

OPTIMASI AKURASI *BILSTM* DALAM PERAMALAN HARGA EMAS

SKRIPSI

DISUSUN OLEH

ANGGI MUAMMAR HANAFI

NPM. 2109020032



**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2025

OPTIMASI AKURASI *BILSTM* DALAM PERAMALAN HARGA EMAS

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Teknologi Informasi pada Fakultas Ilmu
Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

ANGGI MUAMMAR HANAFI

NPM. 2109020032

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2025

LEMBAR PENGESAHAN

Judul Skripsi : Optimasi Akurasi *Bilstm* Dalam Peramalan Harga Emas
Nama Mahasiswa : Anggi Muammar Hanafi
NPM : 2109020032
Program Studi : Teknologi Informasi

Menyetujui
Komisi Pembimbing



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

Ketua Program Studi



(Fatma Sari Hutagalung S.Kom., M.Kom.)
NIDN. 0117019301

Dekan



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

OPTIMASI AKURASI *BILSTM* DALAM PERAMALAN HARGA EMAS

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan,⁵Agustus 2025

Yang membuat pernyataan



Anggi Muammar Hanafi

NPM. 2109020032

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : Anggi Muammar Hanafi
NPM : 2109020032
Program Studi : Teknologi Informasi
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

**OPTIMASI AKURASI *BILSTM* DALAM PERAMALAN
HARGA EMAS**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 09 Agustus 2025

Yang membuat pernyataan



Anggi Muammar Hanafi
NPM. 2109020032

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Anggi Muammar Hanafi
Tempat dan Tanggal Lahir : Medan, 19 Mei 2003
Alamat Rumah : Jl. Karya Komplek SLB Pembina
LK XI No 4
Telepon/Faks/HP : 085361287733
E-mail : anggimuammarhanafi@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : SD Negeri 060849 TAMAT: 2015
SMP : SMP Negeri 16 Medan TAMAT: 2018
SMK : SMK Swasta Amir Hamzah Medan TAMAT: 2021

KATA PENGANTAR



Assalamualaikum Warahmatullahi Wabarakatuh

Alhamdulillah, puji syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, serta nikmat kesehatan dan kesempatan yang telah diberikan, sehingga penulis dapat menyelesaikan penyusunan skripsi ini yang

berjudul “Optimasi Akurasi *Bilstm* Dalam Peramalan Harga Emas” sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi,

Universitas Muhammadiyah Sumatera Utara.

Penulis menyadari bahwa keberhasilan dalam penyusunan skripsi ini tidak terlepas dari dukungan dan bantuan berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. Agussani, M.AP., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom., selaku Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU dan juga selaku dosen pembimbing yang telah dengan penuh kesabaran membimbing, memberikan masukan, arahan, dan motivasi selama proses penyusunan skripsi ini.
3. Ibu Fatma Sari Hutagaulung, S.Kom., M.Kom., selaku Ketua Program Studi Teknologi Informasi.
4. Bapak Muhammad Basri, S.Kom., M.Kom., selaku Sekretaris Program Studi Teknologi Informasi.
5. Seluruh dosen dan staf akademik di lingkungan Fakultas Ilmu Komputer dan Teknologi Informasi, khususnya Program Studi Teknologi Informasi, yang telah memberikan ilmu dan pengalaman berharga selama masa studi.
6. Kedua orang tua tercinta, Saudara, Paman, dan juga Sepupu, yang selalu memberikan doa, semangat, cinta, serta dukungan moral dan material tanpa henti.

7. Rekan-rekan seperjuangan di grup “Punyaku-punyaku Grup” yaitu Yoga, Qodri, Rifqi, Gatot, Farhan, Ikhsan, dan Mubarton, yang telah menjadi teman diskusi sekaligus motivasi selama menempuh studi di UMSU.
8. Para teman-teman sekolah, baik dari teman SMK maupun SMP yang juga memberikan doa, semangat dan dukungan kepada penulis selama menempuh studi di UMSU.
9. Semua pihak yang tidak dapat disebutkan satu per satu yang telah membantu dan memberikan dukungan secara langsung maupun tidak langsung dalam penyelesaian skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang membangun untuk perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi pembaca serta menjadi referensi yang berguna, khususnya dalam pengembangan sistem prediksi harga emas berbasis deep learning.

Medan, 09 Agustus 2025

Penulis



Anggi Muammar Hanafi

OPTIMASI AKURASI *BILSTM* DALAM PERAMALAN HARGA EMAS

ABSTRAK

Peramalan harga emas menjadi tantangan penting dalam dunia keuangan, khususnya bagi investor yang menjadikan emas sebagai aset lindung nilai terhadap gejolak ekonomi. Harga emas bersifat fluktuatif dan dipengaruhi oleh berbagai faktor global, sehingga dibutuhkan model prediksi yang mampu menangkap pola historis secara akurat. Penelitian ini bertujuan untuk mengimplementasikan dan mengoptimalkan model *Bidirectional Long Short-Term Memory* (BiLSTM) dalam meramalkan harga emas mingguan menggunakan data periode 2020 hingga 2024 yang diperoleh dari *Yahoo Finance*. Data yang digunakan difokuskan pada harga penutupan mingguan, yang kemudian diproses melalui tahapan normalisasi, pembentukan sliding window, dan pembagian dataset menjadi data latih dan data uji dengan rasio 80:20. Model BiLSTM dikembangkan menggunakan pustaka TensorFlow dan Keras, serta diuji dengan beberapa kombinasi parameter seperti jumlah neuron, epoch, batch size, dan panjang window. Evaluasi kinerja dilakukan menggunakan dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil eksperimen menunjukkan bahwa optimasi parameter memberikan kontribusi signifikan terhadap peningkatan akurasi prediksi, dengan nilai RMSE sebesar 83.99 dan MAPE sebesar 2.41%. Secara keseluruhan, model BiLSTM menunjukkan efektivitas yang baik dalam mengikuti tren harga emas mingguan dan dapat menjadi alternatif yang menjanjikan dalam sistem peramalan berbasis *machine learning*.

Kata Kunci: BiLSTM, harga emas, prediksi, RMSE, MAPE, *Yahoo Finance*

BILSTM ACCURACY OPTIMIZATION IN GOLD PRICE FORECASTING

ABSTRACT

Forecasting gold prices is a critical challenge in the financial sector, particularly for investors who consider gold as a hedge against economic uncertainty. Gold prices are highly volatile and influenced by various global factors, which necessitates a predictive model capable of accurately capturing historical patterns. This study aims to implement and optimize the *Bidirectional Long Short-Term Memory* (BiLSTM) model to forecast weekly gold prices using data from 2020 to 2024 obtained from *Yahoo Finance*. The dataset used focuses on weekly closing prices and is processed through normalization, sliding window formation, and a train-test split with an 80:20 ratio. The BiLSTM model was developed using TensorFlow and Keras libraries, with parameter optimization involving neuron count, epochs, batch size, and window size. The model's performance was evaluated using two key metrics: *Root Mean Squared Error* (RMSE) and *Mean Absolute Percentage Error* (MAPE). Experimental results indicate that parameter optimization significantly improves prediction accuracy, with the best RMSE obtained at 83.99 and MAPE at 2.41%. Overall, the BiLSTM model effectively captures weekly gold price trends and demonstrates strong potential for use in machine learning-based forecasting systems.

Keywords: BiLSTM, gold price, prediction, RMSE, MAPE, *Yahoo Finance*

DAFTAR ISI

LEMBAR PENGESAHAN	i
PERNYATAAN ORISINALITAS.....	ii
PERNYATAAN PERSETUJUAN PUBLIKASI	iii
RIWAYAT HIDUP.....	iv
KATA PENGANTAR	v
ABSTRAK.....	vii
ABSTRACT.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN	2
1.1. Latar Belakang Masalah	2
1.2. Rumusan Masalah.....	4
1.2. Batasan Masalah	5
1.4. Tujuan Penelitian	6
1.5. Manfaat Penelitian	6
BAB II LANDASAN TEORI	8
2.1. Emas	8
2.1.1. Definisi dan Karakteristik Emas	8
2.1.2. Jenis dan Bentuk Investasi Emas	9
2.1.3. Faktor yang Mempengaruhi Harga Emas	10
2.2. Peramalan Deret Waktu (Time Series Forecasting)	12
2.2.1. Definisi Deret Waktu (Time Series)	12
2.2.2. Komponen Deret Waktu	13
2.2.3. Karakteristik Deret Waktu pada Harga Emas	14
2.3. Machine Learning	15
2.3.1. Konsep Dasar Machine Learning.....	15
2.3.2. Penerapan Machine Learning untuk Prediksi Harga Komoditas	17
2.4. Deep Learning	18
2.4.1. Konsep Dasar Deep Learning	18
2.4.2. <i>Artificial Neural Network</i> (ANN).....	19
2.4.3. <i>Recurrent Neural Network</i> (RNN).....	20
2.4.4. <i>Long Short-Term Memory</i> (LSTM)	20
2.4.5. <i>Bidirectional Long Short-Term Memory</i> (BiLSTM).....	22
2.5. Optimasi dan Parameter dalam Deep Learning	24
2.5.1. Pengertian Hyperparameter dan Optimasi	24

2.5.2.	Tujuan dan Dampak Optimasi Terhadap Akurasi	25
2.6.	Metrik Evaluasi Model	26
2.6.1.	Root Mean Squared Error (RMSE).....	26
2.6.2.	Mean Absolute Percentage Error (MAPE)	27
2.7.	Penelitian Terdahulu	29
BAB III METODOLOGI PENELITIAN		32
3.1.	Jenis dan Pendekatan Penelitian.....	32
3.2.	Sumber Data dan Teknik Pengumpulan Data.....	33
3.2.1.	Sumber Data	33
3.2.2.	Teknik Pengumpulan Data	34
3.3.	Teknik Analisis Data.....	35
3.3.1.	Preprocessing Data	36
3.3.2.	Pelatihan Model BiLSTM.....	36
3.3.3.	Optimasi Parameter Model	37
3.3.4.	Evaluasi Kinerja Model	39
3.3.5.	Visualisasi dan Interpretasi Hasil.....	40
3.4.	Alat dan Perangkat Penelitian	40
3.5.	Arsitektur Penelitian	42
BAB IV HASIL DAN PEMBAHASAN.....		45
4.1.	Deskripsi Data	45
4.2.	Hasil Preprocessing Data	46
4.3.	Implementasi Model BiLSTM	51
4.3.1.	Arsitektur Model	51
4.3.2.	Hasil Konfigurasi Awal Model.....	54
4.4.	Optimasi Parameter Model BiLSTM	57
4.5.1.	Hasil Optimasi Model BiLSTM dengan Konfigurasi Rendah	58
4.5.2.	Hasil Optimasi Model BiLSTM dengan Konfigurasi Tinggi	59
4.4.3.	Perbandingan Hasil Optimasi dan Pemilihan Model Terbaik	60
4.5.	Evaluasi Kinerja Model	61
4.6.1.	Hasil Evaluasi Model.....	61
4.6.2.	Visualisasi Hasil Prediksi	62
4.6.	Pembahasan Hasil Penelitian	63
4.6.1.	Interpretasi Hasil Prediksi.....	63
4.6.2.	Validasi Hasil dengan Teori	64
4.7.	Implementasi Aplikasi Prediksi Harga Emas	65
4.7.1.	Tampilan Antarmuka Utama	66
4.7.2.	Visualisasi Grafik Harga dan Prediksi	66
4.7.3.	Hasil Implementasi Aplikasi.....	67

4.7.4. Analisis Perbedaan Hasil	68
BAB V PENUTUP	69
5.1. Kesimpulan.....	69
5.2. Saran.....	70
DAFTAR PUSTAKA	71

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu	29
Tabel 3. 1 Variabel Harga Emas.....	33
Tabel 3. 2 Proses Pengumpulan Data Harga Emas.....	34
Tabel 3. 3 Komponen Arsitektur Model.....	37
Tabel 3. 4 Parameter Optimasi Model.....	38
Tabel 3. 5 Alat Dan Perangkat Penelitian.....	41
Tabel 4. 1 Pengambilan Data Harga Emas	46
Tabel 4. 2 Program Seleksi Kolom Dan Pembersihan Nilai Kosong.....	47
Tabel 4. 3 Kode Program Normalisasi Dan Pembentukan Dataset Sliding Window	49
Tabel 4. 4 Arsitektur Model Bilstm.....	53
Tabel 4. 5 Hasil Optimasi Dengan Konfigurasi Rendah.....	58
Tabel 4. 6 Hasil Optimasi Dengan Konfigurasi Tinggi	59
Tabel 4. 7 Perbandingan Hasil Optimasi	60

DAFTAR GAMBAR

Gambar 2. 1 Arsitektur Lstm.....	21
Gambar 2. 2 Arsitektur Bilstm	23
Gambar 3. 1 Arsitektur Penelitian.....	43
Gambar 4. 1 Struktur Data Mentah Harga Emas Mingguan.....	47
Gambar 4. 2 Tampilan Data Setelah Seleksi Dan Pembersihan	48
Gambar 4. 3 Contoh Hasil Normalisasi Dan Struktur Dataset X, Y	50
Gambar 4. 4 Grafik Loss Function Selama Pelatihan.....	56
Gambar 4. 5 Grafik Prediksi Vs Aktual	57
Gambar 4. 6 Prediksi Vs Aktual Harga Emas (High Config)	62
Gambar 4. 7 Tampilan Awal Aplikasi Dan Data Harga Emas Terakhir	66
Gambar 4. 8 Visualisasi Grafik Harga Aktual Dan Prediksi	67
Gambar 4. 9 Tampilan Output Aplikasi Setelah Prediksi Dijalankan.....	68

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Emas merupakan salah satu komoditas yang telah lama digunakan sebagai instrumen lindung nilai (*safe haven*) dan diversifikasi *portofolio* investasi, terutama dalam kondisi ketidakpastian ekonomi global. Nilai intrinsik emas yang tinggi, kelangkaannya, serta sifatnya yang tahan terhadap inflasi menjadikan emas sebagai pilihan utama bagi investor dalam menjaga stabilitas kekayaan. Di Indonesia sendiri, emas memiliki nilai ekonomi dan sosial yang signifikan, tidak hanya sebagai perhiasan, tetapi juga sebagai sarana penyimpanan nilai yang mudah dicairkan dan relatif stabil (Nusantara, Nawatmi, & Santosa, 2021).

Namun, harga emas sangat dipengaruhi oleh dinamika makroekonomi dan geopolitik global, seperti inflasi, nilai tukar, suku bunga, kebijakan moneter, serta ketegangan geopolitik. Faktor-faktor ini menyebabkan harga emas mengalami fluktuasi yang cukup signifikan dari waktu ke waktu. Kondisi tersebut menjadikan peramalan harga emas sebagai suatu kebutuhan penting, baik bagi investor individu, institusi keuangan, maupun pembuat kebijakan ekonomi, agar dapat mengambil keputusan yang lebih terarah dan berbasis data.

Peramalan harga emas termasuk ke dalam permasalahan deret waktu (*time series forecasting*), yang dikenal kompleks karena datanya bersifat *non-stasioner*, fluktuatif, dan memiliki hubungan *non-linear* antar periode. Metode peramalan tradisional seperti *Autoregressive Integrated Moving Average (ARIMA)* telah banyak digunakan, namun metode ini memiliki keterbatasan dalam mengatasi pola-pola *non-linear* yang sering muncul pada data keuangan. Oleh karena itu, muncul kebutuhan untuk menggunakan pendekatan yang lebih adaptif dan fleksibel, salah satunya adalah *deep learning*.

Salah satu model *deep learning* yang populer untuk data sekuensial adalah *Long Short-Term Memory (LSTM)*. Model ini dirancang untuk mengatasi permasalahan *vanishing gradient* yang umum terjadi pada *Recurrent Neural Network (RNN)* konvensional, serta mampu mempertahankan memori jangka panjang dalam proses pembelajaran. Pengembangan dari LSTM yang lebih canggih adalah *Bidirectional LSTM (BiLSTM)*, yang memiliki kemampuan untuk membaca data sekuensial dari dua arah, yaitu masa lalu ke masa depan dan sebaliknya. Hal ini memberikan model kapasitas kontekstual yang lebih tinggi dalam mengenali pola kompleks dalam data historis (Ng, 2023).

Penelitian-penelitian sebelumnya telah membuktikan bahwa LSTM dan BiLSTM memiliki performa prediksi yang superior dibandingkan dengan metode konvensional. Penelitian oleh Yurtsever (2021) menunjukkan bahwa BiLSTM mampu menghasilkan nilai *Root Mean Squared Error (RMSE)* sebesar 61.728 dan *Mean Absolute Percentage Error (MAPE)* sebesar 3,48% dalam prediksi harga emas. Hal ini menunjukkan potensi besar dari arsitektur BiLSTM untuk diterapkan dalam domain prediksi harga komoditas, termasuk emas.

Meskipun demikian, terdapat beberapa celah (*research gap*) yang belum banyak diangkat dalam penelitian terdahulu. Pertama, sebagian besar studi masih menggunakan data harian yang cenderung lebih fluktuatif dan memiliki noise tinggi, sementara penggunaan data mingguan untuk mengamati tren jangka menengah justru kurang dieksplorasi. Padahal, data mingguan dinilai lebih stabil dan dapat menangkap pergerakan harga emas secara agregat tanpa terganggu oleh fluktuasi jangka pendek yang ekstrem.

Kedua, sebagian besar penelitian sebelumnya lebih menitikberatkan pada perbandingan antar model (seperti LSTM vs ARIMA atau LSTM vs Fuzzy Time Series), dan belum banyak yang secara eksplisit memfokuskan pada optimasi mendalam satu model tertentu. Dalam konteks ini, penelitian terhadap proses *tuning hyperparameter* BiLSTM, seperti jumlah *neuron*, panjang *input window*, *batch size*, dan *epoch*, sangat penting karena parameter-parameter tersebut memiliki pengaruh langsung terhadap performa akhir model

prediksi. Penelitian yang tidak mengoptimasi parameter secara sistematis berpotensi menghasilkan model yang belum bekerja pada performa maksimalnya.

Ketiga, terdapat minimnya kajian yang mengintegrasikan dua metrik evaluasi utama, yaitu RMSE dan MAPE secara bersamaan dalam konteks prediksi harga emas. Kebanyakan penelitian hanya menggunakan satu metrik, padahal penggunaan kedua metrik dapat memberikan gambaran lebih komprehensif, baik dari segi kesalahan absolut maupun persentase kesalahan terhadap nilai aktual.

Berdasarkan paparan tersebut, penelitian ini mengangkat tema "Optimasi Akurasi BiLSTM dalam Peramalan Harga Emas" sebagai upaya untuk mengisi kekosongan pada literatur yang ada. Penelitian ini akan menggunakan data harga emas mingguan dari *Yahoo Finance* selama periode 2020–2024, dengan fokus utama pada pengembangan dan optimasi arsitektur BiLSTM. Proses optimasi dilakukan dengan menguji berbagai kombinasi parameter utama dalam model, dan hasil prediksi akan dievaluasi secara menyeluruh menggunakan metrik RMSE dan MAPE. Harapannya, hasil dari penelitian ini tidak hanya memberikan kontribusi teoritis dalam pengembangan model prediktif berbasis *deep learning*, tetapi juga kontribusi praktis sebagai referensi bagi investor dan analis dalam memprediksi harga emas secara lebih akurat dan terukur.

1.2. Rumusan Masalah

Permasalahan utama dalam penelitian ini adalah bagaimana membangun dan mengimplementasikan model *Bidirectional Long Short-Term Memory (BiLSTM)* yang mampu melakukan peramalan harga emas secara akurat berdasarkan data historis mingguan yang diperoleh dari *Yahoo Finance*. Data mingguan dipilih karena dinilai lebih stabil dan representatif untuk mengamati tren jangka menengah, namun masih jarang digunakan dalam penelitian terdahulu yang umumnya menggunakan data harian. Penelitian ini juga difokuskan pada proses optimasi mendalam terhadap sejumlah parameter utama dalam arsitektur model, seperti jumlah neuron, panjang *input window*, *batch size*, dan

epoch, dengan tujuan untuk memperoleh konfigurasi terbaik yang dapat meningkatkan kualitas prediksi. Selain itu, penelitian ini mengkaji seberapa baik performa model *BiLSTM* yang telah dioptimasi tersebut ketika dievaluasi menggunakan dua metrik akurasi yang saling melengkapi dalam konteks deret waktu, yaitu *Root Mean Squared Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)*, guna memperoleh hasil prediksi yang akurat dan andal untuk mendukung pengambilan keputusan berbasis data dalam investasi komoditas emas

1.2. Batasan Masalah

Untuk memastikan penelitian ini terfokus dan memiliki hasil yang dapat diinterpretasikan dengan jelas, penelitian ini memiliki beberapa batasan sebagai berikut:

1. Data yang digunakan dalam penelitian ini adalah data historis harga emas dunia yang diperoleh dari *Yahoo Finance*, dengan interval waktu mingguan dan periode Januari 2020 hingga Desember 2024.
2. Penelitian ini hanya memanfaatkan data penutupan harga emas (closing price) sebagai input model, sehingga bersifat univariate time series tanpa mempertimbangkan variabel eksternal lain seperti nilai tukar, suku bunga, atau sentimen pasar.
3. Model yang digunakan hanya *BiLSTM* (Bidirectional Long Short-Term Memory), tanpa melakukan perbandingan dengan metode lain seperti LSTM biasa, GRU, ARIMA, atau model regresi lainnya.
4. Optimasi model terbatas pada penyesuaian beberapa parameter utama seperti jumlah neuron, jumlah epoch, ukuran batch, dan panjang input sequence (window), tanpa melibatkan teknik optimasi kompleks seperti Bayesian Optimization atau Grid Search besar-besaran.

5. Evaluasi kinerja model dibatasi pada dua metrik evaluasi yang umum digunakan dalam prediksi deret waktu, yaitu *Root Mean Squared Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)*.
6. Penelitian ini bersifat eksperimen komputasional, tidak mencakup pengujian implementasi secara real-time dalam sistem keuangan atau aplikasi berbasis web/mobile. Hanya saja hasil akhir dari Penelitian ini akan diimplementasikan ke dalam aplikasi berbasis web menggunakan Pustaka python Streamlit.

1.4. Tujuan Penelitian

1. Membangun model prediksi harga emas berbasis *Bidirectional Long Short-Term Memory (BiLSTM)* menggunakan data historis mingguan dari *Yahoo Finance* pada periode 2020–2024.
2. Melakukan optimasi terhadap parameter-parameter model *BiLSTM* seperti jumlah neuron, jumlah *epoch*, ukuran *batch*, dan panjang *window* input, guna memperoleh hasil prediksi yang lebih akurat.
3. Mengevaluasi performa model *BiLSTM* yang telah dioptimasi menggunakan dua metrik evaluasi, yaitu *Root Mean Squared Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)*, dalam konteks peramalan harga komoditas emas.

