

**IMPLEMENTASI PREDIKSI HARGA SAHAM
MENGUNAKAN MODEL *LONG SHORT-TERM MEMORY*
(LSTM) dan *GATED RECURRENT UNIT* (GRU) PADA
PERUSAHAAN SEKTOR PROPERTI**

LAPORAN TUGAS AKHIR

Laporan ini disusun untuk memenuhi salah satu syarat memperoleh Gelar Sarjana Strata 1 (S1) pada Program Studi Teknik Informatika Fakultas Teknologi Industri Universitas Islam Sultan Agung Semarang



Disusun Oleh :

Ananta Nely Mulyani

NIM 32602100026

**FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG
SEMARANG**

2025

FINAL PROJECT

**IMPLEMENTATION OF STOCK PRICE PREDICTION USING LONG
SHORT-TERM MEMORY (LSTM) AND GATED RECURRENT UNIT
(GRU) MODELS IN PROPERTY SECTOR COMPANIES**

*Proposed to complete the requirement to obtain a bachelor's degree (S1)
at Informatic Engineering Department of Industrial Technology Faculty*

Sultan Agung Islamic University



Arranged by :

NAILATUL FITRIANI A.J

32602100005

**MAJORING OF INFORMATIC ENGINEERING
FACULTY OF INDUSTRIAL TECHNOLOGY
SULTAN AGUNG ISLAMIC UNIVERSITY**

2025

LEMBAR PENGESAHAN
TUGAS AKHIR

IMPLEMENTASI PREDIKSI HARGA SAHAM MENGGUNAKAN
MODEL *LONG SHORT-TERM MEMORY*(LSTM) DAN *GATED
RECURRENT UNIT* (GRU) PADA PERUSAHAAN SEKTOR PROPERTI

ANANTA NELY MULYANI
NIM 32602100026

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal : 25 Februari 2025

TIM PENGUJI UJIAN SARJANA :

Moch. Taufik, S.T.,M.IT

NIDN. 0622037502

(Ketua Penguji)

3 Maret 2025

Badie'ah, S.T.,M.Kom

NIDN. 0619018701

(Anggota Penguji)

3 Maret 2025

Ghufron, S.T.,M.Kom

NIDN. 0602079005

(Pembimbing)

3 Maret 2025

Semarang, 3 Maret 2025

Mengetahui,

Kaprodi Teknik Informatika
Universitas Islam Sultan Agung

Moch. Taufik, S.T.,M.IT

NIDN. 0622037502

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan dibawah ini :

Nama : Ananta Nely Mulyani

NIM : 32602100026

Judul Tugas Akhir : Implementasi Prediksi harga Saham Menggunakan Model *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)* pada Perusahaan Sektor Properti.

Dengan bahwa ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 4 Maret 2025

Yang Menyatakan,



Ananta Nely Mulyani

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan dibawah ini :

Nama : Ananta Nely Mulyani

NIM : 32602100026

Program Studi : Teknik Informatika

Fakultas : Teknologi industri

Alamat Asal : Semarang

Dengan ini menyatakan Karya Ilmiah berupa Tugas akhir dengan Judul : Implementasi Prediksi harga Saham Menggunakan Model *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) pada Perusahaan Sektor Properti.

Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak bebas Royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dan pangkalan data dan dipublikasikan diinternet dan media lain untuk kepentingan akademis selama tetap menyantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan agung.

Semarang, 4 Maret 2025.



METERAI
TEMPEL
3A4F4AKX255927697

Ananta Nely Mulyani

KATA PENGANTAR

Puji syukur penulis panjatkan kepada ALLAH SWT, yang telah memberikan rahmat, taufik serta hidayah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul “Implementasi Prediksi Harga Saham Menggunakan Model LSTM dan GRU Pada Perusahaan Sektor Properti.” ini dengan baik. Dengan penuh rasa hormat, penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Rektor UNISSULA Bapak Prof. Dr. H. Gunarto, SH., M.Hum yang mengizinkan penulis menimba ilmu di kampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Ir. Hj. Novi Marlyana, S.T., M.T
3. Dosen pembimbing penulis Bapak Ghufron, ST, M.kom yang telah memberikan arahan, bimbingan, dan saran yang berarti dalam penyelesaian tugas akhir ini.
4. Seluruh dosen Program Studi Teknik Informatika, Fakultas Teknologi Industri UNISSULA yang telah memberikan ilmunya kepada penulis.
5. Orang tua penulis, Bapak Mulyono dan Ibu Siti Hanifah yang selalu memberikan segala doa, dukungan, dan motivasi dengan penuh limpahan kasih sayang sehingga penulis dapat menyelesaikan tugas akhir ini dengan baik.
6. Kakak penulis beserta suami dan kedua anaknya, Rikyana Frida, Eko Sulistyanto, Assyifa Naira dan Almahyra Inara, yang selalu memberikan dukungan moril sehingga penulis mampu menyelesaikan studinya.
7. Untuk Diri Sendiri yang tidak pernah menyerah dan berhenti mencoba sesulit apapun rintangan kuliah dan selama proses penyusunan laporan ini.
8. Rekan seperjuangan, yang telah memberikan dukungan moral, motivasi, serta semangat dalam proses penyelesaian tugas akhir ini.
9. Dan kepada seluruh pihak yang tidak dapat saya sebutkan satu persatu.

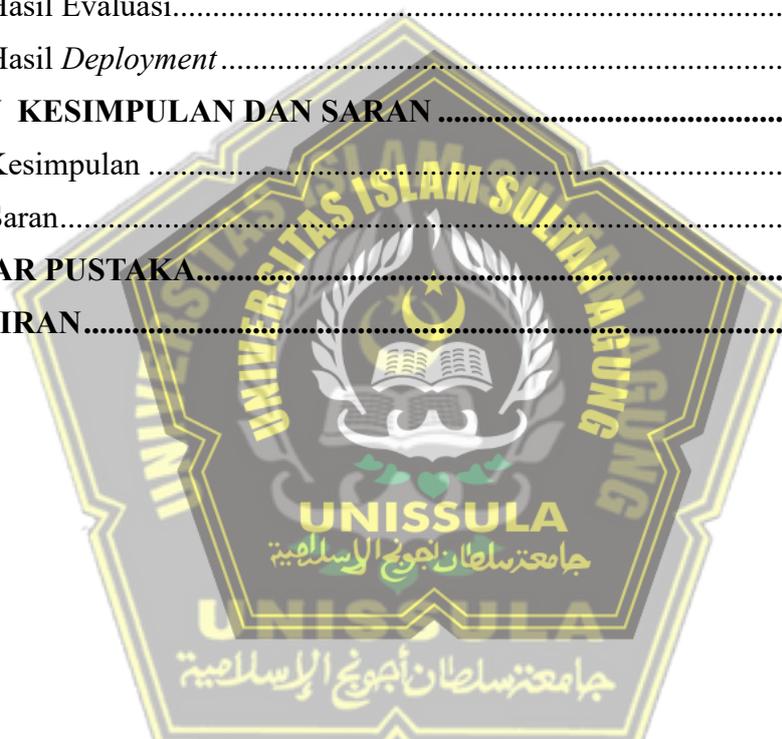
Semarang, 19 Januari 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN TUGAS AKHIR	i
KATA PENGANTAR	iv
DAFTAR ISI	v
DAFTAR TABEL	vii
DAFTAR GAMBAR	viii
ABSTRAK	ix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	2
1.3 Pembatasan Masalah	3
1.4 Tujuan Penelitian.....	3
1.5 Manfaat Penelitian	3
1.6 Sistematika Penulisan	4
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	5
2.1 Tinjauan Pustaka	5
2.2 Dasar Teori	7
2.2.1 Harga Saham dan Pergerakannya.....	7
2.2.2 <i>LONG SHORT TERM MEMORY</i> (LSTM)	8
2.2.3 <i>GATED RECURRENT UNIT</i> (GRU).....	12
BAB III METODOLOGI PENELITIAN	14
3.1 Pengumpulan data	16
3.2 <i>Data Selection</i>	16
3.3 <i>Preprocessing Data</i>	16
3.3.1 <i>Data Cleaning</i>	16
3.3.2 Normalisasi Data.....	16
3.3.3 Pembagian Data	17
3.4 Pembuatan Model LSTM dan GRU.....	17
3.5 Evaluasi Model.....	19

3.6	<i>Software yang digunakan</i>	20
BAB IV HASIL DAN ANALISIS PENELITIAN.....		22
4.1	Hasil Penelitian	22
4.1.1	Pengumpulan data	22
4.1.2	<i>Data Selection</i>	23
4.1.3	<i>Preprocessing Data</i>	24
4.1.4	Pembuatan Model LSTM dan GRU.....	26
4.1.5	Evaluasi Model.....	29
4.2	Hasil Evaluasi.....	30
4.3	Hasil <i>Deployment</i>	32
BAB V KESIMPULAN DAN SARAN		37
6.1	Kesimpulan	37
5.2	Saran.....	37
DAFTAR PUSTAKA.....		38
LAMPIRAN.....		41



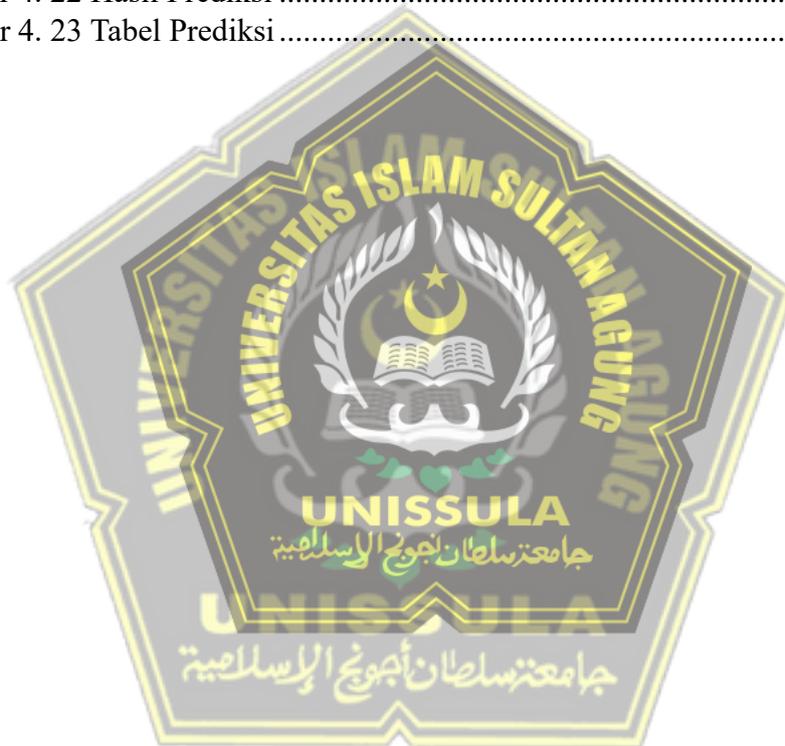
DAFTAR TABEL

Tabel 1. 1 Sistematika Penulisan.....	4
Tabel 4. 1 Dataset PT. Pakuwon Jati Tbk	22
Tabel 4. 2 Dataset PT. Agung Podomoro Land Tbk	22
Tabel 4. 3 Dataset PT. Ciputra Development Tbk	22
Tabel 4. 4 Hasil Missing Value	23
Tabel 4. 5 Hasil Duplicate Data	24
Tabel 4. 6 Data Splitting	25
Tabel 4. 7 Arsitektur LSTM	26
Tabel 4. 8 hyperparameter LSTM	26
Tabel 4. 9 Arsitektur GRU	28
Tabel 4. 10 Hyperparameter GRU	28
Tabel 4. 11 Hasil Evaluasi	30
Tabel 4. 12 Hasil RMSE	32



DAFTAR GAMBAR

Gambar 2. 1 Arsitektur LSTM	9
Gambar 2. 2 Arsitektur GRU	13
Gambar 3. 1 Flowchart Penelitian.....	15
Gambar 3. 2 Flowchart Model	18
Gambar 4. 17 Halaman Awal	33
Gambar 4. 18 Stock Price Data	33
Gambar 4. 19 Stock Price Visualization	34
Gambar 4. 20 Pemilihan Model	34
Gambar 4. 21 Pemilihan Jangka Waktu	35
Gambar 4. 22 Hasil Prediksi	35
Gambar 4. 23 Tabel Prediksi	36



ABSTRAK

Perkembangan teknologi informasi yang semakin maju memberikan dampak yang cukup signifikan salah satunya yaitu pasar saham. Pasar saham dianggap memiliki peranan yang cukup fundamental dalam bidang perekonomian di sebuah negara tentunya di Indonesia. Akan tetapi dalam proses transaksi ini sering kali memberikan resiko yang cukup tinggi karena pergerakan fluktuasi harga saham yang sulit ditebak oleh investor. Hal ini yang menjadikan para investor memiliki keraguan dalam proses jual beli saham. Hal ini lah yang mendasari penelitian ini untuk menggunakan *machine learning* dalam memprediksi harga saham. Metode yang digunakan yaitu LSTM dan GRU yang dimana kedua metode ini digunakan untuk mengolah data yang bersifat *time series*. Data yang digunakan ini berasal dari perusahaan sektor properti yang terdaftar dalam BEI yang diambil dari yahoo finance. Terdapat 3 perusahaan yang digunakan yaitu PT. Pakuwon Jati Tbk, PT. Agung Podomoro Land Tbk dan PT. Ciputra Development Tbk. Dari dataset yang sudah disiapkan dibagi menjadi 80% untuk data pelatihan dan 20% untuk data pengujian model. Dari proses pengolahan ini akan menggunakan RMSE untuk mengukur akurasi dari hasil prediksi. Dimana skor RMSE yang semakin kecil maka semakin baik juga model yang digunakan. Dalam penelitian ini metode GRU lebih unggul dibandingkan dengan model LSTM karena GRU memiliki skor RMSE yang lebih kecil daripada LSTM di ketiga perusahaan.

