

SKRIPSI

**PERBANDINGAN METODE *LONG SHORT-TERM MEMORY*
(LSTM) DAN *GATED RECURRENT UNIT* (GRU) DENGAN
PENDEKATAN UNIVARIAT DAN MULTIVARIAT UNTUK
MEMPREDIKSI HARGA SAHAM
(STUDI KASUS : HARGA SAHAM BMRI PERIODE 2015-2024)**



AMANDA RIYAS UTAMI

22106010003

**STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA**

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA
YOGYAKARTA**

2026

**PERBANDINGAN METODE *LONG SHORT-TERM MEMORY*
(LSTM) DAN *GATED RECURRENT UNIT* (GRU) DENGAN
PENDEKATAN UNIVARIAT DAN MULTIVARIAT UNTUK
MEMPREDIKSI HARGA SAHAM
(STUDI KASUS : HARGA SAHAM BMRI PERIODE 2015-2024)**

Skripsi

Untuk memenuhi sebagian persyaratan
mencapai derajat Sarjana S-1
Program Studi Matematika



diajukan oleh

AMANDA RIYAS UTAMI

22106010003

Kepada

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA
YOGYAKARTA**

2026



SURAT PERSETUJUAN SKRIPSI/TUGAS AKHIR

Hal : Persetujuan Skripsi / Tugas Akhir

Lamp :

Kepada

Yth. Dekan Fakultas Sains dan Teknologi

UIN Sunan Kalijaga Yogyakarta

di Yogyakarta

Assalamu 'alaikum wr. wb.

Setelah membaca, meneliti, memberikan petunjuk dan mengoreksi serta mengadakan perbaikan seperlunya, maka kami selaku pembimbing berpendapat bahwa skripsi Saudara:

Nama : Amanda Riyas Utami

NIM : 22106010003

Judul Skripsi : Perbandingan Metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dengan Pendekatan Univariat dan Multivariat untuk Memprediksi Harga Saham (Studi Kasus: Harga Saham BMRI Periode 2015-2024)

sudah dapat diajukan kembali kepada Program Studi Matematika Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta sebagai salah satu syarat untuk memperoleh gelar Sarjana Strata Satu dalam Program Studi Matematika.

Dengan ini kami berharap agar skripsi/tugas akhir Saudara tersebut di atas dapat segera dimunaqasyahkan. Atas perhatiannya kami ucapkan terima kasih.

Wassalamu 'alaikum wr. wb.

Yogyakarta, 3 Juni 2026

Pembimbing

Sri Utami Zuliana, S.Si., M.Sc., Ph.D.

NIP. 19741003 200003 2 002



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA
FAKULTAS SAINS DAN TEKNOLOGI

Jl. Marsda Adisucipto Telp. (0274) 540971 Fax. (0274) 519739 Yogyakarta 55281

PENGESAHAN TUGAS AKHIR

Nomor : B-1133/Un.02/DST/PP.00.9/06/2026

Tugas Akhir dengan judul : PERBANDINGAN METODE LONG SHORT-TERM MEMORY (LSTM) DAN GATED RECURRENT UNIT (GRU) DENGAN PENDEKATAN UNIVARIAT DAN MULTIVARIAT UNTUK MEMREDIKSI HARGA SAHAM (STUDI KASUS: HARGA SAHAM BMRI PERIODE 2015-2024)

yang dipersiapkan dan disusun oleh:

Nama : AMANDA RIYAS UTAMI
Nomor Induk Mahasiswa : 22106010003
Telah diujikan pada : Selasa, 12 Mei 2026
Nilai ujian Tugas Akhir : A

dinyatakan telah diterima oleh Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta

TIM UJIAN TUGAS AKHIR



Ketua Sidang

Sri Utami Zuliana, S.Si., M.Sc., Ph.D.
SIGNED

Valid ID: 6a14375892817



Penguji I

Dr. Mohammad Farhan Quadratullah, S.Si.,
M.Si
SIGNED

Valid ID: 6a13d23b20b6e



Penguji II

Arif Munandar, M.Sc.
SIGNED

Valid ID: 6a194e5e45624



Yogyakarta, 12 Mei 2026
UIN Sunan Kalijaga
Dekan Fakultas Sains dan Teknologi

Prof. Dr. Dra. Hj. Khurul Wardati, M.Si.
SIGNED

Valid ID: 6a1f9b1adae15

SURAT PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini:

Nama : Amanda Riyas Utami

NIM : 22106010003

Program Studi : Matematika

Fakultas : Sains dan Teknologi

Dengan ini menyatakan bahwa isi skripsi ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar sarjana di suatu Perguruan Tinggi dan sesungguhnya skripsi ini merupakan hasil pekerjaan penulis sendiri sepanjang pengetahuan penulis, bukan duplikasi atau saduran dari karya orang lain kecuali bagian tertentu yang penulis ambil sebagai bahan acuan. Apabila terbukti pernyataan ini tidak benar, sepenuhnya menjadi tanggung jawab penulis.

Yogyakarta, 17 April 2026



Amanda Riyas Utami

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

HALAMAN PERSEMBAHAN

Karya ini penulis persembahkan untuk kedua orang tua, adik, keluarga besar, dan orang-orang yang selalu menyayangi penulis. Terima kasih atas segala dukungan yang telah diberikan hingga penulis dapat mencapai tahap ini.



MOTTO

”Jangan pernah menyerah pada hidup ini karena setiap hal yang kamu lakukan adalah suatu nilai berharga yang akan kembali lagi padamu”



PRAKATA

Puji syukur ke hadirat Allah SWT atas segala rahmat, hidayah, dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul "Perbandingan Metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) untuk Memprediksi Harga Saham (Studi Kasus: Harga Saham BMRI Periode 2015-2024)" dengan baik.

Dalam proses penyusunan skripsi ini, penulis menyadari bahwa banyak tantangan dan kendala yang dihadapi, baik dalam memahami konsep, mengolah data, maupun dalam proses penulisan. Namun, berkat doa, dukungan, serta bimbingan dari berbagai pihak, skripsi ini akhirnya dapat diselesaikan. Oleh karena itu, penulis dengan tulus mengucapkan terima kasih kepada:

1. Ibu Prof. Dr. Dra. Hj. Khurul Wardati, M.Si., selaku Dekan Fakultas Sains dan Teknologi, Universitas Islam Negeri Sunan Kalijaga Yogyakarta sekaligus dosen penasihat akademik yang senantiasa memberikan arahan kepada penulis sejak awal perkuliahan hingga selesai.
2. Ibu Dr. Epha Diana Supandi, S.Si., M.Sc., selaku Kepala Program Studi Matematika.
3. Ibu Sri Utami Zuliana, S.Si., M.Sc., Ph.D., selaku dosen pembimbing skripsi yang dengan sabar memberikan arahan dan bimbingan kepada penulis hingga skripsi ini dapat terselesaikan dengan baik.
4. Seluruh dosen Program Studi Matematika serta karyawan Fakultas Sains dan Teknologi yang telah memberikan ilmu dan pelayanan terbaik selama masa

