

Kombinasi Inisialisasi *Hyperparameter* dan Algoritma Adam untuk Optimasi Model *Gated Recurrent Unit* dalam Meramalkan Harga Penutupan Saham Pasca Isu Boikot

Bintu Labibah, Rangga Gelar Guntara*, Syti Sarah Maesaroh

Bisnis Digital, Universitas Pendidikan Indonesia, Tasikmalaya, Indonesia

Email: ¹bintulabibah@upi.edu, ^{2,*}ranggagelar@upi.edu, ³sytisarah@upi.edu

Email Penulis Korespondensi: ranggagelar@upi.edu

Submitted: 05/10/2024; Accepted: 01/12/2024; Published: 03/12/2024

Abstrak—Penelitian ini bertujuan untuk meningkatkan akurasi peramalan harga penutupan harian saham PT Unilever Indonesia Tbk dengan mengoptimalkan model *Gated Recurrent Unit* (GRU), yang merupakan salah satu arsitektur dalam *deep learning*, melalui eksplorasi kombinasi pengaturan *hyperparameter* dan algoritma Adam, terutama dalam konteks dampak isu boikot terhadap kinerja perusahaan. Dengan memanfaatkan data historis selama lima tahun, penelitian ini menerapkan metode analisis deret waktu. Hasil penelitian menunjukkan bahwa model GRU pada skenario kedua, yang menggunakan kombinasi *epoch* 50, *batch size* 8, dan *hidden state* 64, serta pengaturan parameter Adam dengan *nilai default*, menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1,59% dan *Root Mean Squared Error* (RMSE) sebesar 71,51, yang merupakan nilai terendah dari total 81 pelatihan dengan kombinasi yang berbeda. Selain itu, pengaturan parameter Adam yang lebih tinggi juga memberikan hasil yang stabil dan memuaskan, meskipun tidak menjadi model dengan performa terbaik. Penelitian ini mengidentifikasi bahwa fluktuasi harga yang tajam dapat mempengaruhi akurasi model, sehingga disarankan untuk menggunakan periode peramalan ke depan yang lebih pendek guna mengurangi penyimpangan ketika melakukan implementasi. Temuan ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan model peramalan harga saham yang lebih akurat dan dapat diandalkan.

Kata Kunci: Peramalan Harga Saham; *Gated Recurrent Unit*; *Deep Learning*; *Hyperparameter*; Algoritma Adam

Abstract—This research aims to enhance the accuracy of daily closing price forecasting for PT Unilever Indonesia Tbk shares by optimizing a *Gated Recurrent Unit* (GRU) model, a deep learning architecture. The study focuses on the impact of boycott issues on company performance and explores the effectiveness of hyperparameter tuning and the Adam optimization algorithm. Utilizing a five-year historical dataset, time series analysis was employed. The results demonstrate that the GRU model with a configuration of 50 epochs, batch size 8, hidden state 64, and default Adam parameters achieved the lowest Mean Absolute Percentage Error (MAPE) of 1.59% and Root Mean Squared Error (RMSE) of 71.51 among the 81 configurations tested. While higher Adam parameter settings also yielded satisfactory results, this specific configuration exhibited superior performance. The findings highlight the sensitivity of model accuracy to sharp price fluctuations, suggesting that shorter forecast horizons may be more appropriate. This research contributes significantly to the advancement of accurate and reliable stock price forecasting models.

Keywords: Stock Price Forecasting; *Gated Recurrent Unit*; *Deep Learning*; *Hyperparameter*; Adam Algorithm

1. PENDAHULUAN

Investasi di pasar modal yang mencakup saham dan surat utang menjadi semakin populer di kalangan investor, yaitu seorang individu atau entitas yang menanamkan modalnya untuk mendapatkan keuntungan. Menurut data Kustodian Sentral Efek Indonesia (KSEI), jumlah investor saham meningkat dari 10.310.000 menjadi 12.130.000 *Single Investor Identification* (SID) per tanggal 20 Desember 2023, yang artinya terjadi peningkatan investor saham sebesar 17,6% hanya dalam kurun waktu satu tahun [1].

Salah satu saham *blue chip* yang menarik perhatian investor yaitu PT Unilever Indonesia Tbk. Namun, perusahaan ini tengah terkena dampak dari isu boikot, yang dimana mendorong seruan untuk tidak membeli produk yang terafiliasi dengan Israel. Hal tersebut tentunya memberikan dampak buruk bagi profitabilitas perusahaan karena penjualannya menurun. Firman [2] menyebutkan bahwa selain penjualannya menurun, harga saham PT Unilever juga terkena dampak dan mengalami tren penurunan sejak November 2023 hingga Mei 2024, dengan penurunan sekitar 20% pasca fatwa Majelis Ulama Indonesia (MUI) No. 83 [3]. Situasi ini tentunya menimbulkan kekhawatiran investor terhadap prospek saham Unilever di Indonesia, salah satunya karena penurunan profitabilitas mempengaruhi pengambilan keputusan investasi [4]. Namun, meskipun demikian, tidak dapat dipungkiri bahwa pada dasarnya harga saham memiliki tingkat fluktuatif yang tinggi.

Sifat fluktuatif dan risiko yang tinggi menjadikan investor harus selektif saat membeli saham agar tidak terpapar risiko terjadinya penurunan harga saham (*capital loss*). Hal ini penting karena data harga saham merupakan data deret waktu (*time-series*) yang sangat dinamis, di mana tidak ada saham yang mengalami kenaikan atau penurunan secara konsisten. Fluktuasi harga yang terjadi secara bergantian seiring berjalannya waktu akan menciptakan berbagai pola. Oleh karena itu, peramalan harga saham menjadi sangat penting untuk mengetahui pola yang tercipta sehingga bisa mengoptimalkan keuntungan, yang dimana merupakan tujuan utama investor di pasar modal [5].

Dalam konteks peramalan data *time-series*, diperlukan metode yang tepat agar hasil peramalan tidak menyimpang jauh dari nilai sebenarnya [6]. Ada banyak metode untuk meramalkan data deret waktu, teknik *deep learning* seperti *Recurrent Neural Network* (RNN) merupakan salah satu metode yang dapat digunakan untuk membuat peramalan. Beberapa varian RNN yang telah berkembang hingga saat ini yaitu *Gated Recurrent Unit* (GRU)

[7]. Pernyataan tersebut selaras dengan publikasi jurnal Cho dkk. tahun 2014 [8] dan Zhang dkk. tahun 2024 [9], yang menyebutkan bahwa GRU memiliki kelebihan karena konsep *gating* sehingga dapat menghindari masalah yang hilang dari gradien yang mungkin terjadi pada RNN.