Kata Kunci: Prediksi saham, LSTM, GRU, *Machine learning*, RMSE

ABSTRACT

The development of increasingly advanced information technology has a significant impact, one of which is the stock market. The stock market is considered to have a crucial role in the economy of a country, of course in Indonesia. However, in this transaction process, it often provides a fairly high risk because the movement of stock price fluctuations is difficult for investors to predict. This makes investors have doubts in the process of buying and selling shares. This is the basis for this study to use machine learning in predicting stock prices. The methods used are LSTM and GRU, where both methods are used to process time series data. The data used comes from property sector companies listed on the IDX which are taken from Yahoo Finance. There are 3 companies used, namely PT. Pakuwon Jati Tbk, PT. Agung Podomoro Land Tbk and PT. Ciputra Development Tbk. From the dataset that has been prepared, it is divided into 80% for training data and 20% for model testing data. From this processing process, RMSE will be used to measure the accuracy of the prediction results. Where the smaller the RMSE score, the better the model used. In this study, the GRU method is superior to the LSTM model because GRU has a smaller RMSE score than LSTM in all three companies.

Keywords: Stock prediction, LSTM, GRU, Machine learning, RMSE

BAB I

PENDAHULUAN

1.1 Latar Belakang

Transformasi infrastruktur digital memberikan kontribusi besar terhadap banyak sektor, termasuk pasar saham. Pasar saham dianggap sebagai salah satu faktor terpenting terhadap stabilitas ekonomi negara. Pasar saham mencerminkan kesehatan dan stabilitas dunia bisnis maupun perekonomian itu sendiri. Berinvestasi di pasar saham memang dapat memberikan profit yang signifikan, namun juga memiliki konsekuensi risiko yang patut diperhitungkan karena fluktuasi harga pasar saham yang tidak dapat diprediksi. Hal tersebut menyebabkan kemampuan untuk memprediksi tren harga pasar saham menjadi sangat diperlukan untuk para penanam modal dan pihak yang terlibat di pasar modal. Kurs saham yang sulit ditebak pergerakan arah kelajuannya membuat para praktisi memiliki pandangan yang cukup beragam. Tak heran jika kondisi ini membuat para investor merasa ragu untuk melakukan pembelian, penjualan dan mempertahankan saham. Prediksi saham merupakan aspek krusial di Pasar ekuitas dan bursa prediksi tren harga saham yang cukup bervariasi dengan pengaruh waktu dan informasi historis. Analisis ini akan diterapkan untuk meramalkan harga nilai di masa yang akan datang dari harga saham suatu perusahaan atau instrument investasi lainnya yang diperdagangkan di pasar modal (Aldi & Ana, 2021). Prediksi harga saham biasanya dapat dilakukan dengan pertimbangan beberapa faktor seperti faktor teknikal, fundamental dan sentiment yang dimana dari faktor-faktor yang disebutkan itu menjadi faktor utama dalam proses prediksi harga saham (Julian & Pribadi, 2021a).

Industri properti di Indonesia memegang peranan yang cukup krusial dalam mendorong pertumbuhan ekonomi nasional. Perkembangannya yang pesat dapat memengaruhi berbagai sektor lain, seperti material bangunan, logistik, jasa, hingga sektor keuangan dan perbankan melalui layanan KPR (Kredit Pemilikan Rumah). Dampak ini kemudian berkontribusi pada terciptanya lapangan kerja dan mendorong pertumbuhan ekonomi negara (Sumolang Jannet Rossemia dkk., 2021). Dengan banyaknya perusahaan properti yang terdaftar

dalam Bursa Efek Indonesia (BEI), analisis prediksi harga saham di sektor ini menjadi sangat penting.

Dalam aktivitas jual beli saham, terdapat berbagai metode dan cara untuk melakukan prediksi. Salah satu pendekatan yang banyak digunakan adalah metode berbasis kecerdasan buatan, khususnya *machine learning*. *Machine learning* merupakan cabang dari AI yang dirancang untuk meningkatkan kemampuan atau performa sistem dalam mempelajari pola data, sehingga dapat membantu memprediksi pergerakan harga saham dengan lebih akurat (Julian & Pribadi, 2021a). *Long Short Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)* adalah satu dari sekian model yang bisa diterapkan dalam memprediksi pergerakan harga saham (Yulisa dkk., 2023).

Untuk menentukan model yang sesuai memerlukan alat ukur untuk mendeteksi akurasi nilai prediksi, oleh karena itu pada penelitian ini menggunakan metrik evaluasi berupa RMSE (*Root Mean Square Error*) yang umum digunakan untuk menganalisis sejauh mana kesalahan prediksi dari suatu model terhadap garis regresi linier. RMSE dipilih karena mudah diimplementasikan dan banyak digunakan dalam penelitian harga saham. Pada penelitian ini akan menerapkan dua model pengembangan dari RNN, yaitu LSTM dan GRU yang menggunakan data tren harga saham PT Agung Podomoro Land Tbk (APLN), PT Pakuwon Jati Tbk (PWON), dan PT Ciputra Development Tbk (CTRA) sehingga hasil dari penelitian yang diperoleh akan menentukan metode terbaik didasarkan pada tingkat kesalahan yang dapat dilihat dari hasil RMSE dari kedua metode tersebut (Aryati dkk., 2024a).

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah dituliskan, rumusan masalah dalam penelitian ini adalah :

1. Implementasi model LSTM dan GRU dalam memprediksi harga saham perusahaan sektor properti.
2. Tingkat akurasi prediksi yang dihasilkan oleh metode LSTM dan GRU dalam memprediksi harga saham perusahaan sektor properti.

3. Perbandingan model mana yang lebih unggul dalam memprediksi harga saham diantara LSTM atau GRU.

1.3 Pembatasan Masalah

Untuk menjaga fokus dan ruang lingkup penelitian, terdapat beberapa Batasan yang ditetapkan, yaitu :

1. Penelitian ini melakukan pemfokusan pada perusahaan sektor properti yang tercatat di Bursa Efek Indonesia, yaitu PT Agung Podomoro Land Tbk (APLN) , PT Pakuwon Jati Tbk (PWON), dan PT Ciputra Development Tbk (CTRA).
2. Data yang akan digunakan dalam penelitian ini adalah data harga saham harian dari periode tertentu yang diambil dari sumber terpercaya seperti yahoo finance.
3. Model yang akan dibandingkan dalam penelitian ini hanya mencakup LSTM dan GRU tanpa melibatkan model lain.

1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Mengimplementasikan kinerja model LSTM dalam meramalkan harga saham pada perusahaan sektor properti.
2. Mengimplementasikan kinerja model GRU dalam memprediksi harga saham pada perusahaan sektor properti.
3. Membandingkan kinerja model LSTM dan GRU untuk menentukan model yang lebih akurat dalam prediksi harga saham.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut :

1. Dapat mempermudah para investor dan pelaku pasar modal untuk memprediksi harga saham secara lebih akurat, khususnya di sektor properti, sehingga bisa membantu dalam pengambilan Keputusan investasi.
2. Penelitian ini diharapkan dapat menambah referensi dalam literatur tentang penggunaan model *deep learning*, khususnya LSTM dan GRU dalam prediksi harga saham.

1.6 Sistematika Penulisan

Struktur penulisan yang akan diterapkan dalam pembuatan laporan tugas akhir adalah sebagai berikut :

Tabel 1. 1 Sistematika Penulisan

BAB I	:	PENDAHULUAN
		Pada BAB I menjelaskan tentang latar belakang, pemilihan judul, rumusan masalah, Batasan masalah, tujuan penelitian, metodologi penelitian dan sistematika penelitian
BAB II		TINJAUAN PUSTAKA DAN DASAR TEORI
		Pada BAB II memuat tentang penelitian terdahulu dan landasan teori yang berkaitan untuk membantu memahami konsep algoritma LSTM, GRU dan pasar saham untuk melengkapi penelitian ini.
BAB III		METODE PENELITIAN
		Pada BAB III menjelaskan proses penelitian yang dimulai dari pengumpulan data hingga evaluasi hasil prediksi.
BAB IV		HASIL DAN ANALISIS PENELITIAN
		Pada BAB IV berisi tentang pemaparan hasil penelitian yang dimulai dari pembuatan sistem sampai dengan proses deployment.
BAB V		KESIMPULAN DAN SARAN
		Pada BAB V merangkum keseluruhan proses penelitian dari awal sampai akhir.

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Pada penelitian sebelumnya yang menggunakan metode LSTM untuk memperkirakan harga saham pada bank BRI menghasilkan nilai akurasi yang tinggi dengan hasil skor RMSE 227,47 sehingga dinilai metode ini cukup berhasil untuk melakukan prediksi. Dalam penelitian ini menggunakan data sebanyak 2551 dimana 2211 data untuk training dan 340 untuk testing. Selain itu juga menggunakan *epoch* yang bervariasi sehingga menghasilkan skor RMSE yang cukup variatif (Karno, 2020).

Pada penelitian yang lain yaitu dengan membandingkan metode LSTM dan SVR dalam prediksi harga saham dengan memperhatikan nilai MSE yang memberikan hasil dimana LSTM mampu memberikan prediksi harga saham dengan efektivitas yang unggul hal ini dibuktikan dengan nilai *error* yang kecil. Akan tetapi membutuhkan waktu pemrosesan yang lebih panjang jika dibandingkan dengan SVR dengan angka tingkat kesalahan yang lebih tinggi dan membutuhkan waktu yang lebih singkat dari LSTM. Hal tersebut yang memberikan pandangan bahwa LSTM dipercaya dapat lebih mampu untuk menangani dependensi dalam jangka waktu yang lebih panjang dan memberikan prediksi harga saham yang lebih tepat (Arfan & ETP, 2020).

Penelitian sebelumnya tentang penggunaan metode GRU dalam memperkirakan nilai harga saham perusahaan Coca-Cola dengan tren harga penutupan menunjukkan hasil yang baik. Penelitian ini menggunakan *window-width* 3, jumlah *neuron* 64, *batch size* 32, dan *epoch* sebanyak 30, dengan rasio data latih dan uji 80:20. Model diintegrasikan menggunakan *optimizer* Adam, *loss function mean squared error* (MSE), dan nilai evaluasi menggunakan *mean absolute error* (MAE). Hasilnya, model mencapai nilai MAE sebesar 0,42, RMSE 0,64, dan MSE 0,40 (Silalahi & Muljono, 2024).

