

Long Short-Term Memory and Gated Recurrent Unit Modeling for Stock Price Forecasting

Pemodelan *Long Short-Term Memory* dan *Gated Recurrent Unit* untuk Peramalan Harga Saham

Nurul Khairunisa¹, Putriaji Hendikawati²

¹ Program Studi Matematika, Universitas Negeri Semarang

² Program Studi Statistika Terapan dan Komputasi, Universitas Negeri Semarang

Email: ¹nurulkhairunisa55@students.unnes.ac.id, ²putriaji.mat@mail.unnes.ac.id.

Abstract

The rapid advancement of deep learning technology offers significant benefits, particularly for time series data forecasting. LSTM and GRU are two deep learning methods used for forecasting. This study aims to compare the LSTM and GRU methods in predicting the stock prices of PT Mayora Indah Tbk, listed on the Indonesia Stock Exchange (IDX), accessed through Yahoo Finance. The model architecture was developed using combinations of data splitting, learning rate, epoch count, and neuron count. The combinations used in this study include data splits of 70:30 and 80:20, with varying parameter combinations of learning rates at 0.01, 0.001, and 0.0001, epoch counts of 50, 100, and 150, and neuron counts of 50 and 100. The results indicate that the GRU method outperforms the LSTM method in prediction accuracy. The RMSE and MAPE tests show that the GRU method yields RMSE and MAPE of 34.4233 and 1.27%, respectively, compared to the LSTM method with RMSE and MAPE of 35.3775 and 1.28%. The best GRU architecture was achieved with a learning rate of 0.001, 50 neurons, and 150 epochs, while the best LSTM architecture was achieved with a learning rate of 0.001, 100 neurons, and 150 epochs. The optimal architecture for both methods was found with a data split of 70:30.

Keywords: stocks, LSTM, GRU, RMSE, MAPE

Abstrak

Perkembangan teknologi *deep learning* yang semakin pesat memberikan manfaat salah satunya untuk peramalan data *time series*. LSTM dan GRU adalah dua metode *deep learning* yang digunakan untuk peramalan. Penelitian ini bertujuan membandingkan metode LSTM dan GRU dalam memprediksi harga saham PT Mayora Indah Tbk yang terdaftar pada Bursa Efek Indonesia (BEI) yang diakses melalui *website Yahoo Finance*. Pembentukan arsitektur model menggunakan kombinasi pembagian data, jumlah *learning rate*, jumlah *epoch*, dan jumlah *neuron*. Kombinasi yang digunakan penelitian ini yaitu pembagian data 70:30 dan 80:20, kemudian variasi kombinasi parameter *learning rate* 0,01, 0,001, dan 0,0001, jumlah *epoch* 50, 100, 150 dan jumlah *neuron* 50 dan 100. Hasil penelitian menunjukkan bahwa metode GRU lebih baik dalam memprediksi dibandingkan dengan metode LSTM. Hasil pengujian RMSE dan MAPE menunjukkan pada metode GRU menghasilkan RMSE dan MAPE berturut-turut



adalah 34,4233 dan 1,27% sedangkan metode LSTM 35,3775 dan 1,28%. Arsitektur terbaik metode GRU pada *learning rate* 0,001, 50 *neuron*, dan 150 *epoch* sedangkan metode LSTM dengan *learning rate* 0,001, 100 *neuron*, dan 150 *epoch*. Arsitektur terbaik dari kedua metode terdapat pada pembagian data 70:30.

Kata Kunci: saham, LSTM, GRU, RMSE, MAPE.

1. PENDAHULUAN

1.1. Latar Belakang

Peramalan *time series* adalah teknik analisis data yang bertujuan untuk memprediksi nilai masa depan berdasarkan data historis. Saat ini *machine learning* telah berkembang dalam berbagai hal salah satunya memprediksi data *time series*. Perkembangan teknologi dengan adanya *machine learning* memberikan performa yang lebih baik dibandingkan dengan metode konvensional statistik seperti *Auto-Regressive Integrated Moving Average* (ARIMA) dan *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Pendekatan data *time series* dikembangkan untuk data yang bersifat *nonlinear* karena memiliki data dengan dimensi yang besar dan bersifat dinamis. Salah satu metode peramalan berbasis data *time series* nonlinier adalah Jaringan Saraf Tiruan atau *Artificial Neural Network* (ANN) [20].

ANN merupakan salah satu metode pendekatan nonlinier, kemudian perkembangan lanjutan dari ANN dinamakan *deep learning*. *Deep learning* merupakan salah satu aplikasi dari *machine learning* yang memanfaatkan ANN dengan banyak lapisan (*deep neural network*) [19]. Teknologi *deep learning* telah mencapai kesuksesan besar dalam pemrosesan gambar, pengenalan suara, dan prediksi hujan sehingga hal ini membuat *deep learning* menjadi terobosan dalam menyelesaikan masalah tren harga saham [10]. Pengembangan metode *time series* dari *deep learning* ada *Recurrent Neural Network* (RNN). Peningkatan selanjutnya dari RNN ada *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) yang membantu menyelesaikan masalah *exploding gradient* dan *vanishing gradient* pada RNN [6].

