

## Memprediksikan Harga Saham Bank Rakyat Indonesia (Persero) Tbk Menggunakan Metode *Bidirectional Long Short Term Memory* (Bi-LSTM)

Rahma Darja<sup>\*1</sup>, Irwan<sup>2</sup>, Muh. Irwan<sup>3</sup>

<sup>1,2,3</sup>Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Alauddin Makassar  
Gowa, Sulawesi Selatan, Indonesia

<sup>1</sup>rahmahdarja99@gmail.com, <sup>2</sup>irwan.msi@uin-alauddin.ac.id, <sup>3</sup>muhirwan@uin-alauddin.ac.id

### Abstrak

Pasar modal memegang peranan strategis sebagai indikator stabilitas ekonomi suatu negara, di mana saham berfungsi sebagai instrumen vital untuk pertukaran modal yang memengaruhi berbagai sektor keuangan. Mengingat sifat harga saham yang fluktuatif dan non-linear, prediksi yang akurat menjadi sangat krusial bagi investor untuk meminimalisir risiko kerugian. Penelitian ini bertujuan untuk memprediksi harga saham tertinggi (high price) pada PT Bank Rakyat Indonesia (Persero) Tbk menggunakan pendekatan Deep Learning, yaitu metode Bidirectional Long Short-Term Memory (Bi-LSTM). Dalam metodologi penelitian, skenario pembagian data dilakukan dengan komposisi 50% data latih dan 50% data uji. Penelitian ini melakukan serangkaian eksperimen tuning hyperparameter yang meliputi variasi learning rate, jumlah neuron, dan jumlah epoch. Berdasarkan hasil pengujian, arsitektur model paling optimal diperoleh dengan konfigurasi 50 neuron, penggunaan algoritma optimasi Adam, learning rate sebesar 0,001, batch size 1, dan 5 kali epoch. Evaluasi kinerja model menunjukkan hasil yang sangat impresif, dengan nilai Mean Absolute Percentage Error (MAPE) sebesar 1,24998952%. Mengacu pada standar evaluasi di mana nilai MAPE < 10%, kemampuan prediksi model ini dikategorikan sebagai "sangat baik". Hasil ini mengindikasikan bahwa model Bi-LSTM yang dibangun sangat andal dan dapat dimanfaatkan oleh investor sebagai acuan strategis dalam pengambilan keputusan investasi saham BBRI.

**Kata kunci:** Prediksi, High price, Bi-LSTM, Saham, BBRI

### Abstract

The capital market plays a strategic role as an indicator of a country's economic stability, where stocks serve as vital instruments for capital exchange that influence various financial sectors. Given the fluctuating and non-linear nature of stock prices, accurate prediction is crucial for investors to minimize the risk of loss. This study aims to predict the high price of PT Bank Rakyat Indonesia (Persero) Tbk stocks using a Deep Learning approach, specifically the Bidirectional Long Short-Term Memory (Bi-LSTM) method. The research methodology employed a data splitting scenario comprising 50% training data and 50% testing data. A series of hyperparameter tuning experiments were conducted, covering variations in learning rate, number of neurons, and number of epochs. Based on the test results, the optimal model architecture was obtained with a configuration of 50 neurons, the Adam optimizer, a learning rate of 0.001, a batch size of 1, and 5 epochs. Performance evaluation demonstrated impressive results, yielding a Mean Absolute Percentage Error (MAPE) of 1.24998952%. Referring to evaluation standards where a MAPE < 10% is considered "excellent," the prediction capability of this model falls into the highest category. These results indicate that the developed Bi-LSTM model is highly reliable and can be utilized by investors as a strategic reference for decision-making regarding BBRI stock investments.