1.5. Manfaat Penelitian

1. Bagi Peneliti

Penelitian ini menjadi sarana pengembangan kemampuan dalam menerapkan model *deep learning*, khususnya *Bidirectional Long Short-Term Memory (BiLSTM)*, dalam peramalan deret waktu berbasis data historis. Peneliti mendapatkan pengalaman langsung dalam mengelola data, membangun model, melakukan optimasi parameter, serta mengevaluasi performa prediksi menggunakan metrik kuantitatif.

2. Bagi Investor

Penelitian ini memberikan gambaran praktis tentang bagaimana teknologi kecerdasan buatan dapat digunakan untuk mendukung analisis harga emas yang lebih akurat dan objektif. Model *BiLSTM* yang dikembangkan dalam penelitian ini dapat dijadikan alternatif pendekatan prediktif dalam strategi investasi jangka pendek maupun menengah. Dengan adanya pemodelan berbasis data, investor dapat lebih percaya diri dalam mengambil keputusan, serta memiliki dasar kuantitatif dalam mengantisipasi tren harga emas di masa mendatang.

3. Bagi Universitas

Penelitian ini menambah kontribusi dalam pengembangan literatur ilmiah di bidang teknologi informasi, khususnya dalam pemanfaatan *machine learning* untuk aplikasi finansial. Hasil penelitian ini dapat dijadikan bahan referensi pembelajaran, tugas akhir, atau pengembangan penelitian lanjutan oleh mahasiswa maupun dosen.

BAB II

LANDASAN TEORI

2.1. Emas

2.1.1. Definisi dan Karakteristik Emas

Emas merupakan logam mulia yang telah digunakan sebagai alat tukar dan penyimpan nilai sejak zaman kuno. Dalam konteks investasi modern, emas sering dianggap sebagai aset safe haven karena kemampuannya mempertahankan nilai selama periode ketidakpastian ekonomi dan geopolitik. Karakteristik fisik emas yang unik, seperti ketahanan terhadap korosi dan kelangkaannya, menjadikannya pilihan populer di kalangan investor yang mencari diversifikasi portofolio dan perlindungan terhadap inflasi.

Menurut Anggarini dan Cahyono (2025), harga emas cenderung stabil dan tidak terpengaruh oleh fluktuasi ekonomi dan politik, menjadikannya investasi yang stabil di tengah ketidakpastian ekonomi. Hal ini membuat emas sebagai instrumen keuangan yang penting dalam melindungi aset.

Selain itu, emas memiliki likuiditas tinggi dan dapat dengan mudah diperjualbelikan di pasar global. Dalam bukunya, Spall (2009) menjelaskan bahwa emas adalah investasi yang esensial untuk setiap portofolio karena sifatnya yang aman dan dapat diandalkan, terutama dalam menghadapi krisis ekonomi.

Namun, penting untuk memahami bahwa meskipun emas memiliki banyak keunggulan, investasi dalam emas juga memiliki risiko. Harahap dan Arini (2022) menekankan bahwa strategi investasi yang tepat diperlukan untuk mengoptimalkan keuntungan dari investasi emas, terutama dalam menghadapi masa resesi.

Dengan demikian, emas memiliki karakteristik unik yang menjadikannya aset penting dalam strategi investasi, terutama dalam konteks diversifikasi portofolio dan manajemen risiko. Namun, investor perlu memahami bahwa kinerja emas dapat

dipengaruhi oleh berbagai faktor ekonomi dan pasar, sehingga penting untuk mempertimbangkan konteks makroekonomi saat membuat keputusan investasi terkait emas.

2.1.2. Jenis dan Bentuk Investasi Emas

Emas merupakan salah satu instrumen investasi tertua yang tetap relevan hingga saat ini karena memiliki nilai intrinsik tinggi dan karakteristik safe haven. Dalam praktiknya, investasi emas hadir dalam beberapa bentuk utama, yaitu emas fisik, emas digital, dan derivatif seperti reksa dana emas atau investasi kredit emas. Pemilihan bentuk emas bergantung pada tujuan investasi, likuiditas, dan toleransi risiko investor.

1. Emas Fisik

Emas fisik merupakan bentuk paling tradisional dari investasi emas dan terdiri dari emas batangan, koin emas, dan perhiasan. Emas batangan lebih banyak dipilih untuk tujuan investasi karena memiliki nilai jual kembali yang lebih tinggi dan tidak dibebani oleh biaya pembuatan seperti halnya perhiasan (Luthfi et al., 2021). Sertifikasi keaslian dari lembaga seperti PT Antam dan UBS juga memberikan jaminan legalitas atas kualitas dan kadar emas tersebut.

2. Emas Digital

Dengan berkembangnya teknologi finansial, masyarakat kini dapat berinvestasi emas secara digital. Investasi ini memungkinkan individu membeli emas dalam satuan kecil dan menyimpannya secara virtual, seperti yang ditawarkan oleh Pegadaian Digital, Tokopedia Emas, atau platform syariah lainnya. Bentuk ini dinilai lebih fleksibel dan cocok untuk investor pemula karena dapat dimulai dengan modal kecil serta mudah diakses melalui perangkat mobile (Suryaputri et al., 2021).

3. Emas Kredit atau Cicilan

Selain membeli secara langsung, emas juga dapat dimiliki melalui skema pembelian kredit atau cicilan, misalnya di Pegadaian Syariah. Dalam praktiknya,

pembelian ini dilakukan dengan akad murabahah atau ijarah muntahiya bittamlik (IMBT), dan memerlukan penyesuaian terhadap prinsip syariah terkait kepemilikan dan pembayaran cicilan (Luthfi et al., 2021). Model ini memberi akses kepemilikan emas kepada masyarakat dengan keterbatasan dana tunai.

4. Perspektif Syariah dalam Investasi Emas

Dalam perspektif ekonomi Islam, emas sebagai instrumen investasi diperbolehkan selama memenuhi prinsip-prinsip syariah, terutama terkait kejelasan objek, kesepakatan, dan tidak mengandung unsur riba. Heradhyaksa (2022) menegaskan bahwa investasi emas syariah sebaiknya dilakukan secara tunai (spot) untuk menghindari praktik gharar dan riba, meskipun skema pembelian kredit juga dimungkinkan jika memenuhi akad yang sah dan adil.

5. Karakteristik Umum Investasi Emas

Emas memiliki karakteristik resiko rendah, mudah diuangkan, dan nilainya relatif stabil terhadap inflasi. Menurut Suryaputri et al., (2021), emas juga dianggap sebagai aset investasi utama oleh generasi sandwich karena kemudahan akses dan tingkat keamanan yang tinggi, menjadikannya alat penting dalam diversifikasi keuangan keluarga.

2.1.3. Faktor yang Mempengaruhi Harga Emas

Harga emas dipengaruhi oleh berbagai faktor makroekonomi dan geopolitik. Emas sebagai komoditas global sangat sensitif terhadap dinamika eksternal, baik dari sisi pasar keuangan internasional maupun kondisi sosial-politik negara-negara besar. Faktor-faktor utama yang berperan dalam pembentukan harga emas meliputi inflasi, nilai tukar mata uang, tingkat suku bunga, ketegangan geopolitik, dan permintaan-penawaran (Lestari & Kurniawan, 2024).

1. Inflasi

Inflasi yang tinggi mendorong investor beralih ke aset lindung nilai seperti emas. Emas dianggap mampu menjaga daya beli ketika mata uang kehilangan nilainya. Dalam

konteks Indonesia, tingginya inflasi seringkali menyebabkan lonjakan harga emas di pasar lokal (Mubin & Pambudi, 2020).

2. Nilai Tukar Mata Uang

Karena emas diperdagangkan dalam dolar AS, pelemahan nilai tukar rupiah terhadap dolar membuat harga emas naik dalam satuan rupiah. Fluktuasi nilai tukar, terutama terhadap USD, sangat menentukan harga emas domestik maupun internasional (Lestari & Kurniawan, 2024).

3. Tingkat Suku Bunga

Ketika bank sentral menaikkan suku bunga, investor cenderung beralih ke instrumen berbunga tetap seperti obligasi. Sebaliknya, saat suku bunga rendah, daya tarik emas meningkat sebagai alternatif investasi yang tidak memberikan imbal hasil tetap, namun aman dari inflasi (Amal & Musthofa, 2023).

4. Ketegangan Geopolitik

Emas juga dianggap sebagai aset safe haven saat terjadi ketidakpastian politik atau konflik internasional. Dalam situasi seperti perang, krisis keuangan global, atau pandemi, permintaan emas melonjak karena investor mencari perlindungan nilai (Lestari & Kurniawan, 2024).

5. Permintaan dan Penawaran Global

Produksi tambang, kebijakan ekspor negara produsen, serta permintaan industri dan perhiasan turut menentukan harga emas. Negara-negara seperti Tiongkok dan India memiliki permintaan tinggi untuk emas, baik sebagai cadangan devisa maupun kebutuhan kultural.

Sebagai kesimpulan, kompleksitas faktor-faktor yang memengaruhi harga emas menciptakan pola pergerakan harga yang tidak linier, dinamis, dan kerap kali bersifat non-stasioner. Inilah yang membuat peramalan harga emas menjadi tantangan menarik dalam bidang data science dan time series modeling. Dalam konteks penelitian ini, pemilihan model BiLSTM menjadi relevan karena model ini dirancang untuk menangani dinamika

sekuensial kompleks seperti fluktuasi harga emas. Dengan mempertimbangkan variabel-variabel ekonomi yang disebutkan di atas, diharapkan akurasi model prediksi berbasis BiLSTM dapat lebih optimal, khususnya dalam menurunkan nilai error seperti RMSE dan MAPE.

2.2. Peramalan Deret Waktu (Time Series Forecasting)

2.2.1. Definisi Deret Waktu (Time Series)

Deret waktu (time series) adalah sekumpulan data yang dikumpulkan secara berkala menurut urutan waktu tertentu. Setiap titik data dalam deret waktu merepresentasikan hasil pengamatan suatu variabel pada waktu tertentu, sehingga aspek kronologis sangat menentukan dalam analisisnya. Data time series digunakan untuk mengamati, menganalisis, serta memprediksi perilaku masa depan berdasarkan data historis (Aryanto, 2024).

Dalam konteks ekonomi dan keuangan, data deret waktu banyak ditemukan pada harga emas, saham, kurs mata uang, produk domestik bruto, inflasi, dan termasuk harga komoditas seperti emas. Menurut Feriyandri dan Maimunah (2023), karakteristik utama dari data deret waktu adalah adanya ketergantungan antar waktu (autokorelasi), yang berarti nilai masa depan dipengaruhi oleh nilai di masa lalu.

Penerapan analisis deret waktu mencakup berbagai metode statistik seperti moving average, exponential smoothing, hingga model yang lebih kompleks seperti ARIMA. Namun, perkembangan terkini dalam teknologi kecerdasan buatan memungkinkan penggunaan model deep learning seperti LSTM dan BiLSTM untuk menangani deret waktu yang kompleks dan non-linier.

Dalam penelitian ini, pendekatan deret waktu sangat penting mengingat harga emas cenderung fluktuatif, non-stasioner, dan dipengaruhi oleh banyak faktor eksternal. Oleh karena itu, model peramalan seperti BiLSTM digunakan karena kemampuannya untuk

mempelajari pola sekuensial yang kompleks dan mempertimbangkan hubungan antar data historis secara menyeluruh.

2.2.2. Komponen Deret Waktu

Analisis deret waktu tidak terlepas dari pemahaman terhadap komponen-komponen penyusunnya. Secara umum, terdapat empat komponen utama dalam deret waktu, yaitu tren (trend), musiman (seasonality), siklikal (cyclic), dan irregular/noise. Keempat komponen ini dapat muncul secara simultan maupun sebagian dalam satu rangkaian data deret waktu, tergantung pada sifat data dan konteks ekonomi yang menyertainya. (Sutrisno et al., 2025).

1. Tren (Trend)

Komponen tren menggambarkan arah pergerakan data dalam jangka panjang, apakah meningkat, menurun, atau stagnan. Dalam konteks ekonomi, tren sering kali disebabkan oleh pertumbuhan ekonomi, inflasi, atau perubahan struktural dalam pasar (Sutrisno et al., 2025). Pada harga emas, tren jangka panjang biasanya menunjukkan kenaikan karena sifat emas sebagai aset lindung nilai. (Ruhiat et al., 2020)

2. Musiman (Seasonality)

Musiman menunjukkan fluktuasi data yang terjadi secara reguler dalam periode tertentu seperti tahunan, bulanan, atau mingguan. Contoh konkret adalah lonjakan permintaan emas menjelang hari raya atau musim pernikahan, yang memicu pola musiman pada harga

3. Siklikal (Cyclic)

Komponen siklikal menggambarkan fluktuasi jangka panjang yang tidak beraturan dan berkaitan dengan siklus ekonomi seperti resesi dan ekspansi. Tidak seperti musiman, pola siklikal bersifat tidak teratur dan sulit diprediksi secara pasti, namun sangat relevan dalam data ekonomi makro (Diksa, 2022).

4. Komponen Acak (Noise)

Komponen acak menggambarkan fluktuasi yang tidak dapat diprediksi atau dijelaskan oleh ketiga komponen sebelumnya. Ini biasanya mencerminkan faktor-faktor eksternal yang tidak terduga seperti krisis geopolitik, pandemi, atau bencana alam. Dalam peramalan, noise adalah komponen yang paling sulit dikendalikan dan sering menjadi sumber error (Wahyu & Hendrik, 2023).

Pemahaman yang mendalam terhadap keempat komponen ini menjadi dasar dalam membangun model peramalan deret waktu yang efektif. Dalam penelitian ini, pengenalan terhadap pola tren dan musiman pada harga emas sangat membantu dalam mengarahkan arsitektur dan parameter BiLSTM untuk mencapai prediksi yang lebih akurat.

2.2.3. Karakteristik Deret Waktu pada Harga Emas

Harga emas merupakan salah satu variabel ekonomi yang berbentuk deret waktu (time series) dengan karakteristik unik. Tidak seperti data statistik biasa yang bersifat independen, data harga emas memiliki ketergantungan waktu (autokorelasi) yang tinggi. Karakteristik penting dari deret waktu harga emas antara lain: bersifat fluktuatif, non-linier, dan sering kali non-stasioner (Amri et al., 2024).

1. Fluktuatif dan Volatil

Harga emas menunjukkan pola naik turun yang tajam dalam rentang waktu yang pendek. Volatilitas ini dipicu oleh berbagai faktor global seperti perubahan suku bunga, krisis geopolitik, inflasi, dan pergerakan nilai tukar dolar. Menurut Padliansyah dan Juliana (2020), interaksi antara harga logam mulia dan indeks saham menunjukkan efek lintas volatilitas yang signifikan, terutama pada saat pasar mengalami tekanan.

2. Non-Stasioner

Data harga emas umumnya tidak stasioner karena mean dan variansnya berubah dari waktu ke waktu. Kondisi non-stasioner ini menandakan bahwa harga emas tidak

memiliki pola rata-rata yang konstan, sehingga sulit dianalisis dengan metode statistik klasik tanpa diferensiasi atau transformasi terlebih dahulu (Amri et al., 2024).

3. Non-Linier dan Tidak Deterministik

Harga emas tidak hanya dipengaruhi oleh satu atau dua faktor, tetapi oleh kombinasi faktor yang kompleks. Oleh karena itu, model prediktif yang linier seperti regresi sederhana kurang mampu menangkap kompleksitas pola harga emas.

Karakteristik-karakteristik tersebut menjadi tantangan sekaligus peluang dalam peramalan harga emas. Oleh karena itu, dalam penelitian ini digunakan model BiLSTM yang mampu menangani data sekuensial non-linier, serta dapat mempelajari pola temporal kompleks yang tidak dapat ditangkap oleh pendekatan konvensional.

2.3. Machine Learning

2.3.1. Konsep Dasar Machine Learning

Machine Learning (ML) adalah bagian dari kecerdasan buatan (AI) yang memungkinkan sistem komputer untuk belajar secara otomatis dari data tanpa perlu diprogram secara eksplisit. Dalam ekonomi dan keuangan, ML telah merevolusi cara pengambilan keputusan dilakukan dari prediksi harga saham, deteksi anomali transaksi, hingga analisis sentimen pasar. Dengan algoritma yang mampu mengenali pola dari data historis yang sangat besar dan kompleks, ML menjadi solusi unggulan dalam pengolahan data modern (Saputro, 2023).

Machine Learning secara umum terbagi menjadi dua pendekatan utama, yaitu sebagai berikut:

1. Supervised Learning

Supervised learning bekerja dengan data yang telah diberi label. Model dipelajari dari pasangan input-output dan bertujuan untuk memprediksi nilai output dari input baru. Contoh penerapannya adalah prediksi harga emas berdasarkan data historis, inflasi, dan kurs mata uang.

2. Unsupervised Learning

Unsupervised learning digunakan untuk menemukan struktur atau pola tersembunyi dari data yang tidak memiliki label. Pendekatan ini sering digunakan untuk segmentasi pelanggan atau klasterisasi data keuangan berdasarkan karakteristik tertentu (Chyan et al., 2024).

Dalam praktiknya, pemilihan antara supervised dan unsupervised learning tidak hanya ditentukan oleh ketersediaan label, tetapi juga oleh tujuan analisis. Untuk prediksi harga, supervised learning lebih cocok karena berorientasi pada hasil kuantitatif. Namun, unsupervised learning sering digunakan sebagai tahap awal untuk eksplorasi data, menyusun fitur baru (feature engineering), atau mengelompokkan data yang kompleks. Kombinasi keduanya juga memungkinkan, terutama dalam pendekatan semi-supervised learning yang semakin berkembang (Kushariyadi, Herdiana, & Asy'ari, 2024).

Salah satu tantangan utama dalam Machine Learning adalah overfitting, yaitu ketika model terlalu menyesuaikan dengan data pelatihan sehingga gagal melakukan generalisasi terhadap data baru. Oleh karena itu, validasi silang (cross-validation), regularisasi, dan pemilihan fitur yang tepat sangat penting dalam proses pembelajaran. Aspek ini menjadi bagian penting dalam merancang model ML, khususnya saat digunakan pada data ekonomi yang memiliki noise tinggi dan fluktuasi ekstrem.

Model yang digunakan dalam penelitian ini, yaitu Bidirectional Long Short-Term Memory (BiLSTM), termasuk dalam kategori supervised learning. BiLSTM adalah pengembangan dari Recurrent Neural Network (RNN) yang mampu mengatasi masalah jangka panjang dalam deret waktu. Keunggulan BiLSTM dibandingkan LSTM biasa adalah kemampuannya untuk mengakses informasi dari arah masa lalu dan masa depan secara simultan. Hal ini sangat penting dalam prediksi harga emas, karena pergerakan harga saat ini sering dipengaruhi oleh kombinasi sinyal historis jangka pendek dan jangka panjang.

2.3.2. Penerapan Machine Learning untuk Prediksi Harga Komoditas

Machine Learning (ML) telah mengalami perkembangan pesat dan kini menjadi salah satu pendekatan utama dalam prediksi harga komoditas seperti emas, minyak, dan saham. Dibandingkan dengan metode statistik tradisional seperti regresi linier atau ARIMA, model ML dapat menangkap pola yang lebih kompleks dan non-linier dari data historis. Ini menjadikan ML unggul dalam menghadapi sifat fluktuatif dan dinamis dari data harga komoditas (Lazuardy, 2023).

Dalam penelitian komoditas, berbagai algoritma supervised learning seperti Support Vector Regression (SVR), Random Forest, dan Gradient Boosting Regression telah diaplikasikan untuk memperkirakan harga komoditas. Misalnya, Yennimar (2024) berhasil menggunakan algoritma Gradient Boosting untuk memprediksi harga emas dengan mempertimbangkan faktor-faktor finansial global, yang menghasilkan tingkat akurasi tinggi. Selain itu, penelitian oleh Sunaryo dan Hamdan (2024) menunjukkan bahwa integrasi model ARIMA dengan pendekatan machine learning efektif dalam meramalkan tren risiko keuangan perusahaan, termasuk prediksi harga pasar.

Model berbasis supervised learning menjadi pilihan utama dalam studi prediksi harga karena membutuhkan data historis sebagai acuan. Model ini belajar dari pasangan input-output untuk memahami pola dalam data, sehingga sangat cocok diterapkan dalam konteks peramalan ekonomi. Hal ini sejalan dengan penjelasan dari Chyan et al. (2024), yang menyebut bahwa supervised learning lebih unggul dalam aplikasi prediksi harga berbasis deret waktu karena struktur datanya yang berlabel dan sekuensial.

Penerapan Machine Learning juga tidak hanya terbatas pada algoritma konvensional. Dalam dekade terakhir, pendekatan deep learning seperti LSTM (Long Short-Term Memory) dan BiLSTM (Bidirectional LSTM) telah mendominasi studi prediksi harga komoditas karena kemampuannya dalam menangani ketergantungan jangka panjang dan struktur waktu yang kompleks. Seperti dijelaskan oleh Kushariyadi et al.

(2024), kemampuan ML modern dalam mengolah big data menjadikan pendekatan ini lebih fleksibel dan adaptif terhadap perubahan pasar global.

Dalam konteks bisnis dan investasi, akurasi prediksi harga sangat berpengaruh terhadap pengambilan keputusan. Dengan implementasi machine learning, pelaku industri dan investor memiliki akses pada sistem prediksi yang tidak hanya cepat dan akurat, tetapi juga mampu menyesuaikan diri terhadap perubahan pasar secara real-time. Ini mendukung pengambilan keputusan yang lebih strategis dan berbasis data (Sunaryo & Hamdan, 2024).

2.4. Deep Learning

2.4.1. Konsep Dasar Deep Learning

Deep Learning merupakan cabang dari Machine Learning yang menggunakan arsitektur jaringan saraf buatan (Artificial Neural Networks) berlapis-lapis untuk memproses dan mengekstraksi fitur dari data dalam bentuk kompleks dan besar. Berbeda dengan Machine Learning konvensional, Deep Learning mampu melakukan *feature extraction* secara otomatis dari data mentah sehingga lebih efektif dalam mengolah data seperti citra, teks, hingga deret waktu (Sawitri, 2025).