Hochreiter dan Schmidhuber pertama kali memperkenalkan metode LSTM pada tahun 1997 [16]. Jaringan LSTM terdiri dari sel memori yang dapat menyimpan informasi yang diperbarui melalui tiga gerbang (*gate*) khusus, yaitu *input gate*, *forget gate*, dan *output gate*. Gerbang ini memungkinkan LSTM untuk menghubungkan informasi sebelumnya dengan informasi selanjutnya serta efektif dalam menyimpan informasi jangka panjang sehingga diperlukan dalam mengolah data *time series*. Penelitian yang dilakukan oleh Kumar et al. [9] tentang peramalan energi konsumsi pada hasil pengujian menunjukkan bahwa LSTM memberikan nilai *Mean Squared Error* (MSE) lebih kecil dari *Seasonal Autoregressive Integrated Moving Average* (SARIMA) yang menunjukkan bahwa performa model LSTM lebih baik daripada SARIMA. Penelitian Haq et al. [5] yang berjudul *Long Short-Term Memory Algorithm for Rainfall Prediction Based on El-Nino and IOD Data* memprediksi curah hujan di Sidoarjo, Jawa Timur, untuk mengantisipasi kerusakan tanggul. Percobaan dilakukan dengan dua skema yaitu skema pertama menggunakan parameter *El-Nino* dan *Indian Ocean Dipole* (IOD), sedangkan skema kedua menggunakan pola *time series* curah hujan. Hasil prediksi menggunakan parameter *El-Nino* dan IOD dengan *hidden layer* 100, *batch size* 64, dan *learning rate drop period* 50, diperoleh nilai MAPE sebesar 0.9644. Sedangkan, hasil prediksi menggunakan parameter curah hujan dengan banyak *hidden layer*, *batch size*, dan *learning rate drop period* masing-masing sebesar 100, 32, dan 150, menghasilkan prediksi yang lebih akurat dengan nilai MAPE 0,5810.

Sementara GRU adalah arsitektur jaringan saraf berulang yang mirip dengan LSTM, namun pada GRU hanya terdiri dari dua *gate* saja, yaitu *reset gate* dan *update gate*, GRU memiliki arsitektur yang lebih sederhana dibandingkan dengan LSTM, GRU menggunakan parameter yang lebih sedikit sehingga lebih mudah untuk *training* dan lebih efisien [15]. GRU pertama kali diperkenalkan oleh Kyunghyun Cho *et al.* pada tahun 2014. Penelitian oleh Zhong *et al.* [21] membandingkan metode ARIMA dan GRU untuk memprediksi harga saham memperoleh hasil bahwa metode GRU memiliki performa lebih baik daripada ARIMA. Penelitian lain oleh Natarajan *et al.* [12] meramalkan pertumbuhan COVID-19 di beberapa negara menggunakan metode GRU. Penelitiannya menggunakan data yang luas menunjukkan bahwa metode GRU mengalami pola peningkatan performa dilihat dari nilai RMSE dibandingkan dengan metode RNN.

Peramalan merupakan aspek penting salah satunya dalam bidang investasi saham karena dapat memberikan informasi bagi investor yang ingin berinvestasi di perusahaan. Data yang berkaitan dengan saham merupakan kategori data deret waktu (*time series*). PT Mayora Indah Tbk adalah salah satu saham yang terdaftar di BEI yang selama tahun 2023 terus mengalami kenaikan. Berdasarkan situs *website* CNBC menunjukkan bahwa *Return On Equity* (ROE) PT Mayora Indah Tbk berada di angka yang cukup baik sekali yaitu 21,80%. Semakin tinggi ROE menunjukkan bahwa perusahaan tergolong baik dalam menghasilkan laba bersih sehingga perusahaan dengan ROE yang tinggi cenderung diminati oleh para investor yang berdampak pada peningkatan harga saham dan peningkatan dividen yang akan dibagikan kepada investor [13].

Penelitian ini bertujuan untuk mencari arsitektur terbaik serta melakukan perbandingan kinerja dari metode LSTM dan GRU dalam meramalkan harga saham PT Mayora Indah Tbk. Penelitian berfokus mengidentifikasi model arsitektur yang paling optimal untuk LSTM dan GRU dalam melakukan peramalan dengan melihat hasil evaluasi RMSE dan MAPE.