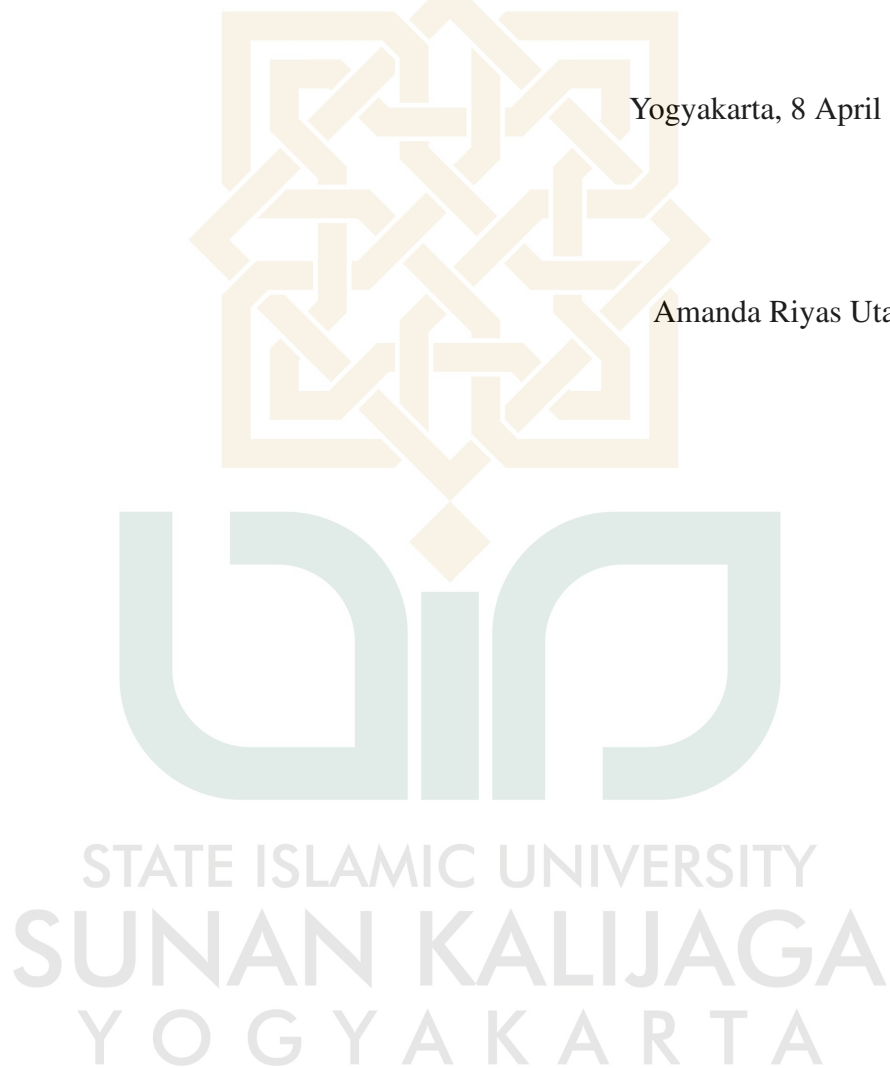
perkuliahan.

5. Kedua orang tua tercinta yang senantiasa memberikan doa, kasih sayang, serta dukungan tanpa henti kepada penulis. Setiap langkah, perjuangan, dan pencapaian hingga saat ini tidak terlepas dari pengorbanan, kerja keras, serta ketulusan yang selalu diberikan. Semoga segala usaha dan doa yang telah dicurahkan dapat terbalaskan melalui hasil yang membanggakan dan membawa kebahagiaan bagi kedua orang tua.
6. Adik penulis, Ulya, yang selalu menjadi alasan bagi penulis untuk berusaha memberikan contoh terbaik dalam setiap langkah. Terima kasih telah menjadi penyemangat dan penghibur di setiap proses yang dilalui penulis.
7. Nenek tercinta yang senantiasa memberikan doa, kasih sayang, serta dukungan tulus kepada penulis. Terima kasih atas perhatian, nasihat, dan cinta yang selalu menguatkan penulis selama menjalani perkuliahan ini.
8. Pakde Karmin yang senantiasa memberikan dukungan dan motivasi kepada penulis selama menempuh pendidikan.
9. Teman-teman penulis, yaitu Tintan, Atina, Bunga, Dzakiyya, Icha, Viga, dan Nafisa yang telah menjadi bagian penting dalam perjalanan perkuliahan ini melalui kebersamaan, dukungan, dan semangat yang selalu diberikan. Terima kasih atas cerita, bantuan, dan momen berharga yang telah dilalui bersama selama masa perkuliahan.
10. Seluruh pihak yang telah membantu dan terlibat dalam proses penyusunan skripsi ini, baik secara langsung maupun tidak langsung, yang tidak dapat penulis sebutkan satu per satu. Terima kasih atas segala bantuan dan dukungan yang telah diberikan dalam proses penyusunan skripsi ini.

Penulis menyadari bahwa skripsi ini masih memiliki keterbatasan. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang membangun untuk perbaikan di masa yang akan datang. Semoga skripsi ini dapat memberikan manfaat serta menjadi kontribusi dalam pengembangan ilmu pengetahuan, khususnya di bidang analisis runtun waktu dan *machine learning*.

Yogyakarta, 8 April 2026

Amanda Riyas Utami



DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERSETUJUAN TUGAS AKHIR	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERNYATAAN KEASLIAN	iv
HALAMAN PERSEMBAHAN	v
HALAMAN MOTTO	vi
PRAKATA	vii
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
DAFTAR LAMBANG	xvii
INTISARI	xxi
ABSTRACT	xxii
I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	4
1.3. Batasan Masalah	4
1.4. Tujuan Penelitian	5
1.5. Manfaat Penelitian	6
1.6. Tinjauan Pustaka	7
1.7. Sistematika Penulisan	9
II DASAR TEORI	11
2.1. Pengertian Data	11

2.2. Peramalan (<i>Forecasting</i>)	13
2.3. Runtun Waktu (<i>Time Series</i>)	17
2.3.1. <i>Augmented Dickey-Fuller</i> (ADF)	18
2.3.2. <i>Autocorrelation Function</i> (ACF)	19
2.3.3. <i>Partial Autocorrelation Function</i> (PACF)	20
2.4. Model <i>Time Series</i> Klasik	21
2.4.1. Model <i>Autoregressive</i> (AR)	22
2.4.2. Model <i>Moving Average</i> (MA)	23
2.4.3. Model <i>Autoregressive Moving Average</i> (ARMA)	23
2.4.4. Model <i>Autoregressive Integrated Moving Average</i> (ARIMA)	26
2.5. <i>Operasi Matriks</i>	27
2.6. Normalisasi	30
2.7. Denormalisasi	31
2.8. <i>Sliding Window</i>	31
2.9. <i>Deep Learning</i>	32
2.10. <i>Long Short-Term Memory</i> (LSTM)	34
2.11. <i>Gated Recurrent Unit</i> (GRU)	39
2.12. Metrik Evaluasi	44
2.12.1. <i>Mean Squared Error</i> (MSE)	44
2.12.2. <i>Mean Absolute Error</i> (MAE)	45
2.13. <i>Adaptive Moment Estimation</i> (Adam)	45
2.14. <i>Hyperparameter Tuning</i>	47
2.15. Fungsi Aktivasi	48
2.16. Saham	50
III METODE PENELITIAN	56
3.1. Pendekatan Penelitian	56