**Keywords:** Prediction; High Price; Bi-LSTM; Stock; BBRI

This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0)



## 1. PENDAHULUAN

Peramalan suatu prediksi tentang kejadian dimasa depan dengan pengujian di masa lalu. Contohnya langit yang mendung biasanya diprediksikan akan turun hujan, sehingga manusia menyiapkan diri agar tidak kehujaan. Hasil prediksi tersebut diketahui dari kebiasaan yang terjadi di masa lalu. Akan tetapi, ada kalanya hujan tidak turun saat langit mendung. Ketidakpastian yang terjadi itu dikarenakan setiap prediksi manusia tidak akan tepat 100% [1].

Analisis data runtun waktu adalah analisis yang diproses dengan data yang berorientasi pada waktu atau kronologis pada peubah yang diamati. Analisis ini sangat bermanfaat jika data dipengaruhi oleh waktu atau pengamatan sebelumnya. Beberapa bidang misalnya bidang ekonomi, bidang keuangan, bidang transportasi serta masih banyak lagi, biasanya menggunakan analisis runtun waktu [2].

Metode peramalan yang paling dikembangkan saat ini adalah metode *Time Series* dengan metode statistik seperti jaringan syaraf (*neural network*), *wavelet*, maupun *system fuzzy*. *Reccurent Neural Network* (RNN) data sekuensial yang dilakukan berulang kali. Dalam proses metode RNN terdapat 3 jenis yaitu *Vanilla*, *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) [3]. LSTM memiliki kelemahan hanya memproses kata dalam satu arah saja. *Bidirectional Long Short Term Memory* (Bi-LSTM) merupakan LSTM yang telah dikembangkan dapat mengatasi kelemahan pada metode LSTM, dimana Bi-LSTM dapat memproses kata dalam dua arah [4].

Saham Bank Rakyat Indonesia (BRI) merupakan salah satu saham disektor perbankan yang masuk indek saham LQ45 dan banyak menarik investor karena kinerja keuangannya yang stabil [5].

Adapun penelitian yang menggunakan metode Bi-LSTM dalam memprediksikan data time series diantaranya penelitian dilakukan oleh [6] penerapan metode LSTM dan Bi-LSTM menunjukkan hasil yang lebih bagus dibandingkan model GRU untuk permasalahan data yang bersifat time series kualitas udara. [7] membandingkan model RNN, LSTM, dan Bi-LSTM dalam meramalkan permukaan laut diperoleh hasil bahwa metode Bi-LSTM memberikan hasil yang lebih baik dibandingkan dengan RNN dan LSTM. [8] menggunakan Bi-LSTM dalam meramalkan harga saham Adaro karena model terbukti memiliki kemampuan untuk memahami struktur data yang berubah secara konsisten dari waktu ke waktu. Selain itu, sangat baik dalam peramalan runtun waktu data keuangan seperti data harga saham. [9] hasil pemodelan menunjukkan bahwa Bi-LSTM mengungguli model prediksi lainnya untuk semua variable lalu lintas. [10] membandingkan model Bi-LSTM, LSTM, GRU, dan Arima dalam memprediksi pandemi untuk perencanaan yang lebih baik diperoleh hasil bahwa model Bi-LSTM lebih unggul dibanding metode lainnya.

Berdasarkan penelitian terdahulu, maka peneliti berinisiatif menggunakan metode Bi-LSTM dalam memprediksikan harga saham Bank Rakyat Indonesia (Persero) Tbk.

## 2. METODE PENELITIAN

### 2.1 Landasan Teori

#### 2.1.1 Recurrent Neural Network

*Recurrent neural network* merupakan jaringan saraf tiruan yang dirancang untuk menangani data berurutan atau sekuensial dengan mempertahankan keadaan internal atau memori. RNN tersebut mendapat input  $X_t$  dan menghasilkan output  $h_t$ . Macam – macam pemrosesan RNN adalah satu ke satu, satu ke banyak, banyak ke satu, dan banyak ke banyak [11]. Rumus dasar untuk menghitung output dari RNN pada langkah waktu  $t$  adalah sebagai berikut:

$$h_t = \sigma(W_{hh}h_{t-1} + W_{xh}x_t + b_h)$$

Terdapat dua proses fungsi aktivasi yaitu fungsi sigmoid dan tanh. *Sigmoid layer* akan memberikan hasil menjadi bentuk range  $[0,1]$ . Yang di mana jika hasilnya 0 maka menunjukkan bahwa informasi akan dihentikan sedangkan jika hasilnya adalah 1 maka informasi akan diteruskan. Adapun persamaan dari fungsi sigmoid adalah sebagai berikut.