Penelitian selanjutnya yang meneliti tentang prediksi harga saham pada sektor farmasi juga pernah dilakukan dengan menggunakan metode LSTM yang dimana konteks permasalahan penelitian ini adalah pergerakan nilai

saham yang didasarkan oleh parameter internal dan eksternal yang dimana pada tahun tersebut terdapat dampak pandemi *Covid-19* yang tidak bisa untuk dihindari. Data yang diambil dari situs Yahoo Finance ini diproses dengan model LSTM yang menggunakan parameter eksperimen berupa *hidden layer*, *units*, *epoch* dan *batch size* dengan hasil penelitian menunjukkan bahwa nilai RMSE memiliki rata-rata sebesar 27.310(Kwanda dkk., 2024).

Perkiraan dengan menerapkan algoritma GRU juga pernah dilakukan pada data *Cargo Service Center Tangerang City* yang digunakan dalam memperkirakan permintaan kargo pada jangka waktu bulan Januari 2016 sampai dengan bulan September 2019. Dari hasil percobaan, memberikan penjelasan bahwa performa model GRU mampu dalam memperkirakan permintaan kargo dengan model penentuan menggunakan *hyperparameter* dan menghasilkan skor RMSE terbaik sebesar 247.3952. Berdasarkan percobaan-percobaan yang sudah disebutkan menjadikan dasar dalam penelitian ini untuk memperkirakan tren harga saham dengan model data time series akan memberikan hasil yang baik jika menggunakan algoritma GRU, karena algoritma GRU memiliki *performance* yang cukup baik yaitu dengan menghasilkan nilai *error* yang cukup rendah sebagaimana yang dijelaskan dari percobaan yang telah dilakukan sebelumnya(Sofi dkk., 2021).

Pada penelitian prediksi harga emas di Indonesia memberikan hasil bahwa menggunakan metode GRU berhasil untuk memperkirakan harga emas di Indonesia. Dimana dalam penelitian tersebut menggunakan 70% dari total data, *timestep* sebesar 20, *epoch* sebanyak 100 dan *batch size* sebesar 16 memberikan hasil skor MAE 300.17, R-Squared 0.97 dan RMSE sebesar 17.33 di parameter pertama lalu di parameter kedua menggunakan data pelatihan sebesar 80%, *timestep* sebanyak 30, *epoch* 50 dan *batch size* 16 menghasilkan performa model yang lebih baik dengan skor MAE 318.13, R-Squared 0.92 dan RMSE 17.84(Prayogi dkk., 2024).

Pada penelitian lain yang membandingkan antara metode LSTM dan GRU untuk memprediksi ekspor migas di Indonesia menghasilkan metode LSTM lebih unggul dibandingkan dengan metode GRU dimana LSTM

memiliki nilai akurasi yang lebih bagus karena menghasilkan MAPE paling kecil sebesar 12,8% dan akurasi yang mencapai 87,2%. Sedangkan metode GRU menghasilkan nilai MAPE paling kecil 13,3% dan tingkat akurasi 86,7%(Yulisa dkk., 2023).

Pada penelitian perbandingan model LSTM dan GRU untuk prediksi nilai saham juga menunjukkan bahwa nilai evaluasi menggunakan metode LSTM dan GRU menunjukkan variasi pada nilai MAPE dan RMSE. Hasil tersebut mengungkapkan bahwa metode GRU memiliki kinerja yang lebih unggul dibandingkan dengan metode LSTM dalam memperkirakan harga saham. Hal ini ditunjukkan oleh nilai MAPE terendah pada metode GRU sebesar 2,14% dan RMSE sebesar 0,01775, sementara metode LSTM memiliki nilai MAPE terendah 2,42% dan RMSE 0,01807. Oleh karena itu, dapat diambil kesimpulan bahwa metode GRU lebih efektif untuk memprediksi harga saham(Aryati dkk., 2024b).

2.2 Dasar Teori

Peramalan pergerakan harga saham merupakan bagian dari tantangan besar di pasar keuangan karena volatilitas dan ketidakpastian yang melekat pada harga saham. Metode tradisional, seperti analisis teknikal dan fundamental, sering digunakan untuk memprediksi harga saham. Namun, seiring perkembangan teknologi, metode berbasis kecerdasan buatan, seperti *machine learning* dan *deep learning*, telah menjadi semakin populer.

2.2.1 Harga Saham dan Pergerakannya

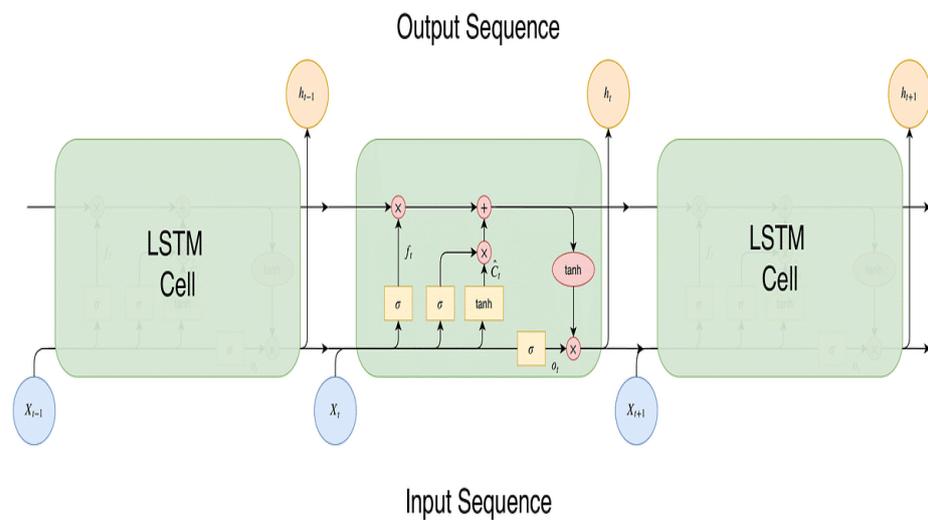
Saham merupakan suatu asset bernilai yang menjadi tanda bukti dari bagian kepemilikan terhadap sebuah perusahaan(Kwanda dkk., 2024). Dalam penjelasan yang lain mengatakan bahwa saham ini dianggap sebagai bukti dari partisipasi investor dalam melakukan transaksi yang ada di perusahaan tersebut(Utami dkk., 2024).Aspek-aspek yang memengaruhi pergerakan harga saham dapat dibagi menjadi dua kategori. Pertama, aspek internal seperti catatan laporan keuangan, perubahan yang terjadi pada struktur organisasi, dan aksi korporasi. Kedua, aspek eksternal yang mencakup keadaan makroekonomi sebuah negara, dinamika politik, dan

sentiment pasar yang dapat mempengaruhi pergerakan harga saham (Dwi Novita, t.t.). Perkembangan teknologi dan informasi tentunya menjadi penunjang para investor untuk mengetahui tren harga saham dengan sangat mudah. Salah satu aspek yang menjadi perhatian utama ini adalah dampak dari sebuah berita atau isu yang dapat mempengaruhi tren harga saham perusahaan tersebut (Utami dkk., 2024).

Dalam prediksi harga saham ini dijelaskan sebagai bentuk proses yang digunakan untuk menganalisis dan menentukan tren harga saham dari suatu perusahaan. Dalam proses ini menggunakan 2 pendekatan dasar yang menjadi pengaruh dalam prediksi yaitu berupa analisis fundamental dan analisis teknikal (Lubis dkk., 2022). Tren harga saham ini menjadi salah satu elemen yang penting dalam pertumbuhan ekonomi karena kemudahan akses modal yang diberikan, tetapi proses dalam mendapatkan keuntungan menjadi tantangan yang cukup kompleks karena pergerakan harga saham yang masih sulit untuk di prediksi (Shalahuddin & Oktaviyani, 2024).

2.2.2 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan transformasi dari arsitektur RNN yang dibuat pada tahun 1997 oleh Sepp Hochreiter dan Jurgen Schmidhuber. LSTM diangkat sebagai pemecahan masalah dari adanya *vanishing gradient* pada RNN saat memproses data *sequential* yang memiliki jangka waktu panjang. Pada arsitektur LSTM digunakan untuk mengatasi penyimpanan memori dalam jangka waktu yang panjang karena *memory cell* telah ditambahkan dari metode sebelumnya sehingga dapat menjadi solusi dari adanya gradien yang hilang pada RNN saat melakukan proses data sekuensial yang panjang. LSTM ini hadir sebagai peningkatan RNN untuk mengatasi masalahnya dengan menghadirkan *gate unit* dan sel memori ke sistem *neural network* yang dimana sel memori ini adalah unit yang tersembunyi yang menjadi inti dari jaringan saraf LSTM. Arsitektur LSTM dapat dilihat pada gambar (Puteri, 2023).



Gambar 2. 1 Arsitektur LSTM

(Sumber : projectpro.io)

Pada gambar 2.1 menjelaskan arsitektur LSTM memiliki tiga jenis *gate*, yaitu *forget gate* (f_t), *input gate* (i_t), dan *output gate* (O_t). *Forget gate* (f_t) memiliki fungsi untuk menghapus informasi yang tidak relevan dari *cell state*. *Input gate* (i_t) menentukan informasi baru yang akan dimasukkan ke dalam *cell state*. Sementara itu, *output gate* (O_t) berfungsi untuk menyaring informasi yang berguna dari *cell state* dan mengeluarkannya sebagai *output* (Puteri, 2023).

Pada *forget gate* ini akan memproses seberapa banyak informasi yang diberikan oleh *cell* sebelumnya yang nantinya akan diteruskan ke dalam tahap selanjutnya. Dalam pengertian yang lain yaitu *forget gate* akan menentukan data yang akan disimpan dan data yang akan dihapus dari *memory cell*. Proses ini menggunakan fungsi aktivasi sigmoid yang akan menghasilkan keluaran rentang dari 0 sampai 1. Jika datang yang dihasilkan mendekati 1 maka seluruh data akan disimpan dan sebaliknya jika hasilnya mendekati 0 maka data akan dihapus. Proses dalam *forget gate* ini dapat dinyatakan dengan persamaan berikut: Proses dalam LSTM dinyatakan dengan persamaan sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots \dots \dots (01)$$

Dimana :

f_t : Nilai *forget gate* (antara 0 dan 1)

σ : Fungsi aktivasi sigmoid

W_f : Bobot *forget gate*

b_f : Bias *forget gate*

h_{t-1} : *Hidden state* dari waktu sebelumnya

x_t : *Input* pada waktu t

Cara kerja *forget gate* sendiri yaitu dengan *input* dari *hidden state* yang sebelumnya dan saat ini yang diproses. Dari hasil tersebut akan masuk ke fungsi sigmoid yang menghasilkan nilai antara 0 dan 1. Nilai inilah yang selanjutnya akan digunakan untuk mengalikan sel memori sebelumnya dan memberikan keputusan apakah informasi akan dipertahankan atau dilupakan.

Gate yang kedua adalah *input gate* yang memiliki fungsi untuk mengontrol informasi baru yang akan dimasukkan ke dalam sel memori. Dalam *input gate* ini akan menentukan seberapa besar informasi baru dari *input* yang saat ini yang harus ditambahkan ke dalam sel memori. Dalam tahapan ini akan melakukan 2 tahapan utama yaitu yang pertama dengan menggunakan rumus berikut:

$$i_t = \sigma (W_i \cdot [h_{t-1}, x_t] + b_i) \dots \dots \dots (02)$$

$$\hat{c}_t = \tanh (W_c [h_{t-1}, x_t] + b_c) \dots \dots \dots (03)$$

Dimana :

i_t : Sebagai gerbang *input* (nilai antara 0 dan 1)

\hat{c}_t : Sebagai memori baru

\tanh : Fungsi aktivasi tanh (menghasilkan nilai antara -1 dan 1)

Pada tahap selanjutnya, nilai memori sel sebelumnya akan diperbaharui dengan nilai yang baru hasil dari kombinasi *output forget gate* dengan *input gate* yang dinyatakan dengan persamaan berikut :

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \hat{c}_t \dots \dots \dots (04)$$

Dimana :

C_t : untuk memperbarui sel memori

Dari ketiga persamaan yang ada didalam *input gate* ini dapat kita jelaskan bahwasannya terdapat beberapa proses yang terjadi yaitu diawali dengan menghitung gerbang input pada persamaan 2 yang memiliki tujuan untuk menentukan seberapa banyak informasi baru yang boleh masuk. Dilanjutkan pada persamaan 3 yang memiliki tujuan untuk mempersiapkan informasi baru yang bisa ditambahkan ke sel memori dan diakhiri dengan persamaan ke 4 yang memiliki tujuan untuk menggabungkan informasi lama dan baru yang akan digunakan untuk memperbarui sel memori.