3.2. Data	56
3.3. Metode Pengolahan Data	57
3.4. Diagram Analisis Data (<i>Flowchart</i>)	59
IV HASIL DAN PEMBAHASAN	61
4.1. Deskripsi Data Penelitian	61
4.2. Pengambilan Data	62
4.3. Input Data	62
4.4. <i>Exploratory Data Analysis</i> (EDA)	63
4.5. <i>Preprocessing</i>	66
4.6. Pemodelan	76
4.7. Perbandingan Evaluasi Model	96
4.8. Prediksi Harga Saham 7 Hari ke Depan	96
V PENUTUP	100
5.1. Kesimpulan	100
5.2. Saran	102
DAFTAR PUSTAKA	104
LAMPIRAN	109
A Persamaan dan Perbedaan Penelitian Sekarang dengan Penelitian Ter- dahulu	110
B Data Penelitian	111
C <i>Source Code Python</i> Pengambilan Data	112
D <i>Source Code Python</i> Model LSTM dan GRU Univariat	113
E <i>Source Code Python</i> Model LSTM dan GRU Multivariat	131
F Biodata Penulis	149

DAFTAR TABEL

4.1	Ringkasan Data Awal dan Akhir Saham BMRI	63
4.2	Hasil Statistik Deskriptif Data Saham	64
4.3	Hasil Statistik Deskriptif Data Saham Setelah Pembersihan	64
4.4	Penghitungan <i>Volatility</i>	71
4.5	Data Harga Saham dengan Variabel Tambahan	72
4.6	Normalisasi Fitur <i>Input Close</i>	75
4.7	Normalisasi Fitur <i>Input Close</i> , <i>EMA7</i> , <i>Return</i> , dan <i>Volatility</i>	75
4.8	Hasil Evaluasi Awal Model LSTM Univariat	79
4.9	Hasil Eksperimen <i>Sliding Window</i> LSTM Univariat	79
4.10	Hasil Eksperimen <i>Hidden layer</i> LSTM Univariat	80
4.11	Hasil Eksperimen Parameter LSTM Univariat	80
4.12	Hasil Evaluasi Awal Model GRU Univariat	82
4.13	Hasil Eksperimen <i>Sliding Window</i> GRU Univariat	82
4.14	Hasil Eksperimen <i>Hidden layer</i> GRU Univariat	83
4.15	Hasil Eksperimen Parameter GRU Univariat	83
4.16	Hasil Evaluasi Model LSTM dan GRU Univariat	85
4.17	Tabel Perbedaan Harga Prediksi dan Harga Aktual Model LSTM dan GRU Univariat	87
4.18	Hasil Evaluasi Awal Model LSTM Multivariat	88
4.19	Hasil Eksperimen <i>Sliding Window</i> LSTM Multivariat	88
4.20	Hasil Eksperimen <i>Hidden layer</i> LSTM Multivariat	89
4.21	Hasil Eksperimen Parameter LSTM Multivariat	89
4.22	Hasil Evaluasi Awal Model GRU Multivariat	91

4.23 Hasil Eksperimen <i>Sliding Window</i> GRU Multivariat	91
4.24 Hasil Eksperimen <i>Hidden layer</i> GRU Multivariat	91
4.25 Hasil Eksperimen Parameter GRU Multivariat	92
4.26 Hasil Evaluasi Model LSTM dan GRU Multivariat	94
4.27 Tabel Perbedaan Harga Prediksi dan Harga Aktual Model LSTM dan GRU Multivariat	95
4.28 Hasil Evaluasi Model LSTM dan GRU Multivariat	96
4.29 Perbandingan Hasil Prediksi dengan Model LSTM dan GRU 7 Hari ke Depan dengan Pendekatan Univariat dan Multivariat	97

DAFTAR GAMBAR

2.1	Pola data <i>trend</i> (Sumber: Montgomery et al. (2015))	14
2.2	Pola data musiman (Sumber: Montgomery et al. (2015))	15
2.3	Pola data siklis (Sumber: Montgomery et al. (2015))	16
2.4	Struktur LSTM (Sumber: Buff ML (2025))	35
2.5	Struktur GRU (Sumber: Rolangon et al. (2023))	40
3.1	Flowchart Penelitian	60
4.1	Tren Harga Penutupan Saham BMRI Periode 1 Januari 2015 - 31 Desember 2024	65
4.2	Visualisasi Split Data <i>Close</i>	73
4.3	Visualisasi Split Data dengan EMA 7, <i>Return</i> , dan <i>Volatility</i>	73
4.4	Training Loss vs Validation Loss LSTM Univariat	78
4.5	Training Loss vs Validation Loss GRU Univariat	81
4.6	Training Loss vs Validation Loss LSTM Univariat Final	84
4.7	Training Loss vs Validation Loss GRU Univariat Final	85
4.8	Grafik Prediksi dan Harga Aktual dengan LSTM Univariat	86
4.9	Grafik Prediksi dan Harga Aktual dengan GRU Univariat	86
4.10	Training Loss vs Validation Loss LSTM Multivariat	87
4.11	Training Loss vs Validation Loss GRU Multivariat	90
4.12	Training Loss vs Validation Loss LSTM Multivariat Final	93
4.13	Training Loss vs Validation Loss GRU Multivariat Final	93
4.14	Grafik Prediksi dan Harga Aktual dengan LSTM Multivariat	94
4.15	Grafik Prediksi dan Harga Aktual dengan GRU Multivariat	95

4.16 Prediksi 7 Hari ke Depan Univariat 97

4.17 Prediksi 7 Hari ke Depan dengan Dataset untuk Model Univariat . . 97

4.18 Prediksi 7 Hari ke Depan Multivariat 98

4.19 Prediksi 7 Hari ke Depan dengan Dataset untuk Model Multivariat . 98



DAFTAR LAMBANG

- ΔY_t = Perubahan nilai variabel Y dari waktu ke waktu ($Y_t - Y_{t-1}$)
- α = konstanta
- γ_i = koefisien lag perbedaan pertama
- ε_t = *white noise* pada waktu ke- t
- H_0 = hipotesis nol
- H_1 = hipotesis alternatif
- ρ_k = koefisien autokorelasi pada lag ke- k
- k = jumlah lag
- $E[\cdot]$ = nilai harapan
- y_t = nilai deret waktu pada waktu ke- t
- y_{t+k} = nilai deret waktu pada waktu ke ($t + k$)
- μ = rata rata deret waktu
- Cov = kovarians dua nilai deret waktu
- Var = variansi
- γ_k = autokovarians pada lag ke-0
- y_{t-1} = nilai deret waktu pada satu periode sebelumnya
- P_k = matriks autokorelasi
- ϕ_k = vektor koefisien parsial
- P_k^{-1} = invers matriks autokorelasi
- ϕ_{kk} = koefisien AR ke- k atau PACF lag ke- k
- δ = konstanta atau *intercept*