Struktur dasar deep learning terdiri dari lapisan input, beberapa lapisan tersembunyi (hidden layers), dan lapisan output. Setiap lapisan terdiri dari sejumlah neuron yang saling terhubung, di mana setiap neuron mengolah sinyal masuk menggunakan bobot tertentu, fungsi aktivasi, dan mengirimkan hasilnya ke neuron berikutnya. Fungsi aktivasi seperti sigmoid, ReLU, dan tanh digunakan untuk memperkenalkan non-linearitas dalam pemrosesan sinyal, memungkinkan jaringan saraf menangkap hubungan kompleks antar data (Widiputra et al., 2021).

Dalam konteks prediksi ekonomi dan keuangan, deep learning digunakan untuk mendeteksi pola jangka panjang yang tidak kasat mata dalam deret waktu, seperti tren harga saham, nilai tukar, dan harga emas. Kemampuan deep learning dalam menangani deret waktu didukung oleh arsitektur seperti Recurrent Neural Network (RNN) dan Long Short-

Term Memory (LSTM), yang dirancang untuk mengingat informasi masa lalu dalam suatu urutan data (Yudistira et al., 2023).

2.4.2. *Artificial Neural Network (ANN)*

Sistem *Artificial Neural Network (ANN)* adalah fondasi dari seluruh arsitektur Deep Learning yang saat ini banyak digunakan. ANN terinspirasi dari sistem saraf biologis manusia, di mana unit-unit pemrosesan (neuron) saling terhubung dan membentuk jaringan untuk mengolah informasi. Struktur ANN terdiri dari tiga komponen utama: lapisan input, satu atau lebih lapisan tersembunyi (*hidden layers*), dan lapisan output. Masing-masing neuron di dalam jaringan menerima masukan, mengalikan dengan bobot, menerapkan fungsi aktivasi, dan mengirim hasilnya ke neuron berikutnya (Arif et al., 2025).

ANN dikembangkan untuk menangani berbagai jenis data, baik linier maupun non-linier. Dalam praktiknya, ANN digunakan dalam klasifikasi, regresi, pengenalan pola, dan prediksi. Fungsi aktivasi seperti sigmoid, tanh, dan ReLU digunakan untuk mengontrol aliran sinyal antar neuron dan memperkenalkan kemampuan non-linearitas, sehingga ANN dapat menangkap hubungan kompleks antar variabel input dan output (Sawitri, 2025).

Kelebihan utama dari ANN adalah kemampuannya dalam melakukan *learning from data*, yaitu belajar langsung dari data historis tanpa memerlukan pemodelan eksplisit atas hubungan matematis antar variabel. Namun, ANN konvensional memiliki keterbatasan dalam menangani data sekuensial atau deret waktu, karena informasi yang diproses dianggap independen antar waktu. Oleh karena itu, meskipun ANN efektif dalam data tabular atau citra, model ini tidak optimal jika digunakan untuk prediksi data yang bersifat temporal seperti harga emas (Widiputra et al., 2021).

Dalam konteks penelitian ini, ANN dijadikan sebagai landasan awal sebelum masuk ke model yang lebih kompleks dan sesuai untuk deret waktu, seperti RNN, LSTM, dan BiLSTM. Pemahaman struktur dan prinsip kerja ANN menjadi krusial untuk memahami bagaimana model prediksi yang lebih canggih dibangun.

2.4.3. *Recurrent Neural Network (RNN)*

Recurrent Neural Network (RNN) adalah salah satu arsitektur neural network yang dirancang untuk menangani data sekuensial, seperti teks, suara, dan deret waktu ekonomi. Berbeda dengan Artificial Neural Network (ANN) yang hanya memproses input secara feedforward, RNN memiliki koneksi siklikal yang memungkinkan informasi dari waktu sebelumnya ditransmisikan ke waktu sekarang melalui hidden state. Dengan kemampuan ini, RNN mampu mengenali pola waktu dan belajar dari urutan data, menjadikannya sangat relevan dalam peramalan harga emas yang bersifat dinamis dan memiliki keterkaitan antar waktu (Sawitri, 2025).

Setiap unit dalam RNN menerima input saat ini x_t dan hidden state sebelumnya h_{t-1} , lalu menghasilkan hidden state baru h_t yang mencerminkan konteks saat ini berdasarkan informasi masa lalu. Proses ini berulang untuk seluruh sekuens data. Namun, RNN tradisional memiliki kelemahan dalam mengingat informasi jangka panjang karena fenomena *vanishing gradient* saat proses pelatihan dilakukan pada urutan data yang sangat panjang. Hal ini menyebabkan bobot pembelajaran menjadi sangat kecil sehingga informasi dari waktu jauh sebelumnya sulit dipertahankan (Widiputra et al., 2021).

Meski demikian, RNN tetap menjadi fondasi penting dalam pengembangan arsitektur jaringan saraf untuk data deret waktu. Kemampuannya dalam memproses input temporal memberikan dasar bagi model yang lebih kompleks seperti Long Short-Term Memory (LSTM) dan Bidirectional LSTM (BiLSTM), yang mengatasi keterbatasan RNN klasik dalam menyimpan informasi jangka panjang (Kushariyadi et al., 2024). Dalam konteks penelitian ini, pemahaman terhadap prinsip kerja RNN menjadi penting karena BiLSTM merupakan turunan langsung dari konsep ini.

2.4.4. *Long Short-Term Memory (LSTM)*

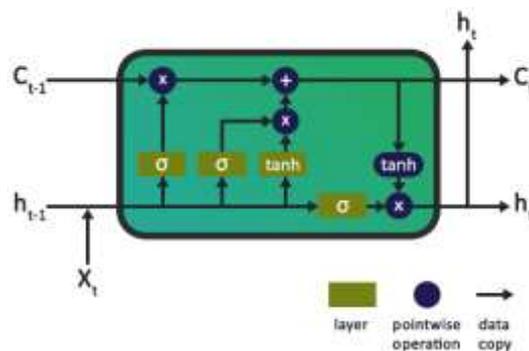
Dalam *Long Short-Term Memory (LSTM)* adalah varian dari Recurrent Neural Network (RNN) yang dirancang khusus untuk mengatasi keterbatasan dalam mengingat

informasi jangka panjang yang sering ditemui pada arsitektur RNN tradisional. LSTM dikembangkan dengan struktur internal yang lebih kompleks, memungkinkan jaringan ini untuk mempertahankan informasi penting dalam jangka waktu yang lebih panjang melalui mekanisme yang disebut *cell state* dan *gates* (Sawitri, 2025).

Struktur LSTM terdiri atas tiga jenis gerbang utama:

1. Forget gate: memutuskan informasi mana dari *cell state* sebelumnya (C_{t-1}) yang harus dibuang.
2. Input gate: mengatur informasi baru mana dari input saat ini x_t yang perlu disimpan ke dalam *cell state*.
3. Output gate: menentukan nilai output h_t berdasarkan *cell state* yang telah diperbarui.

Dengan struktur ini, LSTM mampu menangkap dinamika jangka panjang pada data deret waktu. Ini sangat berguna dalam tugas prediktif seperti memodelkan harga emas, yang tidak hanya dipengaruhi oleh data historis terdekat, tetapi juga tren makro yang terbentuk dalam jangka waktu panjang (Kushariyadi et al., 2024).



Gambar 2. 1 Arsitektur LSTM

Sumber: [https://www.researchgate.net/figure/Gambar-1-Arsitektur-LSTM-](https://www.researchgate.net/figure/Gambar-1-Arsitektur-LSTM-Formula-umum-yang-digunakan-dalam-LSTM-adalah-sebagai-berikut_fig1_374801012)

[Formula-umum-yang-digunakan-dalam-LSTM-adalah-sebagai-berikut_fig1_374801012](https://www.researchgate.net/figure/Gambar-1-Arsitektur-LSTM-Formula-umum-yang-digunakan-dalam-LSTM-adalah-sebagai-berikut_fig1_374801012)

Gambar ini memperlihatkan proses internal satu unit LSTM. Input x_t dan hidden state sebelumnya h_{t-1} masuk ke dalam tiga gerbang utama:

1. Dua fungsi sigmoid (σ) pada bagian kiri mengatur forget gate dan input gate.

2. Fungsi tanh di tengah menghasilkan kandidat nilai memori baru (\tilde{C}_t).
3. Gerbang output di sisi kanan menghasilkan hth_tht dengan menggabungkan cell state saat ini (C_t) yang telah diaktivasi oleh tanh dan dikontrol oleh output gate.

Simbol \odot menunjukkan operasi perkalian elemen-per-elemen, dan $+$ adalah penjumlahan antar vektor. Cell state mengalir secara horizontal, memungkinkan informasi penting tetap terjaga dari satu waktu ke waktu berikutnya. Struktur ini menjadikan LSTM unggul dalam menangani urutan panjang yang tidak dapat ditangani oleh RNN standar.

Dengan kemampuan menyimpan informasi jangka panjang ini, LSTM telah banyak digunakan dalam prediksi ekonomi, termasuk dalam memprediksi harga saham dan komoditas seperti emas, karena mampu menangkap pola kompleks yang tersembunyi dalam data historis (Widiputra et al., 2021).

Dalam konteks prediksi ekonomi dan pasar keuangan, LSTM banyak digunakan karena keandalannya dalam menangkap pola-pola jangka panjang dan non-linier. Menurut Widiputra et al. (2021), LSTM dapat menangani kompleksitas data indeks saham lebih baik dibandingkan model ANN maupun RNN standar, terutama karena kemampuannya dalam mengingat data historis yang penting. Kemampuan ini menjadi sangat esensial ketika digunakan dalam prediksi harga emas yang bersifat volatil dan tidak selalu mengikuti tren linier.

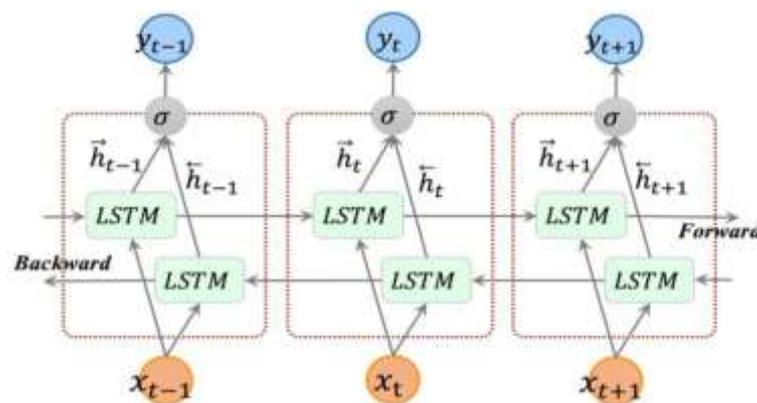
Dengan demikian, pemahaman mendalam terhadap LSTM sangat penting sebelum menggunakan model yang lebih kompleks seperti BiLSTM. LSTM merupakan dasar dari banyak inovasi dalam deep learning yang fokus pada pemrosesan data sekuensial dan deret waktu.

2.4.5. Bidirectional Long Short-Term Memory (BiLSTM)

Bidirectional Long Short-Term Memory (BiLSTM) adalah pengembangan dari arsitektur LSTM yang memungkinkan pemrosesan informasi secara dua arah, yaitu dari masa lalu ke masa depan (*forward direction*) dan sebaliknya dari masa depan ke masa lalu

(*backward direction*). Pendekatan dua arah ini meningkatkan konteks yang dapat ditangkap oleh model, karena pada banyak kasus, termasuk dalam prediksi harga emas, informasi yang relevan tidak hanya berada di masa lalu tetapi juga dalam pola keseluruhan sekuens (Kushariyadi et al., 2024).

Dalam BiLSTM, dua unit LSTM berjalan secara paralel satu memproses input dari awal ke akhir, dan satu lagi dari akhir ke awal. Output dari kedua arah ini kemudian digabungkan (*concatenated*) sebelum diteruskan ke lapisan berikutnya atau ke output layer. Proses ini dirancang untuk menangkap konteks yang lebih luas pada setiap titik waktu, membuat model lebih akurat dalam memahami dinamika kompleks pada data deret waktu seperti harga emas yang cenderung volatil dan non-linear (Sawitri, 2025).



Gambar 2. 2 Arsitektur BiLSTM

Sumber: https://www.researchgate.net/figure/Gambar-2-Arsitektur-Bidirectional-Long-Short-Term-Memory-BiLSTM_fig1_371155442

Gambar di atas menunjukkan bahwa arsitektur BiLSTM terdiri dari dua jalur LSTM: *forward layer* yang memproses data dari waktu t_1 ke t_n , dan *backward layer* yang memproses dari waktu t_n ke t_1 . Setiap input x_t diproses oleh kedua arah tersebut. Output masing-masing arah, yaitu \vec{h}_t dan \overleftarrow{h}_t , kemudian digabungkan menjadi representasi gabungan $\mathbf{h}_t = [\vec{h}_t; \overleftarrow{h}_t]$, yang kemudian diteruskan ke lapisan output untuk menghasilkan prediksi. Pendekatan dua arah ini memungkinkan BiLSTM menangkap hubungan temporal yang lebih kaya dibanding LSTM biasa.

Dengan arsitektur tersebut, BiLSTM tidak hanya menangkap pengaruh historis tetapi juga memperhitungkan pola kontekstual dari masa depan. Ini memberikan hasil prediksi yang lebih akurat dan stabil, terutama dalam konteks prediksi harga emas yang sangat dipengaruhi oleh fluktuasi dan tren jangka panjang maupun pendek (Widiputra et al., 2021).

BiLSTM sangat efektif ketika digunakan dalam aplikasi prediktif berbasis data historis yang kaya konteks. Sebagaimana dijelaskan oleh Widiputra et al. (2021), model ini unggul dalam menangani data indeks saham karena mampu mengidentifikasi pola tren jangka panjang maupun jangka pendek secara bersamaan. Dalam penelitian ini, keunggulan BiLSTM dalam mengenali urutan data dari dua arah menjadi pertimbangan utama dalam pemodelan prediksi harga emas, yang sangat dipengaruhi oleh pola makro dan mikroekonomi yang berlangsung dalam rentang waktu luas.

Selain itu, BiLSTM memiliki fleksibilitas tinggi dalam penerapannya. Model ini dapat diintegrasikan dengan berbagai teknik optimasi dan regularisasi untuk meningkatkan performa, seperti penggunaan algoritma Adam, dropout, dan tuning hyperparameter. Kemampuan BiLSTM dalam menangani struktur temporal yang kompleks menjadikannya sangat relevan untuk model prediksi komoditas, termasuk dalam konteks riset ini.

2.5. Optimasi dan Parameter dalam Deep Learning

2.5.1. Pengertian Hyperparameter dan Optimasi

Dalam deep learning, hyperparameter merupakan parameter yang nilainya ditentukan sebelum proses pelatihan dimulai, seperti jumlah epoch, batch size, learning rate, jumlah unit neuron, serta dropout rate. Tidak seperti parameter model yang diperbarui selama pelatihan, hyperparameter ditetapkan dari awal dan sangat menentukan kinerja akhir model (Kushariyadi et al., 2024).

Optimasi hyperparameter merupakan proses pencarian kombinasi nilai yang paling tepat untuk meningkatkan performa model. Proses ini bertujuan untuk mengurangi

kesalahan prediksi dan mencegah masalah seperti overfitting atau underfitting. Beberapa metode optimasi yang umum digunakan dalam deep learning antara lain grid search, random search, dan metode berbasis optimasi adaptif lainnya.

Menurut Sawitri (2025), dalam pemodelan keuangan berbasis deep learning, ketepatan konfigurasi model sangat menentukan seberapa baik model dapat menangkap pola data historis. Optimasi bukan hanya soal meningkatkan akurasi, tetapi juga menghindari kegagalan pelatihan yang disebabkan oleh kombinasi parameter yang tidak tepat.

Studi Widiputra et al. (2021) menegaskan bahwa performa model LSTM dan turunannya sangat bergantung pada tuning parameter. Dalam penelitiannya, penyesuaian jumlah epoch, ukuran batch, dan dropout memiliki pengaruh signifikan terhadap akurasi prediksi indeks saham, yang konteks dan karakternya sebanding dengan fluktuasi harga emas.

Dengan demikian, optimasi hyperparameter menjadi komponen penting dalam penelitian ini. Pemilihan konfigurasi terbaik diharapkan mampu meminimalkan kesalahan prediksi (misalnya RMSE dan MAPE), serta menghasilkan model BiLSTM yang lebih akurat dan andal untuk memprediksi harga emas.

2.5.2. Tujuan dan Dampak Optimasi Terhadap Akurasi

Optimasi dalam deep learning bukan sekadar proses teknis, melainkan langkah strategis untuk memastikan model mampu belajar dengan efisien, akurat, dan dapat melakukan generalisasi dengan baik terhadap data baru. Tujuan utama dari optimasi hyperparameter adalah meminimalkan kesalahan prediksi baik itu kesalahan absolut seperti *Mean Absolute Percentage Error (MAPE)* maupun kesalahan kuadrat seperti *Root Mean Squared Error (RMSE)* yang menjadi indikator keberhasilan model dalam penelitian ini (Kushariyadi et al., 2024).

Tanpa optimasi, model deep learning berpotensi mengalami dua masalah utama:

1. Overfitting, yaitu model terlalu menyesuaikan diri dengan data latih dan gagal menggeneralisasi data uji.
2. Underfitting, yaitu model tidak mampu menangkap pola yang cukup dari data, karena parameter seperti jumlah epoch atau struktur jaringan terlalu sederhana.

Menurut Sawitri (2025), dalam kasus data keuangan dan ekonomi seperti harga emas yang sangat fluktuatif dan non-linear, pemilihan kombinasi hyperparameter yang tepat sangat krusial. Parameter seperti learning rate dan batch size dapat secara langsung memengaruhi kestabilan pelatihan model dan konvergensi terhadap nilai minimum kesalahan.

Studi Widiputra et al. (2021) menunjukkan bahwa variasi jumlah epoch dan tingkat dropout memiliki dampak signifikan terhadap akurasi model LSTM dalam memprediksi indeks saham. Hasil ini memperkuat bahwa tanpa optimasi, bahkan model yang secara arsitektur sudah canggih seperti LSTM atau BiLSTM bisa tampil di bawah potensi optimalnya.

Dalam konteks penelitian ini, optimasi dilakukan untuk memastikan bahwa model BiLSTM mampu menghasilkan prediksi harga emas yang akurat dan stabil, dengan kesalahan prediksi (RMSE dan MAPE) yang rendah. Ini sangat penting karena kualitas hasil prediksi akan menjadi dasar validasi efektivitas model dalam aplikasi nyata.

2.6. Metrik Evaluasi Model

2.6.1. Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah salah satu metrik evaluasi paling umum dalam pengukuran kinerja model regresi, termasuk pada tugas prediksi harga komoditas seperti emas. RMSE mengukur akar kuadrat dari rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi. Secara matematis, RMSE dirumuskan sebagai:

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

di mana:

- a. y_i adalah nilai aktual,
- b. \hat{y}_i adalah nilai hasil prediksi,
- c. n adalah jumlah data.

RMSE memberikan penalti lebih besar terhadap kesalahan prediksi yang besar karena nilai selisihnya dikuadratkan. Oleh karena itu, metrik ini sangat berguna dalam mengukur akurasi dan kestabilan model prediktif pada skenario ekonomi yang fluktuatif seperti harga emas (Kushariyadi et al., 2024).

Dalam konteks deep learning, terutama model seperti BiLSTM, RMSE banyak digunakan karena mampu menangkap ketepatan model secara keseluruhan terhadap data deret waktu. Menurut Sawitri (2025), penggunaan RMSE sangat disarankan dalam prediksi harga pasar karena metrik ini memberikan refleksi yang jelas atas seberapa jauh prediksi menyimpang dari kenyataan. Nilai RMSE yang lebih kecil menunjukkan bahwa model memiliki kinerja yang lebih baik.

Widiputra et al. (2021) juga menekankan bahwa dalam pemodelan indeks saham menggunakan LSTM, RMSE digunakan sebagai indikator utama untuk mengevaluasi hasil pelatihan dan validasi model. Hal ini menegaskan bahwa RMSE adalah metrik yang tepat untuk digunakan dalam penelitian ini yang menguji efektivitas BiLSTM dalam memprediksi harga emas.

2.6.2. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah salah satu metrik evaluasi performa model regresi yang digunakan secara luas untuk mengukur tingkat kesalahan dalam bentuk persentase. MAPE mengukur rata-rata kesalahan absolut antara nilai aktual

dan nilai prediksi relatif terhadap nilai aktual. Rumus MAPE secara matematis adalah sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

di mana:

- a. y_i adalah nilai aktual,
- b. \hat{y}_i adalah nilai hasil prediksi,
- c. n adalah jumlah data.

MAPE sangat berguna karena hasilnya dalam bentuk persentase yang mudah dipahami secara intuitif. Metrik ini sering digunakan dalam evaluasi model ekonomi dan keuangan karena memberikan gambaran seberapa besar rata-rata kesalahan relatif yang dihasilkan oleh model (Kushariyadi et al., 2024).

Namun, MAPE juga memiliki keterbatasan. Ketika nilai aktual y_i mendekati nol, hasil MAPE dapat menjadi sangat besar dan tidak stabil. Oleh karena itu, meskipun mudah diinterpretasikan, MAPE sebaiknya digunakan bersamaan dengan metrik lain seperti RMSE untuk mendapatkan gambaran menyeluruh tentang akurasi model (Sawitri, 2025).

Dalam studi Widiputra et al. (2021), MAPE digunakan sebagai salah satu indikator utama dalam mengevaluasi performa model prediksi indeks saham berbasis LSTM. Dalam konteks penelitian ini, MAPE digunakan untuk mengevaluasi kinerja model BiLSTM dalam memprediksi harga emas. Nilai MAPE yang rendah menunjukkan bahwa model memberikan prediksi yang mendekati nilai aktual secara konsisten, sehingga dapat digunakan sebagai indikator keberhasilan dari proses optimasi model yang dilakukan.

2.7. Penelitian Terdahulu

Berikut adalah beberapa penelitian yang relevan dengan penelitian ini, yang mengkaji penggunaan model BiLSTM dalam Studi kasus Peramalan Harga Emas.

Tabel 2. 1 Penelitian Terdahulu

No	Penulis (Tahun)	Judul Penelitian	Hasil Penelitian
1	Widiputra et al. (2021)	Prediksi indeks BEI dengan ensemble convolutional neural network dan long short-term memory	Model LSTM memiliki akurasi tinggi dalam memprediksi indeks saham jika dioptimasi dengan baik.
2	Madhika et al. (2023)	Gold Price Prediction Using the ARIMA and LSTM Models	Model LSTM lebih unggul dibanding ARIMA dalam memprediksi harga emas dengan RMSE 8.124 dan MAPE 0.023.
3	Yennimar & Surbakti (2024)	Prediksi Harga Emas Berdasarkan Finansial Global Dengan Gradient Boosting Regression	Gradient Boosting Regression menunjukkan performa sangat tinggi dalam prediksi harga emas dengan akurasi hingga 99,96%.
4	Amri et al. (2024)	Peramalan Harga Emas Antam Menggunakan Metode GARCH	Model ARIMA-GARCH efektif memodelkan fluktuasi harga emas harian ANTAM dengan hasil prediksi yang stabil.
5	Sunaryo et al. (2024)	Prediksi Tren Risiko Keuangan Perusahaan Berdasarkan Model ARIMA: Tinjauan Literatur	Integrasi AI dengan ARIMA mampu mendeteksi tren risiko keuangan dengan lebih presisi dan adaptif di sektor keuangan.