1.2. Peramalan

Peramalan (*forecasting*) adalah proses memperkirakan atau memprediksi suatu kejadian atau nilai masa depan berdasarkan data historis dan analisis tren. Peramalan merupakan proses atau metode yang digunakan untuk memprediksi ketidakpastian masa depan sebagai upaya untuk mengambil keputusan yang lebih baik [14]. Peramalan diperlukan guna memprediksi kejadian di masa mendatang sehingga dapat memilih perencanaan yang lebih efisien dan efektif untuk dilakukan.

1.3. Long Short-Term Memory

Long Short-Term Memory (LSTM) adalah metode yang diperkenalkan pertama kali oleh Hochreiter dan Schmidhuber pada tahun 1997. Model LSTM adalah jenis jaringan saraf berulang yang secara khusus dirancang untuk menangani masalah *exploding gradient* dan *vanishing gradient* yang sering muncul dalam mempelajari ketergantungan jangka panjang. Jaringan LSTM mampu menghubungkan informasi sebelumnya dengan dengan informasi selanjutnya dan keefektifan untuk menyimpan informasi yang panjang sangat diperlukan dalam mengolah data *time series*. Jaringan LSTM menambahkan memori jangka panjang (*long-term memory*) dengan cara yang lebih efisien melalui penambahan parameter yang lebih banyak untuk proses pembelajaran.

Model LSTM terdiri dari lapisan input (*input layer*), lapisan tersembunyi (*hidden layers*), dan lapisan output (*output layers*). LSTM melibatkan komponen seperti *memory cell* dan *gates*, dimana *gates* tersebut terdiri dari bagian, yaitu *forget gate*, *input gate*, dan *output gate*. Dari komponen tersebut, LSTM terdiri dari tiga *gates* dan satu *cell memory* yang memiliki kemampuan untuk melupakan atau menghafal informasi untuk menentukan jumlah banyak informasi yang perlu ditransfer ke sel berikutnya. Struktur jaringan LSTM ditunjukkan pada **Gambar 1**.



Gambar 1 Arsitektur LSTM

Persamaan metode LSTM pada Gambar diuraikan sebagai berikut [4]:

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

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

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (3)$$

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


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

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

1.4. Gated Recurrent Unit

Gated Recurrent Unit (GRU) adalah arsitektur jaringan saraf berulang yang mirip dengan LSTM, GRU dirancang untuk memodelkan data sekuensial dengan memungkinkan informasi untuk diingat atau dilupakan secara selektif seiring waktu. GRU pertama kali diperkenalkan oleh Kyunghyun Cho *et al.* pada tahun 2014. GRU memiliki arsitektur yang lebih sederhana dibandingkan dengan LSTM, GRU menggunakan parameter yang lebih sedikit sehingga lebih mudah untuk *training* dan lebih efisien [1].

Perbedaan utama antara GRU dan LSTM terletak pada cara menangani *cell state memory*. GRU tidak menggunakan *cell state*, melainkan *hidden state* untuk menyimpan informasi. Pada GRU, komponen yang mengatur aliran informasi disebut sebagai *gate*. GRU memiliki 2 *gate*, yakni *reset gate* dan *update gate*. *Reset gate* dalam GRU menentukan informasi baru harus dilupakan atau tidak, sedangkan *update gate* menentukan informasi yang harus diteruskan [8]. **Gambar 2** menjelaskan arsitektur GRU.



Gambar 2 Arsitektur GRU

Formula GRU dirumuskan sebagai berikut:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (7)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (8)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \quad (9)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (10)$$

1.5. Normalisasi Data

Normalisasi bertujuan membuat data lebih mudah dipelajari oleh jaringan dengan menyesuaikan skala nilainya agar berada dalam rentang yang kecil, biasanya antara 0 dan 1 [18]. Salah satu metode normalisasi yang sederhana adalah penskalaan *min-max*, di mana nilai-nilai disesuaikan dengan mengurangnya dan kemudian membaginya dengan selisih antara nilai maksimum dan minimum [3]. Persamaannya dapat dirumuskan sebagai berikut.

$$X' = \frac{X - \min_x}{(\max_x - \min_x)} \quad (11)$$

dimana,

X' = Hasil data setelah dinormalisasi

X = Data yang dinormalisasi

\min_x = Nilai minimum dari keseluruhan data X

\max_x = Nilai maksimum dari keseluruhan data X

1.6. Pengukuran Performa

Pengukuran performa model pada penelitian ini menggunakan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Semakin kecil nilai RMSE semakin baik performa modelnya sedangkan MAPE dihitung dengan mengambil kesalahan untuk setiap prediksi dibagi oleh nilai aktual yang memberikan gambaran tentang seberapa akurat model dalam meramalkan data dan RMSE digunakan untuk mengukur perbedaan antara data hasil peramalan oleh model dan data yang diamati [7].