$\phi_1, \phi_2, \dots, \phi_p$	= koefisien autoregresif pada lag 1 sampai lag p
$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$	= nilai deret waktu pada lag 1 sampai lag p
$\theta_1, \theta_2, \dots, \theta_q$	= koefisien <i>moving average</i> pada lag 1 sampai lag q
$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$	= error pada lag 1 sampai lag q
ϕ_i	= koefisien autoregresif pada lag ke- i
θ_i	= koefisien <i>moving average</i> pada lag ke- i
$\Phi(B)$	= polinomial operator AR dalam operator <i>backshift</i>
$\Theta(B)$	= operator MA dalam <i>backshift</i>
Ψ_i	= koefisien <i>impulse</i> atau bobot dari error masa lalu pada lag ke- i
m	= variabel akar (<i>root</i>) dari polinomial
$\Pi(B)$	= operator AR tak hingga dalam bentuk <i>backshift</i>
d	= derajat <i>differencing</i>
w_t	= hasil <i>differencing</i> orde- d pada waktu ke- t
h_t	= <i>hidden state</i> pada waktu ke- t
f_h	= fungsi aktivasi pada <i>hidden layer</i>
W_{xh}	= matriks bobot dari <i>input</i> x_t menuju <i>hidden state</i>
x_t	= <i>input</i> pada waktu ke- t
W_{hh}	= matriks bobot rekuren dari h_{t-1} ke <i>hidden state</i> saat ini
h_{t-1}	= <i>hidden state</i> pada waktu sebelumnya
y_t	= <i>output</i> pada waktu ke- t
f_y	= fungsi aktivasi pada <i>output layer</i>
W_{hy}	= matriks bobot antara <i>hidden state</i> h_t ke <i>output</i> y_t

h_t	= <i>hidden state</i> pada waktu ke- t
$b_y, b_f, b_i, b_c, b_o, b_r, b_z, b_h$	= bias
f_t	= <i>forget gate</i>
σ	= fungsi sigmoid
$W_f, W_i, W_c, W_o, W_r, W_z, W_h$	= matriks bobot untuk <i>input</i>
$U_f, U_i, U_c, U_o, U_r, U_z, U_h$	= matriks bobot untuk <i>hidden state</i>
\tanh	= fungsi aktivasi <i>hyperbolic tangent</i>
C_t	= <i>cell state</i> pada waktu ke- t
i_t	= <i>input gate</i>
C_{t-1}	= <i>cell state</i> pada waktu ke- $(t - 1)$
\odot	= <i>hadamard product</i>
o_t	= <i>output gate</i> pada waktu ke- t
$\tanh(C_t)$	= aktivasi \tanh dari <i>cell state</i>
z_t	= <i>update gate</i> pada waktu ke- t
\tilde{h}_t	= <i>candidate activation</i>
r_t	= <i>reset gate</i> pada waktu ke- t
n	= jumlah periode pengamatan
y_t	= nilai data aktual pada waktu ke- t
\hat{y}_t	= nilai hasil prediksi pada waktu ke- t
m_t	= estimasi momen pertama pada iterasi ke- t
β_1	= <i>first decay rate</i>
β_2	= <i>second decay rate</i>
g_t	= nilai gradien pada iterasi ke- t

v_t	= estimasi momen kedua pada iterasi ke- t
m_{t-1}	= nilai estimasi momen pertama pada iterasi sebelumnya
v_{t-1}	= nilai momen kedua pada iterasi sebelumnya
\hat{n}_t	= estimasi momen pertama yang sudah dikoreksi bias
\hat{v}_t	= estimasi momen kedua yang sudah dikoreksi bias
w_t	= bobot model pada iterasi ke- t
w_{t-1}	= bobot yang telah diperbarui
η	= <i>learning rate</i>
x'	= nilai hasil normalisasi
x_i	= nilai asli
x_{min}	= nilai minimum
x_{max}	= nilai maksimum
A, B, C	= matriks berukuran $m \times n$
$[a_{ij}], [b_{ij}]$	= notasi elemen matriks A dan B dengan elemen pada baris ke- i dan kolom ke- j
$M^{m \times n}$	= himpunan semua matriks berukuran $m \times n$
c	= bilangan skalar
A^T	= transpose dari matriks A
u	= hasil kombinasi linear dari <i>input</i> , bobot, dan bias
e	= bilangan eksponensial
σ'	= turunan fungsi sigmoid
\tanh'	= turunan fungsi <i>hyperbolic tangent</i>
\tilde{C}_t	= <i>candidate memory</i>

INTISARI

Perbandingan Metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dengan Pendekatan Univariat dan Multivariat untuk Memprediksi Harga Saham

(Studi kasus : Harga Saham BMRI Periode 2015-2024)

Amanda Riyas Utami

22106010003

Runtun waktu (*time series*) adalah urutan pengamatan yang berorientasi waktu atau kronologis pada suatu variabel yang diamati. Data ini banyak digunakan dalam analisis dan peramalan salah satunya dalam analisis harga saham. Data saham umumnya bersifat nonstasioner, fluktuatif, memiliki volatilitas tinggi, serta cenderung membentuk pola nonlinear. Kondisi ini menyebabkan asumsi metode *time series* klasik tidak terpenuhi. Sehingga diperlukan pendekatan yang lebih fleksibel dengan *deep learning*, khususnya metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) untuk memprediksi harga saham dengan pendekatan univariat dan multivariat. Data yang digunakan yaitu data saham PT Bank Mandiri Tbk (BMRI) periode 2015-2024. Tahapan penelitian meliputi *Exploratory Data Analysis* (EDA), *preprocessing*, pemodelan serta pengoptimalan arsitektur model, dengan evaluasi menggunakan *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE). Hasil penelitian menunjukkan bahwa model LSTM dan GRU dengan pendekatan univariat maupun multivariat mampu memprediksi harga saham dengan pergerakan relatif serupa dengan model GRU univariat menjadi model terbaik karena memiliki nilai error terendah dengan arsitektur terbaik *sliding window* 30, satu *hidden layer*, 128 *units*, *dropout* 0,1, *batch size* 32, dan nilai MSE 0,0012 dan MAE 0,0270. GRU memiliki sensitifitas lebih tinggi dibandingkan LSTM yang membuat ketika peramalan GRU menunjukkan penurunan harga yang lebih agresif, sedangkan LSTM menghasilkan prediksi yang lebih realistis.

Kata Kunci: *Deep Learning*, GRU, LSTM, Prediksi Harga Saham, Runtun Waktu

ABSTRACT

A Comparative Analysis of the Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) Methods Using Univariate and Multivariate Approaches for Predicting Stock Prices

(Case study : BMRI Stock Price for the 2015-2024 Period)

Amanda Riyas Utami

22106010003

A time series is a sequence of observations that are time-oriented or arranged chronologically for an observed variable. Time series data are widely used in analysis and forecasting, including stock price analysis. Stock price data are generally non-stationary, fluctuating, highly volatile, and tend to form nonlinear patterns. These characteristics cause the assumptions of classical time series methods, particularly Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), which are used to predict stock prices using univariate and multivariate approaches. The data used in this study were the stock price data of PT Bank Mandiri Tbk (BMRI) from 2015 to 2024. The research stages included Exploratory Data Analysis (EDA), preprocessing, modeling, and architecture optimization, with evaluation conducted using Mean Squared Error (MSE) and Mean Absolute Error (MAE). The results showed that both LSTM and GRU models with univariate and multivariate approaches were able to predict stock prices with movements relatively similar to the actual data. The univariate GRU model was identified as the best architecture consisting of a sliding window of 30, one hidden layer, 128 units, dropout of 0.1, batch size of 32, and MSE and MAE values of 0.0012 and 0.0270, respectively. In addition, GRU demonstrated higher sensitivity than LSTM, resulting in more aggressive predictions of price declines, while LSTM produced predictions that were more realistic.