Selanjutnya adalah tahapan pada *output gate* yang memiliki tugas untuk menghasilkan *hidden state* yang akan digunakan sebagai *output*. Dalam proses ini akan terjadi 2 proses yaitu fungsi aktivasi sigmoid yang digunakan untuk menentukan bagian dari sel memori dan yang kedua yaitu mengalikan hasil tersebut untuk menghasilkan nilai output. Tahap ini menggunakan persamaan sebagai berikut :

$$o_t = \sigma (W_o \cdot [h_{t-1}, x_t] + b_o) \dots\dots\dots(05)$$

$$h_t = \sigma \cdot \tanh(C_t) \dots\dots\dots(06)$$

Dimana :

C_t : Sel memori yang telah diperbarui

$\tanh(C_t)$: fungsi aktivasi tanh yang menjaga nilai rentang -1 hingga 1

h_t : *Hidden state* baru

o_t : nilai output gate (antara 0 dan 1)

Dalam tahapan *output gate* ini akan menggabungkan *hidden state* sebelumnya dengan input saat ini lalu dikalikan dengan bobot *output gate* dan dengan menerapkan fungsi sigmoid beserta tanh. Tahap ini akan menentukan data mana yang harus dihasilkan dalam waktu tertentu dengan tujuan untuk mengontrol informasi mana dari sel memori yang akan dikeluarkan.

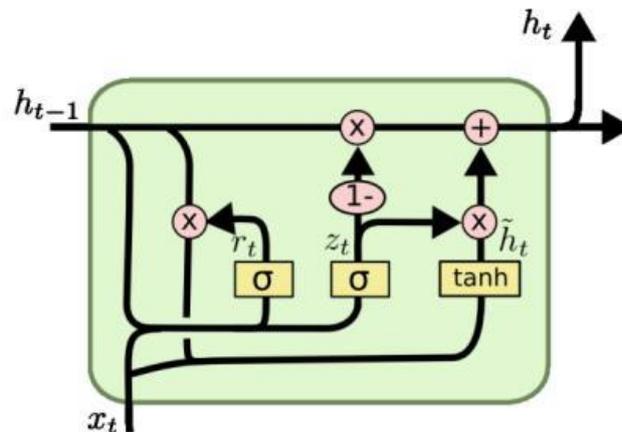
Desain perancangan model LSTM ini dimulai dengan inisialisasi parameter yang di proses (Arfan & ETP, 2020). Dalam perancangan LSTM ini akan menggunakan optimasi ADAM yang dimana *output* yang

akan dihasilkan berupa *Root Mean Square Error* (RMSE) sebagai indikator penentu seberapa dekat nilai prediksi dengan nilai aktual yang dihasilkan (Julian & Pribadi, 2021b).

2.2.3 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan hasil modifikasi dari model RNN yang memiliki dua *gate* yang terdiri dari *update gate* dan *reset gate*. (Aryati dkk., 2024b) selain memiliki 2 *gate* GRU juga memiliki 3 fungsi aktivasi. Struktur *gate* yang lebih sederhana dalam GRU memungkinkan proses pengolahan data menjadi lebih cepat, terutama saat menangani dataset yang berukuran besar. Dengan desain yang lebih efisien, GRU sering kali menunjukkan kinerja lebih baik dibandingkan LSTM, terutama ketika digunakan pada dataset dengan jumlah data yang lebih kecil (Meriani & Rahmatulloh, 2024). *Gated Recurrent Unit* (GRU) memfungsikan *gate*-nya ini untuk memutuskan informasi yang dapat diteruskan menjadi *output*. Arsitektur ini dapat dilatih untuk menyimpan informasi terlebih dahulu tanpa harus menghapus informasi yang tidak berhubungan dengan prediksi yang akan dibuat (Novela Waroi & Setyanto, t.t.).

Kelebihan yang dimiliki oleh metode GRU adalah proses komputasi yang lebih sederhana dibandingkan dengan LSTM, namun tetap mampu mencapai akurasi yang setara. Selain itu, arsitektur GRU cukup efektif dalam mengatasi permasalahan hilangnya gradien (*vanishing gradient*), sehingga dapat meningkatkan stabilitas dan efisiensi dalam pelatihan model (Prayogi dkk., 2024).



Gambar 2. 2 Arsitektur GRU

Dalam gambar 2.2 terdapat arsitektur dari GRU yang terdiri dari dua gerbang yaitu gerbang *reset* dan *update* gate yang keduanya bekerja pada *hidden state*. Tahapan yang pertama yaitu pada *reset gate* yang memiliki persamaan sebagai berikut :

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

Dalam *reset gate* ini digunakan untuk menghapus informasi yang tidak relevan dari *hidden state* sebelumnya. Selain itu, tahap ini juga menggunakan aktivasi sigmoid yang jika hasil dari r ini mendekati 0 maka Gru akan mengabaikan informasi dari *hidden state* sebelumnya dan sebaliknya jika nilai r mendekati 1 maka GRU akan menggunakan seluruh *hidden state* sebelumnya.

Tahapan selanjutnya yaitu dengan menghitung *update gate* yang akan digunakan untuk menentukan seberapa banyak *hidden state* sebelumnya yang akan dibawa ke *hidden state* saat ini yaitu dengan menggunakan persamaan sebagai berikut :

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

Dalam *update gate* ini digunakan untuk mengontrol seberapa banyak *hidden state* sebelumnya yang akan dibawa ke *hidden state* saat ini yang dimana jika nilai z mendekati 1 maka *hidden state* yang lama akan dipertahankan dan sebaliknya jika nilai z mendekati 0 maka *hidden state* lama akan diabaikan dan yang baru akan digunakan sepenuhnya.

Tahapan selanjutnya adalah menghitung kandidat dari *hidden state* yang memiliki persamaan sebagai berikut:

$$\tilde{h} = \tanh(W_h \cdot X_t + r_t * U_h \cdot h_{(t-1)} + b_h) \dots\dots\dots (9)$$

Dimana :

\tilde{h} : sebagai nilai sementara *hidden state* baru

r_t : sebagai *reset gate*

Tahapan ini digunakan untuk menghitung *hidden state* kandidat berdasarkan input baru dan *hidden state* lama yang sudah di filter oleh *reset gate*. Dimana jika hasil r_t mendekati 0 maka *hidden state* lama tidak diperhitungkan dan sebaliknya jika mendekati 1 maka *hidden state* lama akan digunakan dalam perhitungan *hidden state* kandidat.

Tahap selanjutnya adalah menghitung *hidden state* final yang akan mengkombinasikan antara *hidden state* lama dengan *hidden state* kandidat berdasarkan hasil dari nilai *update gate*. Proses ini menggunakan persamaan sebagai berikut :

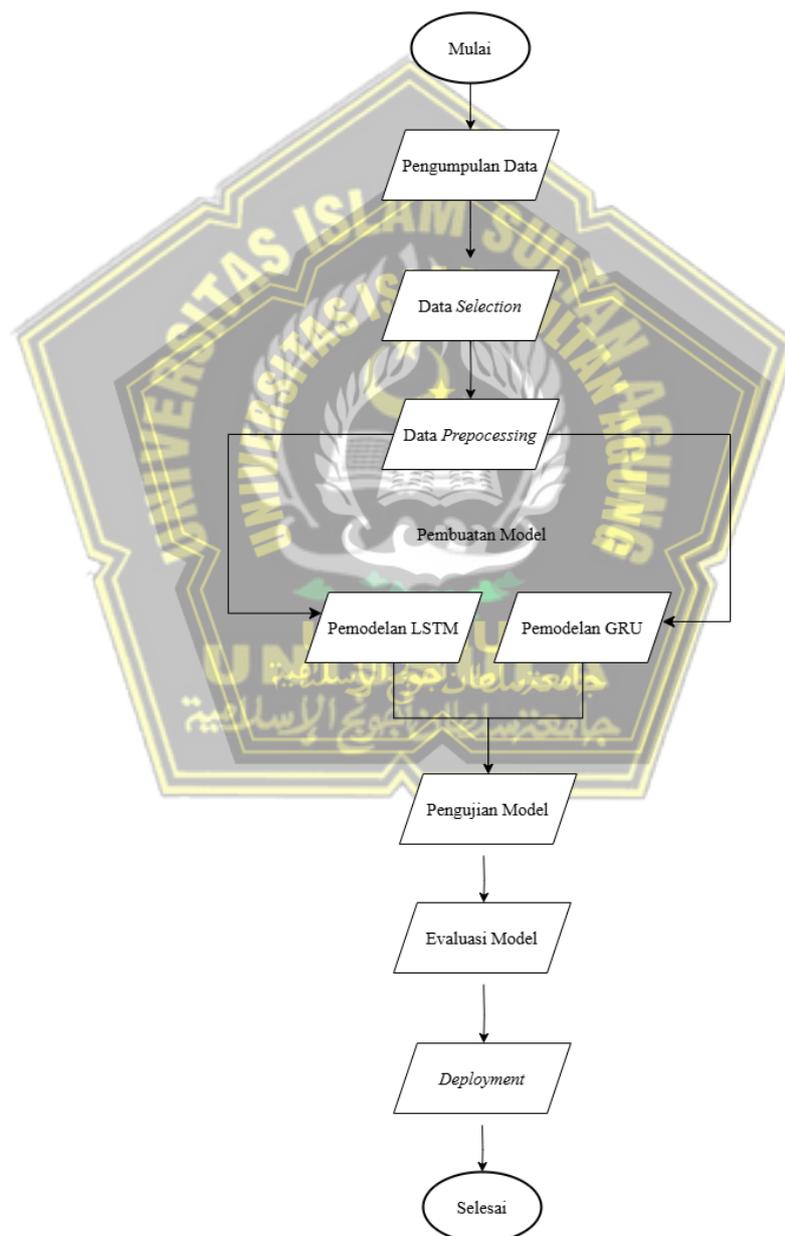
$$h = z * h_{(t-1)} + (1 - z) * \tilde{h} \dots\dots\dots(10)$$

hidden state final ini akan berperan sebagai pengontrol memori yang akan digunakan untuk menentukan seberapa banyak *hidden state* lama yang akan digunakan yang dimana apabila nilai z mendekati 1 maka *hidden state* lama lebih dominan sehingga GRU lebih banyak mengingat informasi sebelumnya. Jika nilai z mendekati 0 maka *hidden state* baru lebih dominan dan GRU akan lebih banyak belajar dari informasi baru dan jika nilai z berada diantara 0 dan 1 maka *hidden state* akan menggunakan kombinasi dari memori lama dan informasi yang baru.

BAB III

METODOLOGI PENELITIAN

Bagian ini akan membahas mengenai langkah-langkah yang akan digunakan dalam penelitian ini. Langkah pertama yaitu pengumpulan dan pengolahan data, di tahap kedua adanya data selection dan dilanjutkan pemodelan atau pembuatan model, tahap ke empat yaitu pengujian dan diakhiri dengan penarikan Kesimpulan sebagai hasil akhir.



Gambar 3. 1 *Flowchart* Penelitian

3.1 Pengumpulan data

Pada tahap pengumpulan data ini merupakan cara yang dilakukan oleh peneliti untuk memperoleh data-data yang diperlukan. Sumber data pada penelitian ini menggunakan data sekunder yang menggunakan dataset saham di perusahaan properti yang berasal dari Yahoo Finance dengan periode data menggunakan data historis dalam rentang 5 tahun dari tahun 2018 sampai tahun 2024. Dalam data ini mengandung beberapa informasi yang dibutuhkan seperti *open*, *high*, *low*, *close* dan *volume* yang akan digunakan untuk proses pengolahan data yang akan dianalisis.

3.2 Data Selection

Pada proses ini dilakukan pemilihan data yang relevan dan berkualitas dari kumpulan data yang lebih besar untuk digunakan dalam pemodelan. Beberapa aspek yang menjadi pertimbangan dalam pemilihan data adalah dari relevansi, kualitas data yang dimana data harus bersih, bebas dari duplikasi, atau nilai yang hilang. Data yang memiliki kualitas rendah akan menyebabkan model menjadi buruk atau hasil yang menyesatkan. Aspek yang ketiga adalah representasi dari semua data yang ada dalam populasi untuk proses analisis.