Selain itu, berbagai studi komparasi pada beberapa studi kasus menunjukkan bahwa model *Gated Recurrent Unit* (GRU) memiliki keunggulan dalam meramalkan harga saham dibandingkan teknik lain seperti *Long Short-Term Memory* (LSTM) dan *Recurrent Neural Network* (RNN) yang ditunjukkan dengan nilai metrik *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE) yang lebih unggul. Studi-studi tersebut antara lain: (1) Rahmadeyan pada tahun 2024 dengan judul “*Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction*” menunjukkan bahwa GRU menjadi model terbaik dengan nilai RMSE 70.4195, dan MAPE 1.1699% [10]. (2) Aryati dkk. pada tahun 2024 dengan judul “Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham” menunjukkan GRU menghasilkan MAPE 2,14% dan RMSE 0,01775, dimana nilainya lebih baik dari LSTM [6]. (3) Ghadimpour & Ebrahimi pada tahun 2022 dengan judul “*Forecasting Financial Time Series Using Deep Learning Networks: Evidence from Long-Short Term Memory and Gated Recurrent Unit*” dalam studi kasus ini, nilai MSE dan MAE mengungguli model LSTM meskipun struktur yang dimiliki oleh GRU lebih sederhana [11]. (4) Nilsen pada tahun 2022 membahas topik mengenai perbandingan model RNN, LSTM, dan GRU dalam memprediksi harga saham-saham LQ45, hasilnya model GRU memperoleh akurasi tertinggi dibanding RNN dan LSTM [12]. (5) Sofi dkk. pada tahun 2021 dengan topik perbandingan antara algoritma *linear regression*, LSTM, dan GRU dalam memprediksi harga saham dengan model *time-series*, hasilnya algoritma GRU memiliki performa terbaik dengan nilai RMSE, MSE, MAE terendah [13].

Berdasarkan penjelasan diatas, model *Gated Recurrent Unit* (GRU) terbukti memiliki keunggulan dibandingkan dengan teknik lainnya. Selain itu, pada beberapa studi kasus, penerapan GRU dibarengi dengan berbagai macam metode optimasi yang diyakini dapat meningkatkan akurasi model. Hal tersebut telah terbukti, karena terdapat perbedaan, khususnya pada nilai akurasi MAPE penelitian Aryati tahun 2024 yang tidak menggunakan algoritma optimasi menghasilkan nilai akurasi MAPE yang lebih besar yaitu 2,14%, sedangkan penelitian Rahmadeyan tahun 2024 menggunakan algoritma optimasi RMSprop menghasilkan nilai akurasi MAPE lebih kecil yaitu 1.1699%. Oleh karena itu, pada penelitian ini penulis ingin memaksimalkan kinerja model GRU yang dilakukan melalui pendekatan algoritma optimasi dan inisialisasi *hyperparameter* untuk mengontrol dan mengoptimalkan peramalan [14], [15]. Dalam konteks optimasi, penggunaan algoritma Adam (*Adaptive Moment Estimation*) dipilih karena dapat membantu mempercepat konvergensi dan meningkatkan kinerja model GRU [16], [17], [18], [19].


Pada penelitian ini, inisialisasi *hyperparameter* dilakukan dengan mengatur variabel – variabel *time step*, *learning rate*, *epoch*, *batch size*, dan *hidden state*, serta menyesuaikan parameter kunci algoritma Adam, yaitu *beta 1*, *beta 2*, dan *epsilon*. Kombinasi pengaturan *hyperparameter* dan algoritma Adam yang lebih rinci menggunakan model GRU ini diterapkan pada studi kasus PT Unilever Indonesia menggunakan data historis harga penutupan harian saham. Pendekatan ini merupakan kebaruan karena penelitian sebelumnya hanya menggunakan beberapa *hyperparameter* yang di atur dan selebihnya menggunakan nilai *default*. Selain itu, pada studi kasus yang sama dalam penelitian sebelumnya masih menggunakan algoritma tradisional seperti regresi linear dan ARIMA-GARCH [20], [21], [22]. Kemudian, *gap* penelitian yang perlu diperhatikan yaitu penerapan tahap evaluasi dari implementasi model terbaik yang dimiliki untuk melakukan peramalan pada periode ke depannya belum dilakukan pada penelitian sebelumnya. Oleh karena itu, penelitian ini melakukan peramalan harga penutupan harian saham untuk 1 bulan (20 hari *trading*) ke depan menggunakan model terbaik GRU-Adam, guna mengevaluasi kemampuan generalisasi model yang dilakukan pada bulan berikutnya setelah data historis sebenarnya tercatat pada situs *website* terkait. Dengan demikian, penelitian ini diharapkan dapat memperluas pemahaman mengenai pengaruh kombinasi pengaturan *hyperparameter* dan pengaturan parameter kunci algoritma Adam dalam model peramalan harga penutupan harian saham, memberikan wawasan mengenai durasi implementasi peramalan terhadap kinerja generalisasi model, serta mengetahui arah pergerakan saham terutama dalam konteks dampak pasca isu boikot.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan data sekunder, dimana sumber data tidak langsung diperoleh oleh pengumpul data, melainkan melalui orang lain atau dokumen [23]. Harga penutupan harian saham PT Unilever Indonesia Tbk (UNVR) merupakan data yang digunakan dalam konteks peramalan. Metode penelitian yang diterapkan yaitu deskriptif dengan pendekatan kuantitatif. Menurut Sugiyono, metode deskriptif digunakan untuk menentukan nilai satu atau lebih variabel tanpa membandingkannya dengan variabel lain [23]. Analisis data dilakukan dengan pendekatan data *mining* menggunakan teknik analisis deret waktu dengan model *sequential Gated Recurrent Unit* (GRU). Dalam proses ini, kombinasi inisialisasi *hyperparameter* yang tepat dan pengaturan parameter kunci algoritma Adam digunakan untuk optimasi model. Tahapan yang dilakukan pada penelitian ini dapat dilihat pada Gambar 1. Tahapan Penelitian, yang dimulai dari proses pengumpulan data, prapemrosesan data meliputi pembagian data dan normalisasi data, pemodelan

GRU-Adam termasuk proses inisialisasi *hyperparameter* dan optimasi dengan algoritma Adam, serta proses pengujian yang menghasilkan *output* peramalan diikuti dengan nilai RMSE dan MAPE.



Gambar 1. Tahapan Penelitian

2.2.1 Pengumpulan Data

Dataset yang digunakan pada penelitian ini yaitu harga saham penutupan (*close*) harian PT Unilever Indonesia Tbk yang diperoleh melalui laman <https://finance.yahoo.com/quote/UNVR.JK/>. Cakupan waktu data adalah lima tahun, terhitung dari periode 02 September 2019 hingga 30 Agustus 2024, yang berjumlah 1.213 baris data deret waktu dalam format CSV. Sampel data harga penutupan harian saham dapat dilihat pada Tabel 1 yang memuat informasi mengenai lima baris pertama periode 02 – 06 September 2019 harga penutupan harian saham.