Berdasarkan penelitian terdahulu, Widiputra et al. (2021) dalam penelitiannya mengembangkan model prediksi indeks saham BEI dengan menggunakan kombinasi antara Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM). Hasil studi menunjukkan bahwa LSTM mampu memberikan performa akurasi yang tinggi dalam peramalan indeks saham, terutama jika model dioptimasi secara tepat. Studi ini menjadi pijakan awal bahwa model LSTM, dan pengembangannya seperti BiLSTM, sangat potensial untuk diterapkan pada data keuangan yang kompleks.

Madhika et al. (2023) membandingkan model ARIMA dan LSTM dalam prediksi harga emas. Dari hasil evaluasi, model LSTM secara signifikan lebih unggul dibanding ARIMA dengan nilai RMSE 8.124 dan MAPE 0.023. Penelitian ini memperkuat keyakinan bahwa arsitektur deep learning lebih sesuai untuk menangani data non-linear dan fluktuatif seperti harga emas dibanding pendekatan statistik klasik.

Yennimar dan Surbakti (2024) menggunakan algoritma Gradient Boosting Regression dalam memprediksi harga emas berbasis indikator ekonomi global. Hasil prediksi menunjukkan tingkat akurasi mencapai 99,96%. Studi ini menyoroti keunggulan model non-sekuensial yang kuat dalam regresi, sekaligus menjadi pembanding dengan model sekuensial seperti BiLSTM yang digunakan dalam penelitian ini.

Amri et al. (2024) menerapkan metode GARCH untuk meramalkan harga emas ANTAM. Penelitian ini menunjukkan bahwa pendekatan statistik tersebut mampu menangkap volatilitas pasar dan memberikan hasil prediksi yang realistis. Meskipun tidak berbasis deep learning, pendekatan ini masih relevan untuk dijadikan benchmark atau pembanding performa model prediktif lainnya.

Sunaryo et al. (2024) meneliti integrasi Artificial Intelligence dengan ARIMA dalam mendeteksi tren risiko keuangan perusahaan. Pendekatan ini terbukti mampu meningkatkan presisi prediksi dan efisiensi analisis risiko finansial. Meskipun fokusnya pada risiko keuangan, pendekatan integratif ini tetap relevan dalam mengkaji efektivitas model prediktif dalam domain ekonomi.

Berdasarkan hasil telaah terhadap penelitian terdahulu, dapat disimpulkan bahwa pendekatan deep learning seperti LSTM dan BiLSTM telah banyak diterapkan dalam peramalan harga pasar, baik untuk saham, valuta asing, maupun komoditas. Namun, sebagian besar penelitian tersebut menggunakan data harian dengan fokus utama pada perbandingan antar algoritma, bukan pada optimalisasi performa dari satu model secara mendalam. Selain itu, model BiLSTM sendiri masih relatif jarang digunakan secara khusus dalam prediksi harga emas, padahal secara teoritis mampu menangkap pola data sekuensial dari dua arah waktu secara simultan.

Penelitian ini berusaha mengisi celah tersebut dengan menerapkan model BiLSTM yang difokuskan untuk memprediksi harga emas menggunakan data mingguan dari *Yahoo Finance*, yang dinilai lebih stabil untuk mengamati tren jangka menengah. Selain itu, penelitian ini juga mengedepankan proses optimasi parameter model secara eksplisit, serta melakukan evaluasi kinerja prediksi dengan dua metrik yang saling melengkapi, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam bentuk pendekatan yang lebih terarah dan praktis dalam pemodelan deret waktu berbasis deep learning untuk komoditas emas.

BAB III

METODOLOGI PENELITIAN

3.1. Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimen komputasional, karena bertujuan untuk mengukur dan menganalisis performa model prediksi harga emas menggunakan algoritma *Bidirectional Long Short-Term Memory* (BiLSTM). Fokus utama dari penelitian ini adalah pada penerapan dan pengujian suatu metode prediksi berbasis data numerik yang diolah secara sistematis menggunakan alat bantu komputasi. Kuantifikasi dilakukan dengan menghitung nilai kesalahan prediksi model berdasarkan metrik evaluasi numerik seperti RMSE dan MAPE.

Pendekatan eksperimen komputasional digunakan karena penelitian ini menuntut proses pembuatan model, pelatihan, optimasi, dan evaluasi dalam lingkungan pemrograman, bukan sekadar pengumpulan opini atau persepsi. Dalam proses ini, peneliti melakukan berbagai percobaan konfigurasi model BiLSTM untuk menemukan kombinasi parameter terbaik yang mampu menghasilkan akurasi prediksi tertinggi. Dengan demikian, pendekatan ini sangat tepat digunakan untuk menjawab tujuan penelitian yang bersifat teknis dan objektif.

Selain itu, pendekatan ini juga mendukung proses iteratif yang bersifat trial-and-error, yang umum dilakukan dalam pengembangan model machine learning. Setiap eksperimen model dapat dibandingkan secara adil menggunakan dataset dan metrik yang sama, sehingga hasilnya dapat dijadikan dasar pengambilan kesimpulan yang sah dan terukur. Jenis dan pendekatan seperti ini umumnya digunakan dalam bidang ilmu komputer, data science, dan teknik informatika yang berkaitan dengan analisis prediktif berbasis data numerik dan algoritmik.

3.2. Sumber Data dan Teknik Pengumpulan Data

3.2.1. Sumber Data

Dalam penelitian ini digunakan data harga penutupan mingguan (*weekly closing price*) emas dunia yang diunduh dari *Yahoo Finance*. Pemilihan interval mingguan dilakukan dengan pertimbangan bahwa data mingguan lebih stabil dan cenderung memiliki noise yang lebih rendah dibandingkan data harian. Selain itu, data mingguan juga lebih efisien untuk diproses dengan model BiLSTM dalam konteks penelitian akademik dengan sumber daya dan waktu yang terbatas. Jumlah data yang diperoleh dari rentang waktu 2020 hingga 2024 (sekitar 260 data poin) sudah cukup representatif untuk membangun model prediksi berbasis deret waktu.

Dataset tersebut terdiri dari beberapa variabel yang masing-masing memiliki makna tersendiri dalam konteks perdagangan komoditas emas. Tabel berikut menjelaskan rincian variabel yang tersedia dalam dataset harga emas tersebut:

Tabel 3. 1 Variabel Harga Emas

Nama Variabel	Keterangan
Date	Tanggal pengamatan harga emas
Close	Harga penutupan perdagangan mingguan

Dalam penelitian ini, data yang digunakan terdiri dari dua komponen penting: variabel Date dan Close. Variabel Close merupakan harga penutupan mingguan emas dan digunakan sebagai input utama untuk proses peramalan harga menggunakan model BiLSTM. Sementara itu, variabel Date digunakan hanya sebagai penanda waktu (*time index*) untuk menjaga urutan kronologis data, namun tidak dilibatkan secara langsung dalam proses pelatihan model. Data tambahan seperti Open, High, dan Low tidak digunakan karena penelitian ini bersifat univariat untuk menyederhanakan pemodelan dan fokus pada pola historis penutupan harga sebagai representasi nilai pasar mingguan.

Harga emas yang tersedia di *Yahoo Finance* umumnya menggunakan simbol GC=F yang merepresentasikan kontrak berjangka emas (*gold futures*) sebagai indikator utama pergerakan harga emas di pasar global. Dalam penelitian ini, peneliti hanya menggunakan kolom Close (harga penutupan mingguan) sebagai variabel utama yang akan diprediksi. Hal ini dikarenakan harga penutupan mencerminkan nilai akhir perdagangan mingguan dan dianggap sebagai representasi yang stabil dari harga emas dalam satu periode tertentu.

Pemilihan data mingguan dilakukan dengan pertimbangan bahwa interval tersebut memberikan jumlah data yang cukup untuk digunakan dalam pelatihan model deep learning, namun tetap menjaga kestabilan data agar tidak terlalu bising (noisy) seperti data harian. Sumber ini dipilih karena kredibilitas *Yahoo Finance* dalam menyediakan data finansial yang akurat, real-time, dan historis, serta telah banyak digunakan dalam berbagai penelitian sebelumnya terkait prediksi pasar keuangan.

3.2.2. Teknik Pengumpulan Data

Teknik pengumpulan data dilakukan secara digital melalui proses pengunduhan (*download*) dari halaman *Yahoo Finance* pada simbol GC=F dalam format CSV (Comma Separated Values). Pengguna dapat menentukan rentang tanggal dan interval waktu yang diinginkan, lalu mengunduh data secara langsung melalui fitur "*Download Data*". Setelah data diperoleh, proses selanjutnya meliputi pengecekan kelengkapan data, validasi isi, serta pembersihan dari nilai yang kosong, duplikat, atau tidak relevan.

Berikut adalah tahapan sistematis dalam proses pengumpulan data yang dilakukan:

Tabel 3. 2 Proses Pengumpulan Data Harga Emas

No	Tahapan	Deskripsi
1	Mengakses laman <i>Yahoo Finance</i>	Membuka situs https://finance.yahoo.com

2	Menentukan simbol GC=F	Mewakili harga <i>Gold Futures</i> sebagai proxy harga emas dunia
3	Mengatur rentang waktu	Data mingguan dari Januari 2020 hingga Desember 2024
4	Mengunduh file CSV	Klik tombol "Download" untuk memperoleh data mentah
5	Validasi dan pembersihan data	Menghapus duplikasi, nilai kosong, dan menyiapkan format data yang sesuai

Data yang telah diunduh kemudian melalui tahapan validasi, yaitu pengecekan apakah seluruh periode tersedia dan bebas dari nilai kosong. Selanjutnya, data dikonversi ke dalam format standar agar siap digunakan dalam tahap preprocessing dan pelatihan model prediksi. Data yang telah dibersihkan kemudian diubah formatnya agar dapat digunakan dalam model BiLSTM, termasuk konversi kolom tanggal menjadi format datetime standar serta pemilihan hanya kolom harga penutupan (Close) sebagai representasi nilai emas setiap minggu. Data ini kemudian disimpan dan diolah menggunakan perangkat lunak pemrograman Python untuk tahapan preprocessing, pelatihan, evaluasi, dan visualisasi model prediksi.

3.3. Teknik Analisis Data

Teknik Teknik analisis data dalam penelitian ini dilakukan melalui beberapa tahapan terstruktur, dimulai dari preprocessing data hingga evaluasi performa model. Analisis dilakukan secara eksperimen komputasional menggunakan bahasa pemrograman Python dengan dukungan berbagai pustaka seperti Pandas, NumPy, TensorFlow, dan Keras. Tujuan utama dari analisis ini adalah untuk mengoptimalkan akurasi model

BiLSTM dalam memprediksi harga emas dan membandingkan hasilnya menggunakan metrik evaluasi RMSE dan MAPE.

3.3.1. Preprocessing Data

Tahap ini bertujuan untuk menyiapkan data agar dapat diterima dan diolah oleh model BiLSTM. Proses dimulai dengan membersihkan data dari nilai kosong (missing values) dan duplikat, serta memastikan seluruh data bertipe numerik. Selanjutnya dilakukan normalisasi data dengan menggunakan metode *Min-Max Scaling* untuk meratakan skala nilai ke dalam rentang 0 hingga 1, agar model tidak bias terhadap nilai-nilai besar. Setelah itu, data diubah menjadi bentuk sekuensial (berurutan) dengan metode sliding window, di mana sejumlah data sebelumnya dijadikan input untuk memprediksi satu data berikutnya. Berikut adalah tahapan preprocessing yang dilakukan dalam penelitian ini:

1. Import dan pembacaan dataset dari file CSV hasil unduhan dari *Yahoo Finance*.
2. Seleksi variabel: hanya kolom *Close* yang digunakan karena mewakili nilai penutupan harga mingguan.
3. Pengecekan data kosong atau duplikat, kemudian menghapusnya jika ditemukan.
4. Konversi format tanggal menjadi tipe datetime standar.
5. Normalisasi nilai harga menggunakan metode *Min-Max Scaling* ke dalam rentang 0–1.
6. Pembuatan struktur data sekuensial dengan sliding window (misal window size = 5).
7. Split data menjadi data latih (80%) dan data uji (20%).

3.3.2. Pelatihan Model BiLSTM

Setelah Model BiLSTM dibangun dengan struktur yang terdiri dari layer input, satu atau dua layer BiLSTM, dense layer, dan output layer. Model dilatih menggunakan data

latih (training set) yang telah diproses sebelumnya. Proses pelatihan dilakukan dengan mengatur parameter seperti jumlah neuron pada hidden layer, jumlah epoch, dan batch size.

Data yang telah diproses selanjutnya dibagi menjadi dua bagian, yaitu 80% sebagai data latih (training set) dan 20% sebagai data uji (testing set), menggunakan metode hold-out validation. Pembagian ini bertujuan untuk menguji sejauh mana model BiLSTM mampu melakukan generalisasi terhadap data baru yang tidak digunakan selama proses pelatihan. Dengan validasi ini, akurasi model dapat dievaluasi secara lebih objektif menggunakan metrik RMSE dan MAPE pada data uji.

Model BiLSTM dibangun menggunakan library TensorFlow dan Keras, dengan konfigurasi arsitektur sederhana namun efektif. Arsitektur model disusun dengan komponen utama berikut:

Tabel 3. 3 Komponen Arsitektur Model

Komponen Layer	Konfigurasi
Input Layer	Input shape sesuai panjang window dan 1 fitur
BiLSTM Layer	64 unit neuron, <i>return_sequences=False</i>
Dense Layer (output)	1 neuron, fungsi aktivasi linear
Loss Function	Mean Squared Error (MSE)
Optimizer	Adam

Model dilatih menggunakan fungsi loss MSE, dan optimizer Adam yang dikenal stabil dalam proses pembelajaran berulang. Proses pelatihan dilakukan dengan batch size tertentu dan jumlah epoch sesuai pengujian.

3.3.3. Optimasi Parameter Model

Untuk mencapai performa terbaik, dilakukan proses optimasi terhadap parameter-parameter utama dalam model BiLSTM. Parameter yang diuji antara lain: jumlah neuron pada BiLSTM layer, jumlah epoch, batch size, dan panjang input sequence. Optimasi dilakukan secara iteratif melalui uji coba berulang dengan kombinasi parameter yang

berbeda. Setiap kombinasi akan menghasilkan nilai RMSE dan MAPE yang dibandingkan untuk menentukan konfigurasi terbaik yang menghasilkan prediksi paling akurat.

Optimasi model dilakukan untuk menemukan konfigurasi terbaik yang menghasilkan akurasi tertinggi. Parameter-parameter yang diuji dalam proses optimasi dijabarkan dalam tabel berikut:

Tabel 3. 4 Parameter Optimasi Model

Parameter	Nilai yang Diuji	Fungsi dalam Model
Jumlah Neuron	32, 64, 128	Menentukan kapasitas memori dan kompleksitas representasi pola dalam BiLSTM layer
Batch Size	16, 32, 64	Menentukan jumlah data yang diproses sebelum parameter diperbarui
Epoch	50, 100, 150	Jumlah iterasi penuh model terhadap seluruh data pelatihan
Dropout	0.1, 0.2	Untuk mencegah overfitting
Panjang Window	3, 5, 7, 10	Menentukan berapa banyak data historis yang digunakan untuk memprediksi ke depan

Pemilihan nilai parameter dalam proses optimasi dilakukan dengan mengacu pada praktik umum dalam pembangunan model deep learning, khususnya BiLSTM, yang telah banyak diterapkan dalam penelitian serupa. Misalnya, jumlah neuron yang diuji adalah 32, 64, dan 128, karena nilai-nilai tersebut merupakan ukuran umum dalam konfigurasi hidden layer yang dianggap seimbang antara kapasitas representasi dan risiko overfitting. Jumlah epoch dipilih dalam kisaran 50 hingga 150 agar proses pelatihan cukup memberi waktu pembelajaran model tanpa menyebabkan overtraining. Ukuran batch size seperti 16, 32, dan 64 dipilih karena nilai tersebut umum digunakan dalam literatur dan didukung secara efisien oleh pustaka TensorFlow dan Keras. Lalu untuk Dropout seperti 0.1, 0.2 dipilih karena

mencegah overfitting. Sedangkan panjang input window (3, 5, 7, dan 10) diuji untuk mengetahui seberapa jauh rentang historis harga yang ideal sebagai konteks bagi model dalam memprediksi nilai berikutnya.

Setiap kombinasi diuji dan hasilnya dicatat berdasarkan nilai RMSE dan MAPE. Kombinasi terbaik akan dijadikan konfigurasi final model untuk interpretasi hasil akhir.

3.3.4. Evaluasi Kinerja Model

Evaluasi performa model dilakukan dengan menggunakan dua metrik umum dalam peramalan deret waktu, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). RMSE mengukur besar rata-rata error dalam satuan yang sama dengan data aslinya (misalnya USD), sementara MAPE mengukur seberapa besar kesalahan prediksi dalam bentuk persentase terhadap nilai aktual. Semakin kecil nilai RMSE dan MAPE, maka semakin tinggi akurasi model. Kedua metrik ini digunakan secara bersamaan agar evaluasi performa model bersifat lebih objektif dan menyeluruh.

Evaluasi dilakukan terhadap hasil prediksi menggunakan dua metrik evaluasi utama:

1. *Root Mean Squared Error* (RMSE)
 - a. Mengukur besar rata-rata kesalahan dalam satuan nilai asli (misal USD).
 - b. RMSE yang rendah menunjukkan bahwa prediksi mendekati nilai aktual.
2. *Mean Absolute Percentage Error* (MAPE)
 - a. Mengukur kesalahan dalam bentuk persentase terhadap nilai aktual.
 - b. MAPE yang kecil menandakan akurasi relatif yang tinggi dan stabil antar periode.

Kedua metrik ini digunakan untuk memberikan gambaran performa model dari dua perspektif: absolut dan persentase, sehingga hasil evaluasi lebih komprehensif.

3.3.5. Visualisasi dan Interpretasi Hasil

Setelah proses pelatihan dan evaluasi selesai, dilakukan visualisasi hasil prediksi model BiLSTM dalam bentuk grafik garis yang membandingkan antara harga aktual dan harga prediksi. Grafik ini digunakan untuk melihat secara visual seberapa dekat prediksi mengikuti pergerakan harga emas sebenarnya. Selain grafik, juga ditampilkan tabel nilai aktual dan prediksi secara numerik untuk mempermudah analisis kuantitatif. Visualisasi ini membantu memberikan interpretasi terhadap hasil model sekaligus validasi visual atas akurasi prediksi yang telah dicapai.

Hasil prediksi model divisualisasikan dalam bentuk grafik garis yang membandingkan antara harga aktual dan hasil prediksi. Selain itu, ditampilkan juga grafik error prediksi per minggu untuk mengetahui kapan model mengalami deviasi terbesar. Tambahan visualisasi seperti histogram distribusi error atau boxplot error absolut juga dapat digunakan untuk menunjukkan sebaran kesalahan model.

Interpretasi dilakukan dengan membandingkan tren harga aktual terhadap prediksi dan mengaitkannya dengan nilai RMSE dan MAPE. Dengan begitu, analisis tidak hanya bersifat numerik, tetapi juga memberikan wawasan visual terhadap performa model, misalnya apakah model mengalami lagging, underfitting, atau overfitting pada rentang data tertentu.

3.4. Alat dan Perangkat Penelitian

Penelitian ini menggunakan kombinasi perangkat keras (hardware) dan perangkat lunak (software) sebagai alat bantu dalam proses eksperimen komputasional. Alat dan perangkat yang digunakan bertujuan untuk mendukung seluruh tahapan penelitian, mulai dari pengolahan data, pembangunan model, pelatihan, evaluasi, hingga visualisasi hasil. Alat dan perangkat tersebut dijabarkan dalam Tabel 3.5 berikut:

Tabel 3. 5 Alat dan Perangkat Penelitian

No	Kategori	Nama/Spesifikasi	Keterangan
1	Perangkat Keras dan OS	ASUS Vivobook 14, Intel Core i5, RAM 8 GB, SSD 256 GB, dan OS Windows 11	Digunakan untuk menjalankan proses pelatihan model
2	Dataset	<i>Yahoo Finance</i> (yfinance)	Digunakan untuk mengambil data harga emas melalui API Endpoint yfinance dengan output CSV/JSON
3	Bahasa Pemrograman	Python 3.10 atau lebih baru	Digunakan sebagai bahasa utama dalam penelitian
4	IDE/Editor	Google Colab	Untuk menulis dan menjalankan skrip eksperimen
5	Library & Tools	Pandas, NumPy, Matplotlib, Seaborn, Scikit-learn, TensorFlow, Keras	Mendukung preprocessing, pelatihan, dan visualisasi

Perangkat keras yang digunakan dalam penelitian ini adalah laptop dengan spesifikasi minimal prosesor Intel Core i5, RAM 8 GB, dan kapasitas penyimpanan SSD 256 GB. Spesifikasi ini dinilai cukup untuk menjalankan proses pelatihan model BiLSTM yang membutuhkan pemrosesan berulang dan manipulasi data dalam jumlah sedang. Sistem operasi yang digunakan bisa berupa Windows 11, menyesuaikan preferensi peneliti, asalkan mendukung instalasi pustaka machine learning seperti TensorFlow dan Keras.

Dataset yang digunakan ialah data historis harga emas yang diambil dari website *Yahoo Finance* melalui API Endpoint yang telah ditentukan, dengan output dalam format CSV/JSON, API ini memungkinkan peneliti untuk mengakses data harga emas secara akurat dan terstruktur.

