

TESIS

**Optimasi Kinerja Metode LSTM dan GRU Pada Kasus Prediksi Harga
Forex**



Disusun oleh:

Nama : Mohammad Rezza Pahlevi
NIM : 21.51.2105
Konsentrasi : Digital Transformation Intelligence

PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA

2023

TESIS

**Optimasi Kinerja Metode LSTM dan GRU Pada Kasus Prediksi Harga
Forex**

**Optimizing the Performance of the LSTM and GRU Methods in the Case of
Forex Price Prediction**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Mohammad Rezza Pahlevi
NIM : 21.51.2105
Konsentrasi : Digital Transformation Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2023

HALAMAN PENGESAHAN

Optimasi Kinerja Metode LSTM dan GRU Pada Kasus Prediksi Harga

**Optimizing the Performance of the LSTM and GRU Methods in the Case of
Forex Price Prediction**

oleh

Mohammad Rezza Pahlevi

21.51.2105

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Rabu, 6 Desember 2023

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 6 Desember 2023

Rektor

Prof. Dr. M. Suyanto, M.M.

NIK. 190302001

HALAMAN PERSETUJUAN

Optimas Kinerja Metode LSTM dan GRU Pada Kasus Prediksi Harga Optimizing the Performance of the LSTM and GRU Methods In the Case of Forex Price Prediction

Dipersiapkan dan Disusun oleh

Mohammad Rezza Pahlevi

21.51.2105

Telah Ditujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Rabu, 6 Desember 2023

Pembimbing Utama

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

Pembimbing Pendamping

Tony Hidayat, M.Kom., Ph.D
NIK. 190302182

Anggota Tim Penguji

Dr. Arief Setyanto, S.Si., M.T.
NIK. 190302036

Dr. Andi Sunvoto, M.kom
NIK. 190302052

Prof. Dr. Kusriani, M.kom
NIK. 190302106

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 6 Desember 2023
Direktur Program Pascasarjana

Prof. Dr. Kusriani, M.Kom
NIK. 19030210

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Mohammad Rezza Pahlevi
NIM : 21.51.2105
Konsentrasi : Digital Transformation Intelligence

Menyatakan bahwa Tesis dengan judul berikut:
Optimasi Kinerja Metode LSTM dan GRU Pada Kasus Prediksi Harga

Dosen Pembimbing Utama : Prof. Dr. Kusriani, M.Kom
Dosen Pembimbing Pendamping : Tony Hidayat, M.Kom., Ph.D

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 6 Desember 2023

Yang Menyatakan,



Mohammad Rezza Pahlevi

HALAMAN PERSEMBAHAN


Alhamdulillah, segala puji bagi Allah SWT yang telah melimpahkan rahmatserta hidayatNya sehingga tesisi ini dapat terselesaikan. Hasil ini saya persembahkan untuk :

- Bapak dan Ibu tercinta dengan segala doa dan perjuangannya
- Kakak yang selalu ada
- Sahabat dan teman – teman yang menjadi support system terbaik.



HALAMAN MOTTO

Makanan bukan hanya masakan yang akan berakhir di perutmu, melainkan sebuah petualangan yang patut dinikmati dan dihargai



KATA PENGANTAR

Puji syukur dipanjatkan kehadiran Allah ta'ala yang telah melimpahkan segala kebutuhan yang diperlukan selama penyusunan tesis ini, sehingga bisa terselesaikan.

Terima kasih penulis ucapkan, kepada :

- Ibu Prof. Dr. Kusrini, M.Kom. sebagai pembimbing utama yang telah mendampingi dalam penyusunan tesis ini.
- Pak Tonny Hidayat, M.Kom., Ph.D. sebagai pendamping yang tak Lelah membimbing penulis dalam pengerjaan tesis.
- Teman – teman MTL-2021 kelas A Universitas Amikom Yogyakarta yang telah memberikan dukungan dan doa. Dan kepada semua yang tidak bisa penulis sebutkan satu persatu, yang telah membantu proses tesis ini.

Penulis mengharapkan penelitian ini dapat membantu bagi pihak yang membutuhkan. Kekurangan dan ketidaksempurnaan masih dapat ditemukan agar dapat menjadi patokan kerah yang lebih baik lagi dimasa yang akan datang.

Selbihnya permohonan maaf apabila terdapat salah kata dan salah dalam penyusunan, Terima kasih

Yogyakarta, Desember 2023


Penulis

DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiv
INTISARI.....	xvi
<i>ABSTRACT</i>	xvii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah.....	6
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	7
BAB II TINJAUAN PUSTAKA.....	9
2.1. Tinjauan Pustaka.....	9
2.2. Keaslian Penelitian.....	13

2.3. Landasan Teori.....	18
2.3.1. <i>Metode Long Short-Term Memory (LSTM)</i>	19
2.3.2. <i>Unit Gated recurrent (GRU)</i>	20
2.3.3. Optimizer Adaptive Moment Estimation (ADAM).....	21
2.3.4. <i>Root Mean Square Error (RMSE)</i>	22
2.3.5. <i>Mean Absolute Percentage Error (MAPE)</i>	23
2.3.6. Koefisien Determinasi (R-Square).....	23
BAB III METODE PENELITIAN	25
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	27
3.2. Metode Pengumpulan Data.....	27
3.3. Metode Analisis Data.....	28
3.4. Alur Penelitian.....	29
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	33
4.1. Pengumpulan data.....	33
4.2. Proses Prediksi Harga Forex.....	35
4.2.1. Proses Prediksi Metode LSTM.....	35
4.2.2. Proses Prediksi Metode GRU.....	41
4.2.3. Perbandingan Arsitektur dan Beban Komputasi Pada Metode LSTM dan GRU.....	47
4.3. Evaluasi Model.....	49
4.3.1. Perbandingan Hasil Kedua Metode.....	49
4.3.2. Faktor Yang Mempengaruhi Mempengaruhi Akurasi prediksi.....	60


4.3.3. Mengoptimalkan Akurasi Prediksi Harga Forex	75
4.4 Perbandingan dengan Penelitian Sebelumnya.....	89
BAB V PENUTUP	90
5.1. Kesimpulan	90
5.2. Saran	93
Daftar Pustaka.....	96



DAFTAR TABEL

Tabel 2.1. Matriks literatur review dan posisi penelitian Prediksi Harga Forex Menggunakan Algoritma Long ShortTerm Memory Dan Recurrent Unit..	13
Tabel 4.1. Rincian Dataset EURUSD	34
Tabel 4.2. Rincian Dataset AUDCAD	34
Tabel 4.3. Sebelum normalisasi	36
Tabel 4.4. Setelah normalisasi	36
Tabel 4.5. Hasil Prediksi EURUSD Menggunakan Metode LSTM	39
Tabel 4.6. Hasil Prediksi AUDCAD Menggunakan Metode LSTM	40
Tabel 4.7. Sebelum normalisasi	42
Tabel 4.8. Setelah normalisasi	43
Tabel 4.9. Hasil Prediksi EURUSD Menggunakan Metode GRU	45
Tabel 4.10. Hasil Prediksi AUDCAD Menggunakan Metode GRU	46
Tabel 4.11. Perbandingan Hasil Kedua Metode	50
Tabel 4.12. Hasil Prediksi dan Nilai aktual EURUSD Menggunakan Metode LSTM	52
Tabel 4.13. Hasil Prediksi dan Nilai aktual AUDCAD Menggunakan Metode LSTM.....	54
Tabel 4.14 Hasil Prediksi dan Nilai aktual EURUSD Menggunakan Metode GRU	56
Tabel 4.15 Hasil Prediksi dan Nilai aktual AUDCAD Menggunakan Metode GRU	58


Tabel 4.16. Perbandingan Penggunaan Data pada Metode LSTM	60
Tabel 4.17. Perbandingan Penggunaan Data pada Metode GRU	62
Tabel 4.18 Perbandingan Penelitian.....	90



DAFTAR GAMBAR

Gambar 2.1. Arsitektur LSTM.....	19
Gambar 2.2. Diagram for GRU Cell.....	20
Gambar 3.1. K-Chart.....	26
Gambar 3.2. Alur Penelitian.....	32
Gambar 4.1. Proses pengumpulan data.....	33
Gambar 4.2. Visualisasi Hasil Prediksi EURUSD Menggunakan Metode LSTM	52
Gambar 4.3. Visualisasi Hasil Prediksi AUDCAD Menggunakan Metode LSTM	54
Gambar 4.4. Visualisasi Hasil Prediksi EURUSD Menggunakan Metode GRU ,	56
Gambar 4.5. Visualisasi Hasil Prediksi AUDCAD Menggunakan Metode GRU	58
Gambar 4.6. Hyperparameter Layer Metode LSTM.....	64
Gambar 4.7 Grafik Model Loss	65
Gambar 4.8. Hyperparameter Layer Metode GRU	67
Gambar 4.9. Hyperparameter Epoch Metode LSTM.....	68
Gambar 4.10. Hyperparameter Epoch Metode GRU	70
Gambar 4.11. Hasil MAPE Metode GRU.....	70
Gambar 4.12. Hyperparameter Hidden Unit Metode LSTM	72
Gambar 4.13. Hasil MAPE Metode	72
Gambar 4.14 Hyperparameter Hidden Unit Metode GRU	74
Gambar 4.15. Hasil MAPE Metode GRU.....	74
Gambar 4.16. Optimizer Metode LSTM.....	77

Gambar 4.17. Hasil MAPE Metode LSTM	77
Gambar 4.18. Optimizer Metode GRU	80
Gambar 4.19. Hasil MAPE Metode GRU	80
Gambar 4.20. Normalisasi Metode LSTM.....	82
Gambar 4.21. Hasil MAPE Metode LSTM	83
Gambar 4.22. Normalisasi Metode GRU.....	85
Gambar 4.23. Hasil MAPE Metode GRU.....	85



INTISARI

Perdagangan mata uang asing senilai triliunan dolar terjadi setiap hari di pasar forex, ditandai dengan pergerakan yang sangat fluktuatif. Pasar forex beroperasi pada harga bid dan ask, dengan nilai tukar ditentukan oleh prinsip-prinsip penawaran dan permintaan. Perdagangan melibatkan pasangan mata uang seperti EURUSD dan AUDCAD, di mana nilai Euro dibandingkan dengan Dolar AS, berfungsi sebagai dasar untuk menganalisis fluktuasi harga. Karena sifat forex yang mudah berubah, pelaku pasar harus membuat keputusan berdasarkan informasi saat membeli dan menjual, karena pilihan yang tidak tepat dapat mengakibatkan kerugian finansial. Salah satu pendekatan untuk mengurangi risiko dalam keputusan trading forex adalah melalui penggunaan teknik peramalan.

Pengumpulan data yang digunakan dalam penelitian ini menggunakan data primer yang diperoleh dari website berita pasar keuangan global yaitu Investing.com. Rentang waktu data yang akan digunakan selama dua puluh tahun dimulai dari Januari 2003 hingga Januari 2023 dengan Timeline data harian. Model latihan akan diujikan pada data training. Dalam proses training dan testing peneliti menerapkan 3 layer, batch size 128, dan optimizer adam.

Studi penelitian ini menggunakan metode LSTM dan GRU untuk memprediksi tren forex, yang dievaluasi menggunakan berbagai divisi dataset. Hasil yang paling akurat diperoleh dengan menggunakan dataset 10,436, untuk pengujian. Pendekatan ini menghasilkan nilai yang paling baik dalam RMSE 0,106, MAPE 7.7%, dan R-square 98,5% pada mata uang EURUSD dengan metode GRU.

Kata kunci: Forex, Prediction, LSTM, GRU, RMSE, MAPE

ABSTRACT

Trillions of dollars' worth of foreign currency trading occurs daily in the forex market, characterized by highly volatile movements. The forex market operates on bid and ask prices, with exchange rates determined by the principles of supply and demand. Trading involves currency pairs such as EURUSD and AUDCAD, where the value of the Euro is compared to the US Dollar, serving as a basis for analyzing price fluctuations. Due to the volatile nature of forex, market participants must make informed decisions when buying and selling, as improper choices can result in financial losses. One approach to reducing risk in forex trading decisions is through the use of forecasting techniques.

The data collection used in this study used primary data obtained from the global financial market news website, Investing.com. The data time span to be used for twenty years starts from January 2003 to January 2023 with a daily data timeline. The training model will be tested on the training data. In the training and testing process, researchers applied 3 layers, batch size 128, and Adam optimizer.

This research study uses LSTM and GRU methods to predict forex trends, which are evaluated using various division datasets. The most accurate results were obtained using a dataset of 10,436, for testing. This approach yields the best values in RMSE 0.106, MAPE 7.7%, and R-square 98.5% on EURUSD currency with the GRU method.

Keyword: Forex, Prediction, LSTM, GRU, RMSE, MAPE

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

The foreign exchange (FOREX) adalah pasar pertukaran mata uang terbesar di dunia. Aktivitas perdagangan mata uang asing triliunan dolar per hari. Pasar forex memiliki pergerakan sangat fluktuatif dalam perdagangan mata uang asing. Pasar forex buka 24 jam sehari, tetapi perdagangan terjadi berdasarkan empat zona waktu utama: zona Australia, Zona Asia, Zona Eropa, dan Zona Amerika Utara di mana masing-masing zona ini zona memiliki jam buka dan jam tutupnya sendiri. Perdagangan berdasarkan harga bid dan ask. Pasar menentukan nilai tukar mata uang asing berdasarkan aturan penawaran dan permintaan. Di ketentuan perdagangan, forex sedikit berbeda dari saham (Hu et al., 2018). Dalam bursa saham, saham perusahaan dapat dibeli dan dijual ketika harga naik. Sedangkan dalam perdagangan FOREX, perdagangan pendek menjadi mungkin di mana keuntungan dihasilkan bahkan jika harga turun (Dash, 2018). Pasar forex adalah salah satu yang paling rumit karena memiliki karakteristik volatilitas tinggi, non linieritas, dan ketidakteraturan. Pasar forex tidak dikendalikan oleh satu lembaga atau organisasi, yang membuatnya sangat fluktuatif dan sulit diprediksi karena prediksi forex mana yang menjadi masalah yang sangat menantang (Henriquez & Kristjanpoller, 2019).

Prediksi adalah usaha menduga atau memperkirakan sesuatu yang akan terjadi di waktu mendatang dengan memanfaatkan berbagai informasi yang relevan

pada waktu-waktu sebelumnya (historis) melalui suatu metode ilmiah. Tujuan dari prediksi adalah mendapatkan informasi apa yang akan terjadi di masa datang dengan probabilitas kejadian terbesar (Wanto & Windarto, 2017).

Memprediksi pasar forex telah menjadi minat utama para peneliti selama beberapa terakhir dekade. Salah satu mekanisme terpenting yang diterapkan ke pasar adalah leverage. Berbeda dengan pasar reguler seperti pasar saham, pasar valuta asing tidak perlu memiliki jumlah yang besar uang. Dalam definisi paling sederhana, leverage memungkinkan pembukaan posisi pada pasangan mata uang apa pun yang hanya memiliki perlindungan modal parsial. Pendekatan semacam itu merupakan fasilitas yang cukup besar bagi orang-orang dengan modal kecil. Selain itu fitur terpenting dari pasar forex yang menarik investor kecil dan swasta (Islam & Hossain, 2021). Metode dalam menganalisis pasar forex yang menjadi utama dalam fundamental dan teknik analisis yang bergantung pada berita forex untuk mengetahui trend dalam pasar, seperti tingkat inflasi, suku bunga, dan pertumbuhan ekonomi (Henriquez & Kristjanpoller, 2019).

Penerapan metode LSTM sangat efektif dalam melakukan prediksi (Yıldırım et al., 2021). (Ahmed et al., 2020) Dalam penelitian ini dilakukan prediksi forex pada mata uang EURUSD dengan menggunakan metode LSTM. Hasil prediksi ditemukan nilai error sebesar 19,19%. (Islam & Hossain, 2021) Penelitian ini memprediksi harga forex dengan menggunakan metode yaitu GRU dan LSTM. Lapisan pertama dari model yang diterapkan yaitu GRU dengan 20 neuron dan lapisan kedua dengan LSTM dengan 256 neuron. dalam penerapan terdapat empat pasang mata uang utama yaitu EURUSD, GBPUSD, USDCAD dan USDCHF.

Waktu yang digunakan untuk memprediksi yaitu selama 10 menit dengan jangka waktu data 1 Januari 2017 sampai dengan 31 Desember 2018 dan jangka waktu 30 menit menggunakan data dari 1 Januari 2019 hingga 30 Juni 2020. Model validasi menggunakan skor MSE, RMSE, MAE dan R2.

Dalam penelitian (Zeng & Khushi, 2020) mereka menerapkan metode Long Short-Term Memory (LSTM) dalam konteks analisis mata uang USDJPY dengan menggunakan timeframe lima menit. Hasil dari penelitian ini menunjukkan bahwa nilai Root Mean Square Error (RMSE) yang diperoleh adalah sebesar 0.08878. Pentingnya mencatat bahwa dalam penelitian ini, mereka juga memanfaatkan teknik normalisasi min-max scaler, yang membantu dalam mengubah rentang nilai data menjadi skala yang lebih terukur dan mendukung kinerja model LSTM dalam memprediksi pergerakan harga mata uang tersebut. Hasil ini memberikan wawasan berharga tentang efektivitas penggunaan LSTM dalam analisis forex dengan interval waktu lima menit dan pentingnya normalisasi data. Pada tahun selanjutnya penelitian yang dilakukan oleh (Chantarakasemchit & Nuchitprasitchai, 2021) mereka melibatkan prediksi harga forex dengan membandingkan tiga metode yang berbeda, yaitu Linear Model (LM), MultiLayer Perceptron (MLP), dan Recurrent Neural Networks (RNN). Hasil yang dihasilkan dari metode RNN dalam penelitian ini sangat mencolok, dengan nilai Mean Square Error (MSE) sebesar 0.0000195. MSE yang rendah ini menunjukkan bahwa model RNN mampu melakukan prediksi harga forex dengan tingkat kesalahan yang sangat kecil, sehingga menjadikannya metode yang menarik untuk dijadikan acuan dalam analisis prediksi harga mata uang. Temuan ini memberikan pandangan penting

tentang potensi kekuatan model RNN dalam mengatasi tugas prediksi harga forex. Pada penelitian yang dilakukan oleh (Hansun et al., 2022) mereka menerapkan metode Bidirectional Long Short-Term Memory (Bi-LSTM) untuk melakukan prediksi harga mata uang. Mata uang yang menjadi fokus penelitian meliputi EURUSD, GBPUSD, USDCHF, dan USDJPY. Hasil penelitian ini mencatat bahwa metode Bi-LSTM berhasil menghasilkan hasil prediksi dalam konteks evaluasi model, nilai Root Mean Square Error (RMSE) yang diperoleh adalah sebesar 0.3068, yang menunjukkan bahwa kesalahan prediksi dalam bentuk nilai absolut relatif kecil. Selain itu, Mean Absolute Error (MAE) sebesar 0.2744 mengindikasikan tingkat kesalahan prediksi dalam bentuk nilai absolut yang juga rendah. Selanjutnya, nilai R-square sebesar 89.55 menunjukkan sejauh mana model ini cocok dengan data aktual.

Penelitian yang dilakukan (Kasus et al., 2019) Dalam penelitian yang dilakukan oleh Kasus dkk. pada tahun 2019, mereka menggunakan metode ARIMA untuk melakukan prediksi harga mata uang GBPUSD dalam periode waktu selama lima tahun. Hasil dari penelitian ini menunjukkan bahwa nilai Mean Absolute Percentage Error (MAPE) yang diperoleh adalah sebesar 3.16%. MAPE yang relatif rendah ini mengindikasikan bahwa metode ARIMA mampu memberikan prediksi harga GBPUSD dengan tingkat kesalahan yang relatif kecil dalam bentuk persentase dari nilai aktual. Temuan ini menggarisbawahi kemampuan ARIMA dalam mengatasi analisis pergerakan harga mata uang dengan jangka waktu yang panjang, dan memberikan wawasan berharga bagi para pelaku pasar dalam pengambilan keputusan investasi. Pada tahun selanjutnya penelitian yang

dilakukan oleh (Son, 2020) memperkenalkan pendekatan yang lebih kompleks dengan menggabungkan model ARIMA dan FIR (Finite Impulse Response) yang memanfaatkan parameter waktu yang bervariasi. Pendekatan ini juga memasukkan komponen Principal Component Analysis (PCA) dalam upaya untuk meningkatkan akurasi prediksi. Hasil dari model hybrid ini menunjukkan nilai Mean Absolute Percentage Error (MAPE) sebesar 4.31998. Penelitian yang dilakukan oleh (Tlegenova, 2015) Penelitian ini menerapkan model ARIMA dalam melakukan prediksi dengan menggunakan data time series tahunan dari tahun 2006 hingga 2014. Mata uang yang menjadi objek prediksi meliputi USD/KZT, EUR/KZT, dan SGD/KZT. Pendekatan ini memanfaatkan analisis deret waktu untuk membandingkan data aktual dengan hasil prediksi yang dihasilkan oleh model ARIMA. Hasil dari penelitian ini menunjukkan bahwa prediksi terbaik diperoleh untuk mata uang SGD/KZT. Hasil tersebut tercermin dalam beberapa metrik evaluasi, di antaranya Mean Absolute Error (MAE) sebesar 3.692546, Mean Absolute Percentage Error (MAPE) sebesar 3.689833, dan Root Mean Square Error (RMSE) sebesar 4.202989.