3.3 Preprocessing Data

Tahapan ini adalah proses mengolah data mentah menjadi data yang siap digunakan untuk pemodelan dengan tujuan untuk menghasilkan data yang lebih akurat. Data *preprocessing* meliputi tahapan sebagai berikut :

3.3.1 Data Cleaning

Data *Cleaning* merupakan proses untuk membersihkan data mentah yang memiliki tujuan untuk memastikan kualitas dari data yang akan digunakan untuk analisis. Tahapan ini meliputi penanganan data hilang, menghapus data duplikat, mengatasi *outlier* serta menghilangkan data yang tidak relevan.

3.3.2 Normalisasi Data

Proses ini merupakan tahapan untuk mengubah nilai-nilai dataset ke dalam skala yang seragam dengan rentang 0 hingga 1. Untuk meminimalkan

error, dilakukan normalisasi pada dataset dengan mengubah data aktual menjadi nilai dengan *rangeinterval* [0,1]. Teknik normalisasi yang digunakan menggunakan *min-max scaling*. (Arfan & Lussiana ETP, 2019) Adapun untuk rumus normalisasi *min-max scaling* adalah :

$$x' = \frac{(x - \min_x)}{(\max_x - \min_x)} \dots \dots \dots (11)$$

keterangan :

x : data yang dinormalisasi

x' : data setelah dinormalisasi

\min : nilai minimum dari keseluruhan data

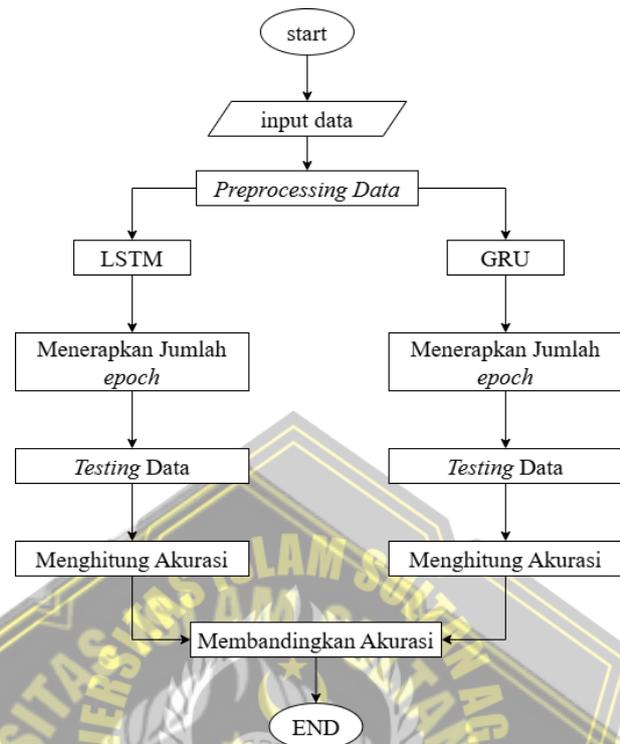
\max : nilai maksimum dari keseluruhan data.

3.3.3 Pembagian Data

Tahapan pembagian data ini digunakan untuk memisahkan data *training* dan data *testing* dengan rasio 80:20. Pembagian data ini penting untuk menghindari *overfitting* dan memastikan model dapat generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

3.4 Pembuatan Model LSTM dan GRU

Tahapan ini adalah proses pengolahan data yang sudah menggunakan model LSTM dan GRU. LSTM dirancang untuk mengatasi masalah keterbatasan memori dalam RNN tradisional, yang kesulitan mengingat informasi jangka panjang dalam urutan data. Sedangkan GRU adalah varian dari LSTM yang lebih sederhana dan lebih cepat untuk dilatih, namun tetap efektif dalam menangani masalah jangka panjang.



Gambar 3. 2 Flowchart Model

Langkah-langkah pembuatan model LSTM:

1. *Preprocessing Data*: Data input biasanya harus dinormalisasi atau distandarisasi, kemudian diubah menjadi format yang sesuai untuk model LSTM (misalnya, dalam bentuk urutan waktu atau sekuens).
2. Membangun Arsitektur Model: Biasanya dimulai dengan layer LSTM untuk menangkap pola dalam urutan data, diikuti oleh *layer Dense* untuk menghasilkan *output* yang sesuai dengan tugas (misalnya, prediksi harga saham).
3. Menentukan *Hyperparameter*: Pilih *hyperparameter* seperti jumlah unit LSTM, jumlah *epoch*, ukuran *batch*, dan fungsi aktivasi. *Optimizer* yang umum digunakan adalah Adam.
4. Melatih Model: Model dilatih menggunakan data latih dengan metrik evaluasi seperti RMSE untuk *regresi*.

Langkah-langkah pembuatan model GRU:

1. *Preprocessing Data*: Sama seperti LSTM, data perlu diproses dan disiapkan agar sesuai dengan input model GRU.

2. Membangun Arsitektur Model: Biasanya dimulai dengan layer GRU, yang kemudian diikuti dengan layer Dense. GRU cenderung lebih ringan dibandingkan LSTM dalam hal jumlah parameter dan kecepatan pelatihan.
3. Menentukan *Hyperparameter*: Tentukan jumlah unit GRU, ukuran *batch*, jumlah *epoch*, dan pilihan *optimizer*.
4. Melatih Model: Model dilatih dengan data yang telah diproses dan hasilnya dievaluasi menggunakan metrik yang sesuai.

3.5 Evaluasi Model

Tahapan ini berfungsi untuk mengevaluasi kinerja model setelah dilatih, untuk memastikan apakah kedua model tersebut memberikan hasil yang akurat dan efektif dalam memprediksi data. Metrik evaluasi yang digunakan untuk mengukur seberapa baik model tersebut digunakan dalam memprediksi yaitu dengan menggunakan RMSE. Dari hasil pengujian ini maka akan diberikan kesimpulan untuk masing-masing model yang di uji.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{\{i=1\}}^n (y_1 - \hat{y}_1)^2} \dots\dots\dots(12)$$

Dimana :

y_1 : nilai aktual

\hat{y}_1 : nilai prediksi

$\frac{1}{n}$: menghitung rata-rata dari kuadrat error

\sum : menjumlahkan semua error dari semua data

Dari perhitungan tersebut memberikan pengertian bahwa semakin kecil RMSE yang dihasilkan maka akurasi model yang digunakan semakin tinggi dan sebaliknya apabila hasil RMSE semakin besar maka nilai akurat pada model semakin kecil. RMSE ini dipilih karena keunggulan yang dimiliki oleh RMSE dibandingkan dengan perhitungan akurasi yang lain seperti RMSE dinilai cocok untuk digunakan dalam pengolahan data yang besar, RMSE juga mampu digunakan untuk membandingkan 2 metode yang sedang digunakan serta satuan error yang dimiliki oleh RMSE memiliki

satuan yang sama dengan harga saham. Hal tersebutlah yang mendasari mengapa RMSE dipilih sebagai parameter evaluasi dalam penelitian ini.

3.6 Software yang digunakan

Dalam penelitian ini menggunakan beberapa *software* yang akan digunakan untuk mengolah data, pembuatan model serta evaluasi hasil. Berikut daftar *software* yang akan digunakan :

1. *Python 3.10.12*

Python merupakan bahasa pemrograman yang digunakan dalam penelitian ini karena fleksibilitas yang mendukung pengolahan data dan pembuatan model *machine learning*.

2. *Pandas*

Pustaka ini digunakan dalam proses manipulasi dan analisis data dalam bentuk *DataFrame*. *Pandas* digunakan untuk memuat, mengelola dan membersihkan data yang akan di analisis. Pada pustaka ini juga bisa mengimpor data dari berbagai format seperti CSV, Excel, SQL, dan JSON.

3. *NumPy*

NumPy ini digunakan untuk perhitungan numerik dalam menghitung statistik dalam melakukan transformasi data.

4. *Matplotlib/Seaborn*

Matplotlib/Seaborn ini digunakan untuk membuat grafik yang membantu dalam eksplorasi dan analisis data, seperti plotting harga saham, tren waktu, atau visualisasi distribusi data.

5. *TensorFlow*

TensorFlow menyediakan kemampuan komputasi yang lebih tinggi dan mendukung pelatihan model pada perangkat keras yang lebih canggih seperti GPU.

6. *Scikit-learn*

Digunakan untuk pra-pemrosesan data yaitu dalam normalisasi dan pemisahan data menjadi set pelatihan dan pengujian serta digunakan untuk matrik evaluasi model yaitu RMSE.

7. *Google Colaboratory*

Google Colab salah satu platform berbasis *cloud* yang serupa dengan *Jupyter Notebook* dengan menawarkan keunggulan berupa akses gratis ke GPU dan TPU (*Tensor Processing Unit*). Ini sangat berguna ketika dataset besar digunakan atau ketika pelatihan model *deep learning* memerlukan waktu komputasi yang panjang

8. *Streamlit*

Streamlit ini digunakan untuk membangun aplikasi web berbasis data dengan cara yang mudah dan cepat. *Streamlit* sering digunakan dalam analisis data, machine learning, dan visualisasi data karena memiliki sintaks yang sederhana.



BAB IV

HASIL DAN ANALISIS PENELITIAN

4.1 Hasil Penelitian

4.1.1 Pengumpulan data

Penelitian ini menggunakan dataset dari 3 perusahaan yang sudah ditentukan pada bidang property yaitu PT. Pakuwon Jati Tbk, PT. Agung Podomoro Land Tbk, dan PT. Ciputra Development Tbk. Data-data tersebut diambil dari *yahoo finance* yang menghasilkan tabel pada nomor 4.1, 4.2 dan 4.3 dibawah ini.

Tabel 4. 1 Dataset PT. Pakuwon Jati Tbk

<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Volume</i>	<i>Dividens</i>	<i>Stock splits</i>
2018-01-01	210.0	210.0	210.0	210.0	0	0.0	0.0
2018-01-02	216.0	236.0	212.0	232.0	100038700	0.0	0.0
2018-01-02	234.0	234.0	224.0	230.0	18645000	0.0	0.0
2018-01-04	230.0	236.0	226.0	228.0	31000700	0.0	0.0
....
2024-11-25	106.0	107.0	102.0	104.0	21352000	0.0	0.0
2024-11-26	107.0	107.0	102.0	103.0	11380600	0.0	0.0
2024-11-28	103.0	104.0	102.0	102.0	3554500	0.0	0.0
2024-11-29	101.0	102.0	100.0	100.0	7385600	0.0	0.0

Tabel 4. 2 Dataset PT. Agung Podomoro Land Tbk

<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Volume</i>	<i>Dividends</i>	<i>Stock Splits</i>
2018-01-01	640.2	640.2	640.2	640.2	0	0	0
2018-01-02	640.2	644.8	626.2	640.2	15578600	0	0
2018-01-03	640.2	644.8	626.2	644.8	24447700	0	0
2018-01-04	644.8	649.5	635.5	649.5	15467900	0	0
....
2024-11-22	432	434	426	428	17385700	0	0
2024-11-25	428	444	428	430	93275100	0	0
2024-11-26	430	432	422	424	28985400	0	0
2024-11-28	422	428	420	424	15735000	0	0
2024-11-29	426	426	414	418	18902600	0	0

Tabel 4. 3 Dataset PT. Ciputra Development Tbk

<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>	<i>Volume</i>	<i>Dividends</i>	<i>Stock Splits</i>
2018-01-01	1084.2	1084.2	1084.2	1084.2	0	0	0
2018-01-02	1084.2	1084.2	1061.3	1061.3	12866600	0	0
2018-01-03	1065.9	1065.9	1038.4	1043.0	19519800	0	0
2018-01-04	1052.1	1052.1	1033.8	1038.4	9685500	0	0
2018-01-05	1033.88	1047.604	1029.305	1033.88	12765900	0	0

....
2024-11-22	1070	1080	1060	1070	9198200	0	0
2024-11-25	1075	1130	1060	1100	29641200	0	0
2024-11-26	1110	1140	1100	1120	16290800	0	0
2024-11-28	1120	1130	1075	1095	11140300	0	0
2024-11-29	1090	1095	1070	1070	5993100	0	0

Data pada tabel adalah data yang dimiliki oleh PT. Agung Podomoro Land Tbk pada tabel 4.1, tabel 4.2 data PT. Pakuwon Jati Tbk dan pada tabel 4.3 data dari PT. Ciputra Development Tbk yang terdiri dari *date*, *open*, *high*, *low*, *close*, *volume*, *dividens* dan *stock splits*. Data ini diambil dari tanggal 01 Januari 2018 sampai dengan tanggal 29 November 2024 dengan rentang waktu 5 tahun sebagai data untuk training dan testing kedua model. Dari ketiga perusahaan tersebut terdapat 5.130 data yang masing-masing tiap perusahaan ada 1710 data yang nantinya akan dibagi sebanyak 80% untuk data training dan 20% untuk data testing.