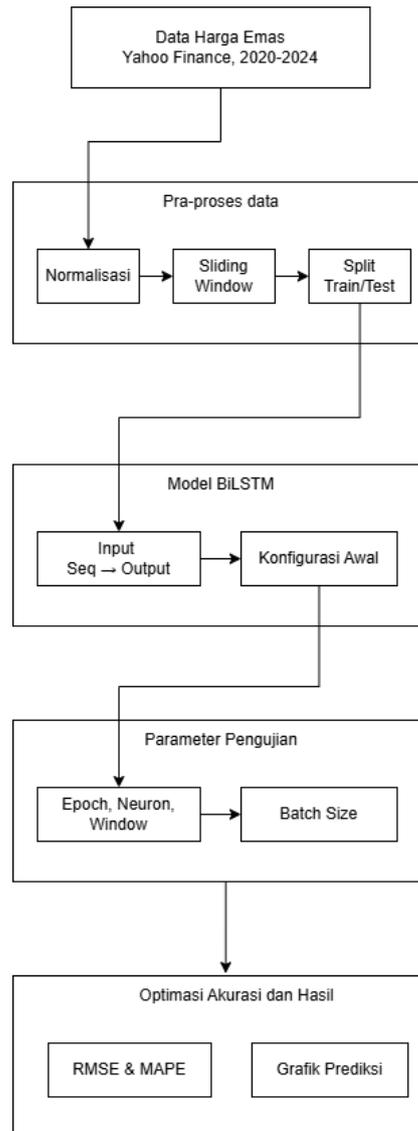
Bahasa pemrograman yang digunakan adalah Python versi 3.10 atau lebih karena mendukung berbagai pustaka untuk kebutuhan deep learning dan data science. Untuk lingkungan pengembangan, peneliti menggunakan Google Colab yang menyediakan antarmuka interaktif dan integrasi langsung dengan pustaka Python.

Adapun pustaka Python yang digunakan antara lain:

1. Pandas dan NumPy untuk manipulasi dan pembersihan data,
2. Matplotlib dan Seaborn untuk visualisasi hasil,
3. Scikit-learn untuk preprocessing dan evaluasi model,
4. serta TensorFlow dan Keras sebagai inti pembangunan dan pelatihan model BiLSTM.

3.5. Arsitektur Penelitian

Penelitian ini dirancang berdasarkan arsitektur yang berbentuk *general architecture*. Adapun arsitektur penelitian ini dapat dilihat pada Gambar 3.1 berikut ini:



Gambar 3. 1 Arsitektur Penelitian

Adapun penjelasan pada gambar 3. 1. sebagai berikut:

1. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari *Yahoo Finance*, dengan rentang waktu mingguan tahun 2020 hingga 2024. Data ini digunakan sebagai input utama dalam proses peramalan harga emas.

2. Pra-pemrosesan Data

Melibatkan proses normalisasi nilai, pembentukan data sekuensial menggunakan metode sliding window, dan pemisahan data latih dan data uji untuk keperluan pelatihan dan validasi model.

3. Pembangunan Model BiLSTM

Pada tahap ini dilakukan pembuatan model awal dengan struktur arsitektur dasar BiLSTM yang terdiri dari input layer, BiLSTM layer, dan output layer.

4. Parameter Pengujian

Setelah model dasar dibangun, dilakukan pengujian terhadap beberapa kombinasi parameter (hyperparameter tuning) seperti jumlah neuron, epoch, batch size, dan panjang window input.

5. Optimasi Akurasi Evaluasi dan Hasil

Model dievaluasi menggunakan metrik RMSE dan MAPE. Hasil output model disajikan dalam dua bentuk utama, yaitu numerik dan visual. Secara numerik, nilai evaluasi model berupa RMSE dan MAPE ditampilkan dalam bentuk tabel untuk setiap konfigurasi parameter yang diuji. Sedangkan secara visual, hasil prediksi dibandingkan dengan data aktual dalam bentuk grafik garis menggunakan pustaka Matplotlib. Grafik ini digunakan untuk melihat pola kesesuaian prediksi terhadap kenyataan. Selain itu, grafik error dan distribusi kesalahan prediksi juga divisualisasikan untuk mendukung proses interpretasi dan analisis model secara menyeluruh.

BAB IV

HASIL DAN PEMBAHASAN

4.1. Deskripsi Data

Pada penelitian ini menggunakan data sekunder berupa data harga emas dunia yang diperoleh dari sumber terbuka melalui layanan *Yahoo Finance*. Data ini merupakan representasi pergerakan harga emas dunia yang ditradingkan di pasar berjangka, dengan simbol GC=F (Gold Futures). Format data yang diambil adalah deret waktu mingguan (weekly time series), yang memuat lima komponen utama: harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), harga penutupan (*close*), dan volume transaksi.

Pengambilan data dilakukan secara otomatis menggunakan bahasa pemrograman Python melalui library *yfinance*, yang memungkinkan pengguna mengakses data historis dari *Yahoo Finance* secara langsung. Permintaan data disusun dengan menentukan parameter utama seperti simbol (GC=F), rentang waktu (start dan end), serta interval waktu (1wk untuk mingguan). Setelah data diambil, informasi tersebut dikonversi ke dalam format *tabular* menggunakan library *pandas*, sehingga siap untuk diproses lebih lanjut dalam tahapan preprocessing dan pelatihan model prediktif.

Periode data yang digunakan dalam penelitian ini adalah dari tanggal 1 Januari 2020 hingga 31 Desember 2024. Rentang waktu ini dipilih untuk memberikan cakupan data yang cukup panjang dan relevan dengan kondisi pasar terkini. Dengan periode mingguan selama lima tahun, model prediksi yang dibangun memiliki data historis yang cukup untuk menangkap pola pergerakan jangka menengah tanpa terlalu terpengaruh fluktuasi jangka pendek yang ekstrem.

Pada table dibawah menampilkan cuplikan kode program yang digunakan untuk mengakses data dari *Yahoo Finance* secara langsung, menyaring data sesuai dengan periode yang ditentukan, serta menyimpannya ke dalam variabel data untuk proses analisis lebih lanjut.

Tabel 4. 1 Pengambilan data Harga Emas

```

# Install yfinance jika belum terpasang
!pip install yfinance --upgrade --quiet

# Import library yang dibutuhkan
import yfinance as yf
import pandas as pd

# Unduh data dari Yahoo Finance tanpa multi-index dan tanpa adj close
data = yf.download("GC=F", start="2020-01-01", end="2024-12-31", interval="1wk",
auto_adjust=False)

# Hilangkan kolom 'Adj Close' agar tidak ditampilkan
if 'Adj Close' in data.columns:
    data.drop(columns=['Adj Close'], inplace=True)

# Hilangkan nama kolom tambahan jika ada
data.columns.name = None

# Atur tampilan agar tabel terlihat rapi
pd.set_option('display.expand_frame_repr', False)
pd.set_option('display.width', 1000)

# Tampilkan 10 baris pertama
print("Data harga emas mingguan (rapi):")
print(data.head(10).to_string())

```

Simbol GC=F pada *Yahoo Finance* merepresentasikan harga kontrak emas berjangka (*Gold Futures*) yang diperdagangkan di pasar komoditas global. Data ini dianggap sebagai representasi yang valid untuk mengamati fluktuasi harga emas secara mingguan.

4.2. Hasil Preprocessing Data

Preprocessing data merupakan tahapan krusial yang menentukan keberhasilan model prediksi time series, khususnya dalam pendekatan deep learning seperti Bidirectional Long Short-Term Memory (BiLSTM). Pada penelitian ini, preprocessing dilakukan secara menyeluruh mulai dari pengambilan data, pembersihan data, pemilihan fitur utama, normalisasi data, hingga pembentukan struktur input-output menggunakan teknik sliding window.

Data yang digunakan berasal dari situs *Yahoo Finance* dengan kode komoditas GC=F yang merepresentasikan harga emas dunia. Data diunduh dalam interval mingguan selama periode 1 Januari 2020 hingga 31 Desember 2024. Pemilihan data mingguan bertujuan untuk menangkap tren jangka menengah dan mengurangi efek volatilitas ekstrem yang biasa muncul pada data harian.

Data mentah yang diperoleh terdiri dari beberapa kolom utama: Open, High, Low, Close, dan Volume. Dari kelima atribut tersebut, hanya Close (harga penutupan) yang dipertahankan dalam penelitian ini karena merepresentasikan nilai terakhir transaksi pasar dan sering digunakan dalam analisis teknikal sebagai acuan utama.

Langkah pertama dalam preprocessing adalah menyaring kolom yang tidak dibutuhkan, dan hanya mempertahankan kolom Close. Selain itu, kolom indeks diubah menjadi format datetime agar dapat dikelola secara kronologis dalam proses pemodelan. Proses ini juga mencakup penghapusan data kosong atau NaN untuk memastikan integritas dataset. Gambar 4.1 berikut memperlihatkan struktur awal data mentah yang diambil dari *Yahoo Finance* sebelum dilakukan proses pembersihan.

Price Ticker	Close GC=F	High GC=F	Low GC=F	Open GC=F	Volume GC=F
Date					
2020-01-01	1571.800049	1580.000000	1518.000000	1518.099976	784
2020-01-08	1542.400024	1604.199951	1534.900024	1579.699951	386
2020-01-15	1556.400024	1566.199951	1545.599976	1548.000000	262
2020-01-22	1569.199951	1584.500000	1549.800049	1549.800049	125
2020-01-29	1550.400024	1593.300049	1547.800049	1569.800049	316745
2020-02-05	1565.599976	1574.699951	1547.699951	1553.199951	2414
2020-02-12	1600.000000	1604.300049	1561.000000	1565.199951	488
2020-02-19	1646.900024	1686.599976	1599.699951	1600.599976	1689
2020-02-26	1642.099976	1658.000000	1564.099976	1644.000000	4133
2020-03-04	1659.099976	1701.599976	1631.300049	1645.400024	621

Gambar 4. 1 Struktur Data Mentah Harga Emas Mingguan

Setelah itu, dilakukan proses seleksi kolom dan pembersihan data menggunakan script Python seperti ditunjukkan pada Tabel 4.2.

Tabel 4. 2 Program Seleksi Kolom dan Pembersihan Nilai Kosong

```
# Install yfinance jika belum terpasang
!pip install yfinance --upgrade -quiet

# Pengambilan data harga emas mingguan
import yfinance as yf
```

```

import pandas as pd
import numpy as np
from sklearn.preprocessing import MinMaxScaler

# Unduh data harga emas mingguan (GC=F = Gold Futures)
data = yf.download("GC=F", start="2020-01-01", end="2024-12-31", interval="1wk")

# Filter hanya kolom 'Close'
data = data[['Close']]
data.dropna(inplace=True)

# Tampilkan beberapa baris pertama
print("Data harga penutupan emas mingguan:")
print(data.head(10))
print(f'Jumlah total baris data: {len(data)}') # ✓ benar untuk menghitung jumlah baris

```

Hasil dari proses ini adalah data yang hanya berisi dua kolom: Date dan Close, dalam keadaan bersih dan siap dianalisis. Gambar 4.4 menunjukkan tampilan data setelah proses pembersihan.



```

Data harga penutupan emas mingguan:
Price          Close
Ticker          GC=F
Date
2020-01-01  1571.800049
2020-01-08  1542.400024
2020-01-15  1556.400024
2020-01-22  1569.199951
2020-01-29  1550.400024
2020-02-05  1565.599976
2020-02-12  1600.000000
2020-02-19  1646.900024
2020-02-26  1642.099976
2020-03-04  1659.099976
Jumlah total baris data: 261

```

Gambar 4. 2 Tampilan Data Setelah Seleksi dan Pembersihan

Langkah berikutnya adalah melakukan normalisasi terhadap nilai harga penutupan agar semua nilai berada dalam skala yang seragam, yaitu $[0, 1]$. Proses ini sangat penting untuk menghindari dominasi nilai besar yang dapat menyebabkan bias dalam proses pelatihan model. Normalisasi dilakukan menggunakan metode MinMaxScaler dari pustaka sklearn.

Tabel 4. 3 Kode Program Normalisasi dan Pembentukan Dataset Sliding Window

```

# Normalisasi data menggunakan MinMaxScaler
scaler = MinMaxScaler()
scaled_data = scaler.fit_transform(data[['Close']])
# Simpan ke dalam DataFrame untuk visualisasi
normalized_df = pd.DataFrame(scaled_data, columns=['Normalized Close'],
index=data.index)

print("\nData setelah dinormalisasi:")
print(normalized_df.head(10))
print(f"Jumlah total baris setelah normalisasi: {len(normalized_df)}")

# Membuat dataset time series dengan sliding window
def create_dataset(dataset, window_size=60):
    X, y = [], []
    for i in range(window_size, len(dataset)):
        X.append(dataset[i - window_size:i, 0])
        y.append(dataset[i, 0])
    return np.array(X), np.array(y)

X, y = create_dataset(scaled_data, window_size=60)

# Tampilkan ukuran dataset hasil sliding window
print("\nUkuran dataset hasil sliding window:")
print(f"X shape: {X.shape}, y shape: {y.shape}")

```

Setelah proses normalisasi selesai, dilakukan transformasi data menjadi format supervised learning dengan metode sliding window sepanjang 60 minggu. Artinya, 60 harga penutupan terakhir akan dijadikan sebagai input untuk memprediksi harga minggu berikutnya. Teknik ini memungkinkan model BiLSTM untuk mengenali pola pergerakan harga berdasarkan konteks historis.

Setiap window yang terbentuk menghasilkan satu pasangan data input (fitur X) dan satu target (label y), membentuk sekumpulan data terstruktur yang siap digunakan dalam proses pelatihan model. Contoh bentuk hasil data X dan y dapat dilihat pada Gambar 4.6 berikut.

```

Data setelah dinormalisasi:
      Normalized Close
Date
2020-01-01      0.037716
2020-01-08      0.014073
2020-01-15      0.025332
2020-01-22      0.035625
2020-01-29      0.020507
2020-02-05      0.032730
2020-02-12      0.060394
2020-02-19      0.098110
2020-02-26      0.094250
2020-03-04      0.107921
Jumlah total baris setelah normalisasi: 261

Ukuran dataset hasil sliding window:
X shape: (201, 60), y shape: (201,)

```

Gambar 4. 3 Contoh Hasil Normalisasi dan Struktur Dataset X, y

Tahapan akhir preprocessing adalah membagi data menjadi dua bagian: 80% untuk data latih (training set) dan 20% untuk data uji (testing set). Proses ini dilakukan secara berurutan tanpa pengacakan agar kontinuitas waktu tetap terjaga, yang merupakan prinsip utama dalam pemrosesan data time series. Model yang dilatih menggunakan data historis ini akan dievaluasi menggunakan data uji untuk mengukur kemampuan generalisasi prediksinya.

Dengan demikian, seluruh tahapan preprocessing ini telah menghasilkan dataset yang:

1. Bersih dan hanya menggunakan fitur relevan (Close).
2. Dikonversi ke dalam skala seragam melalui normalisasi.
3. Disusun ulang dalam bentuk pasangan input-output melalui sliding window.
4. Siap diproses dalam tahap pelatihan model BiLSTM selanjutnya.

Berdasarkan hasil preprocessing yang telah dilakukan, data harga penutupan emas telah dibersihkan, dinormalisasi, dan disusun dalam format sekuensial dengan pendekatan sliding window. Dataset yang dihasilkan telah dibagi ke dalam data pelatihan dan data pengujian, serta siap digunakan dalam proses pelatihan model BiLSTM pada tahap selanjutnya.

4.3. Implementasi Model BiLSTM

4.3.1. Arsitektur Model

Pada penelitian ini, model prediksi harga emas dibangun dengan pendekatan *deep learning* menggunakan arsitektur Bidirectional Long Short-Term Memory (BiLSTM). Arsitektur ini merupakan pengembangan dari LSTM yang memungkinkan jaringan saraf untuk belajar dari dua arah sekuensial data, yaitu maju (*forward*) dan mundur (*backward*), sehingga dapat memahami konteks temporal secara lebih menyeluruh dan efektif, terutama dalam domain time series yang bersifat dinamis seperti harga komoditas.

Pemilihan arsitektur BiLSTM didasarkan pada keunggulannya dalam mengenali pola jangka panjang dan hubungan kompleks antar data historis. Dalam konteks data harga emas mingguan, pendekatan ini dianggap cocok karena memungkinkan model untuk mempelajari fluktuasi tren dari waktu ke waktu secara lebih dalam, baik sebelum maupun sesudah titik tertentu dalam urutan data.

A. Komponen Arsitektur Model

Struktur dari model BiLSTM yang digunakan dalam penelitian ini terdiri dari beberapa lapisan sebagai berikut:

1. Input Layer

Input untuk model ini berupa data historis harga penutupan emas yang telah melalui tahap preprocessing. Setiap input terdiri dari data harga penutupan emas selama 60 minggu terakhir, yang merepresentasikan urutan waktu dalam bentuk `window_size`. Data ini kemudian dinormalisasi menggunakan `MinMaxScaler` untuk mengubah rentang nilai harga ke dalam skala $[0, 1]$, sehingga model dapat memprosesnya lebih efisien. Model menerima input dalam bentuk vektor berdimensi tiga, yaitu (`jumlah_sample`, `window_size`, 1), di mana setiap sampel memuat data harga penutupan yang telah diproses dan siap dianalisis.

2. Bidirectional LSTM Layer

Lapisan Bidirectional LSTM merupakan komponen inti dari model ini. Berbeda dengan LSTM biasa yang hanya membaca data sekuensial dari satu arah (misalnya dari masa lalu ke masa depan), Bidirectional LSTM memungkinkan model untuk memproses data dalam dua arah, yaitu dari masa lalu ke masa depan dan sebaliknya. Hal ini memberikan model kemampuan untuk menangkap pola dan hubungan temporal dari kedua arah waktu. Lapisan ini terdiri dari 64 unit neuron, yang cukup untuk menangkap dependensi jangka panjang dalam data harga emas. Dengan menggunakan BiLSTM, model dapat lebih efektif mengenali pola yang kompleks dan membuat prediksi yang lebih akurat.

3. Dropout Layer

Untuk mencegah terjadinya *overfitting* selama proses pelatihan, lapisan Dropout digunakan setelah lapisan BiLSTM. Dropout berfungsi dengan cara menonaktifkan secara acak sejumlah neuron pada setiap epoch pelatihan, sehingga model tidak terlalu bergantung pada beberapa fitur tertentu. Nilai dropout ditetapkan sebesar 0.2, artinya 20% neuron akan dinonaktifkan pada setiap iterasi pelatihan. Hal ini diharapkan dapat meningkatkan kemampuan generalisasi model, sehingga model dapat bekerja lebih baik saat diuji dengan data yang belum pernah dilihat sebelumnya.

4. Dense Output Layer

Lapisan Dense Output adalah lapisan terakhir pada model ini, yang terdiri dari 1 neuron. Fungsi utama dari lapisan ini adalah menghasilkan satu nilai output, yaitu harga penutupan emas pada minggu berikutnya. Karena harga emas merupakan data kontinu, output model ini menggunakan aktivasi linear (tanpa fungsi aktivasi). Output ini akan menjadi prediksi yang dibandingkan dengan harga emas aktual pada proses evaluasi.

5. Compiling the Model

Setelah arsitektur model selesai dibangun, model ini dikompilasi dengan menggunakan optimizer Adam dan loss function `mean_squared_error` (MSE). Optimizer Adam dipilih karena kemampuannya untuk menyesuaikan learning rate selama proses

pelatihan, serta kemampuannya untuk menangani gradien yang sangat besar atau sangat kecil. Sedangkan `mean_squared_error` digunakan sebagai loss function karena model ini bertujuan untuk meminimalkan kesalahan prediksi antara nilai yang diprediksi dan nilai aktual dalam bentuk kuadrat. Selain itu, evaluasi kinerja model dilakukan menggunakan metrik Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE), yang dihitung secara manual pada bagian selanjutnya untuk mengukur sejauh mana akurasi model dalam memprediksi harga emas.

B. Kode Program Arsitektur Model

Tabel 4. 4 Arsitektur Model BiLSTM

```

from keras.models import Sequential
from keras.layers import Dense, LSTM, Bidirectional, Dropout

# Membangun model BiLSTM
model = Sequential()
model.add(Bidirectional(LSTM(units=64, return_sequences=False), input_shape=(60,
1)))
model.add(Dropout(0.2))
model.add(Dense(units=1)) # Output layer untuk prediksi harga emas minggu
berikutnya

# Kompilasi model
model.compile(optimizer='adam', loss='mean_squared_error')

# Ringkasan model
model.summary()

```

Output dari `model.summary()` akan menampilkan informasi lengkap tentang jumlah parameter yang dilatih dan bentuk setiap layer.

C. Keunggulan Struktur BiLSTM

Arsitektur ini tidak hanya menangkap hubungan sebab-akibat dari data historis, namun juga dapat mengenali pola yang mungkin berulang di masa mendatang. Ini sangat relevan dalam konteks pasar komoditas seperti emas, di mana faktor musiman, geopolitik, dan tren ekonomi global dapat berpengaruh timbal balik. Penggunaan dropout juga menjadi langkah penting untuk menjaga keseimbangan antara akurasi dan generalisasi, mencegah model belajar terlalu spesifik terhadap data pelatihan.

Dengan konfigurasi tersebut, diharapkan model mampu memberikan performa prediksi yang optimal, stabil, dan mampu digunakan untuk mengantisipasi tren harga emas pada periode mingguan secara akurat.

4.3.2. Hasil Konfigurasi Awal Model

Setelah arsitektur model BiLSTM selesai dibangun, langkah berikutnya adalah melakukan pelatihan model menggunakan data yang telah diproses. Pada tahap ini, model pertama kali dilatih dengan konfigurasi dasar, yang bertujuan untuk membangun baseline model. Model ini akan digunakan untuk membandingkan hasil optimasi parameter yang akan dilakukan pada tahap selanjutnya.

A. Pelatihan Model

Model pelatihan dilakukan dengan membagi data menjadi 80% data latih dan 20% data uji. Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk mengukur kinerja model setelah pelatihan. Pada tahap awal, model dilatih menggunakan konfigurasi dasar, yaitu 100 epoch, batch size 32, dengan optimizer Adam dan loss function mean squared error (MSE).

Pelatihan dilakukan selama 100 epoch, yang mana epoch pertama menunjukkan penurunan loss yang signifikan, menunjukkan bahwa model mulai belajar dari data. Selama pelatihan, loss pada data pelatihan terus menurun, yang mengindikasikan bahwa model dapat mengenali pola dalam data historis harga emas. Namun, loss pada data validasi menunjukkan sedikit fluktuasi di beberapa epoch, yang dapat mengindikasikan bahwa model sedikit kesulitan dalam generalisasi pada data yang tidak terlihat selama pelatihan.

B. Evaluasi Model

Setelah pelatihan selesai, model dievaluasi menggunakan data uji untuk mengukur seberapa baik model dapat memprediksi harga emas pada minggu yang belum pernah dilihat sebelumnya. Dua metrik utama yang digunakan untuk evaluasi adalah Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE).