Pasar forex pertukaran mata uang terbesar di dunia yang memiliki aktivitas perdagangan mata uang asing triliunan dolar per hari dengan pergerakan sangat fluktuatif dalam perdagangan, dengan menggunakan parameter naik turun nilai dari mata uang yang dijual belikan dalam pasar forex. Pada permasalahan yang terdapat dari penjelasan yang diatas, maka peneliti ingin melakukan meningkatkan akurasi prediksi harga forex dengan Mengoptimalkan algoritma Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) dalam memprediksi mata uang asing dari

pasar forex dengan beberapa faktor yang berhubungan dalam mata uang itu sendiri. Hasil yang diharapkan dari penelitian ini dapat dimanfaatkan untuk penelitian yang berhubungan dalam algoritma yang digunakan dalam prediksi nilai dari mata uang.

1.2. Rumusan Masalah

Rumusan masalah penelitian ini dapat dijabarkan sebagai berikut;

- a. Berapa nilai eror yang dihasilkan dengan menggunakan metode Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) yang diterapkan pada Forex?
- b. Faktor yang mempengaruhi error prediksi pada metode Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) yang diterapkan pada Forex?
- c. Bagaimana mengoptimalkan kinerja prediksi harga forex dengan Mengoptimalkan metode Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) yang diterapkan pada Forex

1.3. Batasan Masalah

Agar penelitian ini terarah dan pembahasan menjadi relevan, maka diberikan batasan-batasan dan ruang lingkup sebagai berikut;

- a. Memprediksi Forex menggunakan metode Long Short-Term Memory dan Gated Recurrent Unit. Asumsi-asumsi yang digunakan sebagai dasar untuk melaksanakan penelitian.
- b. Data yang digunakan merupakan data mata uang mayor dan minor yaitu EURUSD dan AUDCAD.
- c. Rentang waktu data yang digunakan mulai Januari 2003 hingga Januari 2023 dengan Timeline data harian.

- d. Penerapan metode menggunakan Google Collab untuk melakukan pelatihan, pengujian dan kebutuhan visualisasi data dengan bahasa pemrograman python.
- e. Penerapan library keras pada Google Collab.
- f. Digunakan 2 pembagian data training dan testing yaitu 80/20 dan 70/30 untuk mengetahui hasil yang diperoleh.
- g. Performa evaluasi metode yang digunakan dalam penelitian ini yaitu Mean Absolute Percentage Error (MAPE), R – Square, dan RMSE.
- h. Penerapan optimasi kinerja pada metode yang di terapkan akan berfokus pada hasil error yang di hasilkan.
- i. Mengoptimalkan kinerja prediksi harga forex dengan Mengoptimalkan metode Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) yang diterapkan pada Forex

1.4. Tujuan Penelitian


Tujuan dari penelitian ini adalah untuk mengetahui performa dan mengoptimalkan dari metode LSTM dan GRU yang digunakan dalam memprediksi Forex dengan melakukan evaluasi performa terhadap algoritma dalam memprediksi mata uang asing dari pasar forex.

1.5. Manfaat Penelitian

Bagian ini memuat penjelasan tentang:

- a. Dapat menjadi pedoman pengembangan penelitian dalam bidang prediksi menggunakan metode yang digunakan bukan hanya dalam harga forex juga dapat digunakan dalam memprediksi harga lainnya.

- b. Hasil dari prediksi harga ini diharapkan dapat menjadi bahan evaluasi bagi penelitian selanjutnya.
- c. Hasil dari prediksi ini membuat strategi trading dari aset yang dikelola, dan juga pembuatan website dengan memanfaatkan metode yang digunakan untuk membantu para investor dalam memprediksi harga forex.



BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Penelitian ini mengacu pada beberapa referensi penelitian yang telah dilakukan penelitian – penelitian sebelumnya. Referensi tersebut yang nantinya akan digunakan sebagai landasan dalam melakukan sebuah penelitian. Berikut penelitian terdahulu yang relevan dengan penelitian yang akan dilakukan.

Penelitian yang dilakukan oleh (Qi et al., 2020) Penelitian ini memiliki tujuan utama dalam melakukan prediksi pergerakan mata uang forex dengan memanfaatkan tiga metode yang berbeda, yaitu Long Short-Term Memory (LSTM), Bidirectional Long Short-Term Memory (Bi-LSTM), dan Gate Recurrent Unit (GRU). Rentang waktu yang digunakan sangat luas, mencakup periode 15 tahun, yang memungkinkan analisis yang mendalam terhadap data historis. Mata uang yang menjadi subjek prediksi dalam penelitian ini mencakup pasangan mata uang GBPUSD, EURGBP, AUDUSD, dan CADCHF, yang merupakan representasi dari pasangan mata uang utama. Pada tahap evaluasi, penelitian ini mempertimbangkan beberapa metrik yang mencakup Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE), dan Root Mean Square Error (RMSE). Metrik-metrik ini memberikan pemahaman holistik tentang sejauh mana model-model yang diuji berhasil dalam memprediksi pergerakan harga mata uang dengan akurat. Hasil yang dihasilkan dalam

(WIJESINGHE, 2020) melakukan penelitian dengan menggunakan metode LSTM dan ARIMA untuk memprediksi forex dengan menggunakan data yang di dapat dari Quandl API, data yang digunakan yaitu mata uang USD CAD, GRB USD, AUD USD dengan jangka waktu 26 tahun yaitu dari 1 januari 1993 sampai 29 maret 2019. Pembagian dataset yang digunakan 90% untuk data training dan 10% untuk data validasi. Peneliti melakukan 2 skenario dalam menguji metode dengan menggunakan time series 1 hari dan 5 hari. Nilai error terkecil yang diperoleh yaitu pada mata uang GRB USD dengan RMSE 0.00286 pada skenario 1 hari dengan menggunakan metode LSTM.

(Sarangi et al., 2020) melakukan penelitian FOREX trend analysis using machine learning techniques: INR vs USD currency exchange rate using ANN-GA hybrid approach. Data yang digunakan dengan jangka waktu 36 hari antara agustus sampai september 2019 dengan menggunakan mata uang INR/USD. Model yang digunakan untuk melakukan prediksi menggunakan 2 model yaitu ANN dan ANN-GA yang menghasilkan RMSE 0.39 dan 0.018930.

Pada penelitian (Ulina et al., 2020) membandingkan model yang LSTM dan CEEMDAN-LSTM. Pada mata uang AUD/USD dengan menggunakan hidden layer 32 dan batch size 50 dengan nilai dropout 0.04. Menghasilkan nilai RMSE 0.009546 dan MAPE 0.612705.

(Abedin et al., 2021) melakukan penelitian prediksi dengan menggunakan 21 mata uang USD dengan menerapkan metode LSTM and Bi-LSTM. Data yang digunakan dalam melakukan prediksi rentang waktu 3 januari 2000 sampai 31

December 2019 dengan pembagian data 80:20. Hasil yang paling bagus pada mata uang SGD/USD dengan nilai RMSE 0.0025.


(Lu, 2022) melakukan penelitian mengenai peramalan nilai tukar GBP / CNY dengan menggunakan tiga metode yaitu LSTM, ARIMA dan GRU. Waktu nilai tukar yang digunakan GBP / CNY dari 31 Januari 2020 hingga 30 September 2021 dan membandingkan hasilnya dengan ARIMA dan GRU. Hasil yang terbaik dengan menggunakan metode LSTM dengan hasil RMSE 0.04268.

(Cabrera, 2019) melakukan penelitian forecasting forex dengan menggunakan model ARIMA, RNN dan LSTM. Penelitian ini menggunakan dataset yang berasal dari kaggle dengan range waktu Januari 2016 sampai Juli 2017 dengan data training 70% dan data testing 30%. Mata uang yang digunakan USDCNY, USDEUR, USDJYP dan USDGBP. Hasil yang paling bagus dalam 3 model yaitu ARIMA dengan hasil MSE 0.00024910 dengan mata uang USDCNY.

(Escudero et al., 2021) melakukan penelitian menganalisis perilaku masa depan pasangan mata uang dengan cara forecasting. Data yang digunakan yaitu EUR / USD dengan menggunakan tiga metode dalam uji coba yaitu LSTM, RNN dan ARIMA dengan menggunakan rentang waktu 2 Januari 1998 hingga 2019. Hasil yang terbaik dalam menggunakan metode ini yaitu LSTM dengan RMSE 0.001808.

Penelitian yang dilakukan oleh (Wijaya et al., 2021) fokus pada prediksi pergerakan mata uang forex dengan menerapkan metode Long Short-Term Memory (LSTM). Dalam penelitian ini, hasil yang paling baik pada pasangan mata uang EURUSD. Hasil prediksi yang dihasilkan mencatat nilai Mean Squared Error

(MSE) sebesar 0.0545. MSE yang rendah ini mengindikasikan bahwa prediksi pergerakan harga mata uang EURUSD memiliki tingkat kesalahan yang relatif kecil dalam bentuk nilai kuadrat dari selisih antara nilai aktual dan nilai prediksi. Penerapan model LSTM dengan satu lapisan (1 layer) serta penggunaan optimizer Adam memberikan hasil yang baik dalam hal evaluasi model.



2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian
Prediksi Harga Forex Menggunakan Algoritma Long ShortTerm Memory Dan Recurrent Unit

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	<i>Event-Driven LSTM For Forex Price Prediction</i>	Ling Qi, Matloob Khushi, Josiah Poon 2021	Mengembangkan fitur baru yang didapatkan dari peristiwa yang menunjukkan perubahan arah trend pada prediksi harga forex.	Membentuk sistem prediksi yang mendukung strategi trading yang akurat dengan risiko minimal. Model terbaik pada data interval 15 menit	Penelitian hanya menggunakan percobaan data dengan waktu interval 15 menit tanpa membandingkan dengan interval waktu yang lebih lama.	Penelitian menggunakan rentang waktu yang pendek dengan menggunakan interval waktu 15 menit. Penelitian ini akan menggunakan prediksi dengan menggunakan interval waktu yang lebih lama.
2	<i>Time Series Forecasting Analysis of LSTM Neural Networks to Predict Exchange Rates of Currencies</i>	Samith Wijesinghe 2020	Penelitian dengan menggunakan metode LSTM dan ARIMA untuk memprediksi forex dengan menggunakan data yang di dapat dari Quandl API,	Peneliti melakukan 2 skenario dalam menguji metode dengan menggunakan time series 1 hari dan 5 hari. Nilai error terkecil yang diperoleh yaitu pada mata uang GRB USD dengan RMSE 0.00286 pada skenario 1 hari dengan menggunakan metode LSTM.	Peneliti hanya menggunakan pembagian data 90% untuk traning dan 10% validasi	Peneliti hanya menggunakan pembagian data 90% untuk traning dan 10% validasi Penelitian ini akan melakukan prediksi dengan menambah pembagian data dari 80/20 dan 70/30/

Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	FOREX trend analysis using machine learning techniques: INR vs USD currency exchange rate using ANN-GA hybrid approach	Pradeepa Kumar Sarangi, Muskaan Chawla, Pinaki Ghosh, Sunny Singh, P.K. Singh 2020	Penelitian FOREX trend analysis using machine learning techniques: INR vs USD currency exchange rate using ANN-GA hybrid approach. Data yang digunakan dengan jangka waktu 36 hari antara agustus sampai september 2019 dengan menggunakan mata uang INR/USD	Model yang digunakan untuk melakukan prediksi menggunakan 2 model yaitu ANN dan ANN-GA yang menghasilkan RMSE 0.39 dan 0.018930.	Menambahkan lebih banyak percobaan dengan menggunakan mata uang lain untuk menjadi perbandingan	Peneliti menggunakan satu percobaan mata uang untuk menghasilkan RMSE dari metode yang digunakan Pada penelitian ini akan menambahkan lebih banyak mata uang untuk menguji metode yang digunakan
4	Foreign Exchange Prediction using CEEMDAN and Improved FA-LSTM	Mustika Ulina, Ronsen Purba, and Arwin Halim 2021	Penelitian memprediksi berbagai mata uang salah satunya AUD/USD dengan menggunakan LSTM dan CEEMDAN-LSTM.	Model yang digunakan LSTM dan CEEMDAN-LSTM dengan menggunakan hidden layer 32 dan batch size dengan nilai dropout 0.04. Menghasilkan nilai RMSE 0.009546 dan MAPE 0.612705	Penelitian tidak melakukan beberapa percobaan skenario dalam perbandingan hidden layer, batch size dan dropout	Penelitian ini akan melakukan beberapa scenario dalam menurunkan nilai error dengan cara menambah hidden layer, batch size dan dropout.

Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
5	The Long Short-Term Memory of GBP/CNY Exchange Rate Forecasts	Changhui Lu 2022	Penelitian mengenai forecasting dengan menggunakan Metode LSTM, ARIMA dan GRU dengan menggunakan GBP / CNY dari 31 januari 2020 hingga 30 september 2021.	Dalam prediksi bitcoin dengan menggunakan model LSTM, ARIMA dan GRU. Hasil terbaik dalam penelitian ini menggunakan model LSTM dengan hasil RMSE 0.04268	Dalam penelitian ini menggunakan rentang waktu yang cukup pendek dalam uji coba metode yang digunakan	Dalam penelitian ini akan mencoba melakukan beberapa scenario dalam forecasting menggunakan rentang waktu yang lebih lama dari penelitian sebelumnya.
6	Application of ARIMA, RNN and LSTM on Foreign Exchange Rate Prediction	Fang Cabrera 2019	Melakukan penelitian forecasting forex menggunakan model ARIMA, RNN dan LSTM. Penelitian ini menggunakan dataset yang berasal dari kaggle dengan range waktu januari 2016 sampai juli 2017 dengan data training 70% dan data testing 30%. Mata uang yang	Hasil yang paling bagus dalam 3 model yaitu ARIMA dengan hasil MSE 0.00024910 dengan mata uang USDCNY.	Penelitian hanya menggunakan satu scenario testing dan training data yaitu 70% dan 30%	Dalam penelitian ini akan melakukan beberapa scenario dalam mengujian data testing dan training,

Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
			digunakan USD / CNY, USD / EUR, USD/JPY dan USD /GBP.			
7	Recurrent Neural Networks and ARIMA Models for Euro/Dollar Exchange Rate Forecasting	Pedro Escudero, Willian Alçocer and Jenny Paredes 2021	Melakukan penelitian forecasting mata uang dengan cara. Data yang digunakan yaitu EUR / USD dengan menggunakan tiga metode dalam uji coba yaitu LSTM, RNN dan ARIMA dengan menggunakan rentang waktu 2 januari 1998 hingga 2019.	Dalam menggunakan tiga metode dalam uji coba Hasil yang terbaik dalam menggunakan metode ini yaitu LSTM dengan RMSE 0.001808.	Peneliti hanya menggunakan 1 variabel dalam melakukan forecasting	Peneliti menggunakan satu variable yaitu untuk dilakukan melakukan forecasting EUR / USD Pada penelitian ini akan Menggunakan 2 variabel atau data histori lengkap dari nilai mata uang EUR / USD dan AUD / CAD
8	Deep learning-based exchange rate prediction during the COVID-19 pandemic	Mohammad Zoydul Abedin, Mahmudul Hasan Moon,	Peneliti melakukan prediksi 21 mata uang USD dengan menerapkan LSTM dan Bi-LSTM	Hasil dari pengujian dengan pembagian data 80:20 hasil yang paling bagus terdapat pada mata uang SGD/ USD	Peneliti hanya menggunakan RMSE dalam mengevaluasi model yang digunakan	Penelitian ini akan menambahkan metrik evaluasi model seperti MAPE dan R square.

Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
		M. Kabir Hassan and Petr Hajek 2021	dengan rentang waktu 3 januari sampai 31 december 2019.	dengan nilai RMSE 0,0025.		
9	Prediksi harga <i>forex exchange</i> mata uang EUR/USD dan GBP/USD menggunakan <i>long short-term memory</i>	Wijaya et al., 2021	fokus pada prediksi pergerakan mata uang forex dengan menerapkan metode Long Short-Term Memory (LSTM). Dalam penelitian ini, hasil yang paling baik pada pasangan mata uang EUR/USD.	Hasil prediksi mencatat nilai Mean Squared Error (MSE) sebesar 0.0545. MSE yang rendah ini mengindikasikan bahwa prediksi pergerakan harga mata uang EUR/USD memiliki tingkat kesalahan yang relatif kecil dalam bentuk nilai kuadrat dari selisih antara nilai aktual dan nilai prediksi. Penerapan model LSTM dengan satu lapisan (1 layer) serta penggunaan optimizer Adam memberikan hasil yang baik dalam hal evaluasi model.	Pada tahap pengujian hasil yang terbaik pada penggunaan satu layer tanpa menguji beberapa layer untuk menghasilkan nilai error yang paling baik.	Pada penelitian ini akan mengujian beberapa layer untuk menghasilkan nilai error yang paling baik dan menggunakan optimizer adam untuk menghasilkan nilai yang baik.

2.3. Landasan Teori

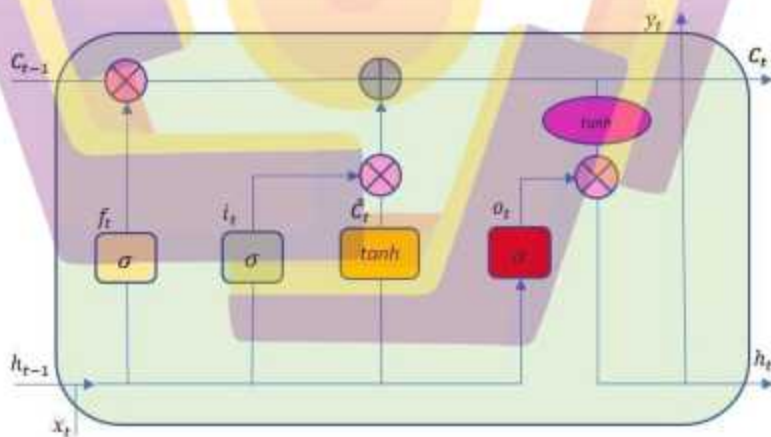
Bagian Forex atau foreign exchange adalah pasar keuangan terbesar di dunia. Pertumbuhan yang cepat dalam pasar mata uang telah membawa keuntungan tinggi dan risiko tinggi pada waktu yang sama. Pasar valuta asing berubah secara tidak teratur dari waktu ke waktu, dengan aturan internasional yang cepat berubah dan kebijakan yang sesuai, ada banyak faktor yang mempengaruhi fluktuasi nilai tukar mata uang (Rana et al., 2021). Berbagai jenis data deret waktu non-stasioner, perdagangan keuangan data sangat fluktuatif dan kompleks. Analisis dapat membantu mengidentifikasi tren dan sekarang menjadi lebih populer dalam riset perdagangan. Selain itu, berdasarkan pada teori "sejarah yang berulang", para analis percaya pola yang mendasari data historis akan berulang lagi di masa depan dan mampu mengidentifikasi pergerakan harga historis penting untuk prediksi tren harga di masa depan. Penggunaan data historis dan indikator teknis diperlukan untuk pemeriksaan yang efektif dari tren yang terjadi dalam waktu yang diinginkan dalam perdagangan valuta asing (Qi et al., 2020).

Unit Gated Recurrent adalah Recurrent Jaringan syaraf yang memiliki struktur yang tidak terlalu rumit. Itu tidak memiliki gerbang keluaran tetapi memiliki pembaruan z dan gerbang reset r . Gerbang ini adalah vektor yang memutuskan apa informasi harus diteruskan ke output. Gerbang Reset menentukan cara menggabungkan input baru dengan memori sebelumnya. Definisi berapa banyak memori terakhir untuk menjaga dilakukan dengan Update (Yamak et al., 2019).

2.3.1. Metode Long Short-Term Memory (LSTM)

Long Short-Term Memory atau LSTM merupakan model yang populer dengan kekuatan menangani kesenjangan ukuran yang tidak diketahui antara sinyal dalam kebisingan data. LSTM dikembangkan akhir tahun 1990 oleh Sepp ochreiter dan Jurgen Schmidhuber. LSTM bersifat unioversal sehingga ketika unit jaringan cukup tersedia, apapun data dihitung computer dengan asumsi ketika memiliki matriks bobot yang dikalibrasi dengan benar (Puspita, 2022).

LSTM merupakan varian dari RNN yang berisi sel memori di dalamnya. Setiap neuron LSTM terdiri dari empat sub neuron lain di dalamnya yang bertindak sebagai sel memori. Bobot dari sub-neuron ini membantu LSTM untuk mengingat urutan yang panjang. Sel LSTM original terdiri dari input gate dan output gate dapat dilihat pada Gambar 2.1.



Gambar 2.1. Arsitektur LSTM

$$\hat{i}_t = \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i) \quad (1)$$

$$\hat{c}_t = \tanh(W_{ch}h_{t-1} + W_{cx}x_t + b_c) \quad (2)$$

$$c_t = c_{t-1} + i_t \cdot \tilde{c}_t \quad (3)$$

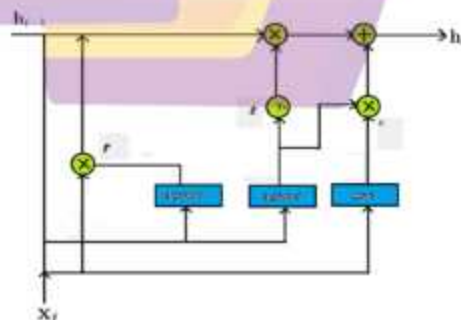
$$o_t = \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o) \quad (4)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (5)$$

c_t pada persamaan (2) merupakan status sel dari LSTM. W_i , W_c dan W_o pada persamaan (1), (2), dan (4) adalah bobot. “ \cdot ” Merupakan operator perkalian vector. Saat memperbarui status sel, gerbang input dapat memutuskan informasi baru apa yang dapat disimpan dalam status sel, dan gerbang keluaran memutuskan informasi apa yang dapat dikeluarkan berdasarkan status sel (Yu et al., 2021).