Keywords: Deep Learning, GRU, LSTM, Stock Price Prediction, Time Series

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Runtun waktu (*time series*) adalah urutan pengamatan yang berorientasi waktu atau kronologis pada suatu variabel yang diamati (Montgomery et al., 2015). Artinya, data dikumpulkan dari waktu ke waktu dengan interval tertentu, seperti harian, mingguan, bulanan, atau tahunan.

Data *time series* dapat diolah dengan menggunakan model *time series* yang dapat mempelajari struktur, pola, dan hubungan dalam data masa lalu agar dapat digunakan untuk membuat suatu prediksi di masa yang akan datang. Hal inilah yang menyebabkan model *time series* sering digunakan dalam berbagai bidang terutama bidang ekonomi dan keuangan.

Salah satu penerapan data *time series* dalam keuangan adalah pada harga saham. Saham merupakan surat berharga yang dimiliki oleh individu maupun lembaga sebagai bukti penyertaan modal sehingga pemegangnya menjadi bagian dari pemilik perusahaan tersebut (Rosalina & Masditok, 2018). Dalam beberapa tahun terakhir, saham menjadi instrumen investasi yang semakin diminati masyarakat. Namun, harga saham memiliki karakteristik yang sangat fluktuatif dan perubahannya sulit diprediksi. Selain fluktuatif, pergerakan harga saham juga cenderung bersifat nonstasioner, menunjukkan adanya tren, serta memiliki volatilitas yang berubah-ubah (*heterokedastisitas*), sehingga pola pergerakannya tampak acak.

Pada analisis data *time series*, berbagai model telah dikembangkan, dianta-

ranya *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan *Autoregressive Integrated Moving Average* (ARIMA). Model-model tersebut merupakan fondasi dalam peramalan dengan data *time series*. Namun, sebelum model tersebut dapat digunakan, terdapat beberapa asumsi yang harus dipenuhi, seperti kestasioneran data dan error yang bersifat *white noise*, yaitu tidak berkorelasi dan memiliki varians yang konstan (Montgomery et al., 2015). Selain itu, setelah proses pemodelan, residual yang dihasilkan diharapkan berperilaku seperti *white noise* sehingga tidak terdapat autokorelasi yang tersisa. Apabila semua asumsi terpenuhi, maka model-model tersebut mampu memberikan performa prediksi yang baik. Namun pada data harga saham, asumsi-asumsi tersebut sering kali tidak terpenuhi. Pelanggaran terhadap asumsi tersebut menyebabkan model AR, MA, ARMA, dan ARIMA mengalami kesulitan dalam menghasilkan prediksi yang akurat. Oleh karena itu diperlukan pendekatan lain yang lebih fleksibel dan mampu menangkap kompleksitas dinamika harga saham.

Untuk menghadapi karakteristik data yang lebih kompleks tersebut, metode *deep learning* menjadi salah satu pendekatan yang banyak digunakan untuk membuat suatu prediksi atau peramalan. *Deep learning* adalah metode pembelajaran yang memungkinkan sistem secara otomatis mempelajari representasi atau fitur dari data mentah melalui serangkaian transformasi non-linear bertingkat (Goodfellow et al., 2016). Metode ini menggunakan jaringan saraf tiruan dengan banyak lapisan *deep neural networks* sehingga mampu mempelajari pola jangka pendek maupun panjang dalam data berurutan. Selain itu, *deep learning* juga tidak mensyaratkan asumsi-asumsi sehingga lebih fleksibel dalam mempelajari pola data.

Salah satu metode *deep learning* yang sering digunakan dalam analisis runtun waktu adalah metode *Long Short-Term Memory* (LSTM) dan *Gated Recur-*

rent Unit (GRU) yang sama-sama merupakan varian dari *Recurrent Neural Network* (RNN) yang dikembangkan untuk mengatasi masalah *vanishing gradient* serta mampu menangkap pola dependensi jangka panjang pada data sekuensial. Di dalam metode LSTM dan GRU sering kali menggunakan percobaan berbagai variabel mulai dari hanya menggunakan satu variabel seperti *Close* yang biasa disebut dengan univariat, maupun dengan banyak variabel yang bisa disebut dengan multivariat. Dalam analisis, model univariat berfokus pada analisis dan prediksi hubungan antara satu variabel prediktor dengan variabel target, sedangkan model multivariat melibatkan beberapa variabel prediktor secara simultan (Salehi et al., 2024).

Berdasarkan latar belakang tersebut, penelitian ini dilakukan untuk menguji dan membandingkan performa metode LSTM dan GRU dalam memprediksi harga saham dengan studi kasus saham BMRI pada rentang data 1 Januari 2015 - 31 Desember 2024. Data ini dipilih karena BMRI merupakan salah satu saham yang termasuk dalam indeks LQ45, IDX30, dan KOMPAS100 di Bursa Efek Indonesia (Bursa Efek Indonesia, 2025). Selain itu, BMRI memiliki tingkat likuiditas dan aktivitas perdagangan yang tinggi, sehingga data harga yang dihasilkan relatif lebih stabil dan tidak banyak mengalami gangguan akibat rendahnya likuiditas. Kondisi ini menjadikan saham BMRI sesuai untuk analisis *time series*. Penelitian ini tidak hanya berfokus pada kemampuan kedua model dalam menangkap pola historis, tetapi juga mengevaluasi tingkat akurasi prediksi melalui beberapa metrik evaluasi yang relevan. Selain itu analisis juga tidak hanya menggunakan variabel univariat saja, namun juga menggunakan variabel multivariat atau beberapa variabel untuk lebih memperjelas perbandingan antara kedua metode. Dengan memanfaatkan *hyperparameter tuning*, penelitian ini diharapkan dapat memberikan gambaran yang lebih komprehensif mengenai efektivitas kedua metode *deep learning* tersebut

dalam konteks data saham Indonesia, khususnya saham BMRI.

1.2. Rumusan Masalah

Dari uraian latar belakang yang telah dipaparkan, dapat dirumuskan permasalahan penelitian sebagai berikut:

1. Bagaimana langkah penerapan *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memprediksi harga saham menggunakan pendekatan univariat dan multivariat?
2. Bagaimana arsitektur *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) pada data saham BMRI periode 2015-2024 dengan pendekatan univariat dan multivariat?
3. Bagaimana perbandingan *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) terhadap harga saham BMRI periode 2015-2024 dengan pendekatan univariat dan multivariat berdasarkan metrik evaluasi *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE)?
4. Bagaimana hasil prediksi harga saham BMRI selanjutnya menggunakan model terbaik *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dengan pendekatan univariat dan multivariat?

1.3. Batasan Masalah

Agar penelitian ini terarah dan fokus pada tujuan yang ingin dicapai, maka ruang lingkup penelitian dibatasi pada beberapa hal berikut:

1. Objek penelitian ini adalah satu jenis saham, yaitu saham Bank Mandiri Tbk (BMRI), yang dipilih sebagai studi kasus. Data yang digunakan merupakan

data harian dari 1 Januari 2015 - 31 Desember 2024. Variabel yang digunakan adalah harga penutupan (`close`), *EMA7*, *Return* dan *Volatility*. Data diperoleh dari Yahoo Finance melalui pustaka `yfinance`.