Persamaan RMSE dinyatakan sebagai berikut,

$$RMSE = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2} \quad (12)$$

dimana,

\hat{y}_i = Nilai prediksi

y_i = Nilai aktual

n = Jumlah data

Persamaan MAPE dinyatakan sebagai berikut,

$$MAPE = \frac{1}{n} \sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (13)$$

dimana,

\hat{y}_i = Nilai prediksi

y_i = Nilai aktual

n = Jumlah data

Tabel 1 Range MAPE Value

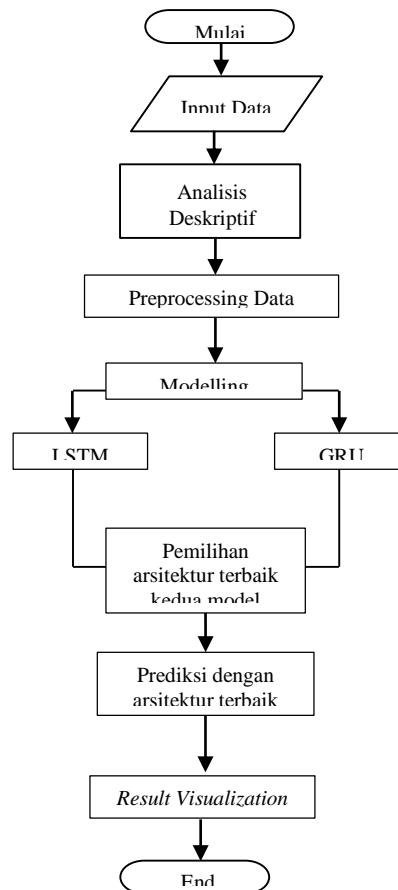
Range MAPE	Arti
<10%	Tingkat akurasi sangat baik
10-20%	Tingkat akurasi baik
20%-50%	Tingkat akurasi layak

>50%

Tingkat akurasi buruk

1.7. Tahapan Analisis Data

Tahap analisis data dalam penelitian ini meliputi pengumpulan data. Data yang terkumpul dianalisis menggunakan metode LSTM dan GRU. Kemudian, *preprocessing data* untuk mempersiapkan data agar siap untuk dilatih. Tahapan *preprocessing data* meliputi pemeriksaan struktur data, normalisasi data menggunakan *min max normalization*, dan pembagian data dengan rasio 80:20 dan 70:30. Pemodelan menggunakan LSTM dan GRU dilakukan dengan proses *trial-error* dalam pemilihan jumlah *learning rate*, *epoch*, dan *neuron*, lalu pemilihan model arsitektur terbaik berdasarkan hasil RMSE dan MAPE. Arsitektur terbaik dari kedua metode tersebut digunakan untuk memprediksi harga saham. *Result visualization* bertujuan untuk membandingkan antara data aktual dan hasil peramalan dari masing-masing metode. Analisis dilakukan menggunakan perangkat lunak *Python*. Alur analisis data ditunjukkan pada **Gambar 3**.



Gambar 3 Tahapan Analisis Data

2. HASIL DAN PEMBAHASAN

2.1. Data Penelitian dan Plot *Time Series*

Data yang digunakan adalah data harga penutupan saham PT. Mayora Indah Tbk periode 02 Januari 2013 sampai dengan 29 Desember 2023. Jumlah data sebanyak 2726 data. Data tersebut

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Nurul Khairunisa, Putriaji Hendikawati

diperoleh dari *website yahoo finance* yaitu <https://finance.yahoo.com>. Grafik harga penutupan saham PT Mayora Indah Tbk ditunjukkan pada **Gambar 4**.



Gambar 4 Grafik Harga Penutupan Saham

Berdasarkan **Gambar 4** terlihat bahwa pergerakan harga penutupan saham PT Mayora Indah Tbk selama 10 tahun terakhir menunjukkan adanya pola *seasonality* (musiman) disertai dengan pola *trend* (kecenderungan) baik dalam peningkatan maupun penurunan serta memiliki siklus yang berulang.

2.2. Preprocessing Data

2.2.1. Pemeriksaan Data

Pemeriksaan struktur data bertujuan untuk memastikan tidak ada data yang hilang agar data yang tidak lengkap tidak mempengaruhi selama proses pengolahan data. Hasil pemeriksaan struktur data ditunjukkan pada **Gambar 5**.

```
missing_value = df.isna().sum()
print(f"Jumlah data hilang : {missing_value}")
```

Jumlah data hilang : 0

Gambar 5 Hasil Pemeriksaan Data

Hasil *output* pada menunjukkan bahwa tidak ada data yang hilang sehingga data dapat diproses langsung tanpa memerlukan langkah-langkah tambahan untuk menangani nilai yang hilang.

2.2.2. Normalisasi Data

Normalisasi data dengan metode *min-max normalization* bertujuan untuk menyesuaikan rentang nilai data sehingga memiliki nilai yang sama. Proses ini diterapkan pada seluruh dataset harga penutupan saham.

Berikut pada **Tabel 2** merupakan nilai seluruh dataset harga saham setelah dilakukan normalisasi data.