2.3.2. Unit Gated recurrent (GRU)

Unit Gated Recurrent adalah Recurrent Jaringan syaraf yang memiliki struktur yang tidak terlalu rumit. Itu tidak memiliki gerbang keluaran tetapi memiliki pembaruan z dan gerbang reset r . Gerbang ini adalah vektor yang memutuskan apa informasi harus diteruskan ke output. Gerbang Reset menentukan cara menggabungkan input baru dengan memori sebelumnya. Definisi berapa banyak memori terakhir untuk menjaga dilakukan dengan Update (Yamak et al., 2019).



Gambar 2.2. Diagram for GRU Cell

GRU memiliki yang berikut ini persamaan

$$\text{Update gate: } z = \sigma(Wzht-1 + Uzxt) \quad (6)$$

$$\text{Reset gate: } r = \sigma(Wrht-1 + Urxt) \quad (7)$$

$$\text{Cell state: } c = \tanh(Wc(ht-1 * r) + Ucxt) \quad (8)$$

$$\text{New state: } ht = (z * c) + ((1 - z) * ht-1) \quad (9)$$

2.3.3. Optimizer Adaptive Moment Estimation (ADAM)

Optimizer merupakan sebuah algoritma atau metode yang digunakan untuk memperbarui parameter dalam model saat training neural Network dengan tujuan mengoptimalkan kinerja model. Optimizer berperan penting dalam proses pelatihan model dengan mengarahkan model untuk menemukan nilai – nilai parameter yang memberikan hasil prediksi yang lebih baik (Doshi, 2019).

Rumus matematika untuk menghitung ADAM terdapat pada persamaan (10) sampai dengan persamaan (11)

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * \delta w^{old} \quad (10)$$

$$v_t = \beta_2 * v_{t-1} + (1 - \beta_1) * (\delta w^{old})^2 \quad (11)$$

Sebagai penjelasan dari persamaan diatas w^{new} merupakan bobot baru, dan w^{old} sebagai bobot lama. δw^{old} sebagai turunan bobot terhadap hasil error. V_t merupakan rata – rata turunan parsial, v_{t-1} sebagai bobot rata - rata turunan parsial sebelumnya. M_t merupakan bobot rata – rata momentum, m_{t-1} sebagai bobot rata –rata momentum sebelumnya. β_1 merupakan nilai beta.

β_2 merupakan nilai beta terhadap turunan parsial. ϵ sebagai epsilon dan λ sebagai learning rate (Maliki dkk., 2022). Optimizer ADAM telah terbukti efektif dalam melatih model neural networks dengan kecepatan konvergensi yang cepat dan kemampuan adaptasi yang terbaik terhadap dinamika gradien. Optimizer akan bekerja dengan sangat baik tergantung terhadap karakteristik tugas dan data yang sedang dihadapi.

2.3.4. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah cara umum dipergunakan untuk mengukur kesalahan model dari prediksi data yang bersifat kuantitatif. RMSE dipergunakan untuk mengetahui ukuran sebaran simpangan titik data dari garis regresi linier atau untuk mengetahui konsentrasi data di sekitar garis regresi linier (Satyo Bayangkari Karno et al., 2020).

Metode ini disebut *Root Mean Square Error (RMSE)* dimana semakin kecil nilai RMSE (semakin mendekati 0) maka hasil pengukuran akan semakin akurat (Dhanardono et al., 2022).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - f_i)^2} \quad (12)$$

n pada persamaan (12) jumlah data atau periode, A_i mewakili nilai aktual pada periode i , F_i mewakili nilai prediksi pada periode i .

2.3.5. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah kesalahan persentase absolut rata-rata, yang dimaksud dengan mean absolute percentage error adalah ukuran statistik dari keakuratan peramalan (*forecast*) dalam proses peramalan. Pengukuran *Mean Absolute Percentage Error (MAPE)* dapat digunakan oleh masyarakat umum karena MAPE mudah dipahami dan digunakan untuk memprediksi akurasi ramalan. Metode Mean Absolute Percentage Error memberikan informasi seberapa baik kesalahan perkiraan dibandingkan dengan nilai sebenarnya dari rangkaian tersebut (Khrisna Wardhani et al., 2022).

Untuk menghitung MAPE total keseluruhan dibuat dengan terlebih dahulu mengurangi nilai data aktual dari data perkiraan, kemudian membagi dengan data aktual dan dikalikan dengan 100, kemudian dibagi dengan jumlah data yang ada. Rumus *Mean Absolute Percentage Error (MAPE)* sebagai berikut:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100\% \quad (13)$$

A_i pada persamaan (13) mewakili nilai aktual, F_i mewakili nilai prediksi dan n mewakili ukuran sampel.

2.3.6. Koefisien Determinasi (R-Square)

R-Squared (atau koefisien determinasi) adalah ukuran evaluasi model statistik yang menilai kebaikan model regresi. Ini membantu analis data untuk menjelaskan model kinerja dibandingkan dengan model dasar. Nilainya terletak antara 0 dan 1. Nilai mendekati 0 mewakili model yang buruk sementara nilai di dekat 1 mewakili kecocokan yang sempurna. Terkadang, R-kuadrat menghasilkan

nilai negatif. Ini berarti model Anda lebih buruk daripada model dasar rata-rata. Koefisien Determinasi memberikan informasi terkait proporsi keragaman ataupun variasi total di sekitar nilai tengah Y yang dapat dijelaskan oleh model regresi yang digunakan.

Ukuran ini sering dinyatakan dalam persentase dengan mengalikannya dengan 100. Persamaan yang dapat digunakan untuk menghitung koefisien determinasi ini dijelaskan pada persamaan (14).

$$R^2 = 1 - \frac{RSS}{TSS} \quad (14)$$

Keterangan untuk persamaan (14) yaitu RSS adalah jumlah kuadrat residual atau jumlah kuadrat yang dijelaskan oleh regresi. TSS adalah jumlah kuadrat total. Kisaran nilai R^2 di antara 0 hingga 1 ($0 \leq R^2 \leq 1$) jika dikalikan dengan 100 maka kisaran nilai R^2 0% hingga 100%. Sehingga semakin besar nilai R^2 maka semakin besar kemampuan model regresi yang digunakan menjelaskan keragaman data sampel. Sebagai contoh kasus jika nilai $R^2 = 0.85$, dapat diartikan variasi dalam variabel tak bebas Y yang disebabkan oleh variabel bebas X sebesar 85% mampu dijelaskan oleh model yang digunakan, sedangkan 15% lainnya disebabkan oleh variabel lainnya yang dinyatakan sebagai faktor galat atau error.

Landasan teori yang dipaparkan nantinya akan dimanfaatkan untuk menunjang teori selama penelitian berlangsung. Baik metode yang digunakan yaitu LSTM dan GRU, hingga evaluasi metode RMSE, MAPE dan R-Square akan digunakan semaksimal mungkin untuk melakukan optimasi metode LSTM dan GRU dalam prediksi harga forex.

BAB III

METODE PENELITIAN

Dalam penelitian ini, ada beberapa aspek penting yang perlu diperhatikan, termasuk pendekatan penelitian yang akan digunakan, metode yang akan diterapkan, dan langkah-langkah yang akan diambil dalam pengumpulan dan analisis data. Semua aspek ini akan berperan penting dalam menentukan arah dan hasil dari penelitian ini. Selain itu, dalam Gambar 3.1, terdapat sebuah K-Chart yang telah disusun berdasarkan temuan masalah yang telah diuraikan sebelumnya. K-Chart ini akan menjadi alat visual yang berguna dalam membantu memahami secara komprehensif seluruh aspek penelitian yang akan dilakukan. Dengan menggunakan K-Chart dapat dengan mudah melihat hubungan antara elemen-elemen kunci dalam penelitian dan bagaimana mereka saling terkait. Hal ini akan mempermudah pemahaman mengenai metodologi dan tujuan dari penelitian yang akan dilakukan, serta membantu dalam menjalankan penelitian sesuai dengan rencana yang telah ditetapkan.

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Penelitian ini termasuk dalam penelitian eksperimental. Pada penelitian ini melakukan pengumpulan dataset, pre-proses, pembagian data, proses training, proses testing dan penerapan beberapa metode. Hasil dari pengujian ini akan mencari nilai RMSE, MAPE, dan R-square. Dalam penelitian ini menggunakan metode kuantitatif pada data time series dari nilai mata uang dalam pasar forex.

Hasil akhir dari prediksi ini akan menampilkan dalam bentuk grafik hasil dari prediksi. Hasil dari nilai RMSE untuk nilai error terkecil dapat digunakan sebagai landasan dalam faktor apa saja yang mempengaruhi nilai performa yang dihasilkan kedua metode yang diterapkan pada Forex. MAPE untuk mengukur seberapa akurat model yang diterapkan dalam penerapan pada forex. R square untuk mengukur seberapa baik model regresi yang digunakan dengan data yang digunakan.

3.2. Metode Pengumpulan Data

Pengumpulan data yang digunakan dalam penelitian ini menggunakan data primer yang diperoleh dari website berita pasar keuangan global yaitu Investing.com. Rentang waktu data yang akan digunakan selama dua puluh tahun dimulai dari Januari 2003 hingga Januari 2023 dengan Timeline data harian. Data yang digunakan dalam melakukan prediksi yaitu EURUSD dan AUDCAD dengan menggunakan price rata-rata harga pada hari itu, dengan mempertimbangkan ciri-ciri sebagai berikut ;

1. Price: Rata-rata harga pada hari itu.
2. Open: Pembukaan harga di hari itu.

3. Close: Penutupan harga di hari itu.
4. High: Harga tertinggi di hari itu.
5. Low: Harga terendah di hari itu.
6. Volume: Volume koin yang diperdagangkan hari itu.

Data yang digunakan dalam penelitian ini bersifat backward karena dalam penelitian ini akan menghasilkan jarak antara data yang digunakan dengan hasil prediksi. Data backward memungkinkan model LSTM dan GRU untuk mengakses informasi masa depan dan masa lalu secara bersamaan, sehingga memperkaya pemahaman tentang konteks urutan data.

Data yang dikumpulkan akan diproses menjadi beberapa *timeline* yang akan digunakan dalam pengujian dan dibagi menjadi beberapa *timeline* data yang akan menghasilkan nilai prediksi yang maksimal

3.3. Metode Analisis Data

Setelah mendapatkan data yang akan di analisis peneliti melakukan preprocessing dengan google collabs dengan pengecekan data, menghitung data dataset. Penerapan library keras akan diterapkan pada model ini karena modularitas dan fleksibilitas keras mudah membangun arsitektur LSTM yang kompleks dengan memadukan berbagai lapisan dan fungsi aktivitas. Dari beberapa library, keras juga dapat mendukung beberapa arsitektur seperti GRU. Fitur yang terdapat library keras seperti, regularisasi, dropout, initializers, optimizers, dan banyak lagi. Ini memungkinkan peneliti untuk melakukan eksperimen dengan berbagai konfigurasi dan teknik untuk meningkatkan performa model LSTM dan

GRU. Data yang sudah melakukan proses preprocessing kemudian akan dibagi menjadi data training dan data testing. Setelah pembagian data maka akan melakukan pengujian dengan dengan model yang akan ditentukan yang akan menghasilkan nilai error terkecil dan mengevaluasi data yang digunakan dalam analisis regresi untuk mengukur seberapa baik model regresi cocok dengan data yang yang digunakan.

Dalam proses pengujian menggunakan metode LSTM dan GRU, akan dilakukan proses pengujian timeline dalam beberapa percobaan data untuk harga mata uang di pasar forex per-satu tahun, per-lima tahun, per-sepuluh tahun dan per-dua puluh tahun. Hal ini dilakukan untuk menjadi perbandingan penerapan metode yang digunakan pada harga Forex yang dapat menghasilkan baik atau sebaliknya

3.4. Alur Penelitian

Pada penelitian ini menerapkan beberapa tahapan utama diantaranya sebagai berikut:

1. Pengumpulan data

Data yang digunakan dalam penelitian termasuk data primer diperoleh dari website berita pasar keuangan global yaitu Investing.com. Rentang waktu data yang akan digunakan selama dua puluh tahun dimulai dari Januari 2003 hingga Januari 2023 dengan jumlah data 5,001 data per pair mata uang di pasar Forex. Jika diakumulasikan keseluruhan sekitar 10,002 data. Data yang sudah dikumpulkan akan dilakukan proses pengurutan data berdasarkan tanggal untuk mempermudah proses load data pada tahapan preprocessing. dilakukan proses pengurutan data

berdasarkan tanggalnya untuk memudahkan proses load data pada tahapan pre – processing nantinya.

2. Load data

Pada proses load data ini akan dilakukan pemanggilan data dari sumber eksternal ke dalam program yang akan digunakan. Data dimuat berupa teks data terstruktur dalam format basis data. Kedua metode akan melewati tahapan ini dengan meload empat dataset yang telah dipisahkan berdasarkan rentang data per tahunnya.

3. Pre – processing

Dalam tahapan preprocessing dengan menyiapkan data yang akan diuji dengan model yang sudah ditentukan. Penerapan library keras akan diterapkan pada model ini karena modularitas dan fleksibilitas keras mudah membangun arsitektur LSTM yang kompleks dengan memadukan berbagai lapisan dan fungsi aktivitas. Dari beberapa library, keras juga dapat mendukung beberapa arsitektur seperti GRU. Pada penelitian ini processing dimulai dari load data untuk memastikan data yang sudah didapatkan udah tersusun dengan baik. Memisahkan data training dan data testing untuk melakukan evaluasi yang akurat terhadap model yang akan digunakan, setelah melakukan pemisahan data akan di lakukan normalisasi data yang berfungsi untuk memastikan data berbeda dalam rentang waktu yang sama dan dapat menghindari dominasi variable dengan skala yang lebih besar. Setelah melakukan normalisasi data maka peneliti akan melakukan konversi pada data dengan cara mengurutkan deret waktu yang digunakan dengan urutan yang sesuai dengan Panjang sekuensial yang di terapkan dalam penelitian. Data

yang tidak digunakan akan dilakukan drop data. Dalam metode LSTM dan GRU proses yang digunakan untuk preprocessing yang dilakukan adalah dengan cara min-max scaler. Setelah menampilkan data yang diperlukan langkah selanjutnya drop data yang tidak digunakan dalam proses pemodelan.

4. Split data

Data yang digunakan pada penelitian ini dibagi menjadi data testing dan training. Pembagian data yang akan digunakan sesuai dari hasil pengujian. Pada penelitian ini data yang dibagi menjadi 80/20 dan 70/30. Pembagian dataset dilakukan dengan pendekatan hold up, dimana dataset akan dibagi menjadi data training dan data testing diawal terlebih dahulu. Namun, pembagian dataset pada penelitian ini dilakukan secara urut berdasarkan urutan pada dataset. Dalam pengujian untuk mengetahui nilai performa yang terbaik peneliti melakukan beberapa skenario pengujian yang dibagi menjadi 4 timeline per-satu tahun, per-lima tahun, per-sepuluh tahun dan per-dua puluh tahun.

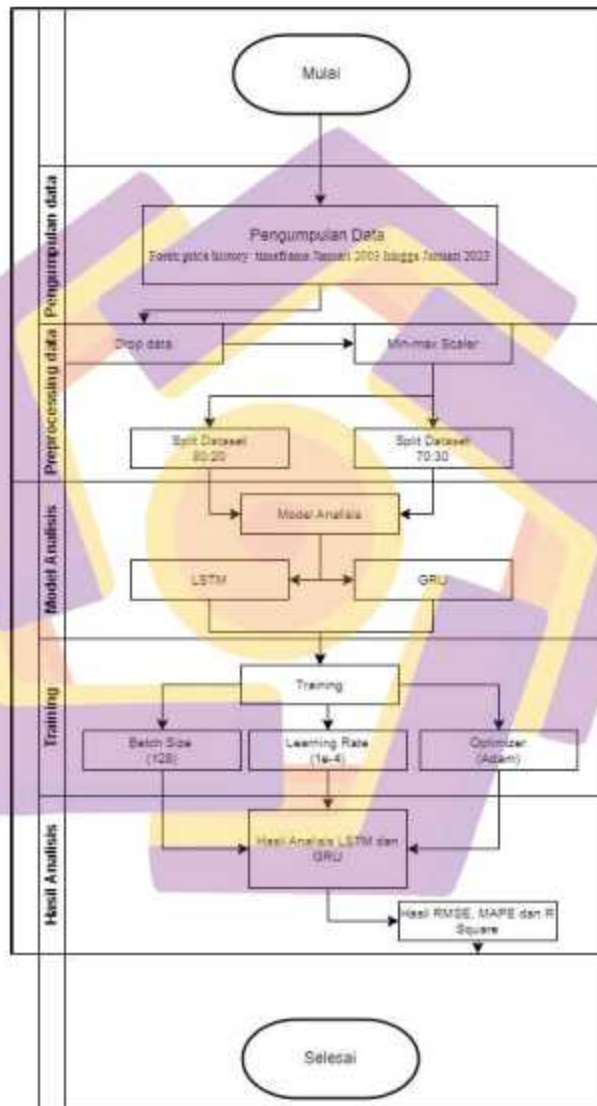
5. Testing dan Training

Data yang sudah dibagi menjadi data testing yang akan diterapkan untuk metode LSTM dan GRU. Selanjutnya untuk model latih akan diujikan pada data training. Dalam proses training dan testing peneliti menerapkan 3 layer, batch size 128, learning rate 10^{-4} , dan optimizer adam.

6. Hasil analisis

Dalam evaluasi akan menerapkan metrik evaluasi seperti Root Mean Squared Error (RMSE), MAPE (Mean Absolute Percentage Error), dan R-squared

(R^2). Metrik evaluasi dapat memberikan indikasi tentang seberapa akurat dan efektif model LSTM dan GRU dalam melakukan prediksi proses prediksi.



Gambar 3.2. Alur Penelitian

Data yang digunakan dengan rentang waktu Januari 2003 hingga Januari 2023. Total data yang digunakan 5218 baris data per mata uang dengan dua mata uang yang digunakan sekitar 10,436 baris data. Rincian data di jelaskan di Tabel 4.1 dan Tabel 4.2 yang terdiri dari beberapa variable data sebagai berikut;

Tabel 4.1. Rincian Dataset EURUSD

Date	Price	Open	High	Low	Vol	Change%
2003-01-01	1.0492	1.0494	1.0502	1.0492	NaN	-0.09%
2003-01-02	1.0362	1.0492	1.0498	1.0334	NaN	-1.24%
2003-01-03	1.0423	1.0359	1.0438	1.0336	NaN	0.59%
2003-01-06	1.0469	1.0417	1.0497	1.0414	NaN	0.44%
2003-01-07	1.0416	1.0463	1.0468	1.0394	NaN	-0.51%
...
2022-12-27	1.0638	1.0638	1.0670	1.0611	NaN	0.03%
2022-12-28	1.0608	1.0642	1.0675	1.0606	NaN	-0.28%
2022-12-29	1.0661	1.0609	1.0691	1.0609	NaN	0.50%
2022-12-30	1.0702	1.0663	1.0714	1.0639	NaN	0.38%
2023-01-02	1.0662	1.0702	1.0708	1.0650	NaN	-0.37%

Tabel 4.2. Rincian Dataset AUDCAD

Date	Price	Open	High	Low	Vol	Change%
2003-01-02	0.8841	0.8843	0.8890	0.8819	NaN	0.18%
2003-01-03	0.8876	0.8833	0.8885	0.8801	NaN	0.40%
2003-01-06	0.8981	0.8860	0.9010	0.8859	NaN	1.18%
2003-01-07	0.8968	0.8973	0.9005	0.8943	NaN	-0.14%
2003-01-08	0.8998	0.8963	0.9011	0.8923	NaN	0.33%
...
2022-12-27	1.0638	1.0638	1.0670	1.0611	NaN	-0.40%
2022-12-28	1.0608	1.0642	1.0675	1.0606	NaN	0.74%
2022-12-29	1.0661	1.0609	1.0691	1.0609	NaN	0.16%
2022-12-30	1.0702	1.0663	1.0714	1.0639	NaN	0.54%
2023-01-02	1.0662	1.0702	1.0708	1.0650	NaN	0.01%

Data yang berhasil dikumpulkan, lalu tahapan selanjutnya mengurutkan data dan memisahkan ke dalam beberapa bentuk file dengan format file yang digunakan yaitu CSV yang dapat dibaca oleh load dataset di collab. Pemisahan ke

dalam beberapa bentuk file dilakukan sebagai bentuk pengujian setiap scenario untuk mengetahui faktor yang mempengaruhi kinerja dalam memprediksi.

4.2 Proses Prediksi Harga Forex

4.2.1 Proses Prediksi Metode LSTM

Tahapan yang pertama yang dilakukan dalam memprediksi forex menggunakan metode LSTM yaitu load data. Load data disini mengacu pada proses mengimpor dataset yang digunakan ke bahasa pemrograman yang digunakan. Dalam kasus ini, metode LSTM akan meload 4 dataset yaitu data 20 tahun, 10 tahun, 5 tahun, dan 1 tahun.