2. Metode yang digunakan hanya mencakup dua model berbasis *Recurrent Neural Network (RNN)*, yaitu:

- *Long Short-Term Memory (LSTM)*
- *Gated Recurrent Unit (GRU)*

dengan proses pelatihan model menggunakan bahasa pemrograman *Python* di Google Colab dengan versi *Python 3.12.12* dan *runtime Graphics Processing Unit (GPU)* untuk mempercepat proses komputasi.

3. Evaluasi kinerja model dilakukan menggunakan metrik kesalahan prediksi yang umum digunakan dalam analisis deret waktu, yaitu:

- *Mean Squared Error (MSE)*
- *Mean Absolute Error (MAE)*

4. Penelitian ini berfokus pada penerapan dan perbandingan performa model, termasuk proses optimisasi melalui *hyperparameter tuning* untuk memperoleh model terbaik.

1.4. Tujuan Penelitian

Adapun tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

1. Menerapkan *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Unit*

(GRU) dengan pendekatan univariat dan multivariat dalam membangun model prediksi harga saham.

2. Mengetahui dan menganalisis arsitektur *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) berdasarkan data harga saham BMRI periode 2015-2024 dengan pendekatan univariat dan multivariat.
3. Membandingkan performa model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) terhadap harga saham BMRI periode 2015-2024 dengan pendekatan univariat dan multivariat berdasarkan metrik evaluasi *Mean Squared Error* (MSE) dan *Mean Absolute Error* (MAE).
4. Mengetahui hasil prediksi harga saham BMRI selanjutnya menggunakan model terbaik *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dengan pendekatan univariat dan multivariat.

1.5. Manfaat Penelitian

Penelitian ini diharapkan memberikan kontribusi dalam dua aspek utama, yaitu aspek teoritis dan aspek praktis.

1. Manfaat Teoritis

Secara teoritis, penelitian ini diharapkan memberikan kontribusi terhadap pengembangan ilmu pengetahuan di bidang *time series* dan *deep learning*. Penelitian ini memvalidasi serta memperluas pemahaman mengenai kemampuan model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dalam memodelkan data *time series* dengan tingkat volatilitas tinggi, seperti harga saham. Selain itu, penelitian ini juga membandingkan model LSTM dan GRU, sehingga dapat menjadi referensi ilmiah bagi peneliti selanjutnya

dalam menentukan model yang paling sesuai untuk kasus prediksi dengan data *time series*.

2. Manfaat Praktis

Dari sisi praktis, penelitian ini diharapkan dapat memberikan manfaat dalam bidang keuangan, khususnya pada analisis dan prediksi harga saham. Hasil penelitian dapat digunakan sebagai bahan pertimbangan dalam pengambilan keputusan investasi, perumusan strategi pembelian dan penjualan saham, serta pengelolaan risiko. Selain itu, penelitian ini juga dapat menjadi acuan dalam memahami pola pergerakan harga saham di pasar modal.

1.6. Tinjauan Pustaka

Pada penelitian yang dilakukan oleh Lawi et al. (2022) yang berjudul *Implementation of Long Short-Term Memory and Gated Recurrent Units on Groped Time-Series Data to Predict Stock Prices Accurately* membahas mengenai prediksi harga saham dengan metode LSTM dan GRU dengan empat arsitektur utama yang meliputi *direct model*, *downsizing model*, *tuned downsizing model*, dan *stabilized downsizing model*, yang masing-masing dirancang untuk mengolah *output* gabungan sebelum digunakan dalam proses prediksi individual tiap saham. Hasil evaluasi menunjukkan bahwa model GRU cenderung memberikan akurasi lebih tinggi dibandingkan LSTM, terutama pada arsitektur *direct model*, sementara LSTM menunjukkan kestabilan yang lebih baik melalui deviasi akurasi yang lebih kecil.

Pada penelitian yang dilakukan oleh Touzani & Douzi (2021) yang berjudul *An LSTM and GRU Based Trading Strategy Adapted to the Moroccan Market* membahas mengenai pengembangan strategi perdagangan saham yang disesuaikan dengan pasar Maroko dengan memanfaatkan dua model *deep learning* yaitu LSTM

untuk prediksi jangka pendek dan GRU untuk prediksi jangka menengah. Hasil penelitian menunjukkan bahwa strategi yang dihasilkan mampu memilih saham yang paling menguntungkan dan menghasilkan portofolio dengan kinerja yang melampaui indeks acuan pasar, sehingga menunjukkan baik LSTM maupun GRU dapat menjadi alat yang efektif dalam mendukung pengambilan keputusan transaksi saham.

Pada penelitian yang dilakukan oleh Hasanli & Dursun (2025) yang berjudul *Integrating High-Dimensional Technical Indicators into Machine Learning Models for Predicting Cryptocurrency Price Movements and Trading Performance: Evidence from Bitcoin, Ethereum, and Ripple* yang membahas mengenai model *machine learning* dan *deep learning* dengan fitur multivariat berdimensi tinggi berupa *Open, High, Low, Close Volume* (OHLCV) dan indikator teknikal untuk memprediksi arah pergerakan harga harian Bitcoin, Ethereum, dan Ripple. Hasil dari penelitian menunjukkan bahwa LSTM efektif dalam menangkap pola sekuensial, sedangkan XGBoost secara konsisten memberikan keseimbangan terbaik antara akurasi, stabilitas, dan profitabilitas.

Pada penelitian yang dilakukan oleh Perdana et al. (2025) yang berjudul Analisis Perbandingan Model GRU dan LSTM untuk Prediksi Harga Saham Bank Rakyat Indonesia membahas mengenai perbandingan performa model LSTM dan GRU dalam memprediksi harga saham Bank Rakyat Indonesia (BBRI.JK) periode Februari 2023 hingga November 2024. Hasil penelitian menunjukkan GRU secara konsisten lebih baik daripada LSTM pada seluruh metrik evaluasi, sehingga GRU dinilai lebih efektif dalam menangkap pola pergerakan harga saham yang bersifat volatil.

Pada penelitian yang dilakukan oleh Khairunisa & Hendikawati (2024) yang

berjudul *Long Short-Term Memory and Gated Recurrent Unit Modeling for Stock Price Forecasting* membahas mengenai perbandingan kinerja metode LSTM dan GRU dalam meramalkan harga penutupan saham PT Mayora Tbk periode 2013-2023. Hasil evaluasi menunjukkan bahwa GRU memberikan performa lebih baik dari LSTM.

Berdasarkan pada beberapa penelitian terdahulu yang telah diuraikan di atas, terlihat bahwa metode *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) terbukti memberikan kinerja yang baik dalam peramalan runtun waktu, khususnya data harga saham. Namun, performa kedua metode tersebut sangat bergantung pada karakteristik data serta pemilihan arsitektur model. Oleh karena itu, penelitian ini dilakukan untuk mengevaluasi kemampuan LSTM dan GRU yang telah dioptimalkan melalui *hyperparameter tuning* pada data harga penutupan satu saham dan membandingkan performa keduanya untuk menentukan model yang efektif.

1.7. Sistematika Penulisan

Sistematika pada penelitian ini yaitu:

BAB 1 PENDAHULUAN

Bab ini berisi latar belakang masalah, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, tinjauan pustaka yang relevan, serta sistematika penulisan.