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

Adapun untuk fungsi aktivasi tanh adalah input berupa sembarang angka yang di mana keluarannya berupa angka antara -1 dan 1 [12]. Adapun persamaan dari fungsi tanh adalah sebagai berikut.

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

### 2.1.2 Long Short Term Memory network (LSTM)

Pada tahun 1997 Hochreiter dan Jurgen Schmidhuber menciptakan Long Short Term Memory network (LSTM) adalah salah satu pengembangan dari pembelajaran RNN yang sering digunakan untuk pemodelan data time series. Output dari algoritma RNN akan dijadikan sebagai input kembali untuk langkah berikutnya. Algoritma RNN memiliki kelemahan yaitu tidak dapat memproses dan memprediksi dalam memori jangka panjang. Untuk mengatasi kelemahan algoritma RNN maka dirancang algoritma LSTM dan kelebihan yang ada pada RNN tetap dipertahankan oleh LSTM. Informasi dalam jangka panjang mampu disimpan oleh algoritma LSTM yang selanjutnya dimanfaatkan untuk prediksi serta pengklasifikasikan informasi tersebut berdasarkan deret waktu [13].

Tahap pertama dalam pemrosesan metode LSTM yaitu mengambil keputusan data apa yang akan dihilangkan dari *cell state* ( $C_t$ ). Proses tersebut dilakukan oleh *layer sigmoid* ( $\sigma$ ) dengan nama *layer forget gate*. *Layer sigmoid* tersebut memproses  $h_{t-1}$  dan  $X_t$  sebagai suatu *input* baru kemudian menghasilkan sebuah output (menjadi nilai 0 dan 1) pada  $C_{t-1}$  yang dapat diuraikan pada persamaan berikut:

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

Dimana, nilai *weight* dan nilai *output* baru diuraikan pada persamaan berikut:

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

$$h_t = o_t \odot \tanh(C_t)$$

Selanjutnya tahap kedua akan diputuskan data apa saja yang akan tersimpan pada *cell state*. Dalam tahap ini terdapat dua *layer gate* yaitu *input gate layer* dan *tanh layer*, *layer* pertama yaitu *input layer gate* akan memproses dan mengambil keputusan nilai yang akan diperbaharui dan menghasilkan  $i_t$ . Kemudian, *tanh layer* membuat nilai baru  $\bar{C}_t$  yang kemudian ditambahkan pada *cell state*. Langkah berikutnya yaitu menggabungkan masing-masing hasil dari *layer input gate* dan *layer tanh*. Dapat diuraikan pada persamaan berikut:

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

Persamaan nilai baru diuraikan sebagai berikut:

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

Langkah ketiga yaitu dilakukan pembaharuan pada *cell state* lama  $C_{t-1}$ , menjadi *cell state* yang baru  $C_t$  yang dapat dilihat pada gambar diatas dan diuraikan pada persamaan berikut:

$$C_t = f_t C_{t-1} + i_t \bar{C}_t$$

Tahap keempat atau terakhir dalam metode LSTM adalah menghasilkan sebuah output seperti pada gambar diatas. Pertama *layer sigmoid* ( $\sigma$ ) akan mengambil keputusan bagian mana dari *cell State* yang menjadi output. Kemudian, output akan dikirim ke dalam *layer tanh* (dengan nilai antara -1 dan 1), lalu dikirim menuju *sigmoid gate* agar output yang dihasilkan sama dengan sebelumnya. Diuraikan pada persamaan berikut [14]:

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

### 2.1.3 Bidirectional Long Short Term Memory (BI-LSTM)

*Bidirectional LSTM* terdiri dari dua lapisan jaringan saraf LSTM, yaitu lapisan LSTM lanjutan untuk memodelkan konteks sebelumnya dan lapisan LSTM mundur untuk memodelkan setiap konteks berikutnya. *Bidirectional LSTM* adalah menghubungkan dua lapisan tersembunyi dari arah yang berlawanan ke output yang sama. Secara matematis, output dari bi-LSTM diperoleh sebagai berikut [15].

#### 1. LSTM Maju

Menghitung aktivasi LSTM maju menggunakan persamaan berikut:

$$\begin{aligned}\vec{i}_t &= \sigma(W_{ix}x_t + W_{ih}\vec{h}_{t-1} + b_i) \\ \vec{f}_t &= \sigma(W_{fx}x_t + W_{fh}\vec{h}_{t-1} + b_f) \\ \vec{c}_t &= \vec{f}_t \odot \vec{c}_{t-1} + \vec{i}_t \odot \tanh(W_{cx}x_t + W_{ch}\vec{h}_{t-1} + b_c) \\ \vec{o}_t &= \sigma(W_{ox}x_t + W_{oh}\vec{h}_{t-1} + b_o) \\ \vec{h}_t &= \vec{o}_t \odot \tanh(\vec{c}_t)\end{aligned}$$

#### 2. LSTM Mundur

Menghitung aktivasi LSTM mundur menggunakan persamaan berikut:

$$\begin{aligned}\tilde{i}_t &= \sigma(W_{ix}x_t + W'_{ih}\tilde{h}_{t-1} + b'_i) \\ \tilde{f}_t &= \sigma(W'_{fx}x_t + W'_{fh}\tilde{h}_{t-1} + b'_f) \\ \tilde{c}_t &= \tilde{f}_t \odot \tilde{c}_{t-1} + \tilde{i}_t \odot \tanh(W'_{cx}x_t + W'_{ch}\tilde{h}_{t-1} + b'_c) \\ \tilde{o}_t &= \sigma(W'_{ox}x_t + W'_{oh}\tilde{h}_{t-1} + b'_o) \\ \tilde{h}_t &= \tilde{o}_t \odot \tanh(\tilde{c}_t)\end{aligned}$$

Output dari bi-LSTM pada langkah waktu  $t$  biasanya gabungan dari LSTM maju dan mundur. Adapun persamaan output dari bi-LSTM adalah sebagai berikut:

$$y_t = W_{\vec{h}_y}\vec{h}_t + W_{\tilde{h}_y}\tilde{h}_t$$

### 2.1.4 Optimization Adaptive Moment Estimation (Adam)

Optimasi adam merupakan Algoritma perluasan untuk stochastic gradient descent yang baru ini telah digunakan sebagai pembelajaran yang mendalam dalam computer vision dan natural language processing. Adam mengintegrasikan ide dari Adagrad dan RMSProp dengan menggunakan dua estimasi momentum (rata-rata gradien dan rata-rata kuadrat gradien) untuk penyesuaian learning rate yang lebih efektif [16].

#### 1. Moment Pertama (Rata-Rata Gradien)

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$$

#### 2. Moment Kedua (Rata-Rata Kuadrat Gradien)

$$v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$$

#### 3. Koreksi Bias

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

#### 4. Update Parameter

$$\theta_{t+1} = \theta_t - \frac{\alpha \cdot \hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon}$$