Setelah melakukan load data maka langkah selanjutnya Pre – processing untuk memprediksi forex menggunakan metode LSTM. Min – max scaler merupakan tahap pre – processing yang diterapkan dalam metode LSTM. Min – max scaler akan mengubah data menjadi bilangan 0 – 1. Pre-processing memanfaatkan fungsi min- max scaler untuk normalization yang dapat mempermudah algoritma dalam membaca data pada proses modeling. Min – max scaler dijelaskan pada persamaan dimana X adalah nilai asli, X' adalah nilai yang digunakan untuk normalisasi, $\min(X)$ adalah nilai asli terkecil dan $\max(X)$ nilai asli terbesar. Berikut proses min max scaler.

$$x' = \frac{x - \min}{\max - \min}$$

Tabel 4.3. Sebelum normalisasi

Date	Price
2003-01-01	1.0492
2003-01-02	1.0362
2003-01-03	1.0423
2003-01-06	1.0469
2003-01-07	1.0416
...	...
2022-12-27	1.0638
2022-12-28	1.0608
2022-12-29	1.0661
2022-12-30	1.0702
2023-01-02	1.0662

Tabel 4.3. merupakan sampel data price dari mata uang EURUSD. Langkah yang pertama menentukan nilai $\min(X)$ dan $\max(X)$.

$$\min(X) = 1.0362$$

$\max(X) = 1.0702$, selanjutnya memasukan nilai yang ada ke persamaan min max scaler sebelumnya.

Tabel 4.4. Setelah normalisasi

Date	Price	Min - max
2003-01-01	1.0492	0.382352941
2003-01-02	1.0362	0
2003-01-03	1.0423	0.179411765
2003-01-06	1.0469	0.314705882
2003-01-07	1.0416	0.158823529
...
2022-12-27	1.0638	0.811764706
2022-12-28	1.0608	0.723529412
2022-12-29	1.0661	0.879411765
2022-12-30	1.0702	1
2023-01-02	1.0662	0.0882352941

Tahapan selanjutnya yaitu melakukan alokasi data untuk memprediksi forex. Dalam penelitian ini akan mengalokasikan data menjadi data training dan testing. Ada 2 alokasi data yang akan diujikan pada metode LSTM ini yaitu 80/20 yang artinya 80% dataset yang digunakan untuk training dan 20% digunakan untuk testing data dan 70/30 yang artinya 70% dataset yang digunakan untuk training dan 30% digunakan untuk testing data. Tahapan berikutnya menerapkan parameter pada metode LSTM. Berikut merupakan pseudocode parameter metode LSTM yang akan digunakan.

Algoritma 2: Pseudocode LSTM Model

```
# Hyperparameters
learning_rate = 0.0001
hidden_unit = 64
batch_size = 128
epoch = 500
# Architecture LSTM
regressorLSTM = Sequential()

# First LSTM layer with dropout
regressorLSTM.add(LSTM(units=hidden_unit, return_sequences=True
, input_shape=(x_train.shape[1],1), activation =
'tanh'))regressorLSTM.add(Dropout(0.5))
# Second LSTM layer with dropout
regressorLSTM.add(GRU(units=hidden_unit, return_sequences=True,
activation = 'tanh'))regressorLSTM.add(Dropout(0.5))
# Third LSTM layer with dropout
regressorGRU.add(LSTM(units=hidden_unit, return_sequences=False
, activation = 'tanh'))regressorLSTM.add(Dropout(0.5))
# Output layer
regressorLSTM.add(Dense(units=1))

# Compiling the Gated Recurrent Unit
regressorLSTM.compile(optimizer=optimizers.Adam(lr=learning_ra
te), loss='mean_squared_error')

# Fitting ke data training dan data validation
pred = regressorLSTM.fit(x_train, y_train,
validation_data=(x_val,y_val), batch_size=batch_size,
epochs=epoch)
```

Parameter yang akan diterapkan akan menentukan performa metode yang digunakan dalam memprediksi forex. Parameter yang diterapkan untuk metode LSTM yaitu layer input LSTM yang berfungsi menerima inputan data timestep. Epoch pada parameter yang akan di terapkan pada LSTM merupakan satu siklus Ketika seluruh dataset training dijalankan akan dipelajari satu kali dalam proses running. Penentuan nilai epoch sangat penting jika penggunaan epoch terlalu banyak akan terjadi overfitting dimana model sempurna namun dalam generalisasi data baru akan buruk. Nilai epoch yang akan ditetapkan yaitu = 500 epoch. Batch size adalah jumlah sampel data yang akan di proses oleh metode. Nilai batch size yang diterapkan yaitu 128.

Tahapan selanjutnya melakukan evaluasi metode LSTM untuk mengetahui performa dari metode dalam melakukan prediksi. Untuk mengukur performa pada metode LSTM memanfaatkan fungsi RMSE untuk nilai error terkecil dapat digunakan sebagai landasan dalam faktor apa saja yang mempengaruhi nilai performa yang dihasilkan kedua metode yang diterapkan pada Forex. MAPE untuk mengukur seberapa akurat model yang diterapkan dalam penerapan pada forex. R square untuk mengukur seberapa baik model regresi yang digunakan dengan data yang digunakan.

Pada penelitian ini akan menggunakan dua mata uang yang terdapat pada pasar forex dengan metode LSTM. Variabel yang digunakan dalam metode LSTM yaitu *price*. Berikut rincian dari hasil prediksi terhadap mata uang pada pasar forex menggunakan metode LSTM.

1. Hasil Prediksi EURUSD Menggunakan Metode LSTM

Hasil prediksi EURUSD yang menggunakan data testing yang sudah dibagi untuk tahapan alokasi data. Skenario yang akan di terapkan dengan metode LSTM untuk memprediksi yaitu 20 tahun, 10 tahun, 5 tahun, dan 1 tahun. Tabel 4.5 menampilkan seluruh hasil dari skenario yang akan diterapkan pada proses prediksi menggunakan metode LSTM.

Tabel 4.5. Hasil Prediksi EURUSD Menggunakan Metode LSTM

Skenario		Parameter	MAPE	R2	RMSE
Alokasi Data	Data				
80/20	20 tahun	Learning Rate = 0.0001 Epoch = 500, BatchSize = 128, Hidden Unit = 64	7.59%	0.974	0.1031
	10 tahun		5.08%	0.901	0.0655
	5 tahun		3.14%	0.594	0.0389
	1 tahun		1.05%	-0.152	0.0141
70/30	20 tahun		6.7%	0.976	0.092
	10 tahun		6.6%	0.960	0.087
	5 tahun		3.6%	0.746	0.0457
	1 tahun		1.5%	0.514	0.020

Kesimpulan dari hasil prediksi yang dilakukan menggunakan metode LSTM dalam memprediksi EURUSD memiliki hasil yang cukup baik. Hasil prediksi terkecil yang diperoleh metode LSTM untuk memprediksi EURUSD berada pada penerapan scenario 70/30, dengan penggunaan data = 20 tahun, memperoleh MAPE = 6.7 %. Nilai yang dihasilkan dari MAPE mengukur seberapa akurat model yang diterapkan pada dataset. Untuk hasil RMSE yaitu 0.092, yang dapat disimpulkan nilai error yang dihasilkan relatif masih kecil dengan penerapan metode LSTM. Untuk nilai persebaran data dengan menggunakan R – Square menunjukkan tingkat keberhasilan data dijelaskan cukup baik dengan hasil 0.976 atau 97.6%.

2. Hasil Prediksi AUDCAD Menggunakan Metode LSTM

Hasil prediksi AUDCAD yang menggunakan data testing yang sudah dibagi untuk tahapan alokasi data. Skenario yang akan di terapkan dengan metode LSTM untuk memprediksi yaitu 20 tahun, 10 tahun, 5 tahun, dan 1 tahun. Tabel 4.6 menampilkan seluruh hasil dari skenario yang akan diterapkan pada proses prediksi menggunakan metode LSTM.

Tabel 4.6. Hasil Prediksi AUDCAD Menggunakan Metode LSTM

Skenario		Parameter	MAPE	R2	RMSE	
Alokasi Data	Data					
80/20	20 tahun	Learning Rate = 0.0001 Epoch = 500, BatchSize = 128, Hidden Unit = 64	3.5%	0.972	0.0415	
	10 tahun		1.6%	0.91	0.0262	
	5 tahun		1.9%	0.876	0.0213	
	1 tahun		0.8%	-0.023	0.0095	
70/30	20 tahun			3.8%	0.97	0.043
	10 tahun			2.2%	0.92	0.025
	5 tahun			2.1%	0.90	0.024
	1 tahun			1.5%	0.71	0.017

Kesimpulan dari hasil prediksi yang dilakukan menggunakan metode LSTM dalam memprediksi EURUSD memiliki hasil yang cukup baik. Hasil prediksi terkecil yang diperoleh metode LSTM untuk memprediksi AUDCAD berada pada penerapan skenario 80/20, dengan penggunaan data = 20 tahun, memperoleh MAPE = 3.5%. Nilai yang dihasilkan dari MAPE mengukur seberapa akurat model yang diterapkan pada dataset. Untuk hasil RMSE yaitu 0.0415, yang dapat disimpulkan nilai error yang dihasilkan relatif masih kecil dengan penerapan metode LSTM. Untuk nilai persebaran data dengan menggunakan R - Square menunjukkan tingkat keberhasilan data dijelaskan cukup baik dengan hasil 0.972 atau 97.2%.

Berdasarkan hasil yang sudah dilakukan uji coba metode LSTM dalam memprediksi forex yang menggunakan dua mata uang yang terdapat pada pasar forex, telah menghasilkan prediksi yang cukup baik dengan berdasarkan nilai error yang di hasilkan. Perolehan nilai error yang melalui proses uji coba trial and error hingga dapat di pertimbangkan untuk digunakan memprediksi forex dengan tujuan tertentu. Hasil error yang rendah menunjukan hasil prediksi dengan metode LSTM cukup memiliki nilai yang sebenarnya. Dalam nilai R square yang memiliki nilai yang cukup tinggi yang mengindikasikan bahwa dengan menggunakan metode LSTM mampu menjelaskan penyebaran data yang cukup baik dalam penerapan metode untuk melakukan prediksi.

4.2.2 Proses Prediksi Metode GRU

Tahapan yang pertama yang dilakukan dalam memprediksi forex menggunakan metode GRU yaitu load data. Load data disini mengacu pada proses mengimpor dataset yang digunakan ke bahasa pemrograman yang digunakan. Dalam kasus ini, metode GRU akan meload 4 dataset yaitu data 20 tahun, 10 tahun, 5 tahun, dan 1 tahun.

Setelah melakukan load data maka langkah selanjutnya Pre - processing untuk memprediksi forex menggunakan metode GRU. Min - max scaler merupakan tahap pre - processing yang diterapkan dalam metode GRU. Min - max scaler akan mengubah data menjadi bilangan 0 - 1. Pre-processing memanfaatkan fungsi min-max scaler untuk normalization yang dapat mempermudah algoritma dalam membaca data pada proses modeling. Min - max scaler dijelaskan pada persamaan

dimana X adalah nilai asli, X' adalah nilai yang digunakan untuk normalisasi, $\min(X)$ adalah nilai asli terkecil dan $\max(X)$ nilai asli terbesar. Berikut proses min max scaler.

$$x' = \frac{x - m_{in}}{m_A x - m_{in}}$$

Tabel 4.7. Sebelum normalisasi

Date	Price
2003-01-02	0.8841
2003-01-03	0.8876
2003-01-06	0.8981
2003-01-07	0.8968
2003-01-08	0.8998
...	...
2022-12-27	0.9099
2022-12-28	0.9166
2022-12-29	0.9181
2022-12-30	0.9231
2023-01-02	0.9232

Tabel 4.7 merupakan sampel data price dari mata uang AUDCAD. Langkah yang pertama menentukan nilai $\min(X)$ dan $\max(X)$.

$\min(X) = 0.8841$

$\max(X) = 0.9232$, selanjutnya memasukan nilai yang ada ke persamaan min max scaler sebelumnya.

Tabel 4.8. Setelah normalisasi

Date	Price	Min - max
2003-01-01	0.8841	0
2003-01-02	0.8876	0.0895140665
2003-01-03	0.8981	0.358256266
2003-01-06	0.8968	0.324808184
2003-01-07	0.8998	0.401534527
...
2022-12-27	0.9099	0.659846547
2022-12-28	0.9166	0.831202046
2022-12-29	0.9181	0.869565217
2022-12-30	0.9231	0.997442455
2023-01-02	0.9232	1

Tahapan selanjutnya yaitu melakukan alokasi data untuk memprediksi forex. Dalam penelitian ini akan mengalokasikan data menjadi data training dan testing. Ada 2 alokasi data yang akan diujikan pada metode GRU ini yaitu 80/20 yang artinya 80 % dataset yang digunakan untuk training dan 20 % digunakan untuk testing data dan 70/30 yang artinya 70 % dataset yang digunakan untuk training dan 30 % digunakan untuk testing data. Tahapan berikutnya menerapkan parameter pada metode GRU. Berikut merupakan pseudocode parameter metode GRU yang akan digunakan.

Algoritma 2: Pseudocode LSTM Model

```
# Hyperparameters
learning_rate = 0.0001
hidden_unit = 64
batch_size = 128
epoch = 500
# Architecture Gated Recurrent Unit
regressorGRU = Sequential()

# First GRU layer with dropout
regressorGRU.add(GRU(units=hidden_unit, return_sequences=True,
    input_shape=(x_train.shape[1],1), activation = 'tanh'))
    regressorGRU.add(Dropout(0.5))
# Second GRU layer with dropout
```



```

regressorGRU.add(GRU(units=hidden_unit, return_sequences=True,
                    activation = 'tanh'))
                    regressorGRU.add(Dropout(0.5))
# Third GRU layer with dropout
regressorGRU.add(GRU(units=hidden_unit,
                    return_sequences=False, activation = 'tanh'))
regressorGRU.add(Dropout(0.5))
# Output layer
regressorGRU.add(Dense(units=1))

# Compiling the Gated Recurrent Unit
regressorGRU.compile(optimizer=optimizers.Adam(lr=learning_rate), loss='mean_squared_error')

# Fitting ke data training dan data validation
pred = regressorGRU.fit(x_train, y_train,
                       validation_data=(x_val,y_val), batch_size=batch_size,
                       epochs=epoch)

```

Parameter yang akan diterapkan akan menentukan performa metode yang digunakan dalam memprediksi forex. Parameter yang diterapkan untuk metode GRU yaitu layer input GRU yang berfungsi menerima inputan data timestep. Epoch pada parameter yang akan di terapkan pada GRU merupakan satu siklus Ketika seluruh dataset training dijalankan akan dipelajari satu kali dalam proses running. Penentuan nilai epoch sangat penting jika penggunaan epoch terlalu banyak akan terjadi overfitting dimana model sempurna namun dalam generalisasi data baru akan buruk. Nilai epoch yang akan ditetapkan yaitu = 500 epoch. Batch size adalah jumlah sampel data yang akan di proses oleh metode. Nilai batch size yang diterapkan yaitu 128.

Tahapan selanjutnya melakukan evaluasi metode GRU untuk mengetahui performa dari metode dalam melakukan prediksi. Untuk mengukur performa pada metode GRU memanfaatkan fungsi RMSE untuk nilai error terkecil dapat digunakan sebagai landasan dalam faktor apa saja yang mempengaruhi nilai

performa yang dihasilkan kedua metode yang diterapkan pada Forex. MAPE untuk mengukur seberapa akurat model yang diterapkan dalam penerapan pada forex. R square untuk mengukur seberapa baik model regresi yang digunakan dengan data yang digunakan.

Pada penelitian ini akan menggunakan dua mata uang yang terdapat pada pasar forex dengan metode GRU. Variabel yang digunakan dalam metode GRU yaitu *price*. Berikut rincian dari hasil prediksi terhadap mata uang pada pasar forex menggunakan metode GRU.

1. Hasil Prediksi EURUSD Menggunakan Metode GRU

Hasil prediksi EURUSD yang menggunakan data testing yang sudah dibagi untuk tahapan alokasi data. Skenario yang akan di terapkan dengan metode GRU untuk memprediksi yaitu 20 tahun, 10 tahun, 5 tahun, dan 1 tahun. Tabel 4.9 menampilkan seluruh hasil dari skenario yang akan diterapkan pada proses prediksi menggunakan metode GRU.

Tabel 4.9. Hasil Prediksi EURUSD Menggunakan Metode GRU

Skenario		Parameter	MAPE	R2	RMSE	
Alokasi Data	Data					
80/20	20 tahun	Learning Rate = 0.0001 Epoch = 500, BatchSize = 128, Hidden Unit = 64	7.7%	0.985	0.106	
	10 tahun		5.3%	0.973	0.0691	
	5 tahun		3%	0.84	0.0382	
	1 tahun		0.8%	0.45	0.0155	
70/30	20 tahun			6.6%	0.968	0.0916
	10 tahun			6.8%	0.980	0.091
	5 tahun			2.4%	0.941	0.0459
	1 tahun			1.3%	0.484	0.018

Kesimpulan dari hasil prediksi yang dilakukan menggunakan metode GRU dalam memprediksi EURUSD memiliki hasil yang cukup baik. Hasil prediksi terkecil yang diperoleh metode GRU untuk memprediksi EURUSD berada pada

penerapan scenario 80/20, dengan penggunaan data = 20 tahun, memperoleh MAPE = 7.7%. Nilai yang dihasilkan dari MAPE mengukur seberapa akurat model yang diterapkan pada dataset. Untuk hasil RMSE yaitu 0.106, yang dapat disimpulkan nilai error yang dihasilkan relatif masih kecil dengan penerapan metode GRU. Untuk nilai persebaran data dengan menggunakan R – Square menunjukkan tingkat keberhasilan data dijelaskan cukup baik dengan hasil 0.985 atau 98.5%.

2. Hasil Prediksi AUDCAD Menggunakan Metode GRU

Hasil prediksi AUDCAD yang menggunakan data testing yang sudah dibagi untuk tahapan alokasi data. Skenario yang akan di terapkan dengan metode GRU untuk memprediksi yaitu 20 tahun, 10 tahun, 5 tahun, dan 1 tahun. Tabel 4.10 menampilkan seluruh hasil dari skenario yang akan diterapkan pada proses prediksi menggunakan metode GRU.

Tabel 4.10. Hasil Prediksi AUDCAD Menggunakan Metode GRU

Skenario		Parameter	MAPE	R2	RMSE
Alokasi Data	Data				
80/20	20 tahun	Learning Rate = 0.0001 Epoch = 500, BatchSize = 128, Hidden Unit = 64	3.49%	0.976	0.041
	10 tahun		2.29%	0.90	0.025
	5 tahun		1.93%	0.864	0.0215
	1 tahun		0.78%	0.019	0.0092
70/30	20 tahun		3.79%	0.975	0.0436
	10 tahun		2.22%	0.922	0.0251
	5 tahun		2.16%	0.894	0.0245
	1 tahun		1.55%	0.685	0.0178

Kesimpulan dari hasil prediksi yang dilakukan menggunakan metode GRU dalam memprediksi AUDCAD memiliki hasil yang cukup baik. Hasil prediksi terkecil yang diperoleh metode GRU untuk memprediksi AUDCAD berada pada penerapan scenario 80/20, dengan penggunaan data = 20 tahun, memperoleh MAPE = 3.49%. Nilai yang dihasilkan dari MAPE mengukur seberapa akurat model yang

diterapkan pada dataset. Untuk hasil RMSE yaitu 0.041, yang dapat disimpulkan nilai error yang dihasilkan relatif masih kecil dengan penerapan metode GRU. Untuk nilai persebaran data dengan menggunakan R – Square menunjukkan tingkat keberhasilan data dijelaskan cukup baik dengan hasil 0.976 atau 97.6%.

Berdasarkan hasil yang sudah dilakukan uji coba metode GRU dalam memprediksi forex yang menggunakan dua mata uang yang terdapat pada pasar forex, telah menghasilkan prediksi yang cukup baik dengan berdasarkan nilai error yang di hasilkan. Perolehan nilai error yang melalui proses uji coba trial and error hingga dapat di pertimbangkan untuk digunakan memprediksi forex dengan tujuan tertentu. Hasil error yang rendah menunjukan hasil prediksi dengan metode LSTM cukup memiliki nilai yang sebenarnya. Dalam nilai R square yang memiliki nilai yang cukup tinggi yang mengindikasikan bahwa dengan menggunakan metode GRU mampu menjelaskan penyebaran data yang cukup baik dalam penerapan metode untuk melakukan prediksi.

4.2.3 Perbandingan Arsitektur dan Beban Komputasi Pada Metode LSTM dan GRU

Dalam perbandingan metode LSTM memiliki unit memori yang kompleks, yang memungkinkannya untuk menyimpan dan mengakses informasi dalam jangka panjang. LSTM menggunakan tiga gerbang yaitu forget gate, input gate, dan output gate. Gerbang ini mengatur aliran informasi ke dan dari unit memori. GRU juga memiliki unit memori, tetapi lebih sederhana dibandingkan LSTM karena hanya memiliki dua komponen yaitu current value dan remembered value. GRU menggunakan dua gerbang pengendali yaitu gerbang reset (reset gate) dan gerbang

pembaruan (update gate). Gerbang ini memungkinkan GRU untuk mengontrol aliran informasi dengan cara yang efisien. Karena memiliki unit memori dan gerbang pengendali, LSTM cenderung memiliki kapasitas pembelajaran yang lebih besar dan dapat menangkap pola yang kompleks dalam data sekuensial. Meskipun lebih sederhana, GRU dapat menangani banyak tugas pemodelan sekuensial dengan baik dan mengatasi masalah hilangnya informasi pada skala yang lebih kecil.