4.1.2 Data Selection

Pada tahapan ini ada beberapa yang perlu di perhatikan dalam pemilihan data yang nantinya akan digunakan untuk proses penelitian yaitu dengan melihat *missing value*, *duplicate data* dan relevansi data yang dibutuhkan.

4.1.2.1 Melihat Missing Value

Sebelum melakukan *handling missing value* sebaiknya melihat data terlebih dahulu untuk memastikan data tersebut tersedia untuk diproses. Pada tahapan ini setiap data dari perusahaan didefinisikan sebagai df1 untuk saham APLN, df2 untuk saham CTRA dan df3 untuk saham PWON.

Tabel 4. 4 Hasil *Missing Value*

Company	Handling Missing value
Pakuwon jati Tbk (PWON)	0
Agung Podomoro Land Tbk (APLN)	0
Ciputra Development Tbk (CTRA)	0

Tahapan ini untuk melihat adanya *missing value* pada saham ketiga perusahaan yang hasil dari pengecekan adalah tidak adanya *missing value* yang dibuktikan dengan 0 data ditemukan sebagai *missing value* sehingga data tersebut

dapat digunakan untuk proses penelitian tanpa perlu mengisi/menggantikan dengan rata-rata.

4.1.2.2 Mengecek *duplicate data*

Tabel 4. 5 Hasil *Duplicate Data*

Company	Duplicate Data
Pakuwon jati Tbk (PWON)	0
Agung Podomoro Land Tbk (APLN)	0
Ciputra Development Tbk (CTRA)	0

Pada tahapan selanjutnya adalah melihat *duplicate data* dari setiap data saham 3 perusahaan. Tahap ini menghasilkan tidak adanya data duplikat yang terdapat pada ketiga perusahaan sehingga data ini tidak perlu dirubah lagi untuk digunakan dalam proses selanjutnya.

4.1.3 *Preprocessing Data*

Pada tahapan *preprocessing* data ini akan mengolah data yang sudah dibersihkan dari *missing value* dan duplikasi data yang akan digunakan untuk pemodelan.

4.1.3.1 *Data cleaning*

Dalam data *cleaning* ini dilakukan tahapan untuk mengatasi *outliers* yang ada pada dataset. Penanganan *outliers* ini menggunakan metode Z-SCORE. Metode ini adalah salah satu metode untuk mengatasi *outliers* dengan menggunakan nilai mean (rata-rata) yang dimiliki oleh data set. Dalam dataset ini banyak *outliers* ditemukan akan tetapi *outliers* ini tidak diproses karena beberapa hal. Salah satunya adalah apabila menghilangkan/mengganti *outlier* ini akan memberikan dampak dalam hasil prediksi harga saham yang dilakukan. Selanjutnya, penulis melakukan normalisasi data yang menjadi solusi untuk data yang melebihi nilai rata-rata data dengan metode *min-max scaler*.

4.1.3.2 Normalisasi Data

Proses ini diambil untuk mengubah nilai dataset ke dalam skala 0 hingga 1 dengan tujuan setelah dilakukan normalisasi data ini dapat meminimalkan error.

Proses normalisasi data yang menggunakan metode *min-max scaler* dengan menggunakan *library MinMaxScaler* untuk merubah dataset ke dalam skala 0-1.

Proses normalisasi data ini sangat penting karena membantu percepatan konvergensi dalam metode LSTM dan GRU sehingga pemrosesan dataset tidak membutuhkan waktu yang lama. Selain itu, normalisasi data ini juga berfungsi untuk stabilitas perhitungan sehingga nilai akurasi yang dihasilkan lebih stabil. Tahapan selanjutnya adalah merubah data menjadi data sekuensial karena metode LSTM dan GRU ini tidak dapat memproses data biasa.

Metode LSTM dan GRU ini sangat bergantung pada nilai di masa lalu sehingga membutuhkan data dalam bentuk sekuensial dengan tujuan untuk memahami pola historis. Tahapan ini juga memiliki tujuan untuk menangkap pola historis dari tren naik/turu harga saham berdasarkan dari nilai sebelumnya. Selain itu, mengubah data ke dalam bentuk sekuensial ini juga dapat mengurangi noise dan overfitting pada dataset dalam pemrosesan data.

4.1.3.3 Pembagian Data (*Data Splitting*)

Tahapan ini digunakan untuk memisahkan data *training* dan data *cleaning* dengan tujuan untuk menghindari overfitting yang akan mengganggu pemrosesan data dalam model LSTM dan GRU. Pembagian data ini juga diperlukan untuk memastikan model yang sudah dibuat dapat mengikuti dengan baik dan memberikan hasil prediksi yang akurat.

Tabel 4. 6 *Data Splitting*

Company	Jumlah Data	Data Splitting	
		Data Training	Data Testing
Pakuwon jati Tbk (PWON)	1701	1368	342
Agung Podomoro Land Tbk (APLN)	1701	1368	342
Ciputra Development Tbk (CTRA)	1701	1368	342

Pada tabel 4.6 memberikan informasi untuk pembagian data yang akan digunakan dalam pemrosesan data yaitu dengan rasio 80:20 dimana 80% merupakan data *training* dan 20% digunakan untuk data testing. Dalam dataset yang ada di setiap perusahaan berjumlah 1701 data sehingga menghasilkan sebanyak 1368 data digunakan untuk *training* dan 342 data digunakan untuk

testing. Rasio ini juga diterapkan untuk data set di semua perusahaan yang digunakan untuk penelitian sehingga jumlah data yang digunakan sama.

4.1.4 Pembuatan Model LSTM dan GRU

4.1.4.1 Pembuatan Model LSTM

Tahapan ini adalah proses untuk mengolah data yang sebelumnya sudah disiapkan untuk proses analisis. Model LSTM ini dirancang untuk mengatasi masalah keterbatasan pada RNN yang kesulitan untuk mengingat informasi jangka Panjang dalam urutan data. Dalam pembuatan model LSTM ini dimulai dengan layer LSTM untuk menangkap pola dalam urutan data, diikuti oleh layer *dense* untuk menghasilkan output yang diinginkan.

Tabel 4. 7 Arsitektur LSTM

MODEL	Arsitektur Model		
	Neuron	Drop out	Dense
LONG SHORT-TERM MEMORY(LSTM)	50	0.2	1

Dalam tabel 4.7 menjelaskan bagaimana arsitektur dibuat yaitu menggunakan 2 layer yang masing-masing terdiri dari 50 unit *neuron*. Lapisan yang pertama memiliki *return_sequence = True* yang dimana akan mengembalikan seluruh urutan ke lapisan LSTM berikutnya. Setelah itu terdapat lapisan *dropout(0.2)* yang digunakan untuk mencegah *overfitting*. Lapisan ini diakhiri dengan lapisan *dense* yang akan berfungsi sebagai lapisan *output* yang akan menghasilkan nilai dari produksi. Tahapan selanjutnya adalah dengan menentukan *hyperparameter* yang akan digunakan dalam pengolahan dataset.

Tabel 4. 8 *hyperparameter* LSTM

MODEL	Hyperparameter		
	Optimizer	Batch Size	Verbose
LONG SHORT-TERM MEMORY(LSTM)	Adam	32	1

Dalam tabel 4.8 menunjukkan penggunaan *hyperparameter* yang digunakan dalam proses pelatihan model LSTM. Penggunaan *optimizer adam* ini digunakan sebagai optimasi yang akan membantu dalam pembaruan model secara efisien

sedangkan untuk fungsi *loss* yang digunakan adalah dengan menggunakan *mean squared error* atau MSE yang digunakan untuk menghitung kesalahan prediksi dari model yang dibuat. *Hyperparameter* lainnya yang digunakan dalam proses pelatihan data ini adalah dengan menerapkan jumlah *epoch* yaitu sebanyak 20 yang digunakan untuk menentukan berapa kali seluruh dataset lalui selama proses pelatihan. Selain parameter *epoch*, pelatihan ini juga menggunakan jumlah *batch size* sebanyak 32 yang digunakan untuk mengatur sampel yang digunakan dalam proses sebelum model memperbarui nilainya. *Hyperparameter* ini memiliki peran yang penting untuk menentukan performa dari model yang sudah dibuat dalam penyesuaian yang tepat berdasarkan dari hasil evaluasi yang dilakukan. Setelah arsitektur LSTM dibuat selanjutnya adalah menentukan matriks evaluasi yang digunakan untuk melihat hasil evaluasi model yang sudah dibuat.

Matriks evaluasi yang digunakan dalam proses pengolahan data ini adalah dengan menggunakan *Root Mean Square Error* (RMSE). RMSE ini dipilih sebagai matriks evaluasi karena memiliki beberapa keunggulan yaitu memiliki satuan yang sama dengan data aslinya yang berupa harga saham sehingga lebih mudah untuk dipahami. Selain itu, RMSE juga dianggap konsisten dan memberikan gambaran yang lebih realistis akan seberapa jauh prediksi dari nilai yang sebenarnya karena RMSE mengurangi dampak dari nilai kuadrat yang membesar pada saat menggunakan MSE. RMSE juga sering digunakan secara luas sebagai metrik evaluasi utama dalam model *time series* sehingga lebih mudah untuk membandingkan hasil dengan studi lain.

Perhitungan RMSE ini diawali dengan menghitung MSE terlebih dahulu diantara nilai aktual dan nilai prediksi. Dilanjutkan dengan mengambil akar kuadrat dari MSE sehingga RMSE yang dihasilkan akan disimpan dalam variable `rmse_all_data`. RMSE ini membantu dalam pemahaman seberapa besar kesalahan model yang telah dibuat dalam satuan yang sama dengan data asli sehingga lebih mudah untuk diinterpretasikan.

4.1.4.2 Pembuatan Model GRU

Tahapan pembuatan model GRU ini hampir sama dengan LSTM, tetapi GRU ini lebih sederhana karena tidak memiliki sel memori yang terpisah seperti

yang ada di model LSTM. Hal ini dikarenakan kedua model tersebut merupakan jenis-jenis yang dimiliki oleh *Recurrent Neural Network* (RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* dan digunakan untuk data sekuensial.

Tabel 4. 9 Arsitektur GRU

MODEL	Arsitektur Model		
	Neuron	Drop out	Dense
GATED RECURRENT UNIT (GRU)	50	0.2	1

Model ini dimulai dengan lapisan yang pertama terdiri dari 50 unit dan diatur untuk mengembalikan urutan *output* (*return_sequences=True*) yang digunakan untuk meneruskan ke dalam lapisan GRU selanjutnya. Setelah itu, terdapat lapisan *dropout* dengan tingkat 0.2 yang memiliki tujuan untuk mencegah *overfitting* pada saat pemrosesan dataset. Kemudian lapisan GRU yang kedua juga memiliki 50 unit akan tetapi tidak mengembalikan urutan *output* yang memiliki arti hanya kan memberikan hasil akhir dari urutan input. Diakhir lapisan GRU terdapat lapisan *dense* yang terdiri dari satu *neuron* untuk menghasilkan output prediksi dari dataset yang sudah di proses.

