. 7–14, 2023, doi: 10.53888/iqtishaduna.v6i1.651.
- [4] M. R. Wijaya, "Inovasi Model Intrusion Detection System (IDS) menggunakan Double Layer Gated Recurrent Unit (GRU) dengan Fitur Berbasis Fusion," *J. Ilm. Educat.*, vol. 12, no. 1, pp. 10–21, 2025, doi: 10.21107/edutic.v12i1.28822.



- [5] D. Sawitri, “Peran Deep Learning Dan Big Data Dalam Mendekteksi Masalah Peran Deep Learning Dan Big Data Dalam Mendekteksi Masalah Keuangan,” *J. Teknol. Inf.*, vol. 6, no. April, 2025, doi: 10.46576/djtechno.
- [6] H. Hartini and D. Marhandrie, “Pengaruh Profitabilitas, Risiko Finansial dan Harga Saham Terhadap Nilai Perusahaan Bank Syariah Indonesia (BSI) Di BEI Periode Tahun 2014 - 2021,” *J. Ilm. Ekotrans Erud.*, vol. 2, no. 1, pp. 104–111, 2022, doi: 10.69989/9wgez3f07.
- [7] Isra Miraltamirus, Fadhilah Fitri, Dodi Vionanda, and Dony Permana, “Prediksi Harga Saham PT Bank Syariah Indonesia Tbk Menggunakan Support Vector Regression,” *UNP J. Stat. Data Sci.*, vol. 1, no. 3, pp. 112–119, 2023, doi: 10.24036/ujsds/voll1-iss3/43.
- [8] Y. Sujatna *et al.*, “Stacked LSTM-GRU Long-Term Forecasting Model for Indonesian Islamic Banks,” *Knowl. Eng. Data Sci.*, vol. 6, no. 2, p. 215, 2023, doi: 10.17977/um018v6i22023p215-250.
- [9] P. L. Seabe, C. Rodrigue, B. Moutsinga, and E. Pindza, “Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach,” *Fractal Fract.*, vol. 7, no. 2, pp. 1–18, 2023, doi: 10.3390/fractalfract7020203.
- [10] M. Mushliha, “Implementasi CNN-BiLSTM untuk Prediksi Harga Saham Bank Syariah di Indonesia,” *Jambura J. Math.*, vol. 6, no. 2, pp. 195–203, 2024, doi: 10.37905/jjom.v6i2.26509.
- [11] N. M. Tuan, “Machine Learning Performance on Predicting Banking Term Deposit,” *Int. Conf. Enterp. Inf. Syst. ICEIS - Proc.*, vol. 1, no. April 2022, pp. 267–272, 2022, doi: 10.5220/0011096600003179.
- [12] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, and Antika Zahrotul Kamalia, “Perbandingan Algoritma Linear Regression, Lstm, Dan Gru Dalam Memprediksi Harga Saham Dengan Model Time Series,” *Seminastika*, vol. 3, no. 1, pp. 39–46, 2021, doi: 10.47002/seminastika.v3i1.275.
- [13] M. R. Luthfi and R. D. Syah, “Model Deep Learning Untuk Analisis Prediksi Harga Saham Menggunakan Metode Long Short-Term Memory (Lstm),” *J. Ilm. Ekon. Bisnis*, pp. 201–213, 2025, doi: 10.35760/eb.2025.v30i1.11870 201.
- [14] F. Ramadhan and J. Hernadi, “Evaluasi optimizer adam dan rmsprop pada arsitektur vgg-19 klasifikasi ekspresi wajah manusia,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 2, pp. 1414–1426, 2025, doi: 10.29100/jupi.v10i2.6197.
- [15] Yahoo Finance, “BRIS.JK - Bank Syariah Indonesia Tbk.” Accessed: May 13, 2025. [Online]. Available: <https://finance.yahoo.com/quote/BRIS.JK/>
- [16] R. S. Andromeda, N. Anisa, and S. Winarsih, “Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga Close Cryptocurrency Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices,” *J. Sist. Inf.*, vol. 14, pp. 366–379, 2025, doi: 10.32520/stmsi.v14i1.4880.
- [17] Galih Adhi Putratama, Satya Maulana Fahreza, and Yudhistira Rakha Ramandhani, “Evaluasi Komparatif Metode Machine Learning Untuk Memprediksi Perubahan Harga Saham,” *Antivirus J. Ilm. Tek. Inform.*, vol. 17, no. 2, pp. 278–285, 2024, doi: 10.35457/antivirus.v17i2.2871.
- [18] E. Koo and G. Kim, “Prediction of Bitcoin price based on manipulating distribution strategy,” *Elsevier*, vol. 110, 2021, doi: 10.1016/j.asoc.2021.107738.
- [19] A. Foresta *et al.*, “Heart Beat Prediction Based on Lstm Model on Raspberry Pi,” *J. Teknol. Inf.*, vol. 10, no. 7, pp. 1555–1562, 2023, doi: 10.25126/jtiik.2024118015.
- [20] R. Erzitha, D. Novaliendry, and K. Budayawan, “Analysis Of Dropout And Learning Rate On Bilstm- Ann Performance In Hate Speech Detection,” *Lentera: Multidisciplinary Studies*, vol. 3, no. 2, pp. 221–232, 2025, doi: 10.57096/lentera.v3i2.142.
- [21] N. N. Aung, J. Pang, M. C. H. Chua, and H. X. Tan, “A novel bidirectional LSTM deep learning approach for COVID-19 forecasting,” *Sci. Rep.*, vol. 13, no. 1, pp. 1–11, 2023, doi: 10.1038/s41598-023-44924-8.
- [22] P. Singla, M. Duhan, and S. Saroha, “An ensemble method to forecast 24-h ahead solar irradiance using wavelet decomposition and BiLSTM deep learning network,” *Earth Sci. Informatics*, vol. 15, no. 1, pp. 291–306, 2022, doi: 10.1007/s12145-021-00723-1.
- [23] M. N. Taukid, Y. V. Via, and E. Y. Puspaningrum, “Implementasi Bilstm Dan Cuckoo Search Optimization Pada Aplikasi Prediksi Harga Emas Antam,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, 2025, doi: 10.36040/jati.v9i3.14310.
- [24] K. E. ArunKumar, D. V. Kalaga, C. M. S. Kumar, M. Kawaji, and T. M. Brenza, “Forecasting of COVID-19 using deep layer Recurrent Neural Networks (RNNs) with Gated Recurrent Units (GRUs) and Long Short-Term Memory (LSTM) cells,” *Chaos, Solitons and Fractals*, vol. 146, p. 110861, 2021, doi: 10.1016/j.chaos.2021.110861.
- [25] F. Meng, T. Song, X. Danya, P. Xie, and Y. Li, “Forecasting tropical cyclones wave height using bidirectional gated recurrent unit,” *Ocean Eng.*, vol. 234, 2021, doi: 10.1016/j.oceaneng.2021.108795.
- [26] L. D. Soares, A. de S. Queiroz, G. P. López, E. M. Carreño-Franco, J. M. López-Lezama, and N. Muñoz-Galeano, “BiGRU-CNN Neural Network Applied to Electric Energy Theft Detection,” *Electron.*, vol. 11, no. 5, pp. 1–13, 2022, doi: 10.3390/electronics11050693.
- [27] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.