Gated Recurrent Unit (GRU) dan Long Short-Term Memory (LSTM) adalah dua jenis arsitektur jaringan saraf rekuren yang memiliki tujuan yang sama dalam mengatasi masalah vanishing gradient dan memungkinkan model untuk mengingat informasi dalam urutan data yang panjang. Kedua arsitektur ini memiliki perbedaan dalam kompleksitas dan jumlah gerbang yang digunakan, tetapi pada dasarnya keduanya adalah jenis sel (unit pengolahan) yang digunakan dalam rekuren neural network (RNN). Kedua metode ini memiliki kemiripan fungsi, keduanya dirancang untuk mengatasi masalah dari rekuren neural network tradisional, yaitu menghadapi kesulitan dalam mengingat informasi jangka panjang dalam data urutan. Dalam LSTM maupun GRU menggunakan gerbang (gate) untuk mengontrol aliran informasi dalam sel. LSTM memiliki tiga gerbang (forget, input, dan output gate) sementara GRU memiliki dua gerbang utama (update gate dan reset gate). Kedua arsitektur ini mempunyai kemampuan untuk menangani ketergantungan jangka panjang dalam data urutan. Hal ini memungkinkan mereka untuk menyimpan informasi dalam jangka panjang dan menggunakannya dalam prediksi.

Dalam komputasi metode LSTM memiliki tiga gerbang forget gate, input gate, dan output gate serta unit memori, jumlah parameter dalam model LSTM cenderung lebih banyak. Sedangkan GRU memiliki dua gerbang reset gate dan update gate dengan unit memori yang lebih sederhana, sehingga memiliki jumlah parameter yang lebih sedikit dibandingkan LSTM. Kompleksitasnya LSTM yang mempunyai tiga gate cenderung memerlukan lebih banyak waktu untuk melatih model, terutama pada dataset besar dan panjang. Pelatihan LSTM biasanya memerlukan lebih banyak iterasi (epochs) untuk konvergensi. Sedangkan GRU memiliki dua gerbang pengendali (reset gate, update gate) dan unit memori yang lebih sederhana, sehingga memiliki jumlah parameter yang lebih sedikit dibandingkan LSTM. komputasi metode GRU seringkali diutamakan jika memiliki batasan sumber daya komputasi, karena ia menawarkan keseimbangan yang baik antara kinerja dan kompleksitas model. Namun, jika Anda memiliki dataset sejarah panjang dan kompleks, di mana pemahaman jangka panjang maka dapat menggunakan LSTM.

4.3. Evaluasi Model

4.3.1 Perbandingan Hasil Kedua Metode

Dalam penerapan dua metode yang sudah dilakukan uji coba untuk memprediksi forex hasil yang di dapatkan cukup baik. Tidak menutup kemungkinan metode yang terapkan memiliki performa baik dalam memprediksi forex. Hal tersebut dapat dilihat berdasarkan hasil dari prediksi yang diperoleh dengan perbedaan nilai yang bervariasi dengan faktor penyebab yang berbeda.

Hasil yang diperoleh dari kedua metode yang sudah diterapkan memiliki

nilai yang cukup berbeda. Tabel 4.11 menampilkan error terkecil dari kedua metode yang sudah di terapkan.

Tabel 4.11. Perbandingan Hasil Kedua Metode

Forex	LSTM			GRU		
	RMSE	R2	MAPE	RMSE	R2	MAPE
EURUSD	0.092	0.976	6.7%	0.106	0.985	7.7%
AUDCAD	0.0415	0.972	3.5%	0.041	0.976	3.4%


Pada penerapan evaluasi error menggunakan RMSE yang bertujuan untuk mengurangi kesalahan fungsi pada perhitungan berbasis kuadrat. Untuk penerapan MAPE digunakan memahami kesalahan prediksi dan mengevaluasi akurasi dari metode regresi yang diterapkan.

Dapat dilihat pada Tabel 4.11 hasil dari EURUSD dalam penerapan metode LSTM dan GRU memiliki nilai error yang cukup besar dari AUDCAD. Penyebab dari nilai error yang cukup besar di karenakan EURUSD memiliki nilai lebih dari 1. Untuk pasangan mata uang EURUSD, metode LSTM memiliki RMSE sebesar 0.092, sedangkan metode GRU memiliki RMSE sebesar 0.106. Ini menunjukkan bahwa metode LSTM memiliki RMSE yang lebih rendah, yang berarti lebih akurat dalam memprediksi nilai EURUSD. Untuk pasangan mata uang AUDCAD, metode LSTM memiliki RMSE sebesar 0.0415, sedangkan metode GRU memiliki RMSE sebesar 0.041. Metode GRU memiliki RMSE yang lebih rendah, menunjukkan keakuratan yang lebih baik dalam memprediksi nilai AUDCAD. Untuk pasangan mata uang EURUSD, metode LSTM memiliki R2 sebesar 0.976, sedangkan metode GRU memiliki R2 sebesar 0.985. Keduanya memiliki nilai R2 yang sangat tinggi, tetapi metode GRU sedikit lebih baik dalam menjelaskan variasi data. Untuk pasangan mata uang AUDCAD, metode LSTM memiliki R2 sebesar 0.972,

sedangkan metode GRU memiliki R2 sebesar 0.976. Lagi, metode GRU memiliki R2 yang lebih tinggi, menunjukkan kemampuan yang lebih baik dalam menjelaskan variasi data AUDCAD. Untuk pasangan mata uang EURUSD, metode LSTM memiliki MAPE sebesar 6.7%, sedangkan metode GRU memiliki MAPE sebesar 7.7%. Keduanya memiliki MAPE yang relatif rendah, tetapi metode LSTM memiliki nilai yang lebih rendah, menunjukkan kesalahan persentase yang lebih rendah dalam prediksinya. Untuk pasangan mata uang AUDCAD, metode LSTM memiliki MAPE sebesar 3.5%, sedangkan metode GRU memiliki MAPE sebesar 3.4%. Metode GRU memiliki MAPE yang lebih rendah, menunjukkan kesalahan persentase yang lebih rendah dalam prediksi AUDCAD.

Meskipun metode LSTM memiliki hasil yang lebih baik dalam memprediksi EURUSD, metode GRU lebih unggul dalam memprediksi AUDCAD. Metode GRU memiliki RMSE dan R2 yang lebih baik untuk AUDCAD, menunjukkan tingkat akurasi dan kemampuan yang lebih baik dalam menjelaskan variasi data. Metode LSTM, meskipun memiliki RMSE dan R2 yang baik untuk EURUSD, masih kalah dalam hal keakuratan jika dibandingkan dengan metode GRU. Dengan demikian, metode GRU lebih disarankan untuk memprediksi nilai pasangan mata uang AUDCAD, sementara untuk pasangan mata uang EURUSD, baik metode LSTM maupun GRU dapat digunakan, meskipun metode LSTM memiliki sedikit keunggulan dalam mengurangi kesalahan persentase (MAPE) dalam prediksinya.

Setelah melakukan uji coba dalam memprediksi harga forex dengan hasil error yang cukup kecil dari kedua metode yang sudah diterapkan.



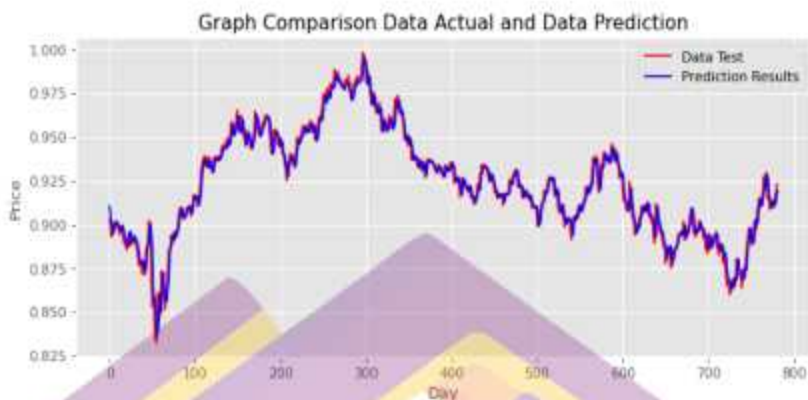
Gambar 4.2. Visualisasi Hasil Prediksi EURUSD Menggunakan Metode LSTM

Pada Gambar 4.4 visualisasi EURUSD dengan error RMSE 0.09 dan MAPE 6,78%. dengan data 20 tahun dengan alokasi data 80/20. Dapat diperhatikan bahwa grafik nilai aktual terhadap hasil prediksi memiliki gap yang cukup kecil terlihat yang menjelaskan keseluruhan data mencapai titik yang baik untuk nilai prediksi. Secara keseluruhan data tersebar dengan baik hingga menghasilkan nilai R – square = 98.1%. Dalam penerapan metode LSTM dengan parameter dan scenario pada EURUSD ini dapat dipertimbangkan dalam penerapan kedepannya.

Tabel 4.12. Hasil Prediksi dan Nilai aktual EURUSD Menggunakan Metode LSTM

Date	Actual	Predict	Gap
2021-07-01	1.1861	1.181483	0%
2021-07-02	1.1822	1.182655	0%
2021-07-05	1.1789	1.181708	0%
2021-07-06	1.1842	1.178111	-1%
2021-07-07	1.1873	1.176554	-1%
...	...		
2022-12-27	1.0638	1.065825	0%
2022-12-28	1.0608	1.067443	-1%
2022-12-29	1.0661	1.067142	0%
2022-12-30	1.0702	1.065833	0%

Tabel 4.12 menampilkan perbandingan nilai aktual dan predict dengan melakukan metode LSTM terhadap EURUSD untuk setiap rentang waktu tertentu. Pada sebagian besar tanggal dalam tabel, perbedaan antara nilai aktual dan nilai prediksi sangat kecil (0%). Ini menunjukkan bahwa model LSTM cukup akurat dalam memprediksi nilai EURUSD pada tanggal-tanggal tersebut. Meskipun sebagian besar prediksi mendekati nilai aktual, terdapat beberapa tanggal, seperti 6 Juli 2021 dan 7 Juli 2021, di mana perbedaan antara nilai aktual dan nilai prediksi mencapai -1%. Ini menunjukkan bahwa model LSTM tidak selalu mampu memprediksi dengan tepat dalam situasi tertentu. Pada tanggal-tanggal tertentu, seperti 27 Desember 2022, 29 Desember 2022, dan 30 Desember 2022, model LSTM memberikan prediksi yang konsisten dengan nilai aktual, yaitu dengan perbedaan 0%. Ini menunjukkan bahwa model ini mampu menghasilkan prediksi yang stabil dalam beberapa situasi. Walaupun sebagian besar prediksi mendekati nilai aktual, masih ada beberapa perbedaan antara nilai prediksi dan nilai aktual. Ini menunjukkan bahwa terdapat tingkat ketidakpastian dalam prediksi yang perlu diperhatikan.



Gambar 4.3. Visualisasi Hasil Prediksi AUDCAD Menggunakan Metode LSTM

Pada Gambar 4.5 visualisasi AUDCAD yang memiliki nilai lebih baik dari EURUSD dengan error RMSE 0.024 dan MAPE 2.1 % namun dengan skenario alokasi data = 70/30 dengan rentang waktu dataset 5 tahun. Dari hasil grafik nilai aktual dan prediksi memiliki gap yang cukup kecil. Secara keseluruhan data tersebar dengan baik hingga menghasilkan nilai R - square = 89.1%. Dalam penerapan metode LSTM dengan parameter dan scenario pada AUDCAD ini dapat dipertimbangkan dalam penerapan kedepannya.


Tabel 4.13. Hasil Prediksi dan Nilai aktual AUDCAD Menggunakan Metode LSTM

Date	Actual	Predict	Gap
2022-04-01	0.9462	0.936710	1%
2022-04-04	0.9420	0.939886	0%
2022-04-05	0.9415	0.942560	0%
2022-04-06	0.9369	0.939214	0%
2022-04-07	0.9367	0.937947	0%
...
2022-12-27	0.9099	0.912437	0%
2022-12-28	0.9166	0.911918	1%

Tabel 4.13. Lamjutan

Date	Actual	Predict	Gap
2022-12-29	0.9181	0.910405	1%
2022-12-30	0.9231	0.915618	1%
2023-01-02	0.9232	0.917645	1%

Tabel 4.13 menampilkan perbandingan nilai aktual dan predict dengan melakukan metode LSTM terhadap AUDCAD untuk penggunaan dataset 5 tahun dengan hasil cukup baik dari pada EURUSD. Pada sebagian besar tanggal dalam tabel, perbedaan antara nilai aktual dan nilai prediksi adalah 0%. Ini menunjukkan bahwa model LSTM yang digunakan cenderung memberikan prediksi yang sangat mendekati nilai aktual, yang merupakan indikasi tingkat akurasi yang baik. Tabel 4.13 menunjukkan konsistensi dalam prediksi pada sebagian besar tanggal, di mana gap adalah 0%. Ini menunjukkan bahwa model LSTM ini cenderung memberikan hasil yang stabil dan konsisten. Meskipun sebagian besar perbedaan adalah 0%, terdapat beberapa tanggal di mana perbedaan mencapai 1%. Ini menunjukkan bahwa model LSTM ini memiliki tingkat ketepatan yang cukup tinggi, tetapi masih memiliki sedikit ketidakakuratan dalam beberapa situasi. Dalam sebagian besar kasus, prediksi cenderung sedikit lebih rendah dari nilai aktual, yang ditunjukkan oleh gap positif. Ini mungkin menunjukkan bahwa model LSTM ini memiliki kecenderungan untuk menghasilkan prediksi yang lebih konservatif atau menghindari prediksi yang terlalu tinggi. Terdapat perbedaan yang lebih besar pada akhir tahun 2022, dengan gap sekitar 1%.




Gambar 4.4. Visualisasi Hasil Prediksi EURUSD Menggunakan Metode GRU

Pada Gambar 4.6 visualisasi EURUSD dengan error RMSE 0.0953 dan MAPE 6.8 % dengan skenario alokasi data = 70/30. Dari hasil grafik nilai aktual dan prediksi memiliki gap yang cukup kecil dengan penggunaan dataset 20 tahun. Secara keseluruhan data tersebar dengan baik hingga menghasilkan nilai R – square = 98.8%. Dalam penerapan metode LSTM dengan parameter dan skenario pada EURUSD ini dapat dipertimbangkan dalam penerapan kedepannya.

Tabel 4.14 Hasil Prediksi dan Nilai aktual EURUSD Menggunakan Metode GRU

Date	Actual	Predict	Gap
2020-01-01	1.1158	1.121786	-1%
2020-01-02	1.1193	1.119429	0%
2020-01-03	1.1151	1.120833	-1%
2020-01-06	1.1103	1.120024	-1%
2020-01-07	1.1105	1.115613	0%
...	...		
2022-12-27	1.0638	1.067251	0%
2022-12-28	1.0608	1.068307	-1%
2022-12-29	1.0661	1.066801	0%
2022-12-30	1.0702	1.068412	0%
2023-01-02	1.0662	1.072897	-1%

Tabel 4.14 menampilkan perbandingan nilai aktual dan predict dengan metode GRU terhadap EURUSD dengan penggunaan dataset 20 tahun. Dalam beberapa kasus, seperti pada tanggal 2 Januari 2020, 27 Desember 2022, 29 Desember 2022, dan 30 Desember 2022, perbedaan antara nilai aktual dan nilai prediksi sangat kecil (0%). Ini menunjukkan bahwa prediksi cukup akurat pada tanggal-tanggal ini. Beberapa tanggal menunjukkan ketidakakuratan dalam prediksi. Misalnya, pada tanggal 1 Januari 2020, 3 Januari 2020, dan 6 Januari 2020, perbedaan antara nilai aktual dan nilai prediksi adalah -1%, yang berarti prediksi lebih rendah dari nilai aktual. Demikian juga, pada tanggal 28 Desember 2022 dan 2 Januari 2023, perbedaan antara nilai aktual dan nilai prediksi adalah -1%, yang juga menunjukkan. Pada beberapa tanggal, seperti tanggal 7 Januari dan 29 Desember 2022, perbedaan antara nilai aktual dan nilai prediksi adalah 0%, yang berarti prediksi mendekati nilai aktual. Dalam beberapa kasus, seperti tanggal 1 Januari 2020, 3 Januari 2020, dan 6 Januari 2020, perbedaan antara nilai aktual dan nilai prediksi konsisten (-1%). Ini menunjukkan bahwa terdapat bias dalam prediksi yang dapat diperhatikan. Dengan hasil yang sudah diterapkan dengan menggunakan metode GRU memiliki gap yang cukup kecil dalam menghasilkan nilai aktual dan prediksi.



Gambar 4.5. Visualisasi Hasil Prediksi AUDCAD Menggunakan Metode GRU

Pada Gambar 4.7 visualisasi AUDCAD yang memiliki nilai lebih baik dari EURUSD dengan error RMSE 0.0432 dan MAPE 3.1 % namun dengan skenario alokasi data = 70/30 dengan rentang waktu dataset 20 tahun. Dari hasil grafik nilai aktual dan prediksi memiliki gap yang cukup kecil. Secara keseluruhan data tersebar dengan baik hingga menghasilkan nilai R – square = 97.6%. Dalam penerapan metode GRU dengan parameter dan scenario pada AUDCAD ini dapat dipertimbangkan dalam penerapan kedepannya.

Tabel 4.15 Hasil-Prediksi dan Nilai aktual AUDCAD Menggunakan Metode GRU

Date	Actual	Predict	Gap
2020-01-01	0.9029	0.909972	-1%
2020-01-02	0.8995	0.905773	-1%
2020-01-03	0.8930	0.902024	0%
2020-01-06	0.8950	0.896762	0%
2020-01-07	0.8950	0.895812	0%
---	---		
2022-12-27	0.9099	0.914521	-1%
2022-12-28	0.9166	0.912244	0%

Tabel 4.15 Lanjutan

Date	Actual	Predict	Gap
2022-12-29	0.9181	0.915236	0%
2022-12-30	0.9231	0.918464	1%
2023-01-02	0.9232	0.922149	0%

Tabel 4.15 menampilkan perbandingan nilai aktual dan predict dengan melakukan metode GRU terhadap AUDCAD untuk penggunaan dataset 20 tahun. Prediksi yang Mendekati Nilai Aktual: Pada sebagian besar tanggal dalam tabel, perbedaan antara nilai aktual dan nilai prediksi adalah 0% atau mendekati 0%. Ini menunjukkan bahwa model GRU yang digunakan cenderung memberikan prediksi yang cukup mendekati atau konsisten dengan nilai aktual, yang merupakan indikasi tingkat akurasi yang baik. Tabel 4.15 menunjukkan konsistensi dalam prediksi pada sebagian besar tanggal, di mana gap adalah 0% atau mendekati 0%. Ini menunjukkan bahwa model GRU ini cenderung memberikan hasil yang stabil dan konsisten. Meskipun sebagian besar perbedaan adalah 0% atau mendekati 0%, terdapat beberapa tanggal di mana perbedaan mencapai -1% atau 1%. Ini menunjukkan bahwa model GRU ini memiliki tingkat ketepatan yang baik, tetapi terdapat beberapa situasi di mana prediksi menjadi lebih rendah atau lebih tinggi dari nilai aktual dalam batasan 1%. Terdapat perbedaan yang lebih besar pada akhir tahun 2022, terutama pada tanggal 30 Desember 2022, dengan gap sekitar 1%. Ini menunjukkan bahwa model GRU mungkin lebih sulit dalam menghadapi volatilitas atau faktor-faktor yang sulit diprediksi pada akhir tahun. Model GRU yang digunakan dalam Tabel 4.15 cenderung memberikan prediksi yang mendekati atau konsisten dengan nilai aktual, dengan sebagian besar perbedaan adalah 0% atau

mendekati 0%. Namun, perlu dicatat bahwa ada beberapa situasi di mana perbedaan mencapai -1% atau 1%, terutama pada akhir tahun. Secara keseluruhan, hasil ini menunjukkan tingkat akurasi yang baik, terutama jika tingkat ketidakakuratan dalam batasan -1% hingga 1% dapat diterima dalam analisis tertentu.

4.3.2. Faktor Yang Mempengaruhi Mempengaruhi Akurasi prediksi

Melihat penjelasan terkait perbandingan hasil kedua metode dan juga visualisasi hasil kedua metode, dapat dikumpulkan beberapa faktor yang mempengaruhi akurasi prediksi kedua metode dalam memprediksi forex. Berikut rincian faktor yang mempengaruhi performa terbaik metode;

1. Faktor dalam penggunaan data pada metode LSTM dan GRU
 - a. Dalam penyebaran data yang mempengaruhi dari hasil prediksi. Dapat dilihat pada Tabel 4.16 yang menunjukan hasil dari perbandingan nilai persebaran data R-square pada metode LSTM menghasilkan nilai yang cukup baik.