##### 2.1.5 Preprocessing

Metode preprocessing yang digunakan adalah perhitungan Min-Max Scaler yang mempunyai rentang nilai antara 0 hingga 1. Min-Max Scaler adalah metode normalisasi dimana transformasi linier dari data asli dilakukan untuk menciptakan keseimbangan nilai perbandingan antara data awal dan akhir setelah proses transformasi dilakukan. Persamaan berikut merupakan implementasi dari metode Min-Max Scaler [17]:

$$X_{norm} = \frac{x - \min_x}{\max_x - \min_x}$$

##### 2.1.6 Evaluasi

RMSE (Root Mean Square Error) adalah metode alternatif yang sering digunakan pada kasus yang berkaitan dengan peramalan. Nilai yang dihasilkan berupa nilai rata-rata kuadrat dari jumlah kesalahan pada model prediksi yang didapatkan. MAPE (Mean Absolute Percentage Error) adalah nilai rata-rata diferensiasi absolut antara nilai yang didapatkan dari hasil peramalan dengan nilai actual, MAPE digunakan dalam menghitung besar persentase kesalahan antara nilai actual dan hasil prediksi. Adapun rumus dari RMSE dan MAPE adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - y_i)^2}$$

$$MAPE = 100 \times \frac{1}{n} \sum_{i=1}^n \left| \frac{\tilde{y}_i - y_i}{y_i} \right|$$

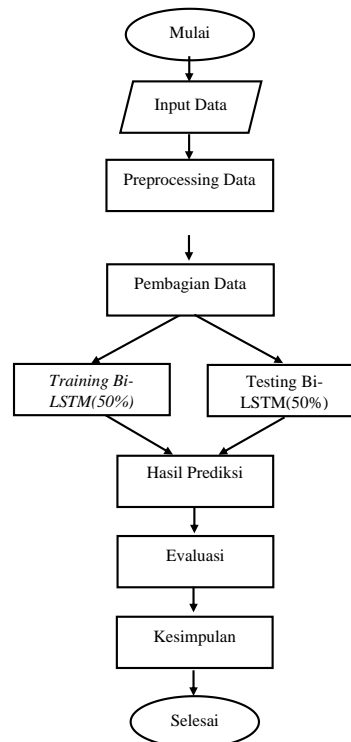
Skala untuk menilai akurasi peramalan berdasarkan nilai MAPE, sebagai berikut [18]:

**Tabel 2.** Kriteria Nilai MAPE dalam Peramalan

Skala MAPE	Interpretasi
< 10%	Sangat baik
10-20%	Baik
20-50%	Layak
>50%	Buruk

## 2.2 Tahapan Analisis Data

Langkah-langkah analisis yang digunakan pada penelitian ini sebagai berikut:



**Gambar 2.** Grafik Harga Tertinggi Saham

## 3. HASIL DAN PEMBAHASAN

### 3.1. Data Penelitian

Pada penelitian ini digunakan data harga tertinggi harian saham Bank Rakyat Indonesia (Persero) Tbk yang diperoleh melalui laman <https://finance.yahoo.com> dari awal periode saham 11/11/2003 sampai dengan 31/12/2023 dengan jumlah data sebanyak 4999.



**Gambar 3. 1** Grafik Harga Tertinggi Saham

Pada gambar 4.1 menunjukkan bahwa pergerakan harga tertinggi harian saham meningkat dari awal periode sampai tahun 2024.

### 3.2. Statistik Deskriptif

**Tabel 3. 1** Statistika Deskriptif Data dalam Satuan IDR

Min	Kuartil Pertama	Median	Mean	Kuartil Ketiga	Max	Standar Deviasi
90,90	581,80	1599,97	1966,89	3036,31	5750,00	1521,52

Berdasarkan tabel 4.2 diketahui bahwa rata-rata harga tertinggi saham sebesar 1966,894826 dengan minimum 90,907516 dan maksimum 5750,000000 dengan standar deviasi 1521,522034.

### 3.3. Preprocessing Data

#### 3.3.1. Normalisasi Data

Menormalisasi data terlebih dahulu agar mengurangi error yang terjadi. Dalam melakukan normalisasi data, data harga tertinggi harian aktual akan diubah menjadi nilai dengan range [0,1] menggunakan Min-Max scalling.