Tabel 4. 10 Hyperparameter GRU

MODEL	Hyperparameter		
	Optimizer	Batch Size	Verbose
GATED RECURRENT UNIT (GRU)	Adam	32	1

Pada tabel 4.10 menjelaskan bahwa *optimizer* yang digunakan adalah dengan menggunakan *optimizer adam* dengan tujuan untuk memperbarui bobot model sehingga dapat meminimalkan kesalahan selama pelatihan. MSE yang digunakan untuk menghitung rata-rata kuadrat perbedaan antara nilai prediksi dan nilai aktual yang dimiliki oleh dataset. Selanjutnya adalah jumlah *epoch* yang digunakan sebanyak 20 yang memiliki arti model akan memproses seluruh data latih satu kali penuh dan dilanjutkan dengan jumlah *batch size* sebanyak 32 yang dimana data akan dibagi menjadi *batch-batch* kecil yang masing-masing berisi 32 sampel. Pada tahap akhir terdapat *verbose* sebanyak 1 yang akan menampilkan pembaruan dari setiap *epoch* sehingga dapat melihat perkembangan model yang

sudah dibuat. Setelah arsitektur dibuat selanjutnya adalah menentukan matriks evaluasi yang digunakan untuk melihat hasil evaluasi model yang sudah dibuat.

Perhitungan dari skor RMSE untuk evaluasi model GRU yang dimana *actual combined* ini menjelaskan tentang nilai asli yang dimiliki oleh dataset dan *predicted combined* digunakan untuk menghitung nilai prediksi yang dihasilkan oleh model. Fungsi ini digunakan untuk menghitung rata-rata kuadrat perbedaan antara nilai prediksi dengan nilai aktual. Setelah MSE dihitung selanjutnya adalah mengambil nilai akar MSE untuk mendapatkan nilai RMSE dari dataset tersebut. RMSE ini digunakan untuk mengukur akurasi yang dimana semakin kecil nilai RMSE maka semakin baik juga model dalam memprediksi nilai yang benar.

4.1.5 Evaluasi Model

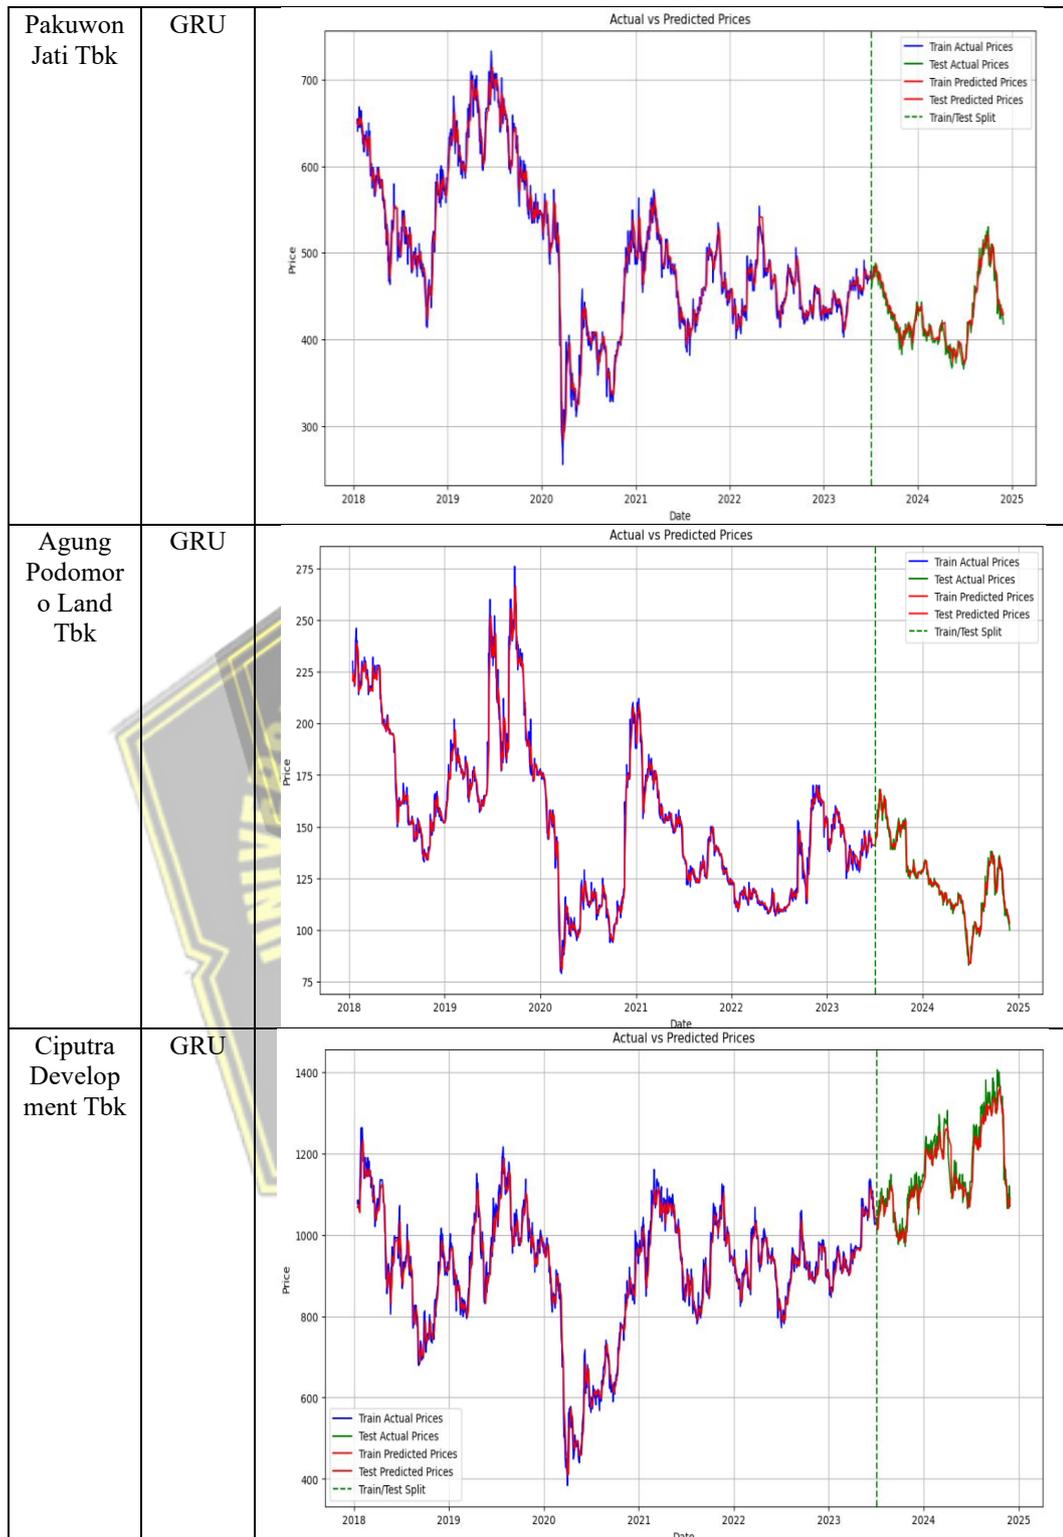
Pada tahapan evaluasi model ini berfungsi untuk mengevaluasi kinerja model yang sudah dilatih. Evaluasi model ini menggunakan matrik evaluasi yaitu *Root Mean Square Error* (RMSE) dengan mempertimbangkan beberapa kelebihan yang dimiliki oleh RMSE sehingga dapat menghasilkan skor evaluasi yang baik untuk model.

Evaluasi ini dilakukan dengan menggunakan data *training* dan data *testing* yang berisi nilai aktual dan nilai prediksi dari dataset yang sudah dilatih. *Actual combined* menunjukkan gabungan dari nilai aktual dari data pelatihan dan pengujian sedangkan *predicted combined* menunjukkan gabungan nilai prediksi dari data pelatihan dan pengujian yang dilakukan pada dataset.

4.2 Hasil Evaluasi

Tabel 4. 11 Hasil Evaluasi

Nama Perusahaan	Model yang Digunakan	Hasil
Pakuwon Jati Tbk	LSTM	
Agung Podomoro Land Tbk	LSTM	
Ciputra Development Tbk	LSTM	



Pada tabel 4.11 menunjukkan grafik dari hasil prediksi yang dilakukan oleh kedua model terhadap tiga perusahaan. Dimana garis yang berwarna biru digunakan untuk harga asli dari data pelatihan dan warna hijau digunakan untuk harga asli dari

data uji. Sedangkan untuk harga prediksi ditandai dengan garis merah pada data pelatihan dan data uji. Diantara data pelatihan dan data uji dipisahkan oleh garis putus-putus yang berwarna hijau.

Dari semua grafik yang ada pada tabel 4.11 dapat dilihat bahwa kedua model dapat mengikuti harga tren saham dari semua perusahaan. Akan tetapi, metode GRU lebih unggul karena grafik yang dihasilkan hampir sama dengan harga aktual dari pergerakan harga saham dari ketiga perusahaan dibandingkan dengan model LSTM.

Tabel 4. 12 Hasil RMSE

Company	Jumlah Epoch	Skor RMSE	
		LSTM	GRU
Pakuwon jati Tbk (PWON)	20	19.958	14.296
Agung Podomoro Land Tbk (APLN)	20	6.996	5.263
Ciputra Development Tbk (CTRA)	20	40.202	31.327

Pada tabel 4.12 menunjukkan hasil evaluasi kinerja yang dihasilkan oleh model LSTM dan GRU. Dari tabel tersebut dapat dilihat bahwa skor RMSE pada model GRU lebih rendah daripada model LSTM. Dari hasil visualisasi grafik dan tabel menunjukkan kedua model mampu untuk memprediksi harga saham yang dimiliki oleh ketiga perusahaan.

Diantara model LSTM dan GRU dapat dilihat bahwa model GRU menunjukkan skor RMSE yang lebih sedikit dibandingkan dengan model LSTM. Hal ini dapat diambil kesimpulan bahwa model GRU lebih unggul daripada LSTM karena skor RMSE yang semakin kecil maka semakin baik model tersebut dalam melakukan prediksi.

4.3 Hasil *Deployment*

Setelah proses pembuatan model yang dilakukan, tahapan selanjutnya adalah diimplementasikan pada *platform* yang berbasis *website*.

1. Halaman awal

Stock Price Prediction with Saved LSTM/GRU Model

This app predicts stock prices using a saved LSTM or GRU model, based on historical data.

Upload CSV with stock price data



Drag and drop file here
Limit 200MB per file • CSV

Browse files

Please upload a CSV file to start.

Gambar 4. 1 Halaman Awal

Pada gambar 4.17 merupakan implementasi desain halaman awal prediksi harga saham dengan menggunakan model LSTM dan GRU. Pada halaman awal ini terdapat judul dari *website* tersebut. Lalu dibawahnya terdapat *Browse Files* yang digunakan untuk memasukan dataset sebelum dilakukan prediksi diikuti dengan kalimat perintah untuk memasukkan file dataset.

- Halaman setelah memasukkan dataset

Stock Price Data

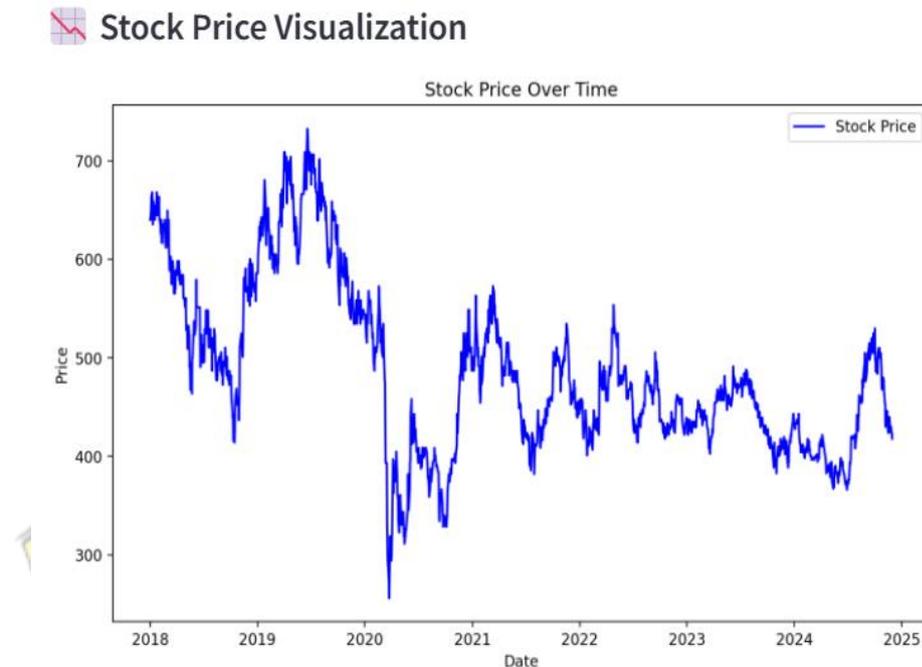
	Date	Close
1,705	2024-11-22 00:00:00+07:00	428
1,706	2024-11-25 00:00:00+07:00	430
1,707	2024-11-26 00:00:00+07:00	424
1,708	2024-11-28 00:00:00+07:00	424
1,709	2024-11-29 00:00:00+07:00	418

Gambar 4. 2 Stock Price Data

Pada gambar 4.18 menunjukkan proses setelah dataset *disubmit* yang akan menampilkan *stock price data* yang dimiliki oleh dataset. Fitur

ini berfungsi untuk memberikan informasi kepada *user* ketika ingin memprediksi dataset saham tersebut.