Tabel 4.16. Perbandingan Penggunaan Data pada Metode LSTM

Skenario		EURUSD			AUDCAD			
Alokasi Data	Parameter	Data	MAPE	R2	RMSE	MAPE	R2	RMSE
80/20	Learning Rate = 0.0001 Epoch = 500,	20 Tahun	7.59%	0.974	0.1031	3.5%	0.972	0.0415
		10 Tahun	5.08%	0.901	0.0655	1.6%	0.91	0.0262
		5 Tahun	3.14%	0.594	0.0389	1.9%	0.876	0.0213
70/30	BatchSize = 128, Hidden Unit = 64	1 tahun	1.05%	-0.152	0.0141	0.8%	-0.023	0.0095
		20 Tahun	6.7%	0.976	0.092	3.8%	0.97	0.043
		10 Tahun	6.6%	0.960	0.087	2.2%	0.92	0.025
		5 Tahun	3.6%	0.746	0.0457	2.1%	0.90	0.024
		1 tahun	1.5%	0.514	0.020	1.5%	0.71	0.017

Berdasarkan Tabel 4.16 kesimpulan yang didapatkan bahwa dalam alokasi data, seperti 80/20 dan 70/30, memiliki pengaruh pada nilai R-

square yang mengukur sejauh mana model LSTM cocok dengan data aktual. Pada beberapa kasus, alokasi data 70/30 menghasilkan nilai R-square yang sedikit lebih tinggi daripada alokasi data 80/20, menunjukkan bahwa alokasi data yang lebih besar untuk data pelatihan (70%) dapat meningkatkan akurasi prediksi. Untuk durasi data, yang mencakup periode waktu 20 tahun, 10 tahun, 5 tahun, dan 1 tahun memiliki dampak yang signifikan pada nilai R-square. Secara umum, semakin lama durasi data yang digunakan, semakin tinggi nilai R-square yang dicapai. Ini menunjukkan bahwa model LSTM lebih baik dalam memprediksi ketika memiliki akses ke data historis yang lebih lama. Perbedaan dalam nilai R-square antara pasangan mata uang EURUSD dan AUDCAD menunjukkan bahwa model mungkin lebih baik dalam memprediksi salah satu dari keduanya. Misalnya, pada beberapa kasus, seperti alokasi data 70/30 dan durasi data 20 tahun, nilai R-square lebih tinggi untuk EURUSD dibandingkan dengan AUDCAD. Dalam durasi data satu tahun menghasilkan nilai R-square yang rendah, untuk kedua pasangan mata uang EURUSD dan AUDCAD. Ini menunjukkan bahwa model LSTM mungkin memiliki kesulitan dalam memprediksi perubahan yang signifikan dalam data ketika hanya memiliki data historis yang sangat terbatas. Performa model LSTM dalam memprediksi nilai EURUSD dan AUDCAD sangat dipengaruhi oleh alokasi data dan durasi data. Durasi data yang lebih lama cenderung meningkatkan akurasi prediksi, sementara alokasi data yang lebih besar untuk data pelatihan juga dapat

meningkatkan akurasi dalam beberapa kasus. Selain itu, ada perbedaan dalam kemampuan model dalam memprediksi antara kedua pasangan mata uang. Durasi data satu tahun cenderung menghasilkan hasil yang paling buruk dalam hal R-square.

- b. Dalam penyebaran data yang mempengaruhi dari hasil prediksi. Dapat dilihat pada Tabel 4.19 yang menunjukan hasil dari perbandingan nilai persebaran data R-square pada metode GRU menghasilkan nilai yang cukup baik.

Tabel 4.17. Perbandingan Penggunaan Data pada Metode GRU

Skenario		EURUSD			AUDCAD			
Alokasi Data	Parameter	Data	MAPE	R2	RMSE	MAPE	R2	RMSE
80/20	Learning Rate = 0.0001 Epoch = 500,	20 Tahun	7.7%	0.985	0.106	3.49%	0.976	0.041
		10 Tahun	5.3%	0.973	0.0691	2.29%	0.90	0.025
		5 Tahun	3%	0.84	0.0382	1.93%	0.864	0.0215
70/30	BatchSize = 128, Hidden Unit = 64	1 tahun	0.8%	0.45	0.0155	0.78%	0.019	0.0092
		20 Tahun	6.6%	0.968	0.0916	3.79%	0.975	0.0436
		10 Tahun	6.8%	0.980	0.091	2.22%	0.922	0.0251
		5 Tahun	2.4%	0.941	0.0459	2.16%	0.894	0.0245
		1 tahun	1.3%	0.484	0.018	1.55%	0.685	0.0178

Berdasarkan Tabel 4.19 kesimpulan yang didapatkan bahwa Dalam Pada alokasi data, seperti 80/20 dan 70/30, memiliki pengaruh yang signifikan pada nilai R2. Pada beberapa kasus, alokasi data 80/20 menghasilkan nilai R2 yang lebih tinggi dibandingkan dengan alokasi data 70/30, menunjukkan bahwa alokasi data yang lebih kecil untuk data pengujian (20%) dapat meningkatkan kemampuan model GRU untuk menjelaskan variasi data aktual. Untuk Durasi data, yang mencakup periode waktu (20 tahun, 10 tahun, 5 tahun, 1 tahun), memiliki dampak

yang signifikan pada nilai R^2 . Secara umum, semakin lama durasi data yang digunakan, semakin tinggi nilai R^2 yang dicapai. Ini menunjukkan bahwa model GRU cenderung memiliki kemampuan yang lebih baik dalam menjelaskan variasi data ketika memiliki akses ke data historis yang lebih lama. Terdapat perbedaan dalam tingkat R^2 antara pasangan mata uang EURUSD dan AUDCAD. Pada beberapa kasus, seperti alokasi data 80/20 dengan durasi data satu tahun, nilai R^2 lebih tinggi untuk EURUSD dibandingkan dengan AUDCAD, menunjukkan bahwa model GRU mungkin memiliki kemampuan yang lebih baik dalam menjelaskan variasi data EURUSD. Durasi data satu tahun menghasilkan nilai R^2 yang lebih rendah, bahkan negatif, yang menunjukkan tingkat ketidakakuratan yang lebih besar dalam prediksi ketika hanya memiliki data historis yang sangat terbatas. Performa model GRU dalam menjelaskan variasi data untuk nilai EURUSD dan AUDCAD sangat dipengaruhi oleh alokasi data dan durasi data. Durasi data yang lebih lama cenderung meningkatkan kemampuan model untuk menjelaskan variasi data, sementara alokasi data yang lebih besar untuk data pengujian juga dapat meningkatkan kemampuan model dalam beberapa kasus. Selain itu, ada perbedaan dalam kemampuan model dalam menjelaskan variasi data antara kedua pasangan mata uang, dengan EURUSD cenderung memiliki kemampuan yang lebih baik dalam beberapa kasus. Durasi data satu tahun cenderung menghasilkan hasil yang paling buruk dalam hal nilai R^2 .

2. Faktor layer dalam metode LSTM dan GRU

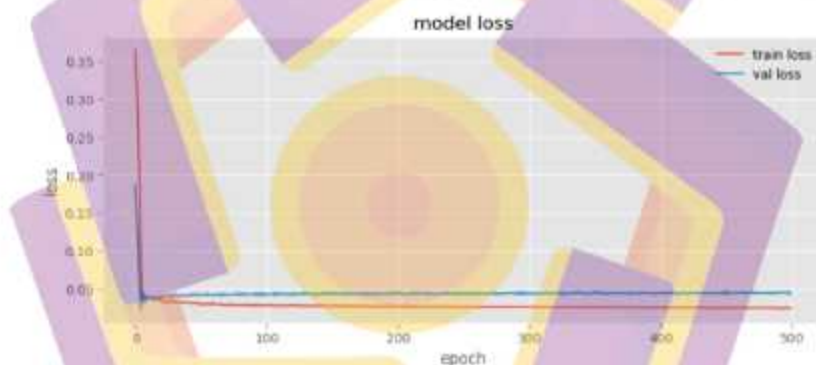
Proses penyesuaian parameter ini kami terapkan pada kedua metode, yaitu LSTM dan GRU. Dalam hal parameter LSTM, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada lapisan (layer) untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan lapisan yang lebih besar, namun setelah serangkaian percobaan, kami memilih untuk mengurangi jumlah lapisan untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam Gambar 4.8 di bawah



Gambar 4.6. Hyperparameter Layer Metode LSTM

Dalam analisis hasil yang telah dilakukan, perlu dicatat bahwa terdapat beberapa aspek penting yang perlu dipertimbangkan dalam pemilihan jumlah layer yang optimal untuk model LSTM. Gambar 4.6. menampilkan data yang memberikan nilai performa model LSTM dalam berbagai konfigurasi layer. ketika

kita melihat nilai MAPE rata-rata, kita melihat bahwa hasilnya berada dalam kisaran 3.59% hingga 3.80%. Hal ini menunjukkan bahwa model LSTM memiliki tingkat kesalahan relatif yang rendah dalam meramalkan pergerakan forex, independen dari jumlah layer yang digunakan. Untuk nilai RMSE dan R-square, dapat melihat trade-off yang menarik. Model LSTM dengan jumlah layer 100 memiliki RMSE terkecil sebesar 0.0395, yang menunjukkan bahwa ia memiliki tingkat kesalahan absolut yang paling rendah dalam memprediksi forex. Namun, hasil R-square pada jumlah layer ini sangat rendah, bahkan negatif (-0.06302).



Gambar 4.7 Grafik Model Loss


Pada Gambar 4.7 memperlihatkan nilai loss yang menunjukkan bahwa nilai loss training lebih rendah dibanding nilai loss validasi. Penambahan layer yang berlebihan bisa menyebabkan overfitting, di mana model "memorizing" data training dengan sangat baik, tetapi gagal untuk generalisasi dengan baik pada data baru. Ini dapat mengakibatkan R-squared negatif pada data yang tidak terlibat dalam pelatihan.

Di sisi lain, model dengan jumlah layer 3 menunjukkan performa yang

sangat baik dalam hal R-square dengan nilai 0.9687, yang menandakan bahwa model ini mampu menjelaskan variasi data dengan sangat baik. Namun, nilai RMSE pada model ini sedikit lebih tinggi (0.0430) dibandingkan dengan model 100 layer. Berdasarkan hasil yang baik ini, keputusan diambil untuk menggunakan model dengan jumlah layer 3 dalam diterapkan pada seluruh dataset forex yang digunakan. Meskipun RMSE-nya sedikit lebih tinggi, kemampuan model ini untuk menjelaskan variasi data yang tinggi (R-square yang tinggi) merupakan faktor yang lebih penting dalam pemilihan model untuk digunakan dalam peramalan harga forex. Hal ini akan memberikan hasil yang lebih konsisten dan dapat diandalkan dalam aplikasi sehari-hari.

Dalam hal parameter dengan metode GRU, kami mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada lapisan (layer) untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, menggunakan lapisan yang lebih besar, namun setelah serangkaian percobaan, kami memilih untuk mengurangi jumlah lapisan untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam Gambar 4.10 di bawah ini

Hyperparameter Layer Metode GRU Dengan Nilai RMSE, R-square, dan Mape




Gambar 4.8. Hyperparameter Layer Metode GRU

Dalam Gambar 4.8, terlihat bahwa nilai MAPE rata-rata berkisar antara 3.39% hingga 3.76%. Namun, perlu dicatat bahwa pada layer 50, terdapat peningkatan signifikan dalam nilai MAPE, mencapai 6.85%. Ketika peneliti mempertimbangkan nilai error terkecil dalam bentuk RMSE, kami menemukan bahwa dengan jumlah layer 100, kita mencapai nilai terendah sebesar 0.0400. Meskipun demikian, ketika melihat rata-rata nilai RMSE dari layer 3 hingga 100, kita melihat bahwa nilai paling rendah adalah 0.0400, sedangkan yang tertinggi adalah 0.0645. Namun, yang lebih menarik adalah hasil R-squared. Hasil terbaik ditemukan pada layer 3, dengan nilai RMSE sebesar 0.0432 dan R-squared sebesar 0.9766. Di sisi lain, hasil yang paling buruk tercatat pada layer 50, dengan nilai R-squared yang negatif, yakni -11.3848. Berdasarkan hasil yang sangat baik yang ditemukan pada layer 3, keputusan diambil untuk menerapkan konfigurasi ini ke seluruh dataset forex yang digunakan. Ini menunjukkan bahwa layer 3 memberikan kinerja yang sangat baik dalam memodelkan data forex.

3. Faktor epoch dalam metode LSTM dan GRU

Dalam hal parameter LSTM, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada epoch untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan jumlah epoch yang lebih besar, namun setelah serangkaian percobaan, kami memilih untuk menambah jumlah epoch untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam Gambar 4.10 di bawah ini



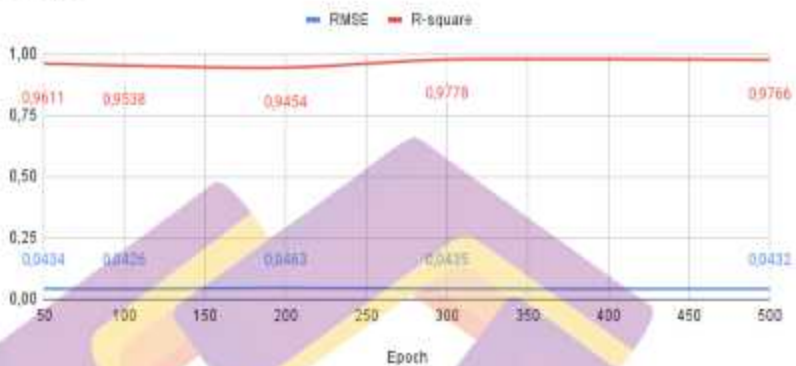
Gambar 4.9. Hyperparameter Epoch Metode LSTM

Dalam Gambar 4.19, kita dapat melihat bahwa nilai MAPE rata-rata berada dalam kisaran 3.49% hingga 3.74%. Namun, ketika kita fokus pada nilai error terkecil dalam bentuk RMSE dengan jumlah epoch 50 mendapatkan nilai sebesar 0.0401. Namun, perlu dicatat bahwa meskipun RMSE rendah, nilai R-squared yang

diperoleh sangat rendah, yaitu hanya 0.9242. Ini menunjukkan bahwa model pada epoch 50 belum sepenuhnya mewakili data dengan baik. Ketika peneliti memeriksa rata-rata nilai RMSE dari epoch 50 hingga 500, peneliti tetap melihat bahwa nilai terendah tetap berada di sekitar 0.0401, sementara nilai tertinggi adalah 0.0430. Namun, yang lebih menarik adalah hasil R-squared. Hasil terbaik ditemukan pada epoch 500, dengan nilai RMSE sebesar 0.0430 dan R-squared sebesar 0.9687. Ini menunjukkan bahwa pada titik ini, model mampu memberikan representasi yang lebih baik terhadap data. Di sisi lain, hasil R-squared yang paling jelek tercatat pada epoch 50, dengan nilai 0.9242. Berdasarkan hasil yang sangat baik yang ditemukan pada epoch 500, keputusan diambil untuk menerapkan konfigurasi ini ke seluruh dataset forex yang digunakan. Ini mengindikasikan bahwa epoch 500 memberikan kinerja yang lebih baik dalam memodelkan data forex.


Dalam hal parameter GRU, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada epoch untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan jumlah epoch yang lebih besar, namun setelah serangkaian percobaan, kami memilih untuk menambah jumlah epoch untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam di bawah ini.

Hyperparameter Epoch Metode GRU Dengan Nilai RMSE dan R-square



Gambar 4.10. Hyperparameter Epoch Metode GRU

Hasil Mape



Gambar 4.11. Hasil MAPE Metode GRU

Pada Gambar 4.10 dan Gambar 4.11, hasil analisis menunjukkan variasi performa model dalam konteks evaluasi yang dilakukan. MAPE rata-rata berkisar antara 3.72% hingga 4.03%, yang menggambarkan tingkat kesalahan prediksi

model terhadap data aktual. Ketika jumlah epoch mencapai 100, terlihat bahwa model mencapai tingkat error terkecil dalam bentuk RMSE sebesar 0.0426. Namun, penting untuk mencatat bahwa R square pada saat itu hanya mencapai 0.9538, menunjukkan bahwa model mungkin tidak cukup baik dalam menjelaskan variasi dalam data. Hasil yang lebih baik terlihat pada epoch 300, di mana RMSE meningkat sedikit menjadi 0.0435, tetapi R square mencapai nilai yang jauh lebih baik, yaitu 0.9778. Ini menandakan bahwa model pada epoch ini mampu menjelaskan lebih banyak variasi dalam data dengan baik. Namun, pada epoch 200, terdapat penurunan kinerja dengan R square sebesar 0.9454. Namun, yang menarik adalah pada epoch 500, meskipun RMSE memiliki tingkat kesalahan yang serupa dengan epoch 300 (0.0435), R square yang diperoleh adalah 0.9764, yang masih sangat baik. Oleh karena itu, berdasarkan hasil yang baik ini, diputuskan untuk menggunakan model dari epoch 500 untuk diterapkan pada seluruh dataset forex yang digunakan, dengan harapan bahwa model ini akan memberikan hasil yang optimal dalam melakukan prediksi.

4. Faktor hidden unit dalam metode LSTM dan GRU

Dalam hal parameter LSTM, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada hidden unit untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan hidden unit yang kecil, namun setelah serangkaian percobaan, kami memilih untuk menambah jumlah hidden unit untuk melihat perbedaan yang mungkin terjadi. Hasil dari

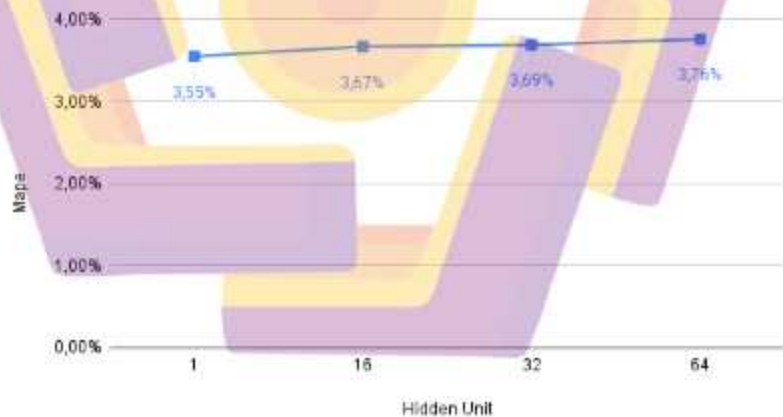
penyesuaian ini telah kami visualisasikan dalam Gambar 4.14 di bawah ini

Hyperparameter Hidden Unit Metode LSTM Dengan Nilai RMSE dan R-square



Gambar 4.12. Hyperparameter Hidden Unit Metode LSTM

Hasil MAPE



Gambar 4.13. Hasil MAPE Metode

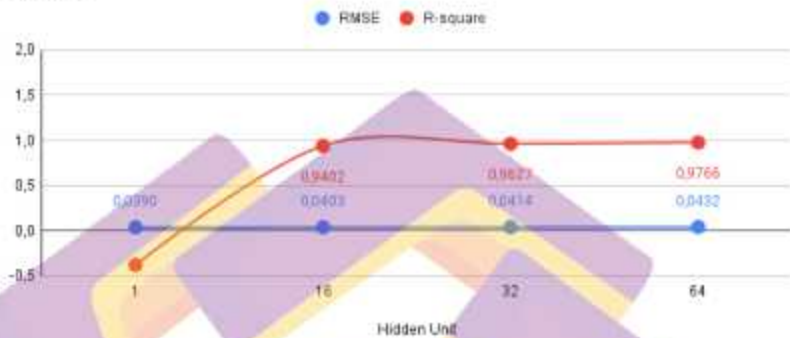
Analisis hasil pengukuran performa model yang telah dilakukan menunjukkan banyak informasi penting, seperti yang ditunjukkan pada Gambar

4.12 dan Gambar 4.13. Pertama nilai MAPE rata-rata berkisar antara 3,55% dan 3,76% dalam kisaran hidden unit yang diuji, menunjukkan tingkat kesalahan prediksi model yang agak rendah. Meskipun demikian, fokus pada evaluasi RMSE menunjukkan sesuatu yang menarik. Nilai RMSE mencapai titik terendah sebesar 0,0390 ketika jumlah hidden unit adalah 1. Namun, hasil ini menunjukkan ketidakcocokan model dengan data, karena nilai R square yang sangat rendah, -0,4499, harus dipertimbangkan. Namun, ketika jumlah hidden unit adalah 64, hasil terbaik dicapai. Nilai RMSE adalah 0,0432, dan R square mencapai tingkat signifikan sebesar 0,9766. Ini menunjukkan bahwa model dengan 64 hidden unit dapat memberikan prediksi yang sangat baik dan sesuai dengan data yang digunakan sebaliknya, konfigurasi dengan hanya 1 hidden unit untuk menghasilkan hasil yang paling buruk, dengan R square sebesar -0,4499, menunjukkan bahwa model tersebut tidak cocok dengan data sama sekali. Berdasarkan hasil yang luar biasa dari model dengan 64 hidden unit, keputusan dibuat untuk menerapkan konfigurasi ini pada keseluruhan dataset. Diharapkan bahwa hal ini akan menghasilkan hasil prediksi yang lebih akurat dan sesuai dengan lebih banyak data.