Tabel 1. Sampel Dataset Harga Penutupan Harian Saham

<i>Date</i>	<i>Close</i>
02 September 2019	9590
03 September 2019	9495
04 September 2019	9515
05 September 2019	9605
06 September 2019	9410

2.2.2 Prapemrosesan Data

Pada tahap prapemrosesan data, dilakukan pengecekan dan penanganan *missing value* (penghapusan atau imputasi) serta transformasi data. Kolom *date* dan *close* dengan periode yang sudah ditentukan digunakan sebagai input untuk pembangunan model GRU. Data dibagi menjadi 80% data pelatihan dan 20% data pengujian. Selanjutnya, dilakukan normalisasi data menggunakan *Min-Max Scaling* untuk menskalakan nilai fitur ke dalam rentang [0, 1], sehingga semua fitur memiliki skala yang sama dan memudahkan proses analisis statistik serta mempercepat proses pelatihan model [24]. Persamaan umum proses normalisasi adalah sebagai berikut.

$$y = \frac{(x - \min)}{(\max - \min)} \quad (1)$$

2.2.3 Inisialisasi *Hyperparameter*

Inisialisasi *hyperparameter* dilakukan untuk mengontrol dan mengoptimalkan hasil peramalan [14], [15]. *Hyperparameter* yang diatur meliputi nilai *timestep*, *learning rate*, *jumlah epoch*, *batch size*, dan *hidden state*. Selain itu, pengaturan algoritma Adam juga diuji dengan tiga set parameter kunci. Tiga skenario tersebut diuji untuk

mengeksplorasi pengaruh variasi *hyperparameter* terhadap kinerja model. Skenario pengujian *hyperparameter* dapat dilihat pada Tabel 2, dimana memuat informasi mengenai masing-masing skenario yang akan diuji coba pada proses pelatihan model.

Tabel 2. Skenario Pengujian *Hyperparameter*


Skenario	Time step	Learning Rate	Parameter Adam	Epoch	Batch Size	Hidden State	Total Pelatihan
1	10	0.01	Beta 1 [0.8], Beta 2 [0.99], Epsilon [1e-8]	20, 50, 100	8, 16, 32	64, 128, 256	27
2	20	0.001	Beta 1 [0.9], Beta 2 [0.999], Epsilon [1e-7]	20, 50, 100	8, 16, 32	64, 128, 256	27
3	30	0.0001	Beta 1 [0.99], Beta 2 [0.9999], Epsilon [1e-6]	20, 50, 100	8, 16, 32	64, 128, 256	27

2.2.4 Modelling

Pada tahap *modelling*, model *Gated Recurrent Unit* (GRU) dibangun dan dilatih menggunakan tiga skenario, dengan total 81 percobaan dari kombinasi *hyperparameter* dan pengaturan parameter kunci Adam yang telah ditentukan sebelumnya.

2.2.4.1 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) diperkenalkan oleh Kyunghyun Cho pada tahun 2014 sebagai variasi dari *Recurrent Neural Network* (RNN) untuk mengatasi masalah ketergantungan jangka panjang. GRU efektif dalam mengingat informasi jangka panjang dan memiliki modul pemrosesan berulang [25]. Menurut Antonio Gulli, GRU dan LSTM mengatasi masalah *vanishing gradient*, tetapi GRU lebih cepat dilatih karena kebutuhan komputasi yang lebih rendah [26]. GRU memiliki dua komponen *gate*, yaitu *reset gate* dan *update gate*. Arsitektur GRU dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur *Gated Recurrent Unit*

Berdasarkan Gambar 2, kedua *gate* yang terdiri dari *reset gate* dan *update gate* tersebut mengelola informasi yang melewati sel, kemudian menentukan berapa banyak informasi masa lalu yang dilupakan melalui fungsi aktivasi *sigmoid* (σ) dengan output r_t . Jika $r_t = 1$, data diteruskan; jika $r_t = 0$, data tidak diteruskan. Input *reset gate* adalah input saat ini x_t dan keadaan tersembunyi sebelumnya h_{t-1} . *Update gate* menggunakan fungsi *sigmoid* untuk menghasilkan output z_t yang dikalikan dengan fungsi *tanh* untuk menghasilkan keadaan tersembunyi baru h_t . Hasil ini ditambahkan ke keadaan tersembunyi sebelumnya. *Reset gate* dan *update gate* dihitung menggunakan Persamaan (2) dan (3), dengan W_r dan W_z sebagai bobot yang dipelajari. Selanjutnya, h_t dari sel GRU ditentukan menggunakan Persamaan (4) [27].

$$r_t = \sigma(W_r * [h_{t-1}, x_t]) \quad (2)$$

$$z_t = \sigma(W_z * [h_{t-1}, x_t]) \quad (3)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tanh(W_h * (r_t * h_{t-1}, x_t)) \quad (4)$$

2.2.4.2 Algoritma Adam

Selanjutnya, penggunaan algoritma Adam (*Adaptive Moment Estimation*) sebagai algoritma optimasi dipilih karena kemampuannya untuk menangani masalah *gradient* yang bersifat *sparse* [28]. Pengaturan parameter kunci dalam tiga

skenario ini diharapkan dapat ditemukan kombinasi optimal yang dapat meningkatkan akurasi model GRU. Skenario pengaturan parameter kunci untuk algoritma Adam dapat dilihat pada Tabel 3, yang memuat informasi mengenai skenario yang akan dilaksanakan, parameter kunci yang diatur, serta kriteria dari masing-masing skenarionya.

Tabel 3. Skenario Pengaturan Parameter Kunci

Skenario	Parameter Adam	Kriteria
1	<i>Beta 1</i> [0.8], <i>Beta 2</i> [0.99], <i>Epsilon</i> [1e-8]	Pengaturan ini memberikan nilai yang lebih rendah dari nilai <i>default</i> parameter kunci algoritma Adam.
2	<i>Beta 1</i> [0.9], <i>Beta 2</i> [0.999], <i>Epsilon</i> [1e-7]	Parameter <i>default</i> Adam digunakan untuk memanfaatkan pengaturan yang telah terbukti efektif.
3	<i>Beta 1</i> [0.99], <i>Beta 2</i> [0.9999], <i>Epsilon</i> [1e-6]	Pengaturan ini memberikan nilai yang lebih tinggi dari nilai <i>default</i> parameter kunci algoritma Adam.

2.2.5 Denormalisasi Data

Setelah model dilatih dan menghasilkan prediksi, hasil prediksi perlu dinormalisasi kembali ke skala aslinya [29]. Hal ini penting karena hasil prediksi yang dihasilkan oleh model berada dalam rentang 0-1 akibat proses normalisasi sebelumnya. Proses denormalisasi dilakukan dengan mengalikan nilai prediksi dengan rentang nilai data asli dan menambahkan nilai minimum data asli. Persamaan umum proses denormalisasi adalah sebagai berikut.

$$d = y(\max - \min) + \min \quad (5)$$

2.2.6 Evaluasi Model

Terakhir, tahapan evaluasi dilakukan untuk mengetahui performa model berdasarkan skenario yang telah ditentukan pada data uji. Metrik evaluasi yang digunakan yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) [30]. Lebih jelas, rumus RMSE dan MAPE didapatkan dari tiga nilai berikut: (1) Nilai Aktual y_i (y true), (2) Nilai Prediksi $\hat{y}_i$ (y pred), (3) Jumlah Data n .