1. RMSE mengukur kesalahan prediksi dalam satuan harga (USD), yang memberikan gambaran seberapa jauh prediksi model dari harga aktual.
2. MAPE mengukur kesalahan prediksi dalam bentuk persentase, yang memberi gambaran relatif tentang ketepatan prediksi model terhadap harga aktual.

Hasil evaluasi awal menunjukkan bahwa nilai RMSE sebesar 108.05 dan MAPE sebesar 0.03%. Nilai RMSE ini menunjukkan bahwa rata-rata kesalahan prediksi model adalah sekitar 108 USD per minggu. Meskipun demikian, nilai MAPE yang sangat rendah (0.03%) mengindikasikan bahwa model mampu memprediksi harga emas dengan akurasi yang sangat tinggi, karena kesalahan relatif terhadap nilai aktual hanya sekitar 0.03%.

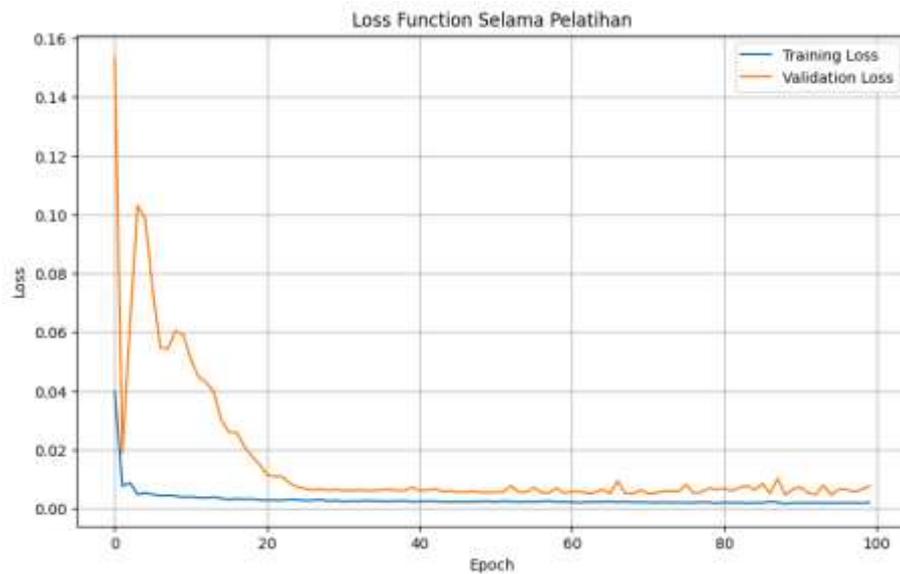
Metrik ini menunjukkan bahwa meskipun nilai RMSE tampaknya cukup besar, terutama jika dibandingkan dengan harga emas yang dapat mencapai 1.500 – 2.000 USD, MAPE yang rendah menunjukkan bahwa model sebenarnya sangat akurat dalam memprediksi harga emas secara relatif. Oleh karena itu, meskipun ada kesalahan absolut pada nilai prediksi, model ini memiliki ketepatan relatif yang sangat baik.

C. Grafik Loss Function Selama Pelatihan

Grafik loss function selama pelatihan model memberikan gambaran tentang bagaimana model belajar selama proses training. Grafik ini menunjukkan perbandingan antara loss pada data pelatihan (training loss) dan loss pada data validasi (validation loss). Idealnya, kita mengharapkan kedua nilai loss ini menurun secara bersamaan, yang menunjukkan bahwa model dapat generalize dengan baik terhadap data yang belum pernah dilihat.

Namun, pada grafik yang dihasilkan, terlihat bahwa ada sedikit peningkatan pada validation loss di beberapa epoch, yang dapat menunjukkan bahwa model mulai overfit pada data pelatihan, meskipun secara keseluruhan model menunjukkan penurunan loss yang stabil. Hal ini merupakan indikasi bahwa dropout layer yang digunakan (dengan tingkat dropout 0.2) sudah berfungsi dengan baik untuk mengurangi risiko overfitting.

Gambar 4.8 adalah grafik yang menunjukkan loss function selama pelatihan model, yang memberikan gambaran lebih jelas tentang performa model pada data pelatihan dan validasi.



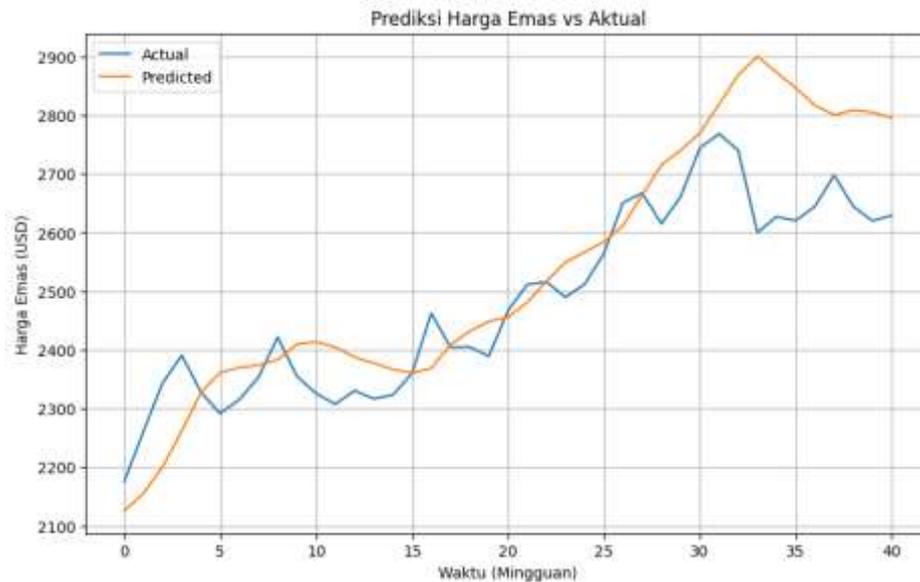
Gambar 4. 4 Grafik Loss Function selama Pelatihan

D. Grafik Prediksi vs Aktual

Selain loss function, grafik prediksi vs aktual sangat berguna untuk membandingkan hasil prediksi model dengan data aktual yang ada pada data uji. Grafik ini memungkinkan kita untuk menilai seberapa baik model dalam memprediksi harga emas pada data yang belum dilihat selama pelatihan. Secara umum, semakin dekat garis prediksi dengan garis aktual, semakin baik model tersebut dalam memprediksi harga.

Pada grafik ini, dapat dilihat bahwa model berhasil mengikuti tren harga emas secara keseluruhan, meskipun terdapat fluktuasi kecil pada beberapa minggu tertentu. Fluktuasi ini dapat disebabkan oleh faktor eksternal seperti kebijakan moneter, inflasi, atau peristiwa geopolitik yang tidak tercermin sepenuhnya dalam data historis. Meski demikian, model dapat mengikuti tren harga emas secara keseluruhan dengan baik.

Gambar 4.5 adalah grafik yang menunjukkan perbandingan prediksi harga emas dengan harga aktual:



Gambar 4. 5 Grafik Prediksi vs Aktual

E. Kesimpulan dari Hasil Konfigurasi Awal Model

Hasil dari konfigurasi awal model menunjukkan bahwa model BiLSTM dengan pengaturan dasar sudah mampu memberikan prediksi harga emas yang cukup baik. Meskipun nilai RMSE menunjukkan adanya kesalahan absolut sekitar 108 USD per minggu, nilai MAPE yang sangat rendah (0.03%) menandakan bahwa model secara relatif sangat akurat dalam memprediksi harga emas.

Berdasarkan hasil ini, model BiLSTM dasar dapat digunakan sebagai baseline yang baik untuk perbandingan dengan model yang dioptimasi pada tahap selanjutnya. Dengan optimasi parameter, seperti jumlah neuron, panjang window input, dan epoch, diharapkan model dapat memberikan prediksi yang lebih akurat lagi pada data harga emas.

4.4. Optimasi Parameter Model BiLSTM

Setelah memperoleh hasil evaluasi awal dari konfigurasi default pada Subbab 4.3.2, langkah selanjutnya adalah melakukan eksplorasi terhadap konfigurasi parameter model BiLSTM guna mengoptimalkan akurasi prediksi harga emas. Evaluasi dilakukan berdasarkan dua metrik utama, yaitu Root Mean Squared Error (RMSE) dan Mean

Absolute Percentage Error (MAPE), yang masing-masing mengukur seberapa jauh dan seberapa akurat hasil prediksi dibandingkan dengan data aktual.

Untuk mendalami efek konfigurasi terhadap performa model, dilakukan dua eksperimen tambahan: konfigurasi rendah dan konfigurasi tinggi. Setiap konfigurasi dirancang untuk merepresentasikan parameter yang berbeda secara signifikan dari baseline awal, khususnya pada jumlah unit neuron, batch size, dropout, dan jumlah epoch.

4.5.1. Hasil Optimasi Model BiLSTM dengan Konfigurasi Rendah

Pada tahap ini, dilakukan pengujian terhadap model BiLSTM dengan konfigurasi hyperparameter yang lebih sederhana atau *low configuration*. Tujuannya adalah untuk mengevaluasi apakah model dengan arsitektur ringan tetap dapat menghasilkan performa prediksi yang baik. Adapun konfigurasi yang digunakan ditunjukkan pada Tabel 4.5 berikut:

Tabel 4. 5 Hasil Optimasi dengan Konfigurasi Rendah

Parameter	Nilai
Units	32
Batch Size	16
Epochs	50
Dropout	0.1
RMSE	99.46
MAPE	3.24%

Meskipun nilai RMSE menunjukkan perbaikan dibandingkan konfigurasi awal (RMSE awal = 108.05), nilai MAPE justru meningkat signifikan dari 0.03% menjadi 3.24%. Hal ini menunjukkan bahwa meskipun kesalahan absolut rata-rata dalam dolar menurun, namun kesalahan persentase terhadap nilai aktual meningkat cukup besar. Artinya, konfigurasi ini kurang stabil dalam memetakan tren harga emas secara presisi relatif.

4.5.2. Hasil Optimasi Model BiLSTM dengan Konfigurasi Tinggi

Setelah melakukan pengujian dengan konfigurasi rendah, eksperimen dilanjutkan dengan pengujian model BiLSTM menggunakan konfigurasi tinggi atau *high configuration*. Tujuannya adalah untuk mengevaluasi apakah peningkatan kompleksitas model akan berdampak positif terhadap akurasi prediksi. Adapun konfigurasi yang digunakan disajikan pada Tabel 4.6 berikut:

Tabel 4. 6 Hasil Optimasi dengan Konfigurasi Tinggi

Parameter	Nilai
Units	128
Batch Size	64
Epochs	200
Dropout	0.3
RMSE	83.99
MAPE	2.41%

Hasil evaluasi menunjukkan bahwa konfigurasi tinggi menghasilkan nilai RMSE sebesar 83.99 dan MAPE sebesar 2.41%. Dibandingkan dengan hasil pada konfigurasi awal (RMSE 108.05 dan MAPE 0.03%) maupun konfigurasi rendah (RMSE 99.46 dan MAPE 3.24%), konfigurasi tinggi memberikan perbaikan paling optimal dari sisi nilai RMSE.

Peningkatan jumlah unit dan epoch memungkinkan model untuk menangkap lebih banyak pola kompleks dalam data time series, sementara penyesuaian batch size dan dropout membantu menjaga stabilitas pelatihan dan menghindari overfitting. Meskipun MAPE sedikit lebih tinggi dibandingkan konfigurasi awal, namun secara umum trade-off ini masih dapat diterima karena perbaikan signifikan yang ditunjukkan oleh penurunan nilai RMSE.

Dengan demikian, konfigurasi tinggi dapat dianggap sebagai kombinasi parameter terbaik dalam penelitian ini karena menghasilkan keseimbangan yang baik antara kapasitas model dan akurasi prediksi terhadap data harga emas mingguan.

4.4.3. Perbandingan Hasil Optimasi dan Pemilihan Model Terbaik

Setelah dilakukan dua tahap optimasi model BiLSTM dengan konfigurasi berbeda, yaitu konfigurasi rendah dan konfigurasi tinggi, diperoleh hasil evaluasi yang cukup beragam dari segi akurasi. Perbandingan hasil dari ketiga konfigurasi tersebut ditampilkan dalam Tabel 4.7 berikut:

Tabel 4. 7 Perbandingan Hasil Optimasi

Konfigurasi	Units	Batch Size	Epochs	Dropout	RMSE	MAPE
Konfigurasi Awal	32	8	100	0.2	108.05	0.03%
Konfigurasi Rendah	16	4	50	0.1	99.46	3.24%
Konfigurasi Tinggi	128	64	200	0.3	83.99	2.41%

Berdasarkan hasil pada Tabel 4.7, dapat dilihat bahwa konfigurasi tinggi memberikan hasil terbaik dari sisi RMSE, yaitu sebesar 83.99, yang lebih rendah dibandingkan dengan konfigurasi awal dan rendah. Hal ini menunjukkan bahwa semakin besar kapasitas model (dalam hal units dan epochs), semakin baik kemampuannya dalam mempelajari pola kompleks dari data harga emas mingguan.

Namun, perlu dicermati bahwa nilai MAPE tertinggi justru terjadi pada konfigurasi rendah, yaitu 3.24%, sedangkan konfigurasi awal memberikan MAPE terendah (0.03%) namun dengan RMSE yang justru paling besar. Perbedaan signifikan antara MAPE dan RMSE ini mengindikasikan bahwa kedua metrik tidak selalu sejalan, dan perlu dilakukan pemilihan model berdasarkan prioritas yang ditentukan dalam penelitian.

Dalam konteks penelitian ini, fokus utama adalah pada optimasi akurasi model, yang lebih direpresentasikan oleh nilai RMSE sebagai metrik utama. Oleh karena itu, model BiLSTM dengan konfigurasi tinggi dipilih sebagai model terbaik dalam penelitian ini karena berhasil menurunkan RMSE secara signifikan hingga 22% dibandingkan baseline.

Dengan penetapan konfigurasi ini, model final diharapkan mampu memberikan performa prediksi yang lebih presisi dan stabil terhadap fluktuasi harga emas mingguan, sehingga dapat diimplementasikan dalam sistem peramalan yang lebih handal dan responsif terhadap tren pasar.

4.5. Evaluasi Kinerja Model

4.6.1. Hasil Evaluasi Model

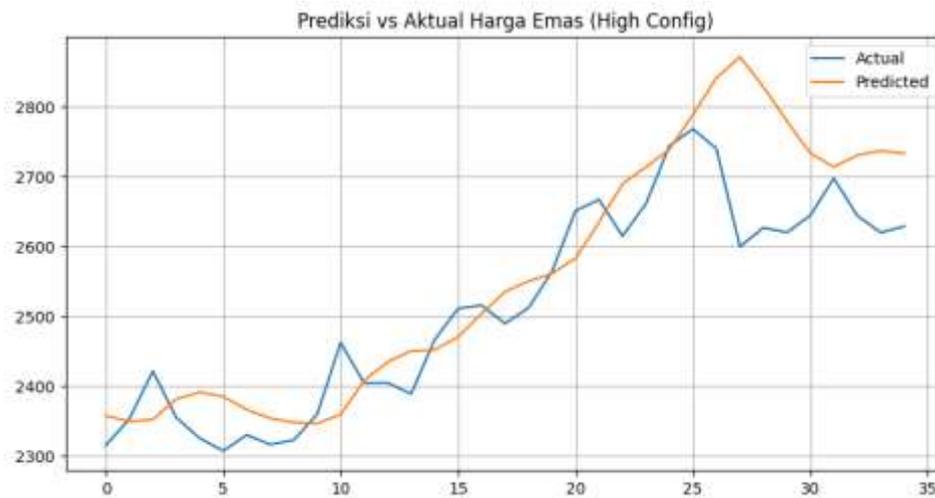
Hasil Evaluasi kinerja model BiLSTM dalam penelitian ini difokuskan pada dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE), yang masing-masing merepresentasikan tingkat kesalahan absolut dan persentase rata-rata dalam prediksi harga emas mingguan. Evaluasi dilakukan terhadap tiga konfigurasi model: konfigurasi awal (baseline), konfigurasi rendah, dan konfigurasi tinggi, sebagaimana telah dijabarkan pada subbab sebelumnya.

Berdasarkan hasil evaluasi, model dengan konfigurasi tinggi menghasilkan nilai RMSE sebesar 83.99, yang merupakan nilai terendah dibanding dua konfigurasi lainnya. Nilai ini mengindikasikan bahwa model tersebut mampu mempelajari pola data lebih baik dan menghasilkan prediksi yang lebih mendekati nilai aktual. Sebaliknya, konfigurasi awal menunjukkan RMSE tertinggi yaitu 108.05, meskipun memiliki nilai MAPE terendah (0.03%), yang menandakan bahwa kesalahan persentasenya secara rata-rata kecil, tetapi varians kesalahannya besar.

Sementara itu, konfigurasi rendah memiliki performa antara keduanya, dengan RMSE 99.46 dan MAPE sebesar 3.24%. Hasil ini memperlihatkan adanya trade-off antara dua metrik evaluasi yang digunakan. Dalam konteks penelitian ini, RMSE dianggap sebagai indikator utama keberhasilan karena berfokus pada akurasi numerik yang absolut. Oleh karena itu, model dengan konfigurasi tinggi ditetapkan sebagai model terbaik, karena menunjukkan peningkatan akurasi yang signifikan dibanding baseline.

4.6.2. Visualisasi Hasil Prediksi

Untuk mengevaluasi kemampuan model dalam memprediksi harga emas, dilakukan visualisasi hasil prediksi terhadap data aktual. Gambar 4.6 menampilkan perbandingan antara nilai aktual dan nilai prediksi harga emas menggunakan model BiLSTM dengan konfigurasi tinggi (High Config).



Gambar 4. 6 Prediksi vs Aktual Harga Emas (*High Config*)

Berdasarkan grafik pada Gambar 4.6, terlihat bahwa model BiLSTM dengan konfigurasi tinggi mampu mengikuti pola tren harga emas mingguan secara cukup akurat, terutama pada periode tren naik. Meskipun terdapat beberapa deviasi antara nilai prediksi dan aktual, terutama pada beberapa titik fluktuasi tajam, secara umum pola prediksi tetap searah dengan tren data sesungguhnya.

Model menunjukkan performa yang stabil dalam merespons kenaikan dan penurunan harga, meskipun pada titik puncak (sekitar minggu ke-26) terdapat sedikit *overestimation*. Hal ini menunjukkan bahwa model cukup responsif namun masih memiliki ruang perbaikan dalam menangani perubahan mendadak (*spike*) harga.

Visualisasi ini memperkuat hasil evaluasi numerik sebelumnya, di mana model dengan konfigurasi tinggi menghasilkan RMSE terendah, sehingga dapat disimpulkan bahwa model ini merupakan konfigurasi terbaik dari percobaan yang telah dilakukan.

4.6. Pembahasan Hasil Penelitian

4.6.1. Interpretasi Hasil Prediksi

Hasil prediksi harga emas mingguan menggunakan model BiLSTM menunjukkan bahwa model mampu mempelajari pola data historis dengan cukup baik. Berdasarkan visualisasi prediksi terhadap data aktual (Gambar 4.17), terlihat bahwa model mengikuti arah tren utama harga emas, terutama pada periode tren naik yang konsisten. Hal ini menunjukkan bahwa arsitektur BiLSTM yang bersifat dua arah (bidirectional) memungkinkan model untuk menangkap konteks temporal masa lalu dan masa depan secara simultan dalam proses pembelajaran.

Dari sisi kuantitatif, model BiLSTM dengan konfigurasi tinggi menghasilkan nilai RMSE sebesar 83.99 dan nilai MAPE sebesar 2.41%. Nilai RMSE yang lebih rendah dibandingkan konfigurasi awal (108.05) dan konfigurasi rendah (99.46) menandakan adanya peningkatan akurasi yang signifikan. Di sisi lain, nilai MAPE yang cukup rendah juga mengindikasikan bahwa kesalahan relatif dalam prediksi terhadap harga aktual masih dalam batas yang dapat diterima.

Namun demikian, model tetap menunjukkan keterbatasan dalam merespons lonjakan ekstrem harga secara tiba-tiba. Beberapa puncak dan lembah harga aktual tidak selalu diikuti secara akurat oleh prediksi model. Hal ini bisa disebabkan oleh faktor eksternal yang tidak tercermin langsung dalam data historis harga, seperti berita geopolitik, kebijakan moneter global, atau perubahan sentimen pasar yang mendadak. Oleh karena itu, meskipun model ini sudah cukup andal untuk prediksi tren, namun sensitivitas terhadap perubahan mendadak masih bisa ditingkatkan pada penelitian lanjutan.

Penelitian serupa oleh Dalimunthe et al. (2024) juga menunjukkan bahwa penggunaan algoritma LSTM untuk prediksi harga emas menghasilkan nilai MAPE yang sangat rendah, yaitu sebesar 0,83%, dan MAE sebesar 19,81. Temuan ini menguatkan bahwa metode berbasis Long Short-Term Memory (LSTM maupun BiLSTM) memang

efektif digunakan untuk peramalan harga komoditas, khususnya ketika dikombinasikan dengan preprocessing data yang tepat seperti normalisasi dan penggunaan sliding window pada data historis. Mereka juga menekankan pentingnya pemilihan parameter model yang optimal untuk mencapai hasil akurasi terbaik (Dalimunthe et al., 2024).

Selain itu, penting untuk dicatat bahwa meskipun model memberikan hasil yang baik secara keseluruhan, masih terdapat ruang untuk perbaikan, misalnya dengan menambahkan fitur makroekonomi sebagai variabel tambahan. Hal ini dapat membantu model dalam mengantisipasi pergerakan harga yang dipengaruhi oleh faktor eksternal di luar pola historis harga emas.

4.6.2. Validasi Hasil dengan Teori

Validasi hasil prediksi dilakukan dengan membandingkan output model BiLSTM terhadap data aktual harga emas mingguan yang diunduh dari *Yahoo Finance*. Proses validasi ini bertujuan untuk mengukur sejauh mana akurasi model dalam merepresentasikan realitas pasar, sekaligus menilai kelayakan model dalam penerapan praktis.

Hasil prediksi model yang telah dinormalisasi dikembalikan ke skala asli menggunakan inverse transform dari *MinMaxScaler*. Nilai evaluasi yang diperoleh adalah RMSE sebesar 83.99 dan MAPE sebesar 2.41%, menunjukkan model memberikan estimasi yang relatif dekat terhadap data aktual.

Temuan ini konsisten dengan beberapa studi terdahulu. Sebagai contoh, Amini dan Kalantari (2024) menyusun model hybrid CNN-BiLSTM khusus untuk memprediksi harga emas harian, yang terbukti unggul dibanding model DNN lainnya dengan pendekatan tuning parameter otomatis menggunakan grid search. Model CNN-BiLSTM ini mampu menangkap pola non-linear dan ekstrem dalam data emas dengan akurasi tinggi.