Dalam hal parameter GRU, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada hidden unit untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan hidden unit yang kecil, namun setelah serangkaian percobaan, kami memilih untuk menambah jumlah hidden unit untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian

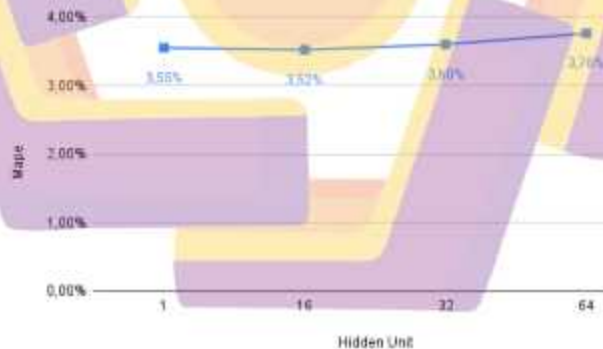
ini telah kami visualisasikan dalam Gambar 4.16 dan Gambar 4.17 di bawah ini

Hyperparameter Hidden Unit Metode GRU Dengan Nilai RMSE dan R-square



Gambar 4.14 Hyperparameter Hidden Unit Metode GRU

Hasil MAPE



Gambar 4.15. Hasil MAPE Metode GRU

Variasi hasil performa model yang signifikan dapat dilihat dengan menganalisis data seperti yang ditunjukkan pada Gambar 4.14 dan Gambar 4.15. Pertama, nilai MAPE berubah dari yang paling rendah hingga yang tertinggi,

berkisar dari 3,55% hingga 3,76%. Ini menunjukkan bahwa tingkat kesalahan relatif model beragam, tetapi umumnya tetap dalam rentang yang wajar. Namun, perhatian khusus harus diberikan pada penilaian menggunakan RMSE dan nilai R square. Nilai RMSE terendah sebesar 0,0390 menunjukkan bahwa model ini berkinerja sangat baik dalam hal kesalahan kuadrat rata-rata. Namun, nilai RMSE terendah ini diimbangi oleh nilai R kuadrat yang sangat rendah, yaitu -0,3764, yang menunjukkan bahwa model tidak mampu menjelaskan variasi data dengan baik. Hasil yang paling baik dicapai dalam konfigurasi dengan 64 hidden unit, dengan nilai RMSE 0,0432 dan nilai R persegi 0,9766. Sebaliknya, konfigurasi dengan hanya 1 hidden unit memiliki hasil yang paling buruk, dengan nilai R square yang sangat rendah sebesar -0,3764, ini menunjukkan bahwa model ini tidak cocok dengan Dengan mengingat hasil yang baik diperoleh dari 64 hidden unit keputusan yang dibuat untuk menerapkan konfigurasi ini pada dataset forex yang digunakan secara keseluruhan. Ini diharapkan akan menghasilkan prediksi yang lebih akurat dan sesuai dengan data secara keseluruhan.

4.3.3. Mengoptimalkan Akurasi Prediksi Harga Forex

Penelitian ini telah menghasilkan hasil yang cukup baik melalui serangkaian eksperimen yang melibatkan langkah-langkah yang cermat dan waktu yang cukup panjang. Tujuan utama penelitian ini adalah untuk mengoptimalkan kinerja dalam meramalkan pergerakan harga forex. Dalam upaya ini, peneliti memilih metode LSTM (Long Short-Term Memory) dan GRU (Gated Recurrent Unit) sebagai dua pendekatan utama yang akan dievaluasi. Pemilihan kedua metode ini dilakukan dengan tujuan untuk membandingkan dan menganalisis kinerja keduanya dalam

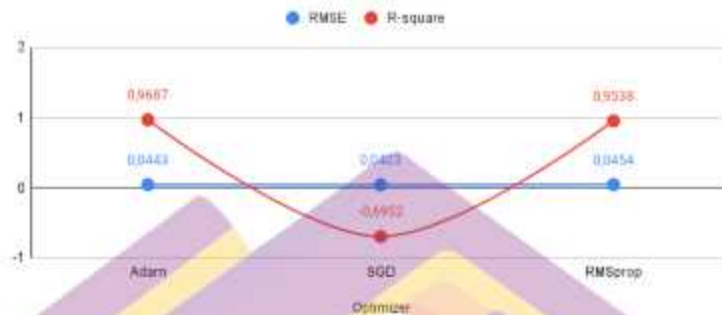
memprediksi harga forex. Hasil dari perbandingan ini akan memberikan wawasan berharga yang dapat menjadi landasan untuk pengembangan penelitian selanjutnya. Dengan demikian, penelitian ini berkontribusi pada upaya pemahaman lebih dalam terkait dengan aplikasi metode-metode tersebut dalam konteks peramalan harga forex.

Hasil perbandingan yang telah dilakukan sebelumnya menunjukkan hasil yang cukup memuaskan dari penelitian ini. Meskipun demikian, kami sadar akan potensi untuk terus meningkatkan kinerja metode yang kami gunakan dalam meramalkan pergerakan harga forex. Oleh karena itu, kami melanjutkan dengan serangkaian percobaan tambahan guna mengoptimalkan metode LSTM dan GRU yang telah kami pilih. Berikut adalah langkah-langkah yang telah kami lakukan dalam upaya meningkatkan performa kedua metode ini:

1. Penyesuaian parameter

Dalam hal parameter LSTM, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada optimizer untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan optimizer adam, namun setelah serangkaian percobaan, kami memilih mencoba beberapa optimizer untuk melihat perbedaan yang mungkin terjadi.

Hyperparameter Optimizer Metode LSTM Dengan Nilai RMSE dan R-square



Gambar 4.16. Optimizer Metode LSTM

Hasil MAPE



Gambar 4.17. Hasil MAPE Metode LSTM

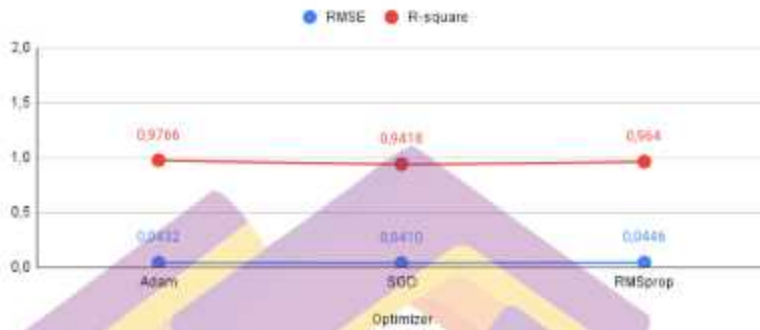
Variasi signifikan dalam performa model menjadi jelas ketika kita mengamati data yang terdokumentasi dalam Gambar 4.16 dan Gambar 4.17. Dalam penelitian ini, berbagai optimizer digunakan selama proses pelatihan model, dan hasil evaluasi kinerjanya memiliki perbedaan yang patut diperhatikan. Pertama,

optimizer Adam menonjol dengan pencapaian yang sangat memuaskan. RMSE yang rendah sebesar 0.0443 mengindikasikan bahwa model memiliki tingkat kesalahan prediksi yang minimal, menghasilkan prediksi yang sangat dekat dengan data aktual. Selain itu, R-square yang tinggi sebesar 0.9687 menunjukkan bahwa model yang menggunakan optimizer Adam memiliki kemampuan yang sangat baik dalam mencocokkan data, menghasilkan hubungan yang erat antara input dan output. MAPE yang relatif rendah sebesar 3.74% juga menandakan tingkat kesalahan yang rendah dalam bentuk persentase, sehingga model ini dapat dianggap sangat akurat dalam meramalkan hasil. Secara keseluruhan, hasil evaluasi menunjukkan bahwa optimizer Adam memberikan kinerja yang sangat baik dalam penelitian ini. Di sisi lain, optimizer SGD berhasil mencapai RMSE yang rendah sebesar 0.0403, mengisyaratkan tingkat kesalahan prediksi yang memadai dalam hal nilai akar kuadrat rata-rata. Meskipun demikian, R-square yang sangat rendah sebesar -0.6952 menggambarkan ketidaksesuaian model ini dengan data yang sangat signifikan. R-square yang negatif mengindikasikan bahwa model dengan optimizer SGD justru memiliki korelasi yang negatif dengan data, yang merupakan hasil yang tidak diinginkan dalam konteks tugas ini. Meskipun MAPE-nya cukup rendah sebesar 3.68%, penurunan yang signifikan dalam R-square mengesampingkan tingkat akurasi ini. Selanjutnya, optimizer RMSprop menghasilkan hasil yang layak, meskipun ada beberapa perbedaan dibandingkan dengan Adam. Dengan RMSE sebesar 0.0454, model ini memiliki tingkat kesalahan prediksi yang masih dapat diterima. R-square yang tinggi sebesar 0.9538 mengindikasikan bahwa model dengan optimizer RMSprop berhasil mencocokkan

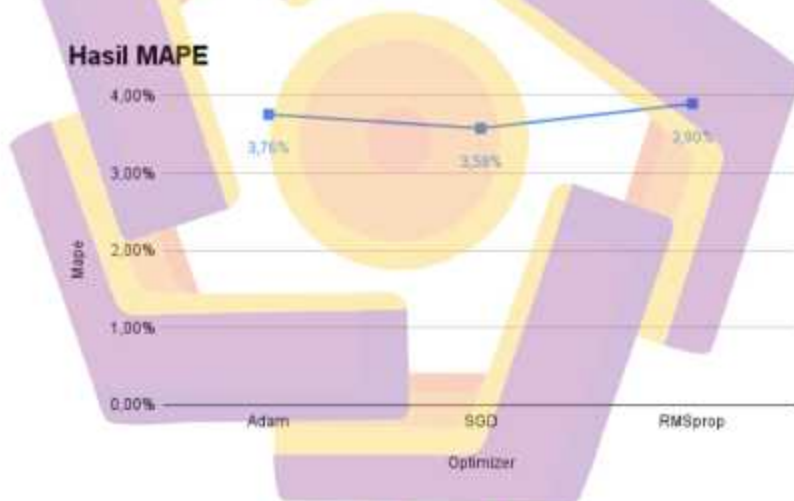
data dengan baik, menjelaskan variasi data dengan baik pula. MAPE yang cukup rendah sebesar 3.97% menunjukkan tingkat kesalahan relatif yang masih dapat diterima dalam bentuk persentase. Bahwa dalam rangkaian eksperimen ini, optimizer Adam telah menunjukkan kinerja yang cukup baik, dengan RMSE rendah, R-square yang tinggi, dan tingkat kesalahan yang minimal dalam bentuk persentase. Meskipun optimizer RMSprop juga memberikan hasil yang baik, pilihan yang lebih bijak adalah menerapkan konfigurasi dengan optimizer Adam pada keseluruhan dataset forex yang digunakan. Ini diharapkan akan menghasilkan prediksi yang lebih akurat dan sesuai dengan data secara keseluruhan, yang merupakan langkah positif dalam mencapai tujuan analisis dan prediksi.

Dalam hal parameter GRU, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan hyperparameter tuning khususnya pada optimizer untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan optimizer adam, namun setelah serangkaian percobaan, kami memilih mencoba beberapa optimizer untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam Gambar 4.20 dan Gambar 4.21 di bawah ini

Hyperparameter Optimizer Metode GRU Dengan Nilai RMSE dan R-square



Gambar 4.18. Optimizer Metode GRU



Gambar 4.19. Hasil MAPE Metode GRU

Variasi signifikan dalam performa model menjadi jelas ketika kita mengamati data yang terdokumentasi dalam Gambar 4.20 dan Gambar 4.21. Dalam penelitian ini, optimizer Adam memberikan hasil yang sangat baik. RMSE yang rendah (0.0432) menunjukkan tingkat kesalahan prediksi yang minimal, sedangkan

R-square yang sangat tinggi (0.9766) mengindikasikan bahwa model dengan optimizer Adam sangat cocok dengan data. MAPE yang relatif rendah (3.76%) juga menunjukkan tingkat kesalahan yang rendah dalam bentuk persentase. Secara keseluruhan, Adam memberikan hasil yang sangat memuaskan dalam evaluasi model. Optimizer SGD memberikan hasil yang baik. RMSE yang rendah (0.0410) menunjukkan tingkat kesalahan prediksi yang memuaskan dalam hal nilai akar kuadrat rata-rata. R-square yang tinggi (0.9418) mengindikasikan model dengan SGD berhasil mencocokkan data dengan baik. MAPE yang relatif rendah (3.58%) juga menunjukkan tingkat kesalahan yang rendah dalam bentuk persentase. SGD cocok untuk tugas ini dan memberikan hasil yang baik. Optimizer RMSprop memberikan hasil yang baik, meskipun sedikit di bawah hasil dari Adam dan SGD. RMSE yang sedikit lebih tinggi (0.0446) masih menunjukkan tingkat kesalahan prediksi yang dapat diterima. R-square yang tinggi (0.9640) mengindikasikan bahwa model dengan RMSprop memiliki kemampuan yang baik dalam mencocokkan data. MAPE yang relatif rendah (3.90%) juga menunjukkan tingkat kesalahan yang masih dapat diterima dalam bentuk persentase. Bahwa ketiga optimizer, yaitu Adam, SGD, dan RMSprop, memberikan hasil yang baik dalam evaluasi model. Adam memberikan kinerja yang sangat baik, sedangkan SGD dan RMSprop juga memberikan hasil yang memadai. Pilihan optimizer dapat bergantung pada preferensi, tetapi hasil ini menunjukkan bahwa Adam adalah pilihan yang kuat dalam hal evaluasi model dengan RMSE rendah dan R-square yang tinggi. pilihan yang lebih baik adalah menerapkan konfigurasi dengan optimizer Adam pada keseluruhan dataset forex yang digunakan. Ini diharapkan

akan menghasilkan prediksi yang lebih akurat dan sesuai dengan data secara keseluruhan, yang merupakan langkah positif dalam mencapai tujuan analisis dan prediksi.

Dalam hal LSTM, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan khususnya pada normalisasi data untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan normalisasi `minmaxscaler`, namun setelah serangkaian percobaan, kami memilih mencoba beberapa normalisasi untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam Gambar 4.22 dan Gambar 4.23 di bawah ini



Gambar 4.20. Normalisasi Metode LSTM

Hasil MAPE



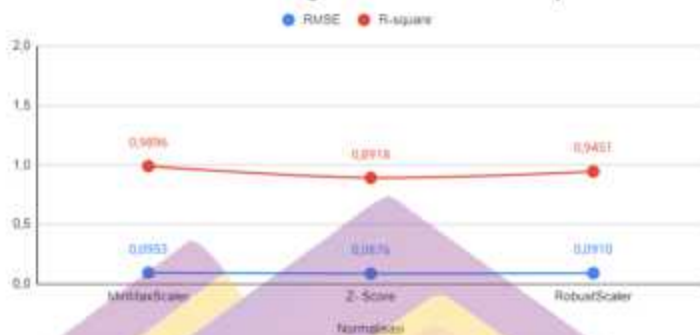
Gambar 4.21. Hasil MAPE Metode LSTM

Variasi hasil performa model dapat memberikan wawasan yang signifikan dalam memahami efektivitas normalisasi data terhadap prediksi. Analisis data, seperti yang ditampilkan dalam Gambar 4.20, mengungkapkan perbedaan hasil antara tiga metode normalisasi yang digunakan. Normalisasi Minmaxscaler memperlihatkan hasil yang sangat baik dengan nilai Root Mean Square Error (RMSE) yang rendah sebesar 0.0939, menunjukkan tingkat kesalahan prediksi yang minim. Tingkat kecocokan model dengan data juga sangat tinggi dengan nilai R-square mencapai 0.9779, serta Mean Absolute Percentage Error (MAPE) yang rendah, yaitu sebesar 6.81%. Normalisasi ini secara jelas memainkan peran penting dalam meningkatkan akurasi prediksi dengan mengurangi kesalahan. Di sisi lain, normalisasi Z-score, meskipun memiliki RMSE yang rendah (0.0911) dan MAPE yang relatif kecil (6.66%), menunjukkan kesesuaian model yang rendah dengan data, dengan R-square sebesar 0.9292. Ini mengindikasikan bahwa metode

normalisasi ini mungkin tidak sesuai dengan kompleksitas data yang dihadapi dalam tugas ini. Normalisasi Robustscaler, sementara memiliki RMSE yang lebih rendah (0.0888) dibandingkan dengan Minmaxscaler, menunjukkan ketidaksesuaian model dengan data, dengan nilai R-square sebesar 0.9064. Meskipun memiliki tingkat kesalahan prediksi yang relatif rendah, hasil ini menunjukkan bahwa normalisasi Robustscaler mungkin kurang mampu menangani variasi data dengan baik. Dalam meningkatkan akurasi dan relevansi prediksi, keputusan diambil untuk menggunakan konfigurasi Normalisasi Minmaxscaler pada keseluruhan dataset forex yang digunakan. Ini diharapkan akan menghasilkan prediksi yang lebih akurat dan sesuai dengan data secara keseluruhan, membantu para pemangku kepentingan dalam pengambilan keputusan yang lebih cerdas dan efektif di pasar forex.

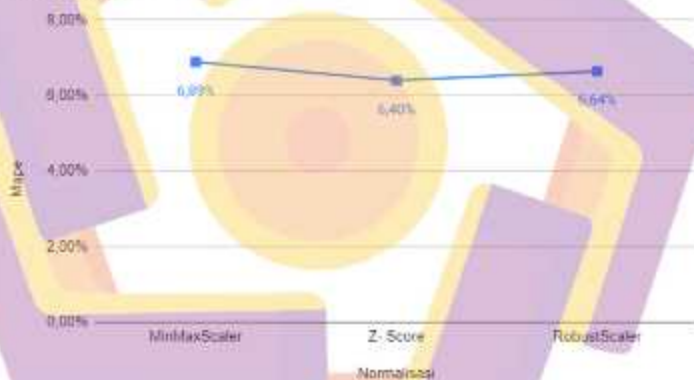
Dalam hal GRU, mendapati bahwa perubahan yang signifikan tidak sepenuhnya diperlukan, mengingat metode ini telah memberikan hasil yang memuaskan sebelumnya. Namun, kami memutuskan untuk melakukan khususnya pada normalisasi data untuk mengeksplorasi kemungkinan perbaikan lebih lanjut. Awalnya, kami menggunakan normalisasi minmaxscaler, namun setelah serangkaian percobaan, kami memilih mencoba beberapa normalisasi untuk melihat perbedaan yang mungkin terjadi. Hasil dari penyesuaian ini telah kami visualisasikan dalam Gambar 4.22 dan Gambar 4.23 di bawah ini.

Normalisasi Metode GRU Dengan Nilai RMSE dan R-square



Gambar 4.22. Normalisasi Metode GRU

Hasil MAPE



Gambar 4.23. Hasil MAPE Metode GRU

Variasi hasil performa model dalam analisis data, seperti yang tercermin dalam Gambar 4.22, memberikan informasi tentang efektivitas normalisasi data dalam konteks prediksi. Dalam evaluasi ini, Normalisasi Minmaxscaler menonjol dengan pencapaian hasil yang luar biasa. RMSE yang rendah sebesar 0.0953 menunjukkan bahwa tingkat kesalahan prediksi sangat minim. Selain itu, nilai R-square yang tinggi (0.9896) mengindikasikan kesesuaian model dengan data yang

sangat baik, sementara MAPE yang relatif rendah (6.89%) menunjukkan bahwa tingkat kesalahan prediksi dalam bentuk persentase juga rendah. Di sisi lain, Normalisasi Z-score memperlihatkan RMSE yang rendah (0.0876) dan MAPE yang relatif kecil (6.40%), namun, R-square yang rendah (0.8918) mengungkapkan ketidaksesuaian model dengan data. Meskipun Normalisasi Robustscaler memiliki RMSE yang sedikit lebih tinggi (0.0910) dibandingkan dengan Minmaxscaler, hasil R-square yang rendah (0.9451) menunjukkan kurangnya kesesuaian model ini dengan data. Dengan mempertimbangkan hasil evaluasi, keputusan diambil untuk menerapkan Normalisasi Minmaxscaler pada keseluruhan dataset forex yang digunakan. Langkah ini diharapkan dapat menghasilkan prediksi yang lebih akurat dan relevan dengan data secara keseluruhan, memberikan landasan yang kuat bagi para pelaku pasar forex dan analis keuangan untuk membuat keputusan investasi yang cerdas dan terinformasi. Keberhasilan Normalisasi Minmaxscaler dalam menghasilkan prediksi yang sangat baik menunjukkan pentingnya memilih metode normalisasi yang tepat untuk meningkatkan kualitas prediksi dalam konteks pasar mata uang.

2. Pemilihan Metode Evaluasi

Metode evaluasi kinerja adalah langkah kritis dalam mengukur keefektifan model prediksi, dan pilihan metode evaluasi harus disesuaikan dengan karakteristik data dan tujuan analisis yang hendak dicapai. Penelitian ini bertujuan untuk memberikan wawasan mendalam tentang sejauh mana model yang telah diterapkan mampu meminimalkan kesalahan dalam melakukan prediksi. Dalam konteks ini, RMSE (Root Mean Square Error) menjadi pilihan yang relevan. RMSE

memberikan gambaran tentang tingkat kesalahan prediksi dalam unit yang sama dengan variabel yang diukur, dan semakin kecil nilai RMSE, semakin baik performa model. Selain RMSE, penelitian ini juga mempertimbangkan perubahan metode evaluasi untuk mencocokkan karakteristik data dan tujuan penelitian.

Penekanan diberikan pada pemahaman kesalahan prediksi dan evaluasi akurasi metode regresi dalam bentuk persentase kesalahan, yang diukur dengan MAPE (Mean Absolute Percentage Error). Penggunaan MAPE sebagai metode evaluasi memberikan wawasan yang lebih jelas tentang tingkat kesalahan relatif dalam bentuk persentase, yang dapat memberikan pemahaman yang lebih mendalam tentang performa model. Dalam penelitian ini, penting untuk dicatat bahwa perubahan metode evaluasi dapat menghasilkan perbedaan signifikan dalam hasil yang diperoleh. Faktor ini juga dipengaruhi oleh penerapan skenario dan parameter metode yang digunakan. Oleh karena itu, pemilihan metode evaluasi yang tepat sangat relevan dalam mengevaluasi kinerja model prediksi dan dapat membantu mengoptimalkan hasil analisis dalam rangka mencapai tujuan penelitian. Ketika mengoptimasi metode LSTM (Long Short-Term Memory) dan GRU (Gated Recurrent Unit), kita harus memahami bahwa kita bekerja dengan arsitektur dasar yang telah ditetapkan untuk kedua metode tersebut. Dalam hal ini, ada sedikit ruang untuk melakukan perubahan drastis dalam arsitektur inti metode.