BAB II DASAR TEORI

Bab ini memuat teori-teori yang mendasari penelitian, meliputi konsep dasar deret waktu (*time series*), peramalan, normalisasi, denormalisasi, *sliding window*, *deep learning*, arsitektur *Long Short-Term Memory (LSTM)*, *Gated Recurrent Unit (GRU)*, metrik evaluasi, *hyperparameter tuning*, fungsi aktivasi, dan saham.

BAB III METODE PENELITIAN

Bab ini menjelaskan metode penelitian yang digunakan, mencakup pendekatan penelitian, data, metode pengolahan data, dan *Flowchart* penelitian.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil penerapan model LSTM dan GRU terhadap data harga saham, menampilkan hasil penelitian dan pengujian model, perbandingan performa berdasarkan metrik evaluasi, serta interpretasi hasil yang diperoleh.

BAB V PENUTUP

Bab ini berisi kesimpulan yang diperoleh dari hasil penelitian serta saran untuk penelitian selanjutnya.

BAB V

PENUTUP

5.1. Kesimpulan

Dengan demikian kesimpulan yang dapat diambil berdasarkan hasil penelitian ini yaitu:

1. Penerapan *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) dengan pendekatan univariat dan multivariat diawali dengan pengumpulan data, kemudian dilanjutkan dengan *Exploratory Data Analysis* (EDA) untuk memahami karakteristik data. Setelah itu dilakukan *preprocessing* meliputi penambahan fitur EMA7, *Return*, dan *Volatility* untuk pendekatan multivariat, sedangkan untuk pendekatan univariat tidak ada penambahan fitur sama sekali karena hanya menggunakan variabel *Close*. Selanjutnya dilakukan pembagian data latih dan data uji dengan proporsi 80:20 kemudian dilakukan normalisasi, pembentukan *sliding window*, dan yang terakhir pembagian data latih yang dengan proporsi 80% untuk data latih dan 20% untuk data validasi. Setelah itu model LSTM dan GRU dibangun, dilatih, dan dievaluasi untuk memperoleh kombinasi arsitektur terbaik. Model kemudian dilatih kembali menggunakan arsitektur terbaik sebelum dilakukan tahap akhir berupa peramalan untuk beberapa hari ke depan.
2. Berdasarkan hasil optimisasi arsitektur menggunakan metode *Grid Search*, di mana setiap kombinasi parameter diuji untuk memperoleh performa terbaik baik pada pendekatan univariat maupun multivariat. Pada model univariat,

kedua model sama-sama mencapai nilai terbaik pada *sliding window* 30 dengan satu *hidden layer*. Parameter terbaik untuk LSTM univariat adalah 64 unit, 0,1 *dropout*, dan *batch size* 32. Sementara untuk pendekatan univariat pada GRU parameter terbaiknya ketika menggunakan 128 unit, *dropout* 0,1, dan *batch size* 32. Sedangkan pada pendekatan multivariat, kedua model sama-sama mencapai nilai terbaik pada *sliding window* 60 dengan satu *hidden layer*. Parameter terbaik model LSTM multivariat adalah 64 unit, *dropout* 0,1, dan *batch size* 64. Untuk yang GRU dengan pendekatan multivariat nilai parameter terbaiknya adalah 128 unit, *dropout* 0,1, dan *batch size* 32.

3. Berdasarkan metrik evaluasi MSE dan MAE, baik pada pendekatan univariat maupun multivariat, GRU menunjukkan kinerja lebih baik dibandingkan LSTM karena menghasilkan nilai kesalahan yang lebih rendah serta waktu pelatihan yang lebih singkat. Pada pendekatan univariat, GRU memperoleh nilai MSE sebesar 0,0012 (normalisasi) dan 12.339,3607 (skala asli), serta MAE sebesar 0,0270 (normalisasi) dan 86,1386 (skala asli) dengan waktu pelatihan 18,80 detik. Pada pendekatan multivariat, GRU menghasilkan nilai MSE 0,0032 (normalisasi) dan 32.521,9076 (skala asli) dengan nilai MAE 0,0480 (normalisasi) dan 153,2345 (skala asli) dengan waktu pelatihan 10,86 detik. Apabila GRU univariat dan GRU multivariat dibandingkan, maka GRU univariat menjadi model terbaik karena memiliki nilai metrik evaluasi baik MSE maupun MAE lebih rendah daripada GRU Multivariat.
4. Secara keseluruhan, baik model LSTM maupun GRU dengan pendekatan univariat dan multivariat mampu memprediksi harga saham BMRI. Model ini juga mampu membuat prediksi harga saham BMRI 7 hari ke depan. Pola pergerakan kedua model relatif serupa namun GRU memiliki nilai *error* yang

lebih rendah daripada LSTM. GRU memiliki sensitifitas yang lebih tinggi dibandingkan LSTM sehingga ketika melakukan peramalan, penurunan harga saham pada model GRU lebih agresif. Sedangkan LSTM yang memiliki hasil peramalan yang relatif lebih stabil karena dinilai lebih realistis sebab GRU memprediksi penurunan harga saham hingga hampir 1.400 hanya dalam periode tersebut.

5.2. Saran

Berdasarkan penelitian yang telah dilakukan, terdapat beberapa saran yang dapat diterapkan untuk penelitian selanjutnya.

1. Menguji model pada berbagai dataset harga saham yang berbeda untuk mengevaluasi kemampuan model terhadap karakteristik data harga saham yang beragam.
 2. Menambahkan analisis sentimen pasar sebagai variabel tambahan agar model mampu merepresentasikan kondisi pasar secara lebih komprehensif.
 3. Membandingkan pengaruh panjang EMA pada pendekatan multivariat untuk mengetahui hubungan panjang EMA dengan hasil prediksi harga saham.
 4. Mengeksplorasi variabel lain yang lebih signifikan dan optimal untuk diterapkan pada pendekatan multivariat sehingga dapat meningkatkan akurasi serta menghasilkan prediksi harga saham yang lebih optimal.
3. Hasil prediksi harga pada penelitian ini dibatasi hingga 7 hari ke depan karena penggunaan model rekursif pada penelitian ini berpotensi mengakumulasi kesalahan seiring bertambahnya panjang prediksi. Oleh karena itu, peneliti selanjutnya diharapkan dapat membuat model yang dapat membuat prediksi

lebih panjang dengan tingkat kesalahan yang lebih stabil.

4. Menggunakan data *real-time* agar proses peramalan tidak bergantung pada data hasil prediksi sebelumnya, melainkan menggunakan data harga aktual terbaru.
5. Mengimplementasikan model ke dalam bentuk *website* atau aplikasi sehingga model dapat dimanfaatkan secara lebih luas, termasuk oleh pengguna non-teknis.