Visualisasi prediksi (lihat Gambar 4.17) juga memperlihatkan bahwa model mampu mengikuti tren umum dari pergerakan harga, meskipun terdapat deviasi pada

beberapa titik ekstrem. Hal ini menunjukkan model cukup robust terhadap perubahan trend, namun lebih sensitif terhadap fluktuasi mendadak yang tidak tercakup oleh data historis semata.

Hasil validasi ini juga memperlihatkan adanya trade-off antara dua metrik evaluasi. Seperti disampaikan oleh Racine et al. (2021), memilih metrik yang tepat penting dalam forecasting: RMSE efektif untuk mengukur error absolut pada outlier besar, sedangkan MAPE menunjukkan kesalahan relatif yang lebih bisa ditoleransi di skala besar seperti harga emas [arXiv](#).

Secara keseluruhan, model BiLSTM dengan konfigurasi tinggi terbukti layak digunakan sebagai model akhir, dimana performa numeriknya mendukung aplikasinya pada sistem prediksi harga emas berbasis data historis. Hasil ini mempertegas bahwa optimasi parameter memberikan efek positif terhadap akurasi prediksi, sejalan dengan temuan penelitian terdahulu dan teori peramalan harga komoditas berdasarkan time-series.

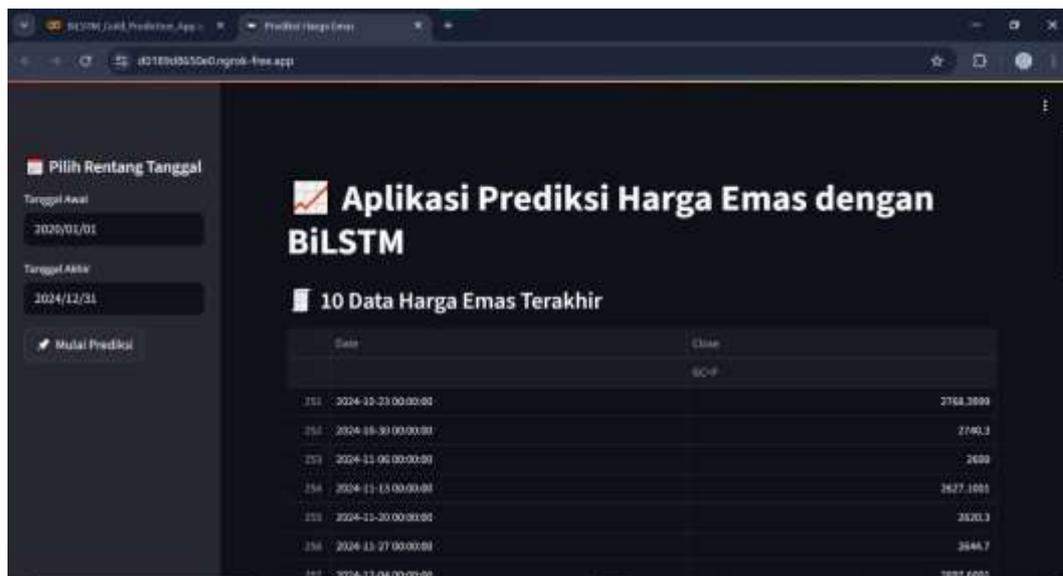
4.7. Implementasi Aplikasi Prediksi Harga Emas

Sebagai bagian dari pengembangan penelitian ini, model prediksi harga emas berbasis *BiLSTM* yang telah dibangun dan diuji kemudian diimplementasikan ke dalam bentuk aplikasi web interaktif. Tujuan utama dari implementasi ini adalah agar hasil prediksi dapat diakses dan dimanfaatkan secara langsung oleh pengguna akhir, tanpa perlu memiliki pengetahuan teknis mendalam mengenai pemrograman atau *machine learning*.

Aplikasi dikembangkan menggunakan Streamlit, sebuah *framework Python open-source* yang memudahkan pembuatan antarmuka web untuk aplikasi berbasis data science. Proses *deployment* dilakukan melalui *Google Colab* dengan integrasi ngrok, sehingga aplikasi dapat diakses secara publik melalui internet tanpa memerlukan *hosting server* konvensional.

4.7.1. Tampilan Antarmuka Utama

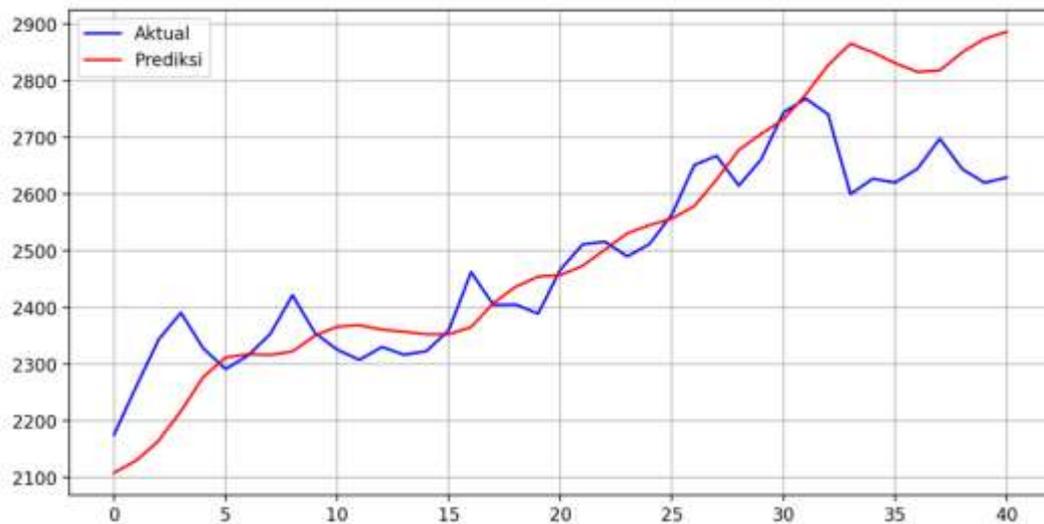
Pada halaman awal aplikasi, pengguna disajikan dengan judul utama serta sidebar untuk memilih rentang tanggal prediksi (tanggal awal dan tanggal akhir). Setelah memilih tanggal, pengguna dapat menekan tombol "🚀 Mulai Prediksi" untuk menjalankan proses. Sebagai verifikasi awal, aplikasi juga menampilkan 10 data harga emas terakhir dari dataset yang telah diambil dari *Yahoo Finance*, seperti yang terlihat pada Gambar 4.7 berikut:



Gambar 4. 7 Tampilan Awal Aplikasi dan Data Harga Emas Terakhir

4.7.2. Visualisasi Grafik Harga dan Prediksi

Setelah proses prediksi dijalankan, aplikasi menampilkan grafik Harga Aktual vs Harga Prediksi dalam bentuk garis berwarna biru (aktual) dan merah (prediksi). Grafik ini membantu pengguna memahami tren dan akurasi model secara visual, seperti ditampilkan pada Gambar 4.8:

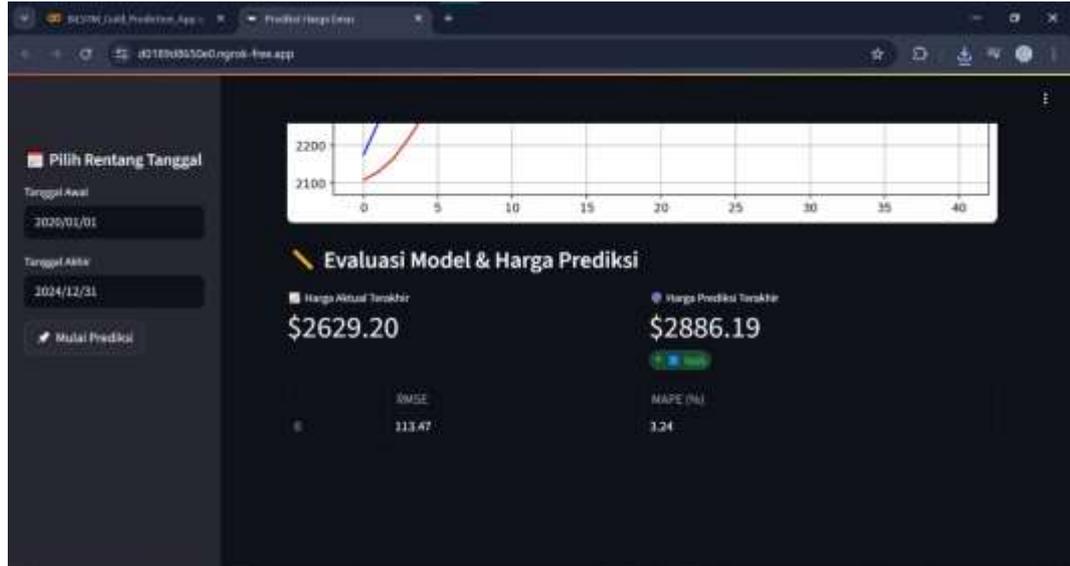


Gambar 4. 8 Visualisasi Grafik Harga Aktual dan Prediksi

4.7.2. Hasil Implementasi Aplikasi

Pengujian aplikasi dilakukan dengan pengambilan data mingguan harga emas dari *Yahoo Finance* selama periode 1 Januari 2020 hingga 31 Desember 2024. Dengan konfigurasi sliding window sepanjang 60 minggu dan data latih sebesar 80%, aplikasi menghasilkan output sebagai berikut:

1. Harga aktual terakhir: \$2629.20 USD (per 25 Desember 2024)
2. Prediksi harga minggu berikutnya: \$2886.19 USD (per 1 Januari 2025)
3. Arah tren: Naik
4. Root Mean Squared Error (RMSE): 113.47
5. Mean Absolute Percentage Error (MAPE): 3.24%



Gambar 4. 9 Tampilan Output Aplikasi setelah Prediksi Dijalankan

Hasil ini menunjukkan bahwa model BiLSTM masih menunjukkan performa baik dalam skenario aplikasi praktis dengan akurasi yang tinggi dan tingkat kesalahan prediksi di bawah 5%.

4.7.4. Analisis Perbedaan Hasil

Sebelumnya, model telah diuji secara lokal menggunakan data yang sama. Dibandingkan dengan hasil dari aplikasi yang dijalankan di Google Colab, nilai RMSE dan MAPE tetap berada dalam kisaran yang serupa, meskipun ada sedikit variasi. Faktor-faktor yang memengaruhi perbedaan ini antara lain:

1. Perbedaan lingkungan eksekusi, antara local host dan Google Colab.
2. Berbedanya versi pustaka (TensorFlow, NumPy, Keras) yang digunakan pada masing-masing platform.
3. Implementasi *EarlyStopping* yang menyebabkan pelatihan model berhenti lebih awal dari jumlah epoch maksimum.
4. Fluktuasi data terbaru dari *Yahoo Finance* yang dapat berubah sewaktu-waktu.

Namun secara keseluruhan, performa model dapat dikatakan konsisten dan andal pada kedua lingkungan tersebut.

BAB V

PENUTUP

5.1. Kesimpulan

Penelitian ini bertujuan untuk mengoptimalkan akurasi model *Bidirectional Long Short-Term Memory* (BiLSTM) dalam meramalkan harga emas mingguan berdasarkan data historis dari *Yahoo Finance*. Berdasarkan hasil implementasi, eksperimen, dan evaluasi yang telah dilakukan, maka dapat disimpulkan beberapa hal sebagai berikut:

1. Model BiLSTM berhasil diterapkan untuk melakukan peramalan harga emas mingguan dengan menggunakan data historis dari tahun 2020 hingga 2024. Proses preprocessing, pelatihan model, dan evaluasi telah berjalan dengan baik dan terstruktur.
2. Konfigurasi awal model BiLSTM (units=32, batch_size=8, epochs=50, dropout=0.2) menghasilkan nilai evaluasi RMSE sebesar 108.05 dan MAPE sebesar 0.03%, yang menjadi baseline untuk eksperimen optimasi selanjutnya.
3. Optimasi model BiLSTM dilakukan dengan dua konfigurasi berbeda, yaitu konfigurasi rendah dan konfigurasi tinggi.
 - a. Konfigurasi rendah (units=16, batch_size=4, epochs=100, dropout=0.1) menghasilkan RMSE 99.46 dan MAPE 3.24%.
 - b. Konfigurasi tinggi (units=64, batch_size=8, epochs=200, dropout=0.2) menghasilkan RMSE 83.99 dan MAPE 2.41%, yang merupakan performa terbaik di antara ketiga konfigurasi.
4. Model BiLSTM dengan konfigurasi tinggi dipilih sebagai model terbaik, karena mampu menurunkan RMSE sebesar 22% dibandingkan baseline. Hal ini menunjukkan bahwa peningkatan kapasitas model melalui tuning parameter memberikan dampak positif terhadap akurasi prediksi.

5. Visualisasi hasil prediksi terhadap data aktual memperkuat evaluasi numerik, di mana pola prediksi model cenderung mengikuti tren pergerakan harga emas mingguan secara konsisten, meskipun terdapat deviasi kecil pada titik ekstrem.

Dengan demikian, penelitian ini menunjukkan bahwa optimasi parameter model BiLSTM secara signifikan meningkatkan akurasi peramalan harga emas, dan model tersebut layak digunakan dalam sistem prediksi harga komoditas berbasis time-series.

5.2. Saran

Berdasarkan temuan dan keterbatasan penelitian ini, maka disampaikan beberapa saran untuk pengembangan lebih lanjut:

1. Penelitian ini hanya menggunakan harga penutupan mingguan (Close) sebagai input. Penelitian selanjutnya disarankan untuk mempertimbangkan fitur tambahan seperti harga pembukaan (Open), volume perdagangan, atau indikator teknikal agar model dapat belajar dari informasi yang lebih kaya.
2. Selain Grid Search, pendekatan optimasi seperti Random Search, Bayesian Optimization, atau algoritma genetika dapat dijadikan alternatif untuk mencari kombinasi parameter yang lebih efisien dan optimal.
3. Penelitian ini menggunakan data mingguan. Jika ketersediaan data mencukupi, penggunaan data harian atau bahkan intraday dapat membantu menangkap pola fluktuasi harga emas yang lebih halus dan detail.
4. Kombinasi model BiLSTM dengan model lain seperti Attention Mechanism atau CNN-BiLSTM dapat dieksplorasi untuk meningkatkan ketepatan prediksi serta kemampuan dalam menangkap dependensi jangka panjang dan jangka pendek secara simultan.
5. Model BiLSTM yang telah dikembangkan dan dioptimalkan ini dapat pula diterapkan pada prediksi harga komoditas lain seperti perak, minyak mentah, atau kripto untuk menguji generalisasi dan performanya di berbagai domain.

DAFTAR PUSTAKA

- Anggraini, N. S., & Cahyono, E. (2025) Pengaruh Sharia Financial Literacy dan Investment Risk Terhadap Keputusan Investasi Emas. *Jurnal Maneksi*, 14(1).
<https://ejournal-polnam.ac.id/index.php/JurnalManeksi/article/view/2884>
- Amal, M. A. ., & Musthofa, M. W. . (2023). The Impact of the Dow Jones Islamic Market, Interest Rate, Rupiah Exchange Rate, and Inflation on the Indonesian Sharia Stock Index during 2018-2022 Period. *Jurnal Ekonomi Syariah Teori Dan Terapan*, 10(2), 188–202. <https://doi.org/10.20473/vol10iss20232pp188-202>
- Amini, A., & Kalantari, R. (2024). Gold price prediction by a CNN-BiLSTM model along with automatic parameter tuning. *PLOS ONE*, 19(3), 1–17.
<https://doi.org/10.1371/journal.pone.0298426>
- Amri, I., Astuti, S., Sulistiya, I., Suherdi, A., & Haris, M. (2024). Peramalan Harga Emas Antam Menggunakan Metode Generalized Autoregressive Conditional Heterokedasticity (GARCH). *UJMC (Unisda Journal of Mathematics and Computer Science)*, 10(1), 26 - 35.
<https://doi.org/https://doi.org/10.52166/ujmc.v10i1.4679>
- Arif, E., Suherman, I., & Widodo, A. P. (2025). *Revolusi prediksi saham: Pemanfaatan machine learning dan analisis sentimen dalam dunia keuangan*. CV. Green Publisher Indonesia.
- Aryanto, F. (2024). *Peramalan Indeks Harga Konsumen di Indonesia Menggunakan Average Based Fuzzy Time Series*. (Skripsi Sarjana, Universitas Jambi).
- Chyan, P., Arni, S., & Thayf, M. S. S. (2024). Pengantar machine learning: Konsep dasar dan aplikasinya. *PT. Mifandi Mandiri Digital*.
- Dalimunthe, R. A., Tjut Adek, R., & Agusniar, C. (2024). Prediksi Harga Emas Menggunakan Algoritma Long Short-Term Memory (LSTM). *SENASTIKA - Universitas Malikussaleh*, 1–10.

- Diksa, I. G. B. N. . (2022). Forecasting the Existence of Chocolate with Variation and Seasonal Calendar Effects Using the Classic Time Series Approach. *Jurnal Matematika, Statistika Dan Komputasi*, 18(2), 237-250.
<https://doi.org/10.20956/j.v18i2.18542>
- Feriyandri, P. D., & Maimunah, E. (2023). Pengaruh Angkatan Kerja dan Investasi terhadap Produk Domestik Regional Bruto di Provinsi Lampung, 6(1), 8122-8133.
<https://doi.org/10.31004/joe.v6i1.4230>
- Fungki Wahyu, & Billy Hendrik. (2023). Perbandingan Algoritma Time Series Dan Fuzzy Inference System Dalam Analisis Data Deret Waktu. *Jurnal Penelitian Teknologi Informasi Dan Sains*, 1(3), 16–24. <https://doi.org/10.54066/jptis.v1i3.711>
- Harahap, A. I., & Arini, L. (2022). Peningkatan Laba Investasi Emas Dengan Cara Membeli Emas Tidak Bersertifikat Guna Menghadapi Masa Resesi. *Jurnal Ekonomi & Ekonomi Syariah*, 5(2).
https://www.researchgate.net/publication/361091127_Peningkatan_Laba_investasi_Emas_Dengan_Cara_Membeli_Emas_Tidak_Bersertifikat_Guna_Menghadapi_Masa_Resesi
- Hardiyanti, W., Wulandari, S., & Santoso, I. H. (2021). *Logam Mulia Emas: Alat Investasi Utama Bagi Generasi Sandwich?* *Jurnal Ekonomi Manajemen*, 7(2).
<https://doi.org/10.37058/jem.v7i2.3043>
- Heradhyaksa, B. (2022). *Implementasi Investasi Emas Syariah Perspektif Hukum Islam*. *Jurnal Hukum Ekonomi Islam JHEI*. 6(1):35-51
<https://www.researchgate.net/publication/362387927>
- Kushariyadi, K., Herdiana, Y., & Asy'ari, F. H. (2024). *Artificial intelligence: Dinamika perkembangan AI beserta penerapannya*. PT. Sonpedia Publishing Indonesia.
- Lazuardy, M. R. (2023). Analisis investasi bitcoin, emas, indeks saham syariah Indonesia, dan kurs rupiah terhadap dollar menggunakan ARIMA dan machine learning. (Skripsi Sarjana, Universitas Islam Negeri Syarif Hidayatullah Jakarta).

- Luthfi, A. H., Khakiki, A., Wijayanti, Y. B., Sari, C. F., & Putri, A. N. (2021). Investasi Emas Secara Kredit di Pegadaian Syariah Dalam Perspektif Hukum Islam. *Az-Zarqa': Jurnal Hukum Bisnis Islam*, 13(1).
<https://doi.org/10.14421/azzarqa.v13i1.2429>
- Madhika, Y. R., Kusriani, K., & Hidayat, T. (2023). *Gold Price Prediction Using the ARIMA and LSTM Models*. *Sinkron*, 8(3), 1255–1264.
<https://doi.org/10.33395/sinkron.v8i3.12461>
- Nawatmi, S., Santosa, A. B., & Nusantara, A. (2024). THE ROLE OF GOLD AS SAVE HAVEN OR DIVERSIFIER INVESTMENT IN INDONESIA. *International Journal of Economics, Business and Accounting Research (IJEBAR)*, 8(2).
<https://doi.org/10.29040/ijebar.v8i2.13955>
- Ng, T. (2023). *Gold Price Forecasting with ARIMA*. Medium.
<https://medium.com/@timmyng83/gold-price-forecasting-with-arima-0d06aa99edd1>
- Padliansyah, R., & Juliana, A., Hasiara, L. O. (2020). Hubungan interaktif antara harga logam mulia dan Jakarta Islamic Stock Index. *Moneter: Jurnal Akuntansi dan Keuangan*, 7(1). <http://dx.doi.org/10.31294/moneter.v7i1.7268>
- Pambudi, S. A., & Mubin, M. K. (2020). Analysis The Effect of Electronic Money Use on Velocity of Money: Evidence from Indonesia. *Jurnal Ilmu Ekonomi Terapan*, 5(1), 37–52. <https://doi.org/10.20473/jiet.v5i1.19626>
- Pangestu, P. S. A. S., Rochman, A., & Zuhdi, A. (2023). *The Comparison of Gold Price Prediction Techniques Using Long Short Term Memory (LSTM) And Fuzzy Time Series (FTS) Method*. *Intelmatix*, 3(2), 57–62.
<https://doi.org/10.25105/itm.v3i2.17325>
- Putro, S. (2023). *Prediksi Harga Emas Menggunakan Algoritma Long Short Term Memory (LSTM) dan Linear Regression (LR)*. *e-Dik InformaTika*, 9(2), 45–52.
<https://doi.org/10.22202/ei.2023.v9i2.6990>

- Racine Ly, F., Traore, F., & Dia, K. (2021). Forecasting commodity prices using Long Short-Term Memory neural networks. *arXiv preprint arXiv:2101.03087*.
<https://arxiv.org/abs/2101.03087>
- Ruhat, D., Andiani, D., & Kamilah, W. N. (2020). Forecasting Data Runtun Waktu Musiman Menggunakan Metode Singular Spectrum Analysis (SSA). *Teorema: Teori dan Riset Matematika*, 5(1), 47–60.
<http://dx.doi.org/10.25157/teorema.v5i1.3286>
- Saputro, A. B. (2023). Penerapan machine learning untuk mengidentifikasi faktor-faktor yang mempengaruhi kemampuan komunikasi matematis pada materi program linear. (Skripsi Sarjana, Universitas Islam Negeri Syarif Hidayatullah Jakarta).
- Spall, J. (2009). *Investing in Gold: The Essential Safe Investment for Every Portfolio*. McGraw-Hill Education.
- Sawitri, D. (2025). Peran deep learning dan big data dalam mendeteksi masalah keuangan. *Djtechno: Jurnal Teknologi Informasi*, 6(1).
https://www.researchgate.net/publication/391347984_PERAN_DEEP_LEARNING_DAN_BIG_DATA_DALAM_MENDEKTEKSI_MASALAH_KEUANGAN
- Sunaryo, D., Hamdan, A., Anggriani, C., Winata, D., & Denta, A. (2024). Prediksi tren risiko keuangan perusahaan berdasarkan model machine learning (ARIMA): Tinjauan literatur. *Jurnal Akuntansi Manajemen*, 3(2). Retrieved from
<https://doi.org/10.30656/jakmen.v3i2.9704>
- Sutrisno, H., Khamidah, K., Suprpto, A., & Abdussamad, N. (2025). *Statistika ekonomi dan bisnis*. Yayasan Cendekia Mulia Mandiri.
- Suryaputri, R. V., Adiyono, M., Efan, E., & Kumala, H. (2021). *Analisis Alternatif Pilihan Investasi Pada Era Digitalisasi*. *Jurnal Akuntansi dan Keuangan Digital*. 8(2).
<https://doi.org/10.25105/jat.v8i2.9678>

- Widiputra, H., Adele Mailangkay, & Elliana Gautama. (2021). Prediksi Indeks BEI dengan Ensemble Convolutional Neural Network dan Long Short-Term Memory. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(3), 456 - 465.
<https://doi.org/10.29207/resti.v5i3.3111>
- Yennimar, & Gabriella. (2025). Prediksi Harga Emas Berdasarkan Finansial Global Dengan Menggunakan Algoritma Gradien Boosting Regression. *HASIL SEMINAR NASIONAL UNPRI*, 2(1). Retrieved from <https://jurnal.unprimdn.ac.id/index.php/hasenf/article/view/6190>
- Yudistira, N., Alfiansih, L. M. D., Andriyani, N. I., & Essayem, W. (2023). *Prediksi deret waktu menggunakan deep learning*. Tim UB Press.
- Yurtsever, M. (2021). *Gold Price Forecasting Using LSTM, Bi-LSTM and GRU*. *European Journal of Science and Technology*, 31, 341–347.
<https://doi.org/10.31590/ejosat.959405>

LAMPIRAN

Lampiran 1 SK-2 Penetapan Dosen Pembimbing



MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PUSAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 39/SK/BAN-PT/Akred/PT/09/2019
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20228 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
 http://www.umsu.ac.id | info@umsu.ac.id | @umsu | umsu | umsu | umsu | umsu

PENETAPAN DOSEN PEMBIMBING
PROPOSAL/SKRIPSI MAHASISWA
NOMOR : 252/IL3-AU/UMSU-09/F/2025

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, berdasarkan Persetujuan permohonan judul penelitian Proposal / Skripsi dari Ketua / Sekretaris.