**Tabel 3. 2** Normalisasi Data

Tanggal	Harga Tertinggi Harian
11/11/2003	0,00000000
12/11/2003	0,00080319
13/11/2003	0,00080319
14/11/2003	0,00080319
17/11/2003	0,00040159
⋮	⋮
21/12/2023	0,97349398
22/12/2023	0,99116466
27/12/2023	0,99558233
28/12/2023	1,00000000
29/12/2023	1,00000000

#### 3.3.2. Pembagian Data Latih dan Data Uji

Pembagian keseluruhan data yang berjumlah 4999 dataset. Data tersebut akan terbagi 2 bagian yaitu data latih dan data uji dengan perbandingan 50% data latih dan 50% data uji.



**Tabel 3. 3** Komposisi Pembagian Data Latih dan Data Uji

Perbandingan	Pembagian	
	Data Latih ( <i>Training</i> )	Data Uji ( <i>Testing</i> )
90:10	4500	499
80:20	4000	999
70:30	3500	1499
60:40	3000	1999
50:50	2500	2499

### 3.3.3. Segmentasi Data

Segmentasi dilakukan dengan membagi data mentah menjadi data yang dibutuhkan dalam system. Semakin panjang proses yang dilakukan maka hasil yang diperoleh semakin bagus. Akan tetapi pada penelitian ini menggunakan segmentasi 60 data dimana diharapkan cukup untuk proses analisis berikutnya. Selain itu, jumlah tersebut dianggap tidak terlalu banyak agar proses pelatihan tidak membutuhkan waktu training yang lama.

### 3.3.4. Inisialisasi Parameter

Inisialisasi parameter yang dilakukan pada data latih dengan menginput nilai neuron hidden, batch size, learning rate, max epoch, dan optimasi. Penentuan parameter tidak adanya ketentuan yang khusus. Sehingga, nilai parameter yang digunakan adalah sebagai berikut:

**Tabel 3. 4** Inisialisasi Parameter Bi-LSTM

Neuron	Optimasi	Learning Rate	Batch Size	Epoch
50	Adam	0,01	1	5
50	Adam	0,001	1	5
50	Adam	0,01	16	5
50	Adam	0.001	16	5
50	Adam	0,01	32	5
50	Adam	0,001	32	5

### 3.3.5. Melakukan *Training* dan *Testing*

Dalam proses *training* dilakukan trial and error untuk mencari kombinasi parameter yang baik. Sebelumnya telah dilakukan beberapa proses pengujian perbandingan data. Berikut tabel hasil pengujian perbandingan data:



**Tabel 3. 5** Hasil Pengujian Perbandingan

Perbandingan	Pembagian		MAPE (%)
	Data Latih ( <i>Training</i> )	Data Uji ( <i>Testing</i> )	
90:10	4500	499	1,30803570%
80:20	4000	999	1,55976647%
70:30	3500	1499	1,68442962%
60:40	3000	1999	1,81851352%
50:50	2500	2499	1,24998952%

Dari pengujian perbandingan data *training* dan *testing* tersebut diperoleh bahwa dengan perbandingan 50:50 menunjukkan persentasi nilai MAPE terbaik (10%). Berikut tabel hasil analisis menggunakan metode *Bidirectional Long Short Term Memory*:

**Tabel 3. 6** Hasil Training Kombinasi Parameter Bi-LSTM

Neuron	Optimizer	Learning Rate	Batch Size	Epoch	RMSE	MAPE (%)
50	Adam	0,01	1	5	100,26896647	2,43026048
50	Adam	0,001	1	5	59,35482880	1,24998952
50	Adam	0,01	16	5	189,63545750	4,30039000
50	Adam	0,001	16	5	283,64839917	6,05422878
50	Adam	0,01	32	5	123,00312142	2,54553303
50	Adam	0,001	32	5	215,74865741	4,75945956

Kemudian kombinasi yang didapatkan akan digunakan pada model untuk melakukan proses testing guna mendapatkan hasil prediksi. Berikut ditampilkan model sequential Bi-LSTM.