DAFTAR PUSTAKA

- Ahmad, N., Raheem Ahmed, R., Vveinhardt, J., & Streimikiene, D. (2016). Empirical analysis of stock returns and volatility: evidence from asian stock markets. *Technological and Economic Development of Economy*, 22(6):808–829.
- Anton, H., Rorres, C., & Kaul, A. (2019). *Elementary Linear Algebra*. Wiley, ISBN: 9781119282365, <https://books.google.co.id/books?id=SkiYDwAAQBAJ>.
- Bartz, E., Bartz-Beielstein, T., Zaefferer, M., & Mersmann, O. (2023). *Hyperparameter tuning for machine and deep learning with R: A practical guide*. Springer Nature.
- Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2022). Prediksi harga saham syariah menggunakan algoritma long short-term memory (lstm). *Jurnal Nasional Teknologi dan Sistem Informasi*, 8(3):164–172.
- Buff ML (2025). Common deep learning algorithms. <https://buffml.com/common-deep-learning-algorithms/>. Diakses 20 November 2025.
- Bursa Efek Indonesia (2025). Fact sheet perusahaan lq45. <https://www.idx.co.id/id/data-pasar/laporan-statistik/fact-sheet-perusahaan-lq45>. Diakses: 15 Mei 2026.
- Büyükşahin, Ü. Ç. & Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new arima-ann hybrid method and empirical mode decomposition. *Neurocomputing*, 361:151–163.

- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- Delalleau, O. & Bengio, Y. (2011). Shallow vs. deep sum-product networks. *Advances in neural information processing systems*, 24.
- Eduardus Tandelilin, M. & CWM, C. (2017). *Pasar modal: Manajemen portofolio dan investasi*. Pt Kanisius.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Adaptive Computation and Machine Learning series. MIT Press, ISBN: 9780262337373, <https://books.google.co.id/books?id=omivDQAAQBAJ>.
- Gujarati, D. N. & Porter, D. C. (2009). *Basic Econometrics*. McGraw-Hill/Irwin, New York, 5th edition.
- Gupta, A. & Mishra, R. (2024). A comprehensive study of stock market volatility: Types, determinants, and measurement methods. *International Journal For Multidisciplinary Research*, 6(6):30054.
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques*. The Morgan Kaufmann Series in Data Management Systems. Morgan Kaufmann, ISBN: 9780123814807, <https://books.google.co.id/books?id=pQws07tdpjoC>.

- Hasanli, R. & Dursun, M. (2025). Integrating high-dimensional technical indicators into machine learning models for predicting cryptocurrency price movements and trading performance: Evidence from bitcoin, ethereum, and ripple. *FinTech*, 4(4):77.
- Hochreiter, S. & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8):1735–1780.
- Horn, R. A. & Johnson, C. R. (2012). *Matrix analysis*. Cambridge university press.
- Hota, H., Handa, R., & Shrivastava, A. K. (2017). Time series data prediction using sliding window based rbf neural network. *International Journal of Computational Intelligence Research*, 13(5):1145–1156.
- Hyndman, R. & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. OTexts, ISBN: 9780987507136, <https://books.google.co.id/books?id=gZB-zgEACAAJ>.
- Keuangan, O. J. (2023). *Buku Saku Pasar Modal*. OJK, Jakarta, <https://www.ojk.go.id/id/berita-dan-kegiatan/publikasi/Documents/Pages/Buku-Saku-Pasar-Modal/BUKU%20SAKU%20PSR%20MODAL%20OJK%202023.pdf>.
- Khairunisa, N. K. & Hendikawati, P. (2024). Long short-term memory and gated recurrent unit modeling for stock price forecasting. *Jurnal Matematika, Statistika dan Komputasi*, 21(1):321–333.
- Kontopoulou, V. I., Panagopoulos, A. D., Kakkos, I., & Matsopoulos, G. K. (2023). A review of arima vs. machine learning approaches for time series forecasting in data driven networks. *Future Internet*, 15(8):255.

- Lawi, A., Mesra, H., & Amir, S. (2022). Implementation of long short-term memory and gated recurrent units on grouped time-series data to predict stock prices accurately. *Journal of Big Data*, 9(1):89.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9):517.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting*. John Wiley & Sons.
- Mufid, M. N. (2020). Faktor-faktor yang mempengaruhi return saham perusahaan farmasi yang terdaftar di bursa efek indonesia. *Jurnal Ilmiah Akuntansi Fakultas Ekonomi. P-ISSN*, pages 2502–3020.
- Otoritas Jasa Keuangan (2020). Siaran pers: Stabilitas sektor jasa keuangan tetap terjaga di tengah merebaknya wabah virus corona. <https://www.ojk.go.id/id/id/berita-dan-kegiatan/siaran-pers/Pages/Siaran-Pers-Stabilitas-Sektor-Jasa-Keuangan-Tetap-Terjaga-di-Tengah-Merebaknya-Wabah-Virus-Corona.aspx>. Accessed: 2026-01-14.
- Owen, L. (2022). *Hyperparameter Tuning with Python: Boost your machine learning model's performance via hyperparameter tuning*. Packt Publishing Ltd.
- Peixeiro, M. (2022). *Time series forecasting in python*. Simon and Schuster.

- Perdana, Y., Hanum, N. R., Rabiula, A., & Anzari, Y. (2025). Analisis perbandingan model gru dan lstm untuk prediksi harga saham bank rakyat indonesia: Deep learning, gru (gated recurrent unit), lstm (long short-term memory), stock price prediction. *JURNAL AKADEMIKA*, 17(2):54–60.
- Permana, I. & Salisah, F. N. S. (2022). Pengaruh normalisasi data terhadap performa hasil klasifikasi algoritma backpropagation: The effect of data normalization on the performance of the classification results of the backpropagation algorithm. *Indonesian Journal of Informatic Research and Software Engineering (IJIRSE)*, 2(1):67–72.
- Quang, P. D., Duy, N. H., Khoai, P. Q., & Duong, B. D. (2025). Integrating moving average indicators with long short-term memory model in bitcoin price forecasting. *Journal of Applied Data Sciences*, 6(3):1850–1864.
- Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 35(23):17095–17112.
- Rolangon, A., Weku, A., & Sandag, G. A. (2023). Perbandingan algoritma lstm untuk analisis sentimen pengguna twitter terhadap layanan rumah sakit saat pandemi covid-19. *TeIKa*, 13(01):31–40.
- Rosalina, L. & Masditok, T. (2018). Pengaruh return on asset (roa), return on equity (roe), debt to equity ratio (der) dan earning per share (eps) terhadap harga saham perusahaan sub sektor transportasi di bursa efek indonesia periode 2012-2016. *JASa (Jurnal Akuntansi, Audit Dan Sistem Informasi Akuntansi)*, 2(4):1–15.
- Salehi, S., Kavagic, M., Bonakdari, H., & Begnoche, L. (2024). Comparative study of univariate and multivariate strategy for short-term forecasting of heat de-

mand density: Exploring single and hybrid deep learning models. *Energy and AI*, 16:100343.

Sianturi, T. B., Cholissodin, I., & Yudistira, N. (2023). Penerapan algoritma long short-term memory (lstm) berbasis multi fungsi aktivasi terbobot dalam prediksi harga ethereum. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7(3):1101–1107.

Situmorang, S. H., Muda, I., Doli, M., & Fadli, F. S. (2010). *Analisis data untuk riset manajemen dan bisnis*. USUpres.

Stock, J. & Watson, M. (2019). *Introduction to Econometrics, Global Edition*. Pearson Education, ISBN: 9781292264523, <https://books.google.co.id/books?id=7b4oEAAAQBAJ>.

Szandała, T. (2020). Review and comparison of commonly used activation functions for deep neural networks. In *Bio-inspired neurocomputing*, pages 203–224. Springer.

Touzani, Y. & Douzi, K. (2021). An lstm and gru based trading strategy adapted to the moroccan market. *Journal of big Data*, 8(1):126.