Tabel 2 Data Setelah Normalisasi

Date	Sebelum Normalisasi	Setelah Normalisasi
2013-01-02	677,14	0,006225
2013-01-03	668,57	0,002767
2013-01-04	668,57	0,002767
...
2023-12-28	2380,0	0,693337
2023-12-29	2500,0	0,741757
2023-12-30	2490,0	0,737722

2.2.3. Pembagian Data

Pembagian data menjadi data latih (*training*) dan data uji (*testing*). Data latih digunakan untuk melatih model, sementara data uji digunakan untuk menguji kinerja model. Pembagian data latih dan data uji pada penelitian ini terdiri dari dua proporsi, yaitu 80:20 dan 70:30. Jumlah pembagian data dapat dilihat pada **Tabel 3**.

Tabel 3 Proporsi Pembagian Data

Proporsi	Data Latih	Data Uji
70:30	1908	818
80:20	2180	546

2.3. Pemodelan LSTM dan GRU

Pembentukan model pada LSTM dan GRU tidak memiliki aturan baku untuk menentukan arsitektur yang optimal untuk diterapkan pada sistem. Pencarian arsitektur dan parameter dilakukan secara *trial* dan *error* dengan variasi kombinasi parameter. Penelitian ini menggunakan beberapa variasi nilai pada *learning rate*, jumlah *neuron*, dan jumlah *epoch*. Pengaturan parameter ditunjukkan pada **Tabel 4**.

Tabel 4 Pengaturan Parameter

Parameter	Pengaturan
Rasio pembagian data	70:30, 80:20
<i>Learning rate</i>	[0,01, 0,001, 0,0001]
<i>Epoch</i>	[50, 100, 150]
<i>Units</i>	[50, 100]

Berikut adalah hasil pengujian evaluasi RMSE dan MAPE pada metode LSTM dan GRU dalam memprediksi harga penutupan saham PT Mayora Indah Tbk. Hasil pengujian masing-masing kombinasi dapat dilihat pada **Tabel 5**.

Tabel 5 Hasil Pengujian RMSE dan MAPE

Rasio Data	<i>Learning rate</i>	<i>Neuron</i>	<i>Epoch</i>	RMSE LSTM	MAPE LSTM	RMSE GRU	MAPE GRU
------------	----------------------	---------------	--------------	-----------	-----------	----------	----------

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI

Nurul Khairunisa, Putriaji Hendikawati

		50	41,3108	1,77%	78,2828	3,91%
	50	100	42,4214	1,78%	47,5546	1,85%
		150	35,8801	1,41%	35,4515	1,39%
	0,01					
		50	36,0477	1,30%	38,9928	1,51%
	100	100	51,6668	2,24%	36,2484	1,48%
		150	35,4539	1,32%	37,8922	1,36%
		50	43,4702	1,77%	38,5218	1,59%
	50	100	36,4786	1,44%	35,2554	1,31%
		150	35,4587	1,30%	34,4233	1,27%
70:30	0,001					
		50	57,8856	2,28%	36,4926	1,46%
	100	100	35,4483	1,32%	40,6489	1,59%
		150	35,3775	1,28%	44,4471	1,89%
		50	66,6775	2,77%	45,5212	1,83%
	50	100	63,2008	2,54%	41,3215	1,67%
		150	49,2756	2,00%	41,1318	1,65%
	0,0001					
		50	63,5866	2,59%	45,7806	1,84%
	100	100	55,1593	2,22%	36,9810	1,44%
		150	48,1176	1,91%	35,4955	1,30%
		50	38,4478	1,56%	44,7731	1,67%
	50	100	36,9210	1,31%	46,2197	1,97%
		150	37,9845	1,52%	37,4056	1,33%
	0,01					
		50	40,4789	1,47%	39,1684	1,41%
	100	100	48,1786	1,68%	46,2189	1,85%
		150	38,0511	1,46%	43,4230	1,69%
		50	46,3164	1,96%	38,1582	1,33%
	50	100	38,7589	1,40%	41,4162	1,61%
		150	37,1348	1,36%	36,8248	1,29%
80:20	0,001					
		50	39,7790	1,45%	36,9570	1,33%
	100	100	37,2433	1,34%	44,4653	1,97%
		150	39,4403	1,46%	37,3390	1,44%
		50	70,5039	2,90%	50,3598	1,98%
	50	100	56,3638	2,32%	38,9435	1,42%
		150	49,0315	1,92%	38,8606	1,50%
	0,0001					
		50	64,7641	2,62%	50,9366	1,99%
	100	100	51,7216	2,03%	38,7546	1,39%
		150	47,4677	1,87%	37,5966	1,31%