**Tabel 3. 7** Model Sequential Bi-LSTM

Layer (type)	Output Shape	Param #
Bidirectional(Bidirectional)	(1, 100)	20800
dense(Dense)	(1, 1)	101

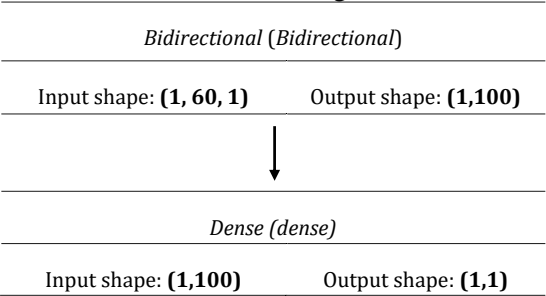
Total params: 62, 705

Trainable Params: 20, 901

Non-trainable params: 0

Dari tabel 3.7 dapat dilihat bahwa model sequential yang digunakan adalah 2 layer, yaitu Bi-LSTM layer dan dense layer. Model tersebut digunakan untuk memprediksi harga saham.

**Tabel 3. 8** Arsitektur Harga Saham




Arsitektur bi-LSTM pada tabel 3.8 diperoleh berdasarkan informasi yang didapatkan dari tabel 3.7. Berikut disajikan hasil prediksi yang telah mengalami proses denormalisasi:

**Tabel 3. 9** Hasil Prediksi

No.	Nilai Aktual (IDR)	Prediksi (IDR)
0	1381,79	1409,09
1	1363,61	1373,66
2	1336,34	1355,90
3	1336,34	1331,50
4	1336,34	1335,93
⋮	⋮	⋮
2494	5600,0	5756,09
2495	5700,0	5536,72
2496	5725,0	5704,99
2497	5750,0	5729,18
2498	5750,0	5725,23

Berikut akan ditampilkan grafik dari hasil prediksi:



**Gambar 3. 2** Grafik Prediksi Harga Saham

#### 4. KESIMPULAN

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa akurasi model *Bidirectional Long Short Term Memory* dalam memprediksi harga saham dengan hasil MAPE sebesar 1,24998952%. Dari nilai MAPE tersebut dapat dikatakan bahwa akurasi prediksi termasuk kategori sangat baik karena  $MAPE < 10\%$ . Adapun saran untuk penekeliti selanjutnya adalah untuk mendapatkan hasil representasi prediksi yang lebih baik dengan menggunakan cara lebih variative dalam mempretimbangkan kombinasi parameter.