Meskipun begitu, penelitian ini memiliki nilai yang signifikan dalam menghadirkan hasil yang layak untuk pertimbangan. Salah satu hal penting yang perlu ditekankan adalah penelitian ini melanjutkan eksplorasi pada metode yang sama yang digunakan dalam penelitian sebelumnya, tetapi dengan rentang data

yang mungkin serupa. Ini memberikan kontribusi berharga dengan cara yang tidak dapat diabaikan. Eksperimen yang dilakukan dalam penelitian ini telah mengintegrasikan upaya penyesuaian yang matang dan pemahaman yang lebih baik tentang kinerja LSTM dan GRU pada konteks data yang digunakan. Penelitian ini, dengan demikian, dapat dianggap sebagai langkah yang signifikan dalam mengisi kesenjangan pengetahuan yang mungkin ada dalam penelitian sebelumnya yang juga menggunakan metode yang sama dengan dataset yang serupa. Dengan demikian, hasil dan temuan dari penelitian ini memberikan kontribusi penting dalam memahami kinerja metode LSTM dan GRU, bahkan jika kita terbatas oleh arsitektur dasar dari kedua metode tersebut. Hal ini membantu mengarahkan penelitian ke arah yang lebih baik dan memungkinkan perkembangan pengetahuan yang lebih mendalam dalam domain ini. Hasil yang telah diperoleh dalam penelitian ini diharapkan akan memberikan kontribusi yang berharga bagi perkembangan ilmu pengetahuan dan memberikan landasan yang kuat untuk penelitian selanjutnya. Selain menjadi pengetahuan baru dalam domain ini, temuan dari penelitian ini juga memiliki potensi aplikatif yang signifikan dalam kehidupan sehari-hari, khususnya bagi para pelaku di pasar forex. Hasil penelitian ini memiliki potensi untuk memberikan panduan dalam pengambilan keputusan saat berinvestasi di pasar forex. Dengan memanfaatkan hasil penelitian ini, para investor dapat membuat strategi trading yang lebih cerdas dan terinformasi. Mereka juga dapat mengelola portofolio forex mereka dengan lebih bijak, mengalokasikan aset digital mereka dengan lebih cermat, dan mempertimbangkan untuk mengurangi eksposur mereka terhadap aset tertentu dalam portofolio mereka.

Selain itu, hasil penelitian ini memiliki potensi untuk digunakan dalam pengembangan alat berbasis web yang dapat digunakan untuk memprediksi pergerakan harga forex dengan menggunakan deep learning. Meskipun perlu diperhatikan bahwa harga forex cenderung tidak stabil dan dipengaruhi oleh berbagai faktor eksternal seperti sentiment pasar, regulasi, dan peristiwa dunia, hasil prediksi dari model deep learning ini dapat digunakan sebagai alat bantu dalam pengambilan keputusan investasi yang lebih cerdas. Dengan mengintegrasikan hasil analisis yang lebih teliti dan mempertimbangkan faktor-faktor lainnya, para pengguna dapat membuat keputusan investasi yang lebih baik dan terinformasi.

Dalam rangka mengingatkan, penting untuk diingat bahwa prediksi harga forex, seperti halnya forex, tetaplah menjadi tantangan yang kompleks karena sifatnya yang sangat dinamis. Oleh karena itu, hasil dari model prediksi yang menggunakan deep learning harus digunakan dengan bijak dan sebagai alat bantu dalam pengambilan keputusan investasi yang lebih cerdas. Kesadaran tentang ketidakpastian dan risiko dalam investasi tetaplah penting, dan hasil penelitian ini dapat menjadi salah satu sumber informasi yang berharga dalam proses pengambilan keputusan yang lebih terinformasi.


4.4 Perbandingan dengan Penelitian Sebelumnya

Berdasarkan hasil analisis yang telah dilakukan pada metode Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU), selanjutnya akan ditampilkan rangkuman terkait studi literature yang ada, yang menjadi landasan pada penelitian ini. Rangkuman ini bertujuan untuk membandingkan hasil

penelitian ini dengan hasil studi literatur yang digunakan. Perbandingan hasil terhadap studi literatur dapat dilihat pada Tabel 4.18

Tabel 4.18 Perbandingan Penelitian

Penulis	Metode	RMSE	R2	MAPE
(Hansun et al., 2022b)	LSTM	0.306	0.089	
(Sarangi et al., 2020)	ANN	0.390	-	
Metode yang diusulkan	LSTM	0.0392	0.976	6.7%
	GRU	0.106	0.098	7.7%



BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik kesimpulan sebagai berikut;

1. Penelitian ini mengeksplorasi efek skenario dan data terhadap performa kedua metode ini, dengan hasil yang menarik. Skema skenario dan variasi penggunaan data sangat penting untuk menghasilkan hasil evaluasi yang bervariasi antara kedua metode, LSTM (Long Short-Term Memory) dan GRU (Gated Recurrent Unit). Baik LSTM maupun GRU berhasil mencapai nilai eror terkecil pada level perbandingan antara mata uang forex, metode LSTM menghasilkan nilai eror terkecil pada pasangan mata uang EURUSD, dengan RMSE sebesar 0.092 dan MAPE sebesar 6.7%. Tingkat kecocokan yang tinggi, dengan nilai R square 0.976, menunjukkan bahwa model LSTM mampu memprediksi pergerakan EURUSD dengan sangat baik. Sebaliknya, dengan RMSE sebesar 0.106 dan MAPE sebesar 7.7%, metode GRU juga berhasil mencapai eror terkecil pada mata uang AUDCAD forex. Namun, GRU menunjukkan kinerja yang lebih baik dengan nilai RMSE sebesar 0.0415, yang menunjukkan bahwa model GRU memiliki kemampuan yang baik untuk mencocokkan data pada pasangan mata uang AUDCAD. Hasil ini menunjukkan betapa pentingnya memikirkan skenario yang tepat dan menggunakan data yang tepat saat melakukan analisis prediksi forex. Selain

itu, perbandingan antara LSTM dan GRU menunjukkan bahwa kedua metode memiliki fitur yang berbeda dalam menangani pergerakan mata uang. Keputusan antara kedua metode ini akan sangat bergantung pada tujuan analisis, karena GRU menonjol dalam hal hasil R square yang tinggi, sementara LSTM menunjukkan akurasi yang tinggi dalam RMSE dan MAPE.

2. Dalam penelitian ini, terdapat beberapa faktor kunci yang memengaruhi kinerja terbaik dari metode LSTM dan GRU dalam melakukan prediksi mata uang forex. Faktor-faktor ini menjadi bagian integral dari proses evaluasi dan pengembangan model prediksi. Dua faktor utama yang mencuat dalam penelitian ini adalah pemilihan alokasi data dan penggunaan data masa lalu yang berbeda dalam metode LSTM dan GRU. Pertama, pemilihan alokasi data yang cermat menjadi salah satu langkah awal yang berpengaruh terhadap hasil akhir dari kedua metode. Proses alokasi data ini harus mempertimbangkan sejumlah faktor, termasuk pemilihan pasangan mata uang tertentu dan kerangka waktu yang sesuai. Keputusan ini sangat penting karena akan memengaruhi seberapa baik model dapat memahami pola pergerakan harga mata uang dan beradaptasi dengan volatilitas pasar yang mungkin berubah-ubah. Selanjutnya, penggunaan data masa lalu menjadi elemen yang penting dalam kedua metode LSTM dan GRU. Data masa lalu digunakan untuk melatih model agar dapat memahami pola dan tren historis dalam pergerakan mata uang. Penggunaan data yang tepat dalam tahap pelatihan sangat krusial dalam memastikan model dapat

menghasilkan prediksi yang akurat. LSTM dan GRU memiliki pendekatan yang berbeda dalam menangani data masa lalu, dan pemahaman yang baik tentang bagaimana keduanya berinteraksi dengan data historis menjadi kunci dalam mencapai kinerja terbaik. Kedua faktor ini menggarisbawahi pentingnya pendekatan yang cermat dan pemahaman yang mendalam dalam merancang, mengkonfigurasi, dan melatih model prediksi mata uang forex menggunakan metode LSTM dan GRU. Sebagai hasilnya, penelitian ini memberikan kontribusi dalam mengidentifikasi faktor-faktor kunci yang memengaruhi kinerja model prediksi dan memberikan wawasan yang lebih dalam tentang bagaimana model dapat dioptimalkan dalam konteks pergerakan mata uang forex.

3. Penelitian ini mengimplementasikan berbagai strategi untuk mengoptimasi kinerja prediksi forex dengan memodifikasi arsitektur pada metode LSTM dan GRU. Modifikasi ini mencakup penyesuaian parameter kunci seperti nilai inputan layer, jumlah epoch yang digunakan, jumlah hidden unit, dan bahkan penyesuaian pada optimizer yang digunakan dalam proses pelatihan model. Pertama-tama, penyesuaian pada nilai inputan layer adalah langkah penting dalam mengoptimalkan kedua metode. Pengaturan input layer yang memungkinkan model untuk memahami data input dengan lebih baik dan dapat menghasilkan representasi yang lebih akurat dari pergerakan harga mata uang. Ini membantu dalam meningkatkan tingkat akurasi prediksi. Selanjutnya, penentuan jumlah epoch, yang mengatur berapa kali seluruh dataset akan dilalui selama pelatihan, adalah faktor penting dalam

mengoptimalkan performa model. Pengaturan jumlah epoch yang sesuai akan memastikan bahwa model mencapai hasil yang baik tanpa terlalu lama atau terlalu pendek dalam proses pelatihan. Pengaturan jumlah hidden unit adalah komponen lain dalam modifikasi arsitektur. Jumlah hidden unit yang tepat dapat memengaruhi kapasitas model dalam menangkap pola-pola yang kompleks dalam data, yang dapat memperbaiki kinerja prediksi. Selain itu, penyesuaian pada optimizer digunakan untuk mengatur algoritma yang mengoptimalkan parameter-model selama pelatihan. Pemilihan optimizer yang sesuai dapat mempercepat proses dan membantu model mencapai hasil yang lebih baik. Dengan kombinasi dari penyesuaian-penyesuaian ini, penelitian ini bertujuan untuk menghasilkan model prediksi forex yang lebih baik dan akurat. Pendekatan ini mencerminkan upaya yang matang dalam mengoptimalkan model prediksi mata uang, mengambil keuntungan dari fleksibilitas dan konfigurabilitas yang ditawarkan oleh metode LSTM dan GRU. Hasil penelitian ini diharapkan dapat memberikan panduan berharga dalam memilih dan mengkonfigurasi model yang efektif dalam konteks pergerakan mata uang forex.

5.2. Saran

Adapun beberapa saran bagi pengembangan penelitian ini yaitu :

- a. Penelitian ini mengadopsi metode dasar LSTM dan GRU sebagai langkah awal untuk menguji konsep penggunaan data yang melibatkan 20 tahun sebelumnya dalam memprediksi pergerakan mata uang forex. Hasilnya menunjukkan bahwa metode ini mampu menghasilkan nilai

error terendah yang dapat diandalkan dalam konteks ini. Untuk penelitian selanjutnya, direkomendasikan untuk mengembangkan metode LSTM dan GRU dengan lebih mendalam, termasuk penggunaan data yang sama selama periode 20 tahun. Dengan melibatkan data historis yang lebih luas, penelitian mendatang dapat membandingkan hasilnya dengan metode yang belum dimodifikasi. Hal ini dapat membantu untuk memahami potensi dan keterbatasan dari model yang lebih canggih. Pengembangan dan peningkatan metode ini akan memberikan pemahaman tentang sejauh mana data yang melibatkan 20 tahun dapat dimanfaatkan dalam memprediksi pergerakan mata uang forex. Langkah-langkah ini dapat membantu dalam merancang model yang lebih kuat dan efektif untuk memahami dinamika pasar yang lebih luas, yang pada gilirannya dapat digunakan dalam pengambilan keputusan investasi yang lebih cerdas dan strategi trading yang lebih baik.

- b. Mempertimbangkan menggunakan metode lainnya seperti Recurrent Neural Network (RNN) dalam memprediksi forex untuk melihat hasil yang lebih baik.
- c. Untuk penelitian selanjutnya, ada potensi besar dalam mempertimbangkan penggunaan variabel independen lain pada dataset, seperti Open (harga pembukaan) atau Close (harga penutupan) dalam rangka memperoleh pemahaman yang lebih komprehensif tentang dinamika pergerakan mata uang forex. Variabel-variabel ini dapat memberikan wawasan tambahan dan hasil yang berbeda dalam analisis

prediksi forex. Penggunaan variabel harga pembukaan (Open) dapat memberikan gambaran tentang harga awal pada suatu periode perdagangan, yang dapat mencerminkan sentimen awal dari pelaku pasar. Sementara itu, variabel harga penutupan (Close) mencerminkan harga pada akhir periode perdagangan, yang dapat memberikan informasi tentang bagaimana pasar bereaksi terhadap berbagai peristiwa selama periode tersebut. Dengan memasukkan kedua variabel ini sebagai independent variable, penelitian berikutnya dapat lebih memahami pengaruhnya terhadap prediksi pergerakan mata uang. Dengan mempertimbangkan berbagai variabel independen yang berbeda, penelitian mendatang dapat mencoba mengidentifikasi faktor-faktor yang paling berpengaruh dalam prediksi pergerakan mata uang dan membangun model yang lebih akurat.

- d. Mempertimbangkan penerapan parameter yang lebih banyak lagi pada metode LSTM dan GRU
- e. Melakukan pengacakan data secara random pada metode yang diterapkan.
- f. Memprediksi metode LSTM dan GRU menggunakan pola-pola yang kompleks dan variasi data yang unik. Dengan memperhatikan perbandingan sebaran dan karakteristik data, dapat membuat keputusan yang lebih luas mengenai metode yang paling cocok untuk digunakan dalam situasi tertentu.

DAFTAR PUSTAKA

PUSTAKA BUKU

- Dhanardono, B., Atmodjo, D., Utomo, A. B., & Hartono, J. (2022). *Pemodelan Tiga Dimensi Menggunakan Total Station, Terrestrial Laser Scanner Dan Unmanned Aerial Vehicle*. Deepublish.
- Fandango, Armando., Idris, Ivan., & Navlani, Avinash. (2021). *Python Data Analysis - Third Edition*. Packt Publishing.
- Khrisna Wardhani, A., Israwan, F., Setiawan, J., S, W., Khikmah, L., Ilham, A., & Nurmuslimah, S. (2022). *Teknik Peramalan Pada Teknologi Informasi*. Get Press.
- Puspita, H., & dkk. (2022). Pengantar Teknologi Informasi - Google Books. HeriUtama.https://www.google.co.id/books/edition/Pengantar_Teknologi_Informasi/43h8EAAAQBAJ?hl=en&gbpv=1&dq=LSTM+adalah&pg=PA197&printsec=frontcover

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Abedin, M. Z., Moon, M. H., Hassan, M. K., & Hajek, P. (2021). Deep learning-based exchange rate prediction during the COVID-19 pandemic. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-021-04420-6>
- Ahmed, S., Hassan, S. U., Aljohani, N. R., & Nawaz, R. (2020). FLF-LSTM: A novel prediction system using Forex Loss Function. *Applied Soft Computing Journal*, 97. <https://doi.org/10.1016/j.asoc.2020.106780>
- Cabrera, F. (2019). *Application of ARIMA, RNN and LSTM on Foreign Exchange Rate Prediction*.
- Chantarakasemchit, O., & Nuchitprasitchai, S. (2021). Enhancing Forex Rates Prediction with Machine Learning on EUR to USD with Moving Average Methods and Financial Factors. *Lecture Notes in Networks and Systems*, 251, 44–54. https://doi.org/10.1007/978-3-030-79757-7_5
- Dash, R. (2018). Performance analysis of a higher order neural network with an improved shuffled frog leaping algorithm for currency exchange rate prediction. *Applied Soft Computing Journal*, 67, 215–231. <https://doi.org/10.1016/j.asoc.2018.02.043>

- Escudero, P., Alcocer, W., & Paredes, J. (2021). Recurrent neural networks and ARIMA models for euro/dollar exchange rate forecasting. *Applied Sciences (Switzerland)*, 11(12). <https://doi.org/10.3390/app11125658>
- Hansun, S., Putri, F. P., Khaliq, A. Q. M., & Hugeng, H. (2022). On searching the best mode for forex forecasting: bidirectional long short-term memory default mode is not enough. *IAES International Journal of Artificial Intelligence*, 11(4), 1596–1606. <https://doi.org/10.11591/ijai.v11.i4.pp1596-1606>
- Henriquez, J., & Kristjanpoller, W. (2019). A COMBINED INDEPENDENT COMPONENT ANALYSIS-NEURAL NETWORK MODEL FOR FORECASTING EXCHANGE RATE VARIATION. *Applied Soft Computing Journal*, 83. <https://doi.org/10.1016/j.asoc.2019.105654>
- Hu, Z., Liu, W., Bian, J., Liu, X., & Liu, T.-Y. (2018). Listening to Chaotic Whispers. *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining, 2018-February*, 261–269. <https://doi.org/10.1145/3159652.3159690>
- Islam, M. S., & Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. *Soft Computing Letters*, 3, 100009. <https://doi.org/10.1016/j.socl.2020.100009>
- Kasus, S., Usd, G. I., Saputra Suryono, M., & Oetama, R. (2019). Peramalan terhadap Forex dengan Metode ARIMA. *ULTIMATICS*, XI(1). www.investing.com.
- Lu, C. (2022). *The Long Short-Term Memory of GBP/CNY Exchange Rate Forecasts*. <https://finance.yahoo.com>
- Qi, L., Khushi, M., & Poon, J. (2020). Event-Driven LSTM For Forex Price Prediction. *2020 IEEE Asia-Pacific Conference on CSDE*, 1–6. <https://doi.org/10.1109/CSDE50874.2020.9411540>
- Rana, M., Mao, N., Ao, M., Wu, X., Liang, P., & Khushi, M. (2021). *Clustering and attention based model for intelligent trading*.
- Sarangi, P. K., Chawla, M., Ghosh, P., Singh, S., & Singh, P. K. (2020). FOREX trend analysis using machine learning techniques: INR vs USD currency exchange rate using ANN-GA hybrid approach. *Materials Today: Proceedings*, 49, 3170–3176. <https://doi.org/10.1016/j.matpr.2020.10.960>
- Satyo Bayangkari Karno, A., Noer Ali, J. K., & Bekasi, K. (2020). Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory). *Journal of Information and Information Security (JIFORTY)*, 1(1), 1–8. <http://ejournal.uharajaya.ac.id/index.php/jiforty>

- Son, H. G. (2020). A Combination of Finite Impulse Response Neural Networks, ARIMA and Principal Component Analysis for Forex Market Prediction. In *Lecture Notes in Networks and Systems* (Vol. 104, pp. 1–10). Springer. https://doi.org/10.1007/978-3-030-37497-6_1
- Tlegenova, D. (2015). *Forecasting Exchange Rates Using Time Series Analysis: The sample of the currency of Kazakhstan*.
- Ulina, M., Purba, R., & Halim, A. (2020, November 3). Foreign Exchange Prediction using CEEMDAN and Improved FA-LSTM. *2020 5th International Conference on Informatics and Computing, ICIC 2020*. <https://doi.org/10.1109/ICIC50835.2020.9288615>
- Wanto, A., & Windarto, A. P. (2017). Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation. *Jurnal & Penelitian Teknik Informatika*, 2(2).
- Wijaya, A. J., Swastika, W., & Kelana, O. H. (2021). PREDIKSI HARGA FOREIGN EXCHANGE MATA UANG EUR/USD DAN GBP/USD MENGGUNAKAN LONG SHORT-TERM MEMORY. *Sainsbertek Jurnal Ilmiah Sains & Teknologi*, 2(1), 16–31. <https://doi.org/10.33479/sb.v2i1.121>
- WIJESINGHE, S. (2020). Time Series Forecasting: Analysis of LSTM Neural Networks to Predict Exchange Rates of Currencies. *INSTRUMENTATION*, 7(4), 25–39.
- Yamak, P. T., Yujian, L., & Gadosey, P. K. (2019). A Comparison between ARIMA, LSTM, and GRU for Time Series Forecasting. *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence*, 49–55. <https://doi.org/10.1145/3377713.3377722>
- Yıldırım, D. C., Toroslu, I. H., & Fiore, U. (2021). Forecasting directional movement of Forex data using LSTM with technical and macroeconomic indicators. *Financial Innovation*, 7(1). <https://doi.org/10.1186/s40854-020-00220-2>
- Yu, H., Liu, J., Chen, C., Heidari, A. A., Zhang, Q., Chen, H., Mafarja, M., & Turabieh, H. (2021). Corn Leaf Diseases Diagnosis Based on K-Means Clustering and Deep Learning. *IEEE Access*, 9, 143824–143835. <https://doi.org/10.1109/ACCESS.2021.3120379>
- Zeng, zhiwen, & Khushi, M. (2020). Wavelet Denoising and Attention-based RNN-ARIMA Model to Predict Forex Price. *IEEE*.