Berdasarkan **Tabel 5**, hasil pengujian RMSE dan MAPE menunjukkan bahwa LSTM dan GRU merupakan dua jenis arsitektur *Recurrent Neural Network* (RNN) yang dirancang untuk menangani masalah memori jangka panjang dalam pemodelan data sekuensial. Penelitian ini menggunakan beberapa kombinasi rasio dataset dan kombinasi parameter pengujian jumlah

learning rate, pengujian jumlah *epoch*, dan pengujian jumlah *neuron*. Berdasarkan hasil evaluasi nilai RMSE dan MAPE, hasil pengujian dengan berbagai kombinasi parameter pada metode LSTM dan GRU terdapat variasi yang signifikan pada kinerja masing-masing metode dalam memprediksi data harga saham. Berdasarkan hasil, penggunaan *learning rate* 0,001 cenderung memberikan hasil yang lebih baik dan memberikan hasil yang stabil dibandingkan dengan *learning rate* lainnya. Hal tersebut menunjukkan bahwa parameter *learning rate* berpengaruh pada hasil evaluasi, seperti pada penelitian Maliki et al. [11] menjelaskan bahwa semakin kecil nilai *learning rate* mengakibatkan model tidak melakukan pelatihan dikarenakan proses pendekatan model membutuhkan pelatihan yang lama dan semakin besar nilai *learning rate*, model akan melakukan pelatihan dengan cepat tetapi model akan kehilangan ketelitian saat pelatihan.

Terdapat perbedaan dalam performa LSTM dan GRU pada beberapa kombinasi parameter dan jumlah *epoch* yang berbeda. Peningkatan jumlah *epoch* dapat meningkatkan kinerja model tetapi penambahan *epoch* dalam beberapa kasus tidak memberikan peningkatan yang signifikan atau bahkan menurunkan kinerja misalnya, peningkatan jumlah *epoch* dari 50 ke 100 cenderung meningkatkan performa, tetapi peningkatan *epoch* dari 100 ke 150 tidak selalu memberikan peningkatan signifikan. Hal ini menandakan bahwa peningkatan jumlah *epoch* dapat mempengaruhi kemampuan masing-masing metode dalam memahami pola yang lebih kompleks pada data. Hal ini serupa dengan penelitian Wayan et al. [17] yang membandingkan jumlah *epoch* 100, 150, dan 200 performa peningkatan model terbaik pada *epoch* 100 ke 150, namun pada jumlah *epoch* 150 ke 200 model menjadi tidak optimal, menunjukkan bahwa peningkatan jumlah *epoch* dapat mempengaruhi kemampuan metode tetapi tidak selalu sebab penambahan *epoch* yang terlalu banyak juga dapat menyebabkan *overfitting*.

Penggunaan *neuron* 50 dan 100 pada kedua metode LSTM dan GRU terlihat memberikan hasil yang berbeda-beda dalam hasil evaluasi MAPE dan RMSE. Penggunaan *neuron* 100 pada metode LSTM memberikan hasil nilai RMSE dan MAPE yang terendah, sedangkan pada metode GRU penggunaan *neuron* 50 memberikan hasil RMSE dan MAPE terendah. Penggunaan *neuron* 50 pada GRU memberikan hasil yang baik karena strukturnya yang lebih sederhana, sedangkan penggunaan *neuron* 100 pada LSTM dapat memberikan hasil yang baik karena memungkinkan model untuk menangkap lebih banyak pola data. Hasil pengujian RMSE dan MAPE menunjukkan bahwa arsitektur terbaik dari metode LSTM menghasilkan arsitektur terbaik dengan menggunakan *learning rate* 0,001, 100 *neuron*, dan 150 *epoch*, sedangkan pada metode GRU kombinasi parameter terbaik yaitu dengan menggunakan *learning rate* 0,001, 50 *neuron*, dan 150 *epoch*, kedua metode baik LSTM dan GRU memiliki hasil optimal pada pembagian data dengan rasio 70:30, hasil penelitian ini juga serupa dengan penelitian oleh Awaludin et al. [2] menggunakan metode LSTM dengan membandingkan rasio data 70:30, 80:20, dan 90:10.

Penelitian ini membandingkan nilai RMSE dan MAPE dari metode LSTM dan GRU untuk memprediksi harga saham PT Mayora Indah Tbk. Hasil pada **Tabel 5** menunjukkan bahwa metode GRU memiliki nilai RMSE dan MAPE terendah pada rasio data 70:30 berturut-turut 34,4233, 1,27% dan 36,8248, 1,29% pada rasio 80:20, sedangkan metode LSTM memiliki nilai RMSE dan MAPE terendah yaitu 35,3775 dan 1,28% pada rasio 70:30, serta 36,9210 dan 1,31% pada rasio 80:30. Berdasarkan hal tersebut dapat disimpulkan metode GRU lebih baik dalam memprediksi dibandingkan metode LSTM.