2.2.6.1 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) merupakan akar kuadrat selisih antara nilai prediksi dengan nilai sebenarnya [31], [32]. RMSE digunakan karena dapat mengukur sejauh mana nilai prediksi yang dihasilkan menyimpang dari nilai sebenarnya. Dimana, nilai RMSE yang semakin kecil menunjukkan keakuratan model dalam melakukan peramalan [33]. Rumus RMSE dapat ditulis sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (6)$$

2.2.6.2 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan ukuran tingkat akurasi dalam bentuk persentase pada sebuah prediksi atau peramalan [34]. Rumus RMSE dapat ditulis sebagai berikut:

$$MAPE = \frac{\sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}}{n} \times 100\% \quad (7)$$

Pada penelitian ini, MAPE digunakan karena memudahkan proses interpretasi data. Kriteria nilai MAPE dapat dilihat pada Tabel 4, yang menyajikan informasi mengenai makna dari setiap persentase nilai MAPE.

Tabel 4. Kriteria Nilai MAPE

Nilai MAPE	Kriteria
< 10%	Kemampuan peramalan sangat baik
10% – 20%	Kemampuan peramalan baik
20% – 50%	Kemampuan peramalan cukup
> 50%	Kemampuan peramalan buruk

3. HASIL DAN PEMBAHASAN

3.1 Hasil Prapemrosesan Data

Pada tahap prapemrosesan data, dilakukan pemilihan variabel yaitu berupa kolom *date* dan *close* (harga penutupan harian saham) dimana rentang data yang digunakan berkisar lima tahun (periode 02 September 2019 – 30 Agustus 2024) dengan total 1.213 baris data. Selanjutnya, dilakukan pembagian data dengan partisi 80:20, yaitu 80% untuk data latih dengan total 970 baris data terhitung dari 02 September 2019 – 24 Agustus 2023 dan 20% untuk data uji

dengan total 243 baris data terhitung dari 25 Agustus 2023 – 30 Agustus 2024. Terakhir, normalisasi data dilakukan menggunakan *Min-Max Scaling* untuk menskalakan nilai fitur ke dalam rentang [0, 1]. Hasil prapemrosesan data dapat dilihat pada Tabel 5, yang memuat informasi mengenai pembagian data dengan partisi 80:20 dan hasil normalisasi data yang telah dilakukan.

Tabel 5. Hasil Prapemrosesan Data

Data Latih			Data Uji		
Tanggal	Harga	Partisi	Tanggal	Harga	Partisi
02 September 2019	0.997963	80% (970 Baris Data)	25 Agustus 2023	0.206382	20% (243 Baris Data)
03 September 2019	0.985064		28 Agustus 2023	0.209097	
04 September 2019	0.987780		29 Agustus 2023	0.206382	
:	:		:	:	
22 Agustus 2023	0.199593		28 Agustus 2024	0.001358	
23 Agustus 2023	0.205024		29 Agustus 2024	0.000000	
24 Agustus 2023	0.200950		30 Agustus 2024	0.004073	

3.2 Pemodelan GRU

Sebelum model dibangun, dilakukan proses inisialisasi *hyperparameter* terlebih dahulu. Skema yang dibuat terdiri dari tiga skenario berbeda yang diuji sebanyak 81 kali percobaan pada model GRU, dengan fokus pada variabel *time step* (10,20,30), *learning rate* (0,1, 0,001, 0,0001), dan parameter Adam ([*Beta* 1 [0.8], *Beta* 2 [0.99], *Epsilon* [1e-8]], [*Beta* 1 [0.9], *Beta* 2 [0.999], *Epsilon* [1e-7]], dan [*Beta* 1 [0.99], *Beta* 2 [0.9999], *Epsilon* [1e-6]]). Setiap skenario dirancang untuk menguji bagaimana variasi dalam pengaturan ini mempengaruhi kinerja model, dengan nilai *epoch* (20, 50, 100), *batch size* (8, 16, 32), dan *hidden state* (64, 128, 256) yang tetap diuji secara konsisten di seluruh skenario.

Selanjutnya, arsitektur model GRU yang dibangun merupakan model *sequential*, yang dibuat menggunakan *tools Google Colaboratory* [35] dengan *library python* yaitu *Tensorflow*. Salah satu contoh arsitektur model dapat dilihat pada tabel 6. Ringkasan Model. Dimana, model ini memiliki lima *layer*, *layer* pertama GRU menerima input *sequence* dengan panjang 20 *time steps* dan 64 unit GRU (*hidden state*) dengan *output shape* (None, 20, 64). Kemudian, dilanjutkan dengan *layer* kedua yang tetap menghasilkan *output sequence* sama. Selanjutnya, *layer* ketiga menghasilkan *output* tanpa *sequence* dengan *output shape* (None, 64), di mana 64 mewakili *hidden state* terakhir dari *sequence*. Setelah itu, terdapat *layer dropout* untuk mencegah *overfitting* dengan *output shape* (None, 64). Terakhir, lapisan *dense* berfungsi sebagai *output layer* yang menghasilkan nilai tunggal dengan *shape* (None, 1) yang digunakan untuk peramalan akhir.

Tabel 6. Ringkasan Model

Model: “Sequential”		
Total params: 188, 549 (736.52 KB)		
Trainable params: 62, 849 (245.50 KB)		
Non-trainable params: 0 (0.00 KB)		
Optimizer params: 125, 700 (491.02 KB)		
Layer (Type)	Output Shape	Param (#)
gru (GRU)	(None, 20, 64)	12,864
gru_1 (GRU)	(None, 20, 64)	24, 960
gru_2 (GRU)	(None, 20, 64)	24, 960
dropout (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65

Kemudian, proses *training* model dilakukan pada skenario yang telah ditentukan sebelumnya, dimana nilai evaluasi dari setiap skenario dicatat untuk kemudian dipilih dan disimpulkan model terbaik dari 81 percobaan yang dilakukan.

3.2.1 Evaluasi Hasil Pengujian Skenario 1

Pada skenario pertama, digunakan nilai *time step* 10, *learning rate* 0.01, dan parameter Adam yang diatur lebih rendah dari nilai *default*. Secara keseluruhan rata-rata MAPE yang dihasilkan cukup besar yaitu 16.90%. Hal tersebut menunjukkan bahwa *time step* yang rendah membatasi kemampuan model dalam menangkap pola jangka panjang dalam data yang berpotensi mengurangi akurasi peramalan. Selain itu, penggunaan *learning rate* yang lebih tinggi berisiko mengakibatkan *overshooting* dan ketidakstabilan dalam proses pembelajaran. Pengaturan *hyperparameter* lainnya seperti *hidden state* juga berpengaruh terhadap akurasi model, dimana salah satu kombinasi yang menggunakan *hidden state* 256 menghasilkan MAPE paling tinggi yaitu 47.50 %. Hal ini disebabkan oleh kombinasi yang tidak seimbang dan penggunaan *hidden state* yang terlalu besar menjadikan model terlalu kompleks untuk menangkap pola dari data dengan *time step* yang sangat terbatas. Nilai evaluasi dari skenario 1 dapat dilihat pada

Tabel 7 yang menyajikan informasi mengenai hasil pengujian menggunakan metrik evaluasi RMSE, MAPE, dan rata-rata MAPE yang didapatkan dari skenario pertama.