3. Halaman *Stock Price Visualization*



Gambar 4. 3 *Stock Price Visualization*

Gambar 4.19 menjelaskan fitur visualisasi dari informasi pergerakan harga saham secara aktual untuk membantu para investor melihat pergerakan harga saham selama 5 tahun terakhir sebagai pendukung keputusan yang akan diambil sebelum melakukan keputusan berinvestasi.

4. Halaman pemilihan model untuk prediksi

Select Model Type

LSTM ▼

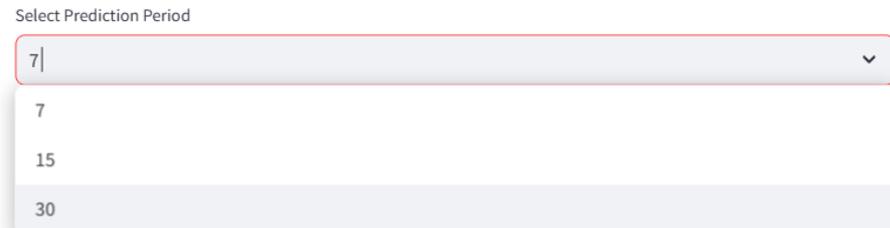
LSTM

GRU

Gambar 4. 4 Pemilihan Model

Gambar 4.20 menunjukkan tahapan untuk pemilihan model yang akan digunakan untuk memprediksi saham dari dataset. Dalam fitur ini diberikan *selectbox* untuk memilih model antara LSTM atau GRU sehingga *user* dapat membandingkan nilai prediksi pada saham.

5. Halaman pemilihan jangka waktu prediksi



Select Prediction Period

7

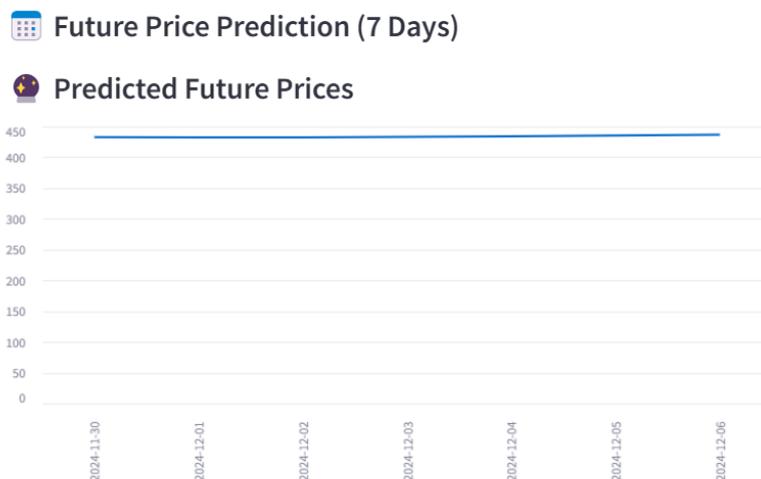
15

30

Gambar 4. 5 Pemilihan Jangka Waktu

Pada gambar 4.21 menunjukkan fitur untuk pemilihan jangka waktu prediksi saham yang dihasilkan. Terdapat *selectbox* yang memberikan 3 pilihan periode waktu yaitu 7 hari kedepan, 15 hari kedepan dan 30 hari kedepan sehingga *user* dapat melihat prediksi saham dalam sebulan kedepan dan dapat membantu keputusan *user* dalam melakukan transaksi di pasar saham.

6. Halaman hasil prediksi



Gambar 4. 6 Hasil Prediksi

Pada gambar 4.22 menunjukkan hasil prediksi selama 7 hari dengan visualisasi berbentuk grafik. Dalam visualisasi grafik tersebut masih belum terlihat secara jelas untuk pergerakan sahamnya karena jangka waktu yang pendek.

7. Halaman Tabel Prediksi

🌟 Future Price Prediction Table

	Date	Predicted Price
0	2024-11-30	432.9460144042969
1	2024-12-01	432.29925537109375
2	2024-12-02	432.41375732421875
3	2024-12-03	433.1416015625
4	2024-12-04	434.2660217285156
5	2024-12-05	435.57708740234375
6	2024-12-06	436.9460754394531

Gambar 4. 7 Tabel Prediksi

Pada gambar 4.23 menunjukkan tabel prediksi selama 7 hari kedepan dengan tujuan untuk mempermudah *user* dalam melihat detail harga dari prediksi yang dihasilkan oleh model.



BAB V

KESIMPULAN DAN SARAN

7.1 Kesimpulan

Dalam penelitian ini dapat memberikan beberapa kesimpulan yaitu :

1. Antara LSTM dan GRU mampu mengikuti tren harga saham yang dimiliki oleh setiap perusahaan.
2. Metode GRU lebih unggul dibandingkan dengan LSTM dari hasil RMSE yang lebih kecil dan mendekati angka 0.
3. Keunggulan yang dimiliki oleh GRU ini karena pengaruh arsitektur nya yang lebih sederhana dibandingkan dengan arsitektur yang dimiliki oleh LSTM.

5.2 Saran

Untuk meningkatkan akurasi prediksi harga saham dalam penelitian selanjutnya, disarankan untuk:

1. Penambahan faktor yang dapat mempengaruhi tren harga saham.
2. Mengeksplorasi teknik optimasi *hyperparameter* lebih lanjut untuk meningkatkan performa model.
3. Mengeksplorasi arsitektur LSTM dan GRU yang dapat dioptimalkan seperti jumlah unit, *hidden layer*, *learning rate*, *batch size* serta jumlah epoch dalam proses pelatihan.

DAFTAR PUSTAKA

- Arfan, A., & ETP, L. (2020). Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia. *PETIR*, 13(1), 33–43. <https://doi.org/10.33322/petir.v13i1.858>
- Arfan, A., & Lussiana ETP, dan. (2019). Prediksi Harga Saham Di Indonesia Menggunakan Algoritma Long Short-Term Memory. *Universitas Gunadarma Jl. Margonda Raya No, 3(1)*. <https://www.ofx.com>
- Dwi Novita, V. (t.t.). *ANALISIS FAKTOR-FAKTOR YANG MEMPENGARUHI HARGA SAHAM PADA PERUSAHAAN PROPERTY AND REAL ESTATE DI BURSA EFEK INDONESIA (BEI) Nur Laily Sekolah Tinggi Ilmu Ekonomi Indonesia (STIESIA) Surabaya*.
- Julian, R., & Pribadi, M. R. (2021a). Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM). *Jurnal Teknik Informatika dan Sistem Informasi*, 8(3). <http://jurnal.mdp.ac.id>
- Julian, R., & Pribadi, M. R. (2021b). Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM). *Jurnal Teknik Informatika dan Sistem Informasi*, 8(3). <http://jurnal.mdp.ac.id>
- Karno, A. S. B. (2020). Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory). *Journal of Informatic and Information Security*, 1(1), 1–8. <https://doi.org/10.31599/jiforty.v1i1.133>
- Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, & Antika Zahrotul Kamalia. (2021). PERBANDINGAN ALGORITMA LINEAR REGRESSION, LSTM, DAN GRU DALAM MEMPREDIKSI HARGA SAHAM DENGAN MODEL TIME SERIES. *SEMINASTIKA*, 3(1), 39–46. <https://doi.org/10.47002/seminastika.v3i1.275>
- Kwanda, K., Herwindiati, D. E., Lauro, M. D., & Id, K. K. C. (2024). Perbandingan LSTM dan Bidirectional LSTM pada Sistem Prediksi Harga Saham Berbasis Website. *R2J*, 7(1). <https://doi.org/10.38035/rrj.v7i1>
- Lubis, C., Sutedjo, E., & Setiadi, B. (2022). E-17 PREDIKSI HARGA SAHAM DENGAN MENGGUNAKAN ALGORITMA HYBRID NEURAL NETWORK. Dalam *Universitas Tarumanagara, Jl Let. Jend. S. Parman* (Vol. 1, Nomor 1). Abstrak. <http://www.journal.au.edu/ijcim/2000/sep00/hui>
- Meri Aryati, N. W., Wiguna, I. K. A. G., Putri, N. W. S., Widiartha, I. K. K., & Ginantra, N. L. W. S. R. (2024a). Komparasi Metode LSTM dan GRU dalam

- Memprediksi Harga Saham. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 8(2), 1131. <https://doi.org/10.30865/mib.v8i2.7342>
- Meri Aryati, N. W., Wiguna, I. K. A. G., Putri, N. W. S., Widiartha, I. K. K., & Ginantra, N. L. W. S. R. (2024b). Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 8(2), 1131. <https://doi.org/10.30865/mib.v8i2.7342>
- Meriani, A. P., & Rahmatulloh, A. (2024). PERBANDINGAN GATED RECURRENT UNIT (GRU) DAN ALGORITMA LONG SHORT TERM MEMORY (LSTM) LINEAR REFRESSION DALAM PREDIKSI HARGA EMAS MENGGUNAKAN MODEL TIME SERIES. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(1). <https://doi.org/10.23960/jitet.v12i1.3808>
- Novela Waroi, E., & Setyanto, A. (t.t.). *408 Elsin Novela Prediksi Harga Laptop Menggunakan Algoritma GRU dan BiLSTM*.
- Nusaiba Yulisa, P., Al Haris, M., & Rismawati Arum, P. (2023). Peramalan Nilai Ekspor Migas di Indonesia dengan Model Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU). Dalam *J Statistika* (Vol. 16, Nomor 1).
- Prayogi, K., Gata, W., & Kussanti, D. P. (2024). *Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU*.
- Puteri, D. I. (2023). Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah. *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, 11(1), 35–43. <https://doi.org/10.34312/euler.v11i1.19791>
- Putra Lidiansyah Aldi, & Kurniawati Ana. (2021). Analisis Prediksi Harga Saham PT. Astra International Tbk Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA) dan Support Vector Regression (SVR). *Jurnal Ilmiah Komputasi*, 20(3). <https://doi.org/10.32409/jikstik.20.3.2732>
- Shalahuddin, M., & Oktaviyani, H. (2024). MODEL ARIMA BOX-JENKINS UNTUK PERAMALAN PERGERAKAN HARGA SAHAM PT. ASTRA INTERNATIONAL TBK ARIMA BOX-JENKINS MODEL FOR FORECASTING STOCK PRICE MOVEMENTS OF PT. ASTRA INTERNATIONAL TBK. *Journal of Social and Economics Research*, 6(2). <https://idm.or.id/JSER/index.php/JSER>
- Silalahi, R. N., & Muljono, M. (2024). Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coca-Cola. *Komputika : Jurnal Sistem Komputer*, 13(2), 201–211. <https://doi.org/10.34010/komputika.v13i2.12265>

- Sumolang Jannet Rossemia, V Joane, & Keles Dantje Keles. (2021). analisis Prediksi Kebangkrutan Perusahaan Properti Yang Terdaftar di BEI Dengan Model Altman Z-Score. *Rossemia Jannet Sumolang Joane V. Mangindaan Dantje Keles, 1*(productivity), 25–36.
- Utami, H. A., Herwiyanti, E., & Suparlinah, I. (2024). PENGARUH SENTIMEN PASAR TERHADAP PERGERAKAN HARGA SAHAM PADA PERUSAHAAN INDUSTRI MANUFAKTUR PADA BURSA EFEK INDONESIA. Dalam *Bisnis dan Akuntansi (JEBA)* (Vol. 26). www.idx.co.id.