2.4. Prediksi dengan Arsitektur Terbaik

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Nurul Khairunisa, Putriaji Hendikawati



Gambar 6 Grafik Prediksi vs Aktual

Pada **Gambar 6** perbandingan antara harga saham PT Mayora Indah Tbk dan hasil prediksi dari arsitektur LSTM dan GRU terbaik pada masing-masing rasio 70:30 dan 80:20. Grafik menunjukkan bahwa hampir semua model terbaik dari masing-masing metode mengikuti tren harga saham aktual dengan baik dan terdapat sedikit perbedaan di antara hasil prediksi prediksi setiap metode. Hasil prediksi dengan data aktual diambil sampel dari tanggal 6 Oktober 2021 sampai dengan 12 Desember 2022 yang ditunjukkan pada **Tabel 6**.

Tabel 6 Hasil Prediksi

Date	Aktual	LSTM 70:30	GRU 70:30	LSTM 80:20	GRU 80:20
2021-10-06	2450	2510,82	2495,26	2520,73	2507,38
2021-10-07	2410	2452,82	2439,42	2460,55	2451,47
2021-10-08	2430	2417,22	2405,44	2418,57	2414,78
2021-10-11	2420	2440,37	2427,32	2435,32	2433,21
...
2023-12-06	2400	2430,01	2413,12	2420,26	2415,06
2023-12-07	2330	2412,67	2396,99	2408,50	2400,48
2023-12-08	2380	2336,98	2320,11	2344,08	2330,29
2023-12-11	2380	2384,41	2368,05	2384,01	2375,84
2023-12-12	2500	2390,23	2377,27	2385,73	2381,51

Secara keseluruhan, **Tabel 6** menunjukkan bahwa model dengan rasio data 70:30 seringkali memberikan hasil prediksi yang mendekati nilai aktual terutama pada model GRU. Penentuan arsitektur terbaik pada LSTM dan GRU ditunjukkan dari nilai terendah dari RMSE dan MAPE. Berdasarkan **Tabel 5**, metode LSTM menghasilkan arsitektur terbaik dengan parameter *learning rate* 0,001, 100 *neuron*, dan 150 *epoch*, sedangkan metode GRU pada *learning rate* 0,001, 50 *neuron*, dan 150 *epoch*, arsitektur terbaik dari kedua metode terdapat pada pembagian data 70:30.

3. KESIMPULAN

Berdasarkan hasil pembahasan dapat disimpulkan bahwa metode GRU lebih unggul dalam memprediksi harga penutupan saham PT Mayora Indah Tbk dengan arsitektur terbaik pada *learning rate* 0,001, 50 *neuron*, dan 150 *epoch* serta rasio data pelatihan dan pengujian 70:30 dengan hasil evaluasi RMSE 34,4233 dan MAPE 1,27%. Sedangkan, metode LSTM model terbaik dengan pembagian data 70:30 dan arsitektur terbaik pada *learning rate* 0,001, 50 *neuron*, dan 150 *epoch* dengan RMSE 35,3775 dan MAPE 1,28%. Penggunaan *learning rate* 0,001 sudah menunjukkan hasil yang baik dan jumlah *neuron* sebanyak 50 sudah optimal untuk GRU, sementara untuk LSTM sebaiknya menggunakan jumlah neuron yang lebih banyak dari GRU mengingat struktur LSTM yang lebih kompleks dibandingkan dengan GRU.