Tabel 7. Nilai evaluasi skenario 1

No	Time step	Learning Rate	Epoch	Batch Size	Hidden State	Parameter Adam	RMSE	MAPE %	Rata - Rata MAPE
1	10	0.01	20	8	64	Beta 1 [0.8] Beta 2 [0.99] Epsilon [1e-8]	410.8916964	13.50%	16.90%
2			50	8	64		618.9949312	17.50%	
3			100	8	64		225.5472064	6.73%	
4			20	8	128		191.0818624	5.43%	
5			50	8	128		334.9400386	9.91%	
6			100	8	128		248.7897914	7.54%	
7			20	8	256		1093.328213	36.30%	
8			50	8	256		1068.326972	35.00%	
9			100	8	256		545.8173346	15.70%	
10			20	16	64		482.5338599	15.20%	
11			50	16	64		455.5719797	12.20%	
12			100	16	64		181.9194668	4.67%	
13			20	16	128		221.347238	6.05%	
14			50	16	128		590.1604584	19.60%	
15			100	16	128		202.4481327	4.70%	
16			20	16	256		349.5763517	10.40%	
17			50	16	256		1434.883256	47.50%	
18			100	16	256		609.6098699	19.70%	
19			20	32	64		193.4983295	6.10%	
20			50	32	64		134.7488548	3.97%	
21			100	32	64		341.1664381	10.10%	
22			20	32	128		152.7109609	4.67%	
23			50	32	128		1155.12835	38.30%	
24			100	32	128		909.4650311	30.00%	
25			20	32	256		346.2262239	11.10%	
26			50	32	256		1225.576215	40.30%	
27			100	32	256		739.4360677	24.00%	

3.2.2 Evaluasi Hasil Pengujian Skenario 2

Skenario kedua meningkatkan *time step* menjadi 20, menurunkan *learning rate* menjadi 0.001, dan parameter Adam yang diatur menggunakan nilai *default*. Kombinasi ini memberikan kesempatan dalam menangkap informasi temporal yang lebih kaya untuk meningkatkan kinerja model. Penyesuaian pada nilai *Beta 1* dan *Beta 2* juga menunjukkan dampak positif, di mana *Beta 1* yang lebih tinggi membantu model dalam mengatasi momentum gradien, sedangkan *Beta 2* yang lebih tinggi meningkatkan stabilitas dalam pembaruan parameter. Hasil evaluasi menunjukkan penurunan yang signifikan dalam nilai RMSE dan MAPE dibandingkan dengan skenario pertama. Nilai evaluasi dari skenario 2 dapat dilihat pada Tabel 8 yang menyajikan informasi mengenai hasil pengujian menggunakan metrik evaluasi RMSE, MAPE, dan rata-rata MAPE yang didapatkan dari skenario kedua.

Tabel 8. Nilai evaluasi skenario 2

No	Time step	Learning Rate	Epoch	Batch Size	Hidden State	Parameter Adam	RMSE	MAPE %	Rata - Rata MAPE
28	20	0.001	20	8	64	Beta 1 [0.9] Beta 2 [0.999] Epsilon [1e-7]	92.1686075	2.40%	2.65%
29			50	8	64		71.50814066	1.59%	
30			100	8	64		73.91479889	1.73%	
31			20	8	128		75.75228966	1.67%	
32			50	8	128		107.2116231	3.09%	
33			100	8	128		135.1518487	4.09%	
34			20	8	256		174.5963704	5.51%	
35			50	8	256		182.8126267	5.75%	
36			100	8	256		81.09107111	1.92%	
37			20	16	64		93.80648157	2.21%	
38			50	16	64		108.6929742	2.99%	
39			100	16	64		77.42656618	1.80%	
40			20	16	128		97.01057675	2.33%	
41			50	16	128		113.5651762	3.31%	

42	100	16	128	126.3493855	3.76%
43	20	16	256	77.50504873	1.86%
44	50	16	256	71.77548683	1.63%
45	100	16	256	92.62407641	2.43%
46	20	32	64	135.5261277	3.83%
47	50	32	64	115.2705694	3.09%
48	100	32	64	82.64072743	1.98%
49	20	32	128	110.6711181	2.93%
50	50	32	128	82.44169899	2.02%
51	100	32	128	78.59684869	1.89%
52	20	32	256	91.4159141	2.13%
53	50	32	256	75.54544748	1.78%
54	100	32	256	75.26776886	1.75%

3.2.3 Evaluasi Hasil Pengujian Skenario 3


Skenario ketiga melanjutkan tren peningkatan dengan menggunakan *time step* 30, *learning rate* 0.0001, dan parameter Adam yang diatur lebih tinggi dari nilai *default*. Pengaturan ini memungkinkan model untuk menangkap lebih banyak informasi temporal yang sangat penting dalam konteks data sekuensial. Meskipun *learning rate* yang sangat rendah dapat memperlambat proses pembelajaran, namun disisi lain dapat memberikan kesempatan bagi model untuk mencapai konvergensi yang lebih baik. Penyesuaian pada *Beta* 1 dan *Beta* 2 yang lebih tinggi juga meningkatkan efisiensi pembaruan parameter dan membuatnya sangat stabil. Hal tersebut dibuktikan dengan nilai evaluasi RMSE dan MAPE yang berada di rentang angka 1-3%, dimana pada skenario ini nilai *hidden state* yang besar tidak berpengaruh pada penurunan kinerja model seperti yang terjadi pada skenario sebelumnya. Nilai evaluasi dari skenario 3 dapat dilihat pada Tabel 9 yang menyajikan informasi mengenai hasil pengujian menggunakan metrik evaluasi RMSE, MAPE, dan rata-rata MAPE yang didapatkan dari skenario ketiga.

Tabel 9. Nilai evaluasi skenario 3

No	Time step	Learning Rate	Epoch	Batch Size	Hidden State	Parameter Adam	RMSE	MAPE %	Rata - Rata MAPE
55	30	0.0001	20	8	64	Beta 1 [0.99] Beta 2 [0.9999] Epsilon [1e-6]	113.7880437	2.73%	2.55%
56			50	8	64		113.9192876	2.78%	
57			100	8	64		85.9185083	1.94%	
58			20	8	128		110.3480167	2.58%	
59			50	8	128		94.40373931	2.15%	
60			100	8	128		85.0464754	2.04%	
61			20	8	256		103.3934769	2.46%	
62			50	8	256		86.14542161	1.91%	
63			100	8	256		83.95376492	2.09%	
64			20	16	64		119.0617297	2.87%	
65			50	16	64		116.32398	2.79%	
66			100	16	64		98.59951531	2.39%	
67			20	16	128		116.0955486	2.77%	
68			50	16	128		105.8720599	2.47%	
69			100	16	128		102.4745645	2.59%	
70			20	16	256		113.1096659	2.78%	
71			50	16	256		113.4933691	2.90%	
72			100	16	256		97.9380679	2.47%	
73			20	32	64		122.8738089	2.96%	
74			50	32	64		122.3871232	3.07%	
75			100	32	64		107.517868	2.52%	
76			20	32	128		118.8323707	2.84%	
77			50	32	128		114.7906685	2.76%	
78			100	32	128		103.9914866	2.40%	
79			20	32	256		112.7520677	2.77%	
80			50	32	256		104.8497282	2.44%	
81			100	32	256		98.83909245	2.39%	