#### DAFTAR PUSTAKA

- [1] Junaidi, "Analisis Hubungan Deret Waktu Untuk Peramalan Fakultas Ekonomi dan Bisnis," *Universitas Jambi*, 2014.
- [2] B. D. Prasetya, F. S. P. dan I. K. , "Pemodelan dan Peramalan data Saham Dengan Analisis Time Series Menggunakan Python," *Prisma, Prosiding Seminar Nasional Matematika*, vol. 3, 2020.
- [3] S. A. F. M. H. & M. B. A. Aini Hanifa, "Perbandingan Metode LSTM dan GRU (RNN) Untuk Klasifikasi Berita Palsu Berbahasa Indonesia," *Jurusan Informatika, Fakultas Teknik, Universitas Jenderal Soedirman Purwokerto*, Vol. %1 dari %217, No. 1, 2021.
- [4] M. E. & L. F. Dloifur Rohman Alghifari, "Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab indonesia," *Jurnal Manajemen Informatika (JAMIKA)*, Vol. %1 dari %212, No. 2, no. ojs:<https://ojs.unikom.ac.id/index.php/jamika>, 2022.
- [5] S. H. Permatasari, I. M. N. dan F. F. , "Metode Bidirectional Long Short-Term Memory (BiLSTM) Untuk Memprediksi Harga Saham BBRI Dengan Saham Optimasi Nesterov Adaptive Moment (Nadam)," *Jurnal Seminar Nasional (SEMNAS)*, vol. 7, no. e-ISSN: 2654-3168/p-ISSN: 2654-3257.
- [6] Y. Karyadi dan H. S. , "Prediksi Kualitas Udara Dengan Metode LSTM, Bidirectional LSTM, dan GRU," *Jurnal Teknik Informatika dan Sistem Informasi*, Vol. %1 dari %29, No. 1, no. doi: <https://doi.org/1.35957/jastivi.v9i1.1588>, 2022.
- [7] F. Masri, D. S. dan D. A. , "Forecasting of Sea Level Time Series Using Deep Learning RNN, LSTM, and BiLSTM Case Study in Indonesia Bay, Indonesia," *e-Proceeding of Engineering*, Vol. %1 dari %27, No. 2, 2022.
- [8] G. Fitrinanda dan A. D. , "Peramalan Harga Saham PT Adaro Energy Indonesia Tbk Yang Mempertimbangkan Faktor Kurs Dolar Amerika Menggunakan Bidirectional Long Short Term Memory," *Jurnal Teknik ITS*, Vol. %1 dari %211, No. 3, 2022.
- [9] R. L. Abduljabbar, H. D. dan P.-W. T. , "Unidirectional and Bidirectional LSTM Models For Short Term Traffic Prediction," *Journal of Advanced Transportation*, vol. 2021, no. doi: <https://doi.org/10.1155/2021/5589075>.
- [10] F. Shahid, A. Z. dan M. M. , "Predictions For COVID-19 With Deep Learnig of LSTM, GRU and Bi--LSTM," *Chaos, Solitons and Fractals*, vol. 140, no. doi: <https://doi.org/10.1016/j.chaos.2020110222>, 2020.
- [11] T. Fardiani, "Ekstraksi Informasi Pada Surat Keputusan Menggunakan Metode Recurrent Neural Network," *Universitas Komputer Indonesia*, 2020.
- [12] H. K. Choi, "Stock Price Correlation Coefficient Prediction with Arima-Lstm Hybrid Model," no. doi: 10.48550/arXiv.1808.01560, 2018.
- [13] D. A. Napitupulu, "Prediksi Anomali Lintasan Kapal Berdasarkan Data Ais Menggunakan LSTM dan DBSCAN," *Insitut Teknologi Bandung*, 2023.

- [14] A. B. Nujaman, A. H. dan A. M. Z. , “Long Short Term Memory (LSTM) Untuk Prediksi Harga Saham Prizor Inc,” *Universitas Padjadjaran*, 2021.
- [15] A. R. Isnain, A. S. dan Y. S. , “Bidirectional Long Short Term Memory Method and Word2vec Extraction Approach For hate Speech Detection,” *e-Proceeding of Engineering*, Vol. %1 dari %214, No. 2, 2020.
- [16] M. W. P. Aldi dan A. A. , “Analisis dan Implementasi Ling Short Term Memory Neural Network untuk Prekdiksi Harga Bitcoin,” *Jurnal of Computing and Cybernetics System*, Vol. %1 dari %25, No.2, no. doi: 10.22146/ijccs.51743, 2018.
- [17] V. R. Prasetyo, S. A. J. T. S. D. S. S. A. W. dan S. D. N. , “Prediksi Harga Emas Berdasarkan Data Gold.org Menggunakan Metode Long Short term Memory,” *Jurnal Sistem Informasi*, Vol. %1 dari %211, No. 3, 2022.
- [18] A. S. B. Karno, “Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long Short Term Memory),” *Jurnal of Information and information Security (JIFORY)*, Vol. %1 dari %21, No. 1, 2020.