REFERENSI

- [1] Anishnama, 2018. *Understanding Gated Recurrent Unit (GRU) in Deep Learning*. Medium Publishing, Amerika. <https://medium.com/@anishnama20/understanding-gated-recurrent-unit-gru-in-deep-learning-2e54923f3e2>. [4 Mei 2024].
- [2] Awaludin, A., & Oktarina, T., 2023. Application of the LSTM Algorithm in Predicting Urea Fertilizer Production at IIB Plant PT. Pupuk Sriwidjaja Palembang. *Jurnal Sains Komputer & Informatika*, Vol. 7, No. 2, 1015-1024. <https://tunasbangsa.ac.id/ejurnal/index.php/jsakti/issue/view/30>.
- [3] Geron, A. 2017. *Hands-On Machine Learning with Scikit-Learn and TensorFlow*.
- [4] Gers, F. A., Schmidhuber, U. J., & Cummins, F., 2000. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, Vol. 12, No. 10, 2451-2471. <https://doi.org/10.1162/089976600300015015>.
- [5] Haq, D. Z., Rini, N. D. C., Hamid, A., Ulinnuha, N., Arnita, Farida, Y., Nugraheni, R. D., Nariswari, R., Ilham, Rohayani, H., Pramulya, R., & Widjayanto, A., 2021. Long Short-Term Memory Algorithm for Rainfall Prediction Based on El-Nino and IOD data. *Procedia Computer Science*, Vol. 179, 829–837. <https://doi.org/10.1016/j.procs.2021.01.071>.
- [6] Hochreiter, S. & Schmidhuber, U. J., 1997. Long Short-Term Memory. *Neural Computation*, Vol. 9, No. 8, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>. <https://doi.org/10.52166/ujmc.v6i01.1927>.
- [7] Korstanje, J., 2021. *Advanced Forecasting with Python*. Apress Media.
- [8] Kostadinov, S., 2017. *Understanding GRU Networks*. Medium Publishing, Amerika. <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>. [4 Mei 2024].
- [9] Kumar, D. A., Kumar, A., García, D. V., Kumar, S. A., & Kanhaiya, K., 2021. Study and analysis of SARIMA and LSTM in forecasting time series data. *Sustainable Energy Technologies and Assessments*, 47. <https://doi.org/10.1016/j.seta.2021.101474>.
- [10] Liu, H., & Long, Z., 2020. An improved deep learning model for predicting stock market price time series. *Digital Signal Processing: A Review Journal*, 102, 102741. <https://doi.org/10.1016/j.dsp.2020.102741>.
- [11] Maliki, M. A., Cholissodin, I., & Yudistira, N., 2022. Prediksi Pergerakan Harga Cryptocurrency Bitcoin terhadap Mata Uang Rupiah menggunakan Algoritme LSTM. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 6, No. 7, 3259-3268. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/issue/view/70>.
- [12] Natarajan, S., Kumar, M., Gadde, S. K. K., & Venugopal, V., 2023. Outbreak Prediction of COVID-19 using Recurrent Neural Network with Gated Recurrent Units. *Materials Today: Proceedings*, 80, 3433–3437. <https://doi.org/10.1016/j.matpr.2021.07.266>.

- [13] Pangestu, P. S., & Wijayanto, A., 2020. Pengaruh Return on Assets (ROA), Return on Equity (ROE), Earning Per Share (EPS), Price Earning Ratio (PER), Dandebt to Equity Ratio (DER) Terhadap Return Saham. *Ilmu Administrasi Bisnis*, Vol. 9, No. 1, 63–71. <https://doi.org/https://doi.org/10.14710/jiab.2020.26220>.
- [14] Panggabean, S., Sihombing, P. R., Dewi, K. H. S., & Pramatha, I. N. B., Junaidy, J., & Syahrudin, S., 2021. Simulasi Exponential Moving Avarage dan Single Exponential Smoothing: Sebuah Perbandingan Akurasi Metode Peramalan. *Jurnal Pemikiran dan Penelitian Pendidikan Matematika*, Vol. 4, No. 1, 1–10. <https://journal.rekarta.co.id/index.php/jp3m/issue/view/12>.
- [15] Sofi, K., Sunge, A. S., Riady, S. R., & Kamalia, A. Z., 2021. Perbandingan Algoritma Linear Regression, LSTM, Dan GRU dalam Memprediksi Harga Saham dengan Model Time Series. *PROSIDING SEMINASTIKA*, Vol. 3, No. 1, 39–46. <https://doi.org/10.47002/seminastika.v3i1.275>.
- [16] Van Houdt, G., Mosquera, C., & Nápoles, G., 2020. A review on the long short-term memory model. *Artificial Intelligence Review*, Vol. 53, No. 8, 5929–5955. <https://doi.org/10.1007/s10462-020-09838-1>.
- [17] Wayan, N., Aryati, M., Komang, I., Ganda Wiguna, A., Putri, S., Widiartha, K., Luh, N., Sri, W., & Ginantra, R., 2024. Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham. *Jurnal Media Informatika Budidarma*. Vol. 8, No. 2, 1131-1140. <https://doi.org/10.30865/mib.v8i2.7342>.
- [18] Yamak, P. T., Yujian, L., & Gadosey, P. K., 2019. A Comparison between ARIMA, LSTM, and GRU for Time Series Forecasting. In *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence* (pp. 49-55). <https://doi.org/10.1145/3377713.3377722>.
- [19] Yotenka, R., Fikri, F., & Huda, E., 2020. Implementasi Long Short-Term Memory Pada Harga Saham Perusahaan Perkebunan di Indonesia. *Unisda Journal of Mathematics and Computer*, Vol. 6, No. 1, 9–18.
- [20] Yulisa, N. P., Al Haris, M., & Arum, R. P., 2023. Peramalan Nilai Ekspor Migas di Indonesia dengan Model Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU). *J Statistika: Jurnal Ilmiah dan Aplikasi Statistika*, Vol. 16, No. 1, 328-341. <https://jurnal.unipasby.ac.id/index.php/jstatistika/issue/view/514>.
- [21] Zhong, Z., Wu, D., & Mai, W., 2023. Stock Prediction Based on ARIMA Model and GRU Model. *Academic Journal of Computing & Information Science*, Vol. 6, No. 7, 114-123. <https://doi.org/10.25236/ajcis.2023.060715>.