3.3 Pembahasan

Hasil pengujian menunjukkan bahwa skenario kedua merupakan model terbaik dengan kombinasi *epoch* 50 dengan *batch size* 8 dan *hidden state* 64. Hal tersebut ditandai dengan nilai hasil evaluasi MAPE yang masuk dalam kriteria sangat baik yaitu sebesar 1.59% dan nilai RMSE model ini sebesar 71, 50814066. Artinya, selisih kesalahan antara nilai peramalan dengan nilai sebenarnya bisa lebih besar atau lebih kecil dari 71 (Rupiah). Kemudian, nilai MAPE 1.59% tersebut menunjukkan tingkat kesalahan model, dimana sisanya yaitu sebesar 98.41% dapat meramalkan nilai yang sangat dekat dengan nilai sebenarnya. Hasil ini menegaskan pentingnya pemilihan parameter serta validitas penggunaan nilai *default* yang sering kali memberikan hasil yang baik, memang terbukti efektif pada penelitian ini. Grafik perbandingan nilai sebenarnya dengan data latih dan data uji menggunakan model terbaik dapat dilihat pada gambar 3, dimana gambar sebelah kiri menunjukkan visualisasi keseluruhan harga penutupan harian saham periode 02 September 2019 – 30 Agustus 2024. Secara lebih jelas, garis warna biru mewakili nilai sebenarnya, kemudian garis warna merah mewakili hasil peramalan pada data latih, dan garis warna hijau mewakili hasil peramalan pada data uji. Lalu, gambar sebelah kanan merupakan perbesaran gambar sebelumnya yang menunjukkan visualisasi nilai sebenarnya dengan hasil peramalan pada data uji.



Gambar 3. Perbandingan Nilai Sebenarnya dengan Data Latih dan Data Uji

Berdasarkan gambar 3, hasil yang ditunjukkan oleh garis berwarna biru dan garis berwarna hijau memperlihatkan beberapa celah yang cukup renggang. Namun, jika diamati, celah tersebut berada pada titik pergerakan yang sangat curam dimana diakibatkan oleh fluktuasi harga yang tidak terduga. Kondisi pergerakan saham yang cenderung tajam pada data historis memang dapat menyebabkan nilai RMSE memiliki bobot lebih besar, seperti yang terjadi pada kasus ini. Namun, hasil peramalan dari model ini masih bisa dikatakan sangat baik karena memiliki nilai MAPE yang sangat rendah. Jika dibandingkan dengan beberapa penelitian sebelumnya yang menggunakan algoritma tradisional dengan studi kasus yang sama, hasil penelitian ini menunjukkan nilai MAPE yang paling rendah [20], [21], [22]. Artinya, meskipun dataset pada periode yang digunakan yaitu pasca isu boikot memiliki arah pergerakan yang cenderung tajam, model GRU yang dibangun menggunakan algoritma optimasi Adam masih dapat beradaptasi dengan sangat baik.

3.4 Implementasi dan Evaluasi Skenario Model Terbaik untuk Peramalan 1 Bulan ke depan

Implementasi peramalan menggunakan model terbaik yang dipilih dilakukan 1 Bulan (20 hari *trading*) ke depan dari hari terakhir periode dataset penelitian ini, yaitu dari 02 September – 30 September 2024. Periode peramalan ini dipilih untuk mengidentifikasi apakah durasi peramalan yang semakin lama akan berpengaruh terhadap kinerja generalisasi model. Evaluasi hasil peramalan dilakukan pada bulan berikutnya, yaitu ketika data historis harga penutupan harian saham telah tercatat pada laman <https://finance.yahoo.com/quote/UNVR.JK/>. Hasil peramalan harga penutupan harian saham dapat dilihat pada Tabel 10, yang memuat informasi mengenai selisih antara nilai sebenarnya dengan nilai peramalan serta keterangan rinci besaran penyimpangannya.


Tabel 10. Hasil Peramalan Harga Penutupan Harian Saham

Tanggal	Nilai Sebenarnya	Nilai Peramalan	Selisih Nilai	Keterangan Selisih antara Nilai Peramalan dengan Nilai Sebenarnya
02	2290	2251	39	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 39 Rupiah
03	2250	2246	4	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 4 Rupiah
04	2240	2240	0	Nilai ramalan sama dengan nilai sebenarnya dengan selisih 0 Rupiah
05	2220	2234	14	Nilai ramalan lebih besar dari nilai sebenarnya sebanyak 14 Rupiah
06	2220	2228	8	Nilai ramalan lebih besar dari nilai sebenarnya sebanyak 8 Rupiah



09	2190	2212	22	8 Rupiah Nilai ramalan lebih besar dari nilai sebenarnya sebanyak 22 Rupiah
10	2210	2207	3	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 3 Rupiah
11	2190	2201	11	Nilai ramalan lebih besar dari nilai sebenarnya sebanyak 11 Rupiah
12	2220	2196	24	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 24 Rupiah
13	2200	2191	9	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 9 Rupiah
17	2180	2172	8	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 8 Rupiah
18	2210	2167	43	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 43 Rupiah
19	2200	2163	37	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 37 Rupiah
20	2170	2158	12	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 12 Rupiah
23	2210	2146	64	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 64 Rupiah
24	2260	2141	119	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 119 Rupiah
25	2300	2137	163	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 163 Rupiah
26	2300	2134	166	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 166 Rupiah
27	2270	2130	140	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 140 Rupiah
30	2210	2119	91	Nilai ramalan lebih kecil dari nilai sebenarnya sebanyak 91 Rupiah

Berdasarkan Tabel 10, terbukti bahwa selisih nilai yang dihasilkan berada pada rentang nilai RMSE 71, dimana 14 data hasil peramalan menunjukkan penyimpangan lebih kecil dari 71 Rupiah, 5 data hasil peramalan menyimpang lebih besar dari 71 Rupiah, dan 1 data hasil peramalan menunjukkan hasil akurat dengan selisih 0 Rupiah. Hal lain yang berhasil diamati yaitu, semakin lama durasi peramalan maka penyimpangan tersebut terjadi lebih besar yang ditunjukkan pada hari peramalan ke-24 sampai dengan hari terakhir. Hal tersebut terjadi karena setiap peramalan yang menjadi *output* model memiliki tingkat *error*, dimana pada konteks ini adalah nilai RMSE yang akan terakumulasi seiring waktu, sehingga peramalan untuk periode berikutnya menjadi semakin tidak akurat. Selain itu, model mungkin hanya mampu menangkap pola jangka pendek, karena fluktuasi yang cepat dan tak terduga di dunia nyata membuat prediksi untuk periode yang lebih panjang menjadi lebih sulit dan tidak stabil. Selisih hasil peramalan dengan nilai sebenarnya yang di evaluasi satu bulan setelahnya dapat dilihat pada gambar 4, dimana garis berwarna biru menunjukkan nilai sebenarnya dan garis berwarna merah menunjukkan nilai hasil peramalan.



Gambar 4. Selisih Hasil Peramalan dengan Nilai Sebenarnya

Berdasarkan gambar 4, hasil peramalan menunjukkan tren penurunan, informasi tersebut dapat berguna bagi masyarakat atau investor dalam konteks hanya sebagai gambaran umum mengenai arah pergerakan harga penutupan harian saham tersebut. Selain itu, disarankan juga untuk menggunakan periode waktu peramalan yang lebih singkat (jangka pendek) agar nilai *loss* atau penyimpangannya tidak terlalu besar. Faktor eksternal utama saham penutupan harian UNVR ini mengalami penurunan dan terjadi fluktuasi tidak terduga yaitu karena dampak sentimen negatif pasar yang terjadi akibat isu boikot. Namun, faktanya menjelang akhir bulan harga penutupan harian saham tersebut kembali naik dengan kenaikan maksimal senilai 130 Rupiah dari nilai minimum harga penutupan hariannya. Oleh karena itu, untuk memutuskan melakukan investasi terhadap saham selain faktor teknikal, faktor lain yaitu fundamental dan sentimen perlu dipertimbangkan dengan baik.

4. KESIMPULAN

Penelitian ini membandingkan tiga skenario pengaturan *hyperparameter* dan algoritma Adam pada model *Gated Recurrent Unit* (GRU) untuk peramalan harga penutupan harian saham PT Unilever Indonesia Tbk. Hasilnya, Skenario 1 menghasilkan nilai MAPE rata-rata yang paling tinggi, menunjukkan akurasi yang kurang optimal, dimana pengaturan parameter Adam dan *time step* yang lebih rendah serta *learning rate* yang besar membuat model kurang sensitif dalam menangkap pola dan menimbulkan ketidakstabilan dalam proses pembelajaran. Selanjutnya, skenario 2 yang menggunakan *time step* 20, *learning rate* 0,001, dan parameter *default* Adam mencapai akurasi terbaik dengan nilai MAPE sebesar 1,59% dan RMSE sebesar 71,5, karena pengaturan *default* Adam, *learning rate default* serta *time step* yang lebih besar membantu konvergensi dan stabilitas. Terakhir, skenario 3 yang menggunakan *time step* 30, *learning rate* 0,0001, dan parameter Adam yang lebih tinggi dari nilai *default* menunjukkan stabilitas yang lebih baik meskipun masih dibawah skenario 2, karena pengaturan Adam yang lebih tinggi dan *learning rate* yang rendah memberikan kestabilan yang lebih baik serta *time step* yang besar memungkinkan model menangkap lebih banyak informasi temporal. Penemuan lain yang ditemukan yaitu, pergerakan saham yang cenderung tajam pada data historis dapat menyebabkan nilai RMSE memiliki bobot yang lebih besar, hal tersebut terbukti nyata karena 3 bulan sebelumnya dilakukan *forecasting* serupa namun bobot RMSE yang dihasilkan cukup rendah yaitu 0,70. Selain itu, pada proses implementasi peramalan 1 bulan ke depan (20 hari *trading*), hasil evaluasi pada bulan berikutnya menunjukkan bahwa semakin lama durasi peramalan, penyimpangan hasil peramalan semakin besar, maka disarankan agar model GRU-Adam yang digunakan diterapkan pada peramalan jangka pendek. Pada penelitian selanjutnya, disarankan untuk mempertimbangkan integrasi faktor eksternal seperti nilai inflasi dan kurs, serta kinerja keuangan perusahaan sebagai input model, atau penyertaan pengembangan model *hybrid* untuk meningkatkan akurasi model.

REFERENCES

- [1] M. Heriyanto, "Investor pasar modal Indonesia capai 12,13 juta SID per Desember 2023," AntaraNews. Accessed: Jul. 30, 2024. [Online]. Available: <https://www.antaranews.com/berita/3889137/investor-pasar-modal-indonesia-capai-1213-juta-sid-per-desember-2023>
- [2] M. Firman, "Strategi Public Relations Unilever Indonesia dalam Menjaga Reputasi Pasca Isu Boikot Pro-Israel," *Jurnal Ilmiah Ekonomi Dan Manajemen*, vol. 2, no. 6, pp. 171–178, 2024, doi: 10.61722/jiem.v2i6.1319.
- [3] P. L. Puji and T. Jazil, "The Role of Religiosity, Consumer Animosity, and Ethnocentrism in Explaining the Boycott Motivation," *Journal of Islamic Economics and Finance Studies*, vol. 5, no. 1, pp. 134–152, Jun. 2024, doi: 10.47700/jiefes.v5i1.7755.
- [4] S. Sarah Maesaroh, M. Sandi Marta, and M. Sari, "Uji Beda Dampak Pandemi Covid 19: Pengaruh Pertumbuhan Aset, Profitabilitas, dan Struktur Modal terhadap Nilai Perusahaan Sub Sektor Restoran, Hotel & Pariwisata," *OPTMAL: Jurnal Ekonomi dan Kewirausahaan*, vol. 14, no. 2, pp. 76–90, 2020, doi: 10.33558/optimal.v14i2.3099.
- [5] A. T. Oyewole, O. B. Adeoye, W. A. Addy, C. C. Okoye, O. C. Ofodile, and C. E. Ugochukwu, "Predicting Stock Market Movement using Neural Network: A Review and Application Study," *Computer Science & IT Research Journal*, vol. 5, no. 3, pp. 651–670, Mar. 2024, doi: 10.51594/csitrj.v5i3.912.
- [6] N. W. Meri Aryati, I. K. A. G. Wiguna, N. W. S. Putri, I. K. K. Widiartha, and N. L. W. S. R. Ginantra, "Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 2, p. 1131, Apr. 2024, doi: 10.30865/mib.v8i2.7342.
- [7] N. L. W. S. R. Ginantra, I. M. D. P. Asana, W. G. S. Parwita, and M. L. D. Wiadnyana, "Forecasting System Analysis using Gated Recurrent Unit Neural Network," *Journal of System and Management Sciences*, vol. 13, no. 5, pp. 470–482, 2023, doi: 10.33168/JSMS.2023.0530.
- [8] K. Cho *et al.*, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation," Jun. 2014, doi: 10.3115/v1/D14-1179.
- [9] S. Zhang, E. Robinson, and M. Basu, "Wind power forecasting based on a novel gated recurrent neural network model," *Wind Energy and Engineering Research*, vol. 1, p. 100004, Aug. 2024, doi: 10.1016/j.weer.2024.100004.
- [10] A. Rahmadayan and Mustakim, "Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 204–212. doi: 10.1016/j.procs.2024.02.167.
- [11] M. Ghadimpour and S. B. Ebrahimi, "Forecasting Financial Time Series Using Deep Learning Networks: Evidence from Long-Short Term Memory and Gated Recurrent Unit," *Iranian Journal of Finance*, vol. 6, no. 4, pp. 81–94, Oct. 2022, doi: 10.30699/ijf.2022.313164.1286.
- [12] A. Nilsen, "Perbandingan Model RNN, Model LSTM, dan Model GRU dalam Memprediksi Harga Saham-Saham LQ45," *Jurnal Statistika dan Aplikasinya*, vol. 6, no. 1, Jun. 2022, doi: 10.21009/JSA.06113.



- [13] K. Sofi, A. S. Sunge, S. R. Riady, and A. Z. Kamalia, “Perbandingan Algoritma Linear Regression, LSTM, dan GRU dalam Memprediksi Harga Saham dengan Model Time Series,” *SEMINASTIKA*, vol. 3, no. 1, pp. 39–46, Nov. 2021, doi: 10.47002/seminastika.v3i1.275.
- [14] P. N and S. Sugave, “Optimizing Machine Learning Models: An Adaptive Hyperparameter Tuning Approach,” *International Journal of Intelligent Systems and Applications in Engineering*, vol. 11, no. 4, pp. 344–354, Jul. 2023, Accessed: Nov. 10, 2024. [Online]. Available: <https://ijisae.org/index.php/IJISAE/article/view/3532>
- [15] T. Yu and H. Zhu, “Hyper-Parameter Optimization: A Review of Algorithms and Applications,” Mar. 2020, doi: 10.48550/arXiv.2003.05689.
- [16] D. P. Kingma and J. L. Ba, “Adam: A Method for Stochastic Optimization,” Dec. 2014, doi: 10.48550/arXiv.1412.6980.
- [17] M. F. Cahyadi and T. H. Rochadiani, “Implementasi Ensemble Deep Learning Untuk Analisis Sentimen Terhadap Genre Game Mobile,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 3, p. 1512, Jul. 2024, doi: 10.30865/mib.v8i3.7832.
- [18] S. Lakshmi and C. P. Maheswaran, “Effective deep learning based grade prediction system using gated recurrent unit (GRU) with feature optimization using analysis of variance (ANOVA),” *Automatika*, vol. 65, no. 2, pp. 425–440, 2024, doi: 10.1080/00051144.2023.2296790.
- [19] A. Makinde, “Optimizing Time Series Forecasting: A Comparative Study of Adam and Nesterov Accelerated Gradient on LSTM and GRU networks Using Stock Market data,” Sep. 2024, doi: 10.48550/arXiv.2410.01843.
- [20] M. Citra, “Comparative Study of Stock Price Forecasting Models PT. Unilever Indonesia Tbk Using Arima and Garch,” *International Journal of Community Service*, vol. 02, no. 01, pp. 1–22, 2021, doi: 10.55299/ijcs.v1i2.220.
- [21] R. W. Wilda, M. A. Sukmarini, and A. C. Mahar, “Prediksi Harga Saham PT. Unilever Indonesia Tbk dengan Metode Regresi Linier Sederhana,” *Balance: Media Informasi Akuntansi dan Keuangan*, vol. 16, no. 2, pp. 76–81, Jul. 2024, doi: 10.52300/blnc.v16i2.14249.
- [22] A. D. Pramesti and W. Sulistijanti, “ARIMA-GARCH Model Price Forecasting in PT. Unilever Indonesia Tbk,” *EKSYAR : Jurnal Ekonomi Syari’ah & Bisnis Islam*, vol. 10, no. 1, pp. 147–156, Aug. 2023, doi: 10.54956/eksyar.v10i1.459.
- [23] P. D. Sugiyono, *Educational Research Methods (Quantitative, Qualitative, Combination, R&d and Educational Research)*. Educational Research Methods, 2019.
- [24] J. Sun and Y. Xia, “Pretreating and normalizing metabolomics data for statistical analysis,” *Genes Dis*, vol. 11, no. 3, pp. 2–18, May 2024, doi: 10.1016/j.gendis.2023.04.018.
- [25] L. Zaman, S. Sumpeno, and M. Hariadi, “Analisis Kinerja LSTM dan GRU sebagai Model Generatif untuk Tari Remo,” *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 8, no. 2, pp. 142–150, May 2019, doi: 10.22146/jnteti.v8i2.503.
- [26] A. Gulli, S. Pal, and A. Kapoor, *Deep learning with TensorFlow 2 and Keras: regression, ConvNets, GANs, RNNs, NLP, and more with TensorFlow 2 and the Keras API*, Second Edition. Packt Publishing Ltd, 2019.
- [27] S. Mohsen, “Recognition of human activity using GRU deep learning algorithm,” *Multimed Tools Appl*, vol. 82, no. 30, pp. 47733–47749, Dec. 2023, doi: 10.1007/s11042-023-15571-y.
- [28] J. A. Ripto and H. Heryanto, “Penerapan Gated Recurrent Unit untuk Prediksi Pergerakan Harga Saham pada Bursa Efek Indonesia,” Doctoral Dissertation, Institut Teknologi Harapan Bangsa, Bandung, 2022.
- [29] L. Sufriyah, A. Fanani, A. Hamid, N. Ulinnuha, and K. Intan, “Peramalan Harga Emas dengan Metode Backpropagation Neural Network (Studi Kasus: PT. Aneka Tambang Tbk),” *Scientica: Jurnal Ilmiah Sains dan Teknologi*, vol. 2, no. 12, pp. 888–898, Sep. 2024, doi: 10.572349/scientica.v2i12.3479.
- [30] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 3rd Edition. O’Reilly Media, Inc, 2022.
- [31] S. Hansun and J. C. Young, “Predicting LQ45 financial sector indices using RNN-LSTM,” *J Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00495-x.
- [32] A. Kurniawati, M. Sabri Ahmad, M. Fhadli, and S. Lutfi, “Analisis Perbandingan Metode Time Series Forecasting untuk Prediksi Penjualan Obat di Apotek (Studi Kasus: Kimia Farma Apotek Takoma),” *Jurnal Jaringan dan Teknologi Informasi*, vol. 3, no. 1, pp. 96–106, 2023, Accessed: Nov. 10, 2024. [Online]. Available: <https://e-journal.unkhair.ac.id/index.php/jati/article/view/62>
- [33] Moch Farryz Rizkillah and Sri Widiyanesti, “Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM),” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 1, pp. 25–31, Feb. 2022, doi: 10.29207/resti.v6i1.3630.
- [34] H. Hewamalage, K. Ackermann, and C. Bergmeir, “Forecast evaluation for data scientists: common pitfalls and best practices,” *Data Min Knowl Discov*, vol. 37, no. 2, pp. 788–832, Mar. 2023, doi: 10.1007/s10618-022-00894-5.
- [35] R. Gelar Guntara, “Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7,” *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 1, pp. 55–60, Feb. 2023, doi: 10.47233/jteksis.v5i1.750.