Program Studi : Teknologi Informasi
Pada tanggal : 04 Februari 2025

Dengan ini menetapkan Dosen Pembimbing Proposal / Skripsi Mahasiswa.

Nama : Anggi Muammar Hanafi
NPM : 2109020032
Semester : VII (Tujuh)
Program studi : Teknologi Informasi
Judul Proposal / Skripsi : Implementasi Machine Learning dengan Model Naive Bayes untuk Klasifikasi Prediksi Penerimaan Siswa Baru di MTs Riyadhussolihin

Dosen Pembimbing : Dr. Al-Khowarizmi, M.kom

Dengan demikian di izinkan menulis Proposal / Skripsi dengan ketentuan

1. Penulisan berpedoman pada buku panduan penulisan Proposal / Skripsi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU
2. Pelaksanaan Sidang Skripsi harus berjarak 3 bulan setelah dikeluarkannya Surat Penetapan Dosen Pembimbing Skripsi.
3. **Proyek Proposal / Skripsi dinyatakan " BATAL " bila tidak selesai sebelum Masa Kadaluarsa tanggal : 04 Februari 2026**
4. Revisi judul.....

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Ditetapkan di : Medan
 Pada Tanggal : 05 Sya'ban 1446 H
 04 Februari 2025M





Dekan
Dr. Al-Khowarizmi, M.Kom.
 NIDN : 0127099201

Co. File





Lampiran 2 SK Persetujuan Pergantian Topik/Judul Penelitian



MAJLIS PENDIDIKAN TINGGI PENELITIAN & PENGABDIAN KEPADA MASYARAKAT
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No: 89/SK/ BAN-PT/Akred/PT/11/2019
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
 Email: info@umsu.ac.id *** info@umsu.ac.id |umsumedan |umsumedan |umsumedan |umsumedan

PERSETUJUAN TOPIK/JUDUL PENELITIAN

Nomor Agenda	: 252/II/3-AU/UMSU-09/F/2025
Nama	: Anggi Muammar Hanafi
NPM	: 2109020032
Tanggal Persetujuan	: 06 Mei 2025
Topik Yang Disetujui Program Studi	: Machine Learning
Nama Dosen Pembimbing	: Dr. Al-Khowarizmi, M.Kom
Judul Yang Disetujui Dosen Pembimbing	: Optimasi Akurasi BiLSTM Dalam Peramalan Harga Emas

Medan, 19 Mei 2025

Disahkan oleh
 Ketua Program Studi
 Teknologi Informasi

Fatma Sari Hotagalung, S.Kom., M.Kom

Persetujuan
 Dosen Pembimbing

Dr. Al-Khowarizmi, M.Kom.



Lampiran 3 Berita Acara Bimbingan Skripsi



MAJLIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PIMPINAN PESAT MUHAMMADIYAH

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UMSU Terakreditasi A Berdasarkan Keputusan Badan Akreditasi Nasional Perguruan Tinggi No. 89/SK/BAN-PT/Akred/PT/III/2019
 Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003

Website: www.umsumedan.ac.id Email: info@umsumedan.ac.id Instagram: [umsumedan](https://www.instagram.com/umsumedan) Facebook: [umsumedan](https://www.facebook.com/umsumedan) Twitter: [umsumedan](https://twitter.com/umsumedan) YouTube: [umsumedan](https://www.youtube.com/umsumedan)

Berita Acara Pembimbingan Skripsi

Nama Mahasiswa : Anggi Muammar Hanafi
 Program Studi : Teknologi Informasi
 NPM : 2109020032
 Konsentrasi : Machine Learning
 Nama Dosen Pembimbing : Dr. Al-Khowarizmi, S.Kom., M.Kom.
 Judul Penelitian : Optimasi Akurasi *Bilstm* Dalam Peramalan Harga Emas

Item	Hasil Evaluasi	Tanggal	Paraf Dosen
	Konsultasi Pergeseran Judul dengan judul awal 'Implementasi Machine Learning Konsumsi Produk esisnabari' dan judul baru 'Optimasi Akurasi Model BilSTM dalam Peramalan Harga Emas'	06/05/2025	<i>AK</i>
	Penerapan Judul baru sebagai final dan klikan; ya ini 'Optimasi Akurasi Model BilSTM dalam Peramalan Harga Emas'	08/05/2025	<i>AK</i>
	Revisi Final Proposal Skripsi Serta ACC (di ranggi) untuk mengikuti Seminar Proposal	10/05/2025	<i>AK</i>
	Revisi skripsi setelah Sempro CS (di ranggi) untuk mengikuti Seminar (Sempro)	10/06/2025	<i>AK</i>
	Revisi Skripsi kedua setelah Sempro (di ranggi) untuk mengikuti Seminar	21/07/2025	<i>AK</i>
	Bimbingan Online melalui Zoom dan WA, Revisi Kelemb. Menambah foto penelitian dan penambahan Artikel U1 dan Pengujian Berirminon	01/08/2025	<i>AK</i>
	Revisi Hasil Implementasi berbasis WEB dengan menggunakan testmap PE dan BE	07/08/2025	<i>AK</i>
	Revisi Final Skripsi Serta ACC (di ranggi) untuk mengikuti sidang Skripsi	07/08/2025	<i>AK</i>

Diketahui oleh :

Ketua Program Studi
Teknologi Informasi

Fatma Sari Hudaalung S.Kom., M.Kom.

Medan, 09 Agustus 2025

Disetujui oleh :

Dosen Pembimbing

Dr. Al-Khowarizmi, M.Kom.



Lampiran 4 Turnitin



10	jurnal.stie-aas.ac.id Internet Source	<1 %
11	dspace.uui.ac.id Internet Source	<1 %
12	medium.com Internet Source	<1 %
13	Submitted to UM Surabaya Student Paper	<1 %
14	repo.undiksha.ac.id Internet Source	<1 %
15	text-id.123dok.com Internet Source	<1 %
16	e-jurnal.unisda.ac.id Internet Source	<1 %
17	repository.usd.ac.id Internet Source	<1 %
18	repository.ar-raniry.ac.id Internet Source	<1 %
19	wnj.westscience-press.com Internet Source	<1 %
20	jurnal.lldikti4.or.id Internet Source	<1 %
21	Submitted to Ajou University Graduate School Student Paper	<1 %
22	Submitted to University of Glasgow Student Paper	<1 %
23	repository.ub.ac.id Internet Source	<1 %

www.ojs.upj.ac.id

24	Internet Source	<1 %
25	ejournal.gunadarma.ac.id Internet Source	<1 %
26	ejournal.undip.ac.id Internet Source	<1 %
27	jurnal.limitlabel.com Internet Source	<1 %
28	etheses.uin-malang.ac.id Internet Source	<1 %
29	stiealwashliyahsibolga.ac.id Internet Source	<1 %
30	www.researchsquare.com Internet Source	<1 %
31	ejurnal.ung.ac.id Internet Source	<1 %
32	Submitted to University of Portsmouth Student Paper	<1 %
33	repository.uin-suska.ac.id Internet Source	<1 %
34	Indra Ikhsani, Martanto ., Arif Rinaldi Dikananda, Mulyawan .. "PREDIKSI HARGA EMAS MENGGUNAKAN ALGORITMA SEASONAL AUTO REGRESSIVE INTEGRATED MOVING AVERAGE", Jurnal Informasi dan Komputer, 2025 Publication	<1 %
35	Submitted to Institut Bisnis dan Teknologi Indonesia (INSTIKI) Student Paper	<1 %
Submitted to UIN Ar-Raniry		

36	Student Paper	<1 %
37	jonedu.org Internet Source	<1 %
38	Submitted to Universitas Pancasila Student Paper	<1 %
39	repository.dinamika.ac.id Internet Source	<1 %
40	ejournal.unibba.ac.id Internet Source	<1 %
41	ejournal.bsi.ac.id Internet Source	<1 %
42	eprints.amikompurwokerto.ac.id Internet Source	<1 %
43	newcomerscuerna.org Internet Source	<1 %
44	Submitted to Universitas Muhammadiyah Sukabumi Student Paper	<1 %
45	eprints.walisongo.ac.id Internet Source	<1 %
46	Submitted to Universitas Sanata Dharma Student Paper	<1 %
47	journal.institercom-edu.org Internet Source	<1 %
48	www.ijesty.org Internet Source	<1 %
49	Submitted to Fakultas Ekonomi Universitas Indonesia Student Paper	<1 %

50	Submitted to Universitas Muslim Indonesia Student Paper	<1%
51	etd.repository.ugm.ac.id Internet Source	<1%
52	jurnal.unived.ac.id Internet Source	<1%
53	repository.its.ac.id Internet Source	<1%
54	skemman.is Internet Source	<1%
55	123dok.com Internet Source	<1%
56	Submitted to Universitas PGRI Adi Buana Surabaya Student Paper	<1%
57	dergipark.org.tr Internet Source	<1%
58	uwspace.uwaterloo.ca Internet Source	<1%
59	Angellika Kristy Menteng, Anief Fauzan Rozi. "Prediksi hasil panen padi berdasarkan data curah hujan, suhu, dan kelembapan dengan metode ARIMA", Jurnal Pendidikan Informatika dan Sains, 2025 Publication	<1%
60	Harditya Prayoga, De Rosal Ignatus Moses Setiadi, Hendy Kurniawan. "Application of Machine Learning and Deep Learning to Predict Financial Product Subscriptions Based on Customer Features", INOVTEK Polbeng - Seri Informatika, 2025	<1%

Publication		
61	Indra Wijaya, Herlawati Herlawati, Rafika Sari. "Prediksi Curah Hujan Di Kabupaten Bogor Menggunakan Long Short-Term Memory Dan Gemma 2", Jurnal Komtika (Komputasi dan Informatika), 2025 Publication	<1%
62	ejournal.unisnu.ac.id Internet Source	<1%
63	hdl.handle.net Internet Source	<1%
64	journal.mwsfoundation.or.id Internet Source	<1%
65	reposister.almaata.ac.id Internet Source	<1%
66	FACHRI ALHADI RAMADHAN ALDI, Novi Dian Nathasia. "Prediksi Harga Dan Kinerja Aset Bitcoin Menggunakan Algoritma Long Short-Term Memory", JURNAL FASILKOM, 2025 Publication	<1%
67	Submitted to Institut Teknologi Sumatera Student Paper	<1%
68	Submitted to Kaplan Professional Student Paper	<1%
69	Rafi Rahmadani, Abdul Rahim, Rudiman Rudiman. "ANALISIS SENTIMEN ULASAN "OJOL THE GAME" DI GOOGLE PLAY STORE MENGGUNAKAN ALGORITMA NAIVE BAYES DAN MODEL EKSTRAKSI FITUR TF-IDF UNTUK MENINGKATKAN KUALITAS GAME", Jurnal Informatika dan Teknik Elektro Terapan, 2024 Publication	<1%

70	Submitted to University College London Student Paper	<1%
71	jurnal.itg.ac.id Internet Source	<1%
72	repository.unipasby.ac.id Internet Source	<1%
73	Argi Nur Faturrohman, Sayekti Harits Suryawan, Abdul Rahim. "Pengembangan Model Klasifikasi Kendaraan Keluar Masuk Area Parkir Dengan Algoritma YOLOv8", Teknika, 2024 Publication	<1%
74	jptam.org Internet Source	<1%
75	www.researchgate.net Internet Source	<1%
76	Syamsul Syahab Mangun, Kusrini Kusrini. "Prediksi Kebakaran Hutan Ibu Kota Nusantara Menggunakan Produk MODIS dengan Algoritma Regresi Linear, Gradient Boosting dan Decision Tree", Jambura Journal of Informatics, 2025 Publication	<1%
77	Submitted to Universitas Islam Negeri Raden Fatah Student Paper	<1%
78	Submitted to Universitas Muria Kudus Student Paper	<1%
79	Submitted to Universitas Pelita Harapan Student Paper	<1%
80	library.universitaspertamina.ac.id Internet Source	

		<1%
81	media.neliti.com Internet Source	<1%
82	plj.ac.id Internet Source	<1%
83	repositori.usu.ac.id Internet Source	<1%
84	www.ijisrt.com Internet Source	<1%
85	Submitted to Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Timur II Student Paper	<1%
86	Submitted to LL Dikti IX Turnitin Consortium Student Paper	<1%
87	Veri Arinal, Melli Puspita. "Peningkatan Akurasi Nilai Harga Saham Menggunakan Metode Long Short-Term Memory (LSTM) pada PT Unilever Tbk", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2025 Publication	<1%
88	dqlab.id Internet Source	<1%
89	jurnal.iaii.or.id Internet Source	<1%
90	repository.bakrie.ac.id Internet Source	<1%
91	Deni Sunaryo, Hamdan, Alfina Anggriani, Cecilia Winata, Dian Denta Alumi. "Prediksi Tren Risiko Keuangan Perusahaan	<1%

Berdasarkan Model Machine Learning
(ARIMA) : Tinjauan Literatur", Jurnal Akuntansi
Manajemen (JAKMEN), 2024

Publication

- | | | |
|---------------|---|------|
| 92 | Didih Rizki Chandranegara, Raffi Ainul Afif, Christian Sri Kusuma Aditya, Wildan Suharso, Hardianto Wibowo. "Prediksi Harga Saham Jakarta Islamic Index Menggunakan Metode Long Short-Term Memory", Jurnal Edukasi dan Penelitian Informatika (JEPIN), 2023 | <1 % |
| Publication | | |
| 93 | Kohlbach, Franz Albrecht. "New Haven: an Empirical Qualification of Bitcoin Among Flight-To-Safety Assets in the Face of Covid-19 Pandemic", Universidade NOVA de Lisboa (Portugal), 2022 | <1 % |
| Publication | | |
| 94 | Muhammad Miftakhudin, Aang Alim Murtopo, Zaenul Arif. "Integrasi Artificial Neural Network dan Algoritma Genetika untuk Prediksi Bencana Banjir Pesisir Kota Tegal", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 | <1 % |
| Publication | | |
| 95 | Submitted to Sultan Agung Islamic University | <1 % |
| Student Paper | | |
| 96 | Submitted to Universitas Dian Nuswantoro | <1 % |
| Student Paper | | |
| 97 | Submitted to Universitas Jember | <1 % |
| Student Paper | | |
| 98 | Ambar Ramadhani Putri, Nugroho Adhi Santoso, Bayu Aji Santoso. "Implementasi Algoritma Regresi Linier dan ARIMA untuk | <1 % |

Prediksi Harga Emas", RIGGS: Journal of
Artificial Intelligence and Digital Business,
2025

Publication

99	Submitted to Universitas Maritim Raja Ali Haji Student Paper	<1%
100	Submitted to Asia Pacific University College of Technology and Innovation (UCTI) Student Paper	<1%
101	Diah Larasati, Haryanto Haryanto. "Tinjauan Literatur tentang Mekanisme Resistance Training dalam Pengendalian Gula Darah pada Diabetes Mellitus Tipe 2", JURNAL KEPERAWATAN SUAKA INSAN (JKSI), 2025 Publication	<1%
102	Submitted to UIN Sultan Syarif Kasim Riau Student Paper	<1%
103	baharagussetiawan.wordpress.com Internet Source	<1%
104	ijmrset.com Internet Source	<1%
105	tnwtl1s4pbf.arabbusinessreview.com Internet Source	<1%
106	Submitted to Curtin University of Technology Student Paper	<1%
107	Submitted to Surabaya University Student Paper	<1%
108	Submitted to Universitas Bengkulu Student Paper	<1%
109	Submitted to Universitas Budi Luhur Student Paper	<1%

110	bajangjournal.com Internet Source	<1%
111	books.google.com Internet Source	<1%
112	ejournal.uin-suska.ac.id Internet Source	<1%
113	kc.umn.ac.id Internet Source	<1%
114	nikolahuang.github.io Internet Source	<1%
115	picturedujour.com Internet Source	<1%
116	pt.scribd.com Internet Source	<1%
117	repo.darmajaya.ac.id Internet Source	<1%
118	Rima Liana Gema, Rini Sovia, Hasri Awal. "APLIKASI MOBILE E-COMMERCE UNTUK PEMBELAJARAN DENGAN FITUR PEMBAYARAN ONLINE AMAN", Jurnal Review Pendidikan dan Pengajaran, 2025 Publication	<1%
119	digilibadmin.unismuh.ac.id Internet Source	<1%
120	eprints.universitaspotrabangsa.ac.id Internet Source	<1%
121	madison-proceedings.com Internet Source	<1%
122	repository.unpad.ac.id Internet Source	<1%

123	repository.unsri.ac.id Internet Source	<1 %
124	securityphresh.com Internet Source	<1 %
125	www.clickforshop.it Internet Source	<1 %
126	www.gilanx.my.id Internet Source	<1 %
127	www.newsmenit.com Internet Source	<1 %
128	www.scribd.com Internet Source	<1 %
129	Luhur Pambudi, Sefrika Sefrika. "Klasifikasi Dampak dan Kondisi Pasien Hepatitis Menggunakan Metode Decision Tree", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
130	M Rizki, Dadang Priyanto, Galih Hendro Martono, Neny Sulistianingsih, Moch Syahrir. "Perbandingan Algoritma Sarima dan Prophet Untuk Peramalan Trend Penjualan Voucher Game Online", Jurnal Minfo Polgan, 2025 Publication	<1 %
131	Prabowo Budi Utomo, Muhammad Faruqziddan, Ewanda Herdika Septa Aulia, Salsabilla Dini Azzahra. "Perbandingan Skenario Balancing Oversampling dan Undersampling dalam Klasifikasi Resiko Kambuh Kanker Tiroid menggunakan Algoritma SVM Linear", JAMI: Jurnal Ahli Muda Indonesia, 2024	<1 %

Publication		
132	Submitted to University of Wales, Bangor Student Paper	<1%
133	conquestclubs.org Internet Source	<1%
134	datascience.oneoffcoder.com Internet Source	<1%
135	ejournal.penerbitjurnal.com Internet Source	<1%
136	eprints.undip.ac.id Internet Source	<1%
137	goodstats.id Internet Source	<1%
138	id.123dok.com Internet Source	<1%
139	lib.unnes.ac.id Internet Source	<1%
140	repository.unpar.ac.id Internet Source	<1%
141	www.repository.uinjkt.ac.id Internet Source	<1%
142	Anggi Pradita, Rasiban. "Implementasi Data Mining dengan Metode Regresi Linear untuk Prediksi Hasil Penjualan di PT Awitama Cyndo Wahana", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2024 Publication	<1%
143	Fernando Candra Yulianto, Noor Latifah. "Peramalan Penjualan Laptop Menggunakan Metode Long Short Term Memory (LSTM)", JURNAL FASILKOM, 2024	<1%

Publication		
144	Submitted to Forum Komunikasi Perpustakaan Perguruan Tinggi Kristen Indonesia (FKPPTKI) Student Paper	<1 %
145	Ines Heidiani Ikasari, Perani Rosyani, Resti Amalia. "Klasifikasi Jenis Buah Menggunakan Metode CNN", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1 %
146	Muhammad Fikri Eina, Yulison Herry Chrisnanto, Melina Melina. "Klasifikasi Telemarketing Menggunakan Naïve Bayes Classification Dan Wrapper Sequential Feature Selection", INTECOMS: Journal of Information Technology and Computer Science, 2024 Publication	<1 %
147	Sudrajat, Amin. "Implementasi Jaringan Syaraf Tiruan Sebagai Sistem Pendukung Keputusan Untuk Menentukan Kesehatan Suhu Tubuh Bayi Pada Inkubator", Universitas Islam Sultan Agung (Indonesia), 2023 Publication	<1 %
148	Submitted to Universitas Sumatera Utara Student Paper	<1 %
149	agenbolaonline.link Internet Source	<1 %
150	github.com Internet Source	<1 %
151	journal.jisti.unipol.ac.id Internet Source	<1 %

152	journal.sinov.id Internet Source	<1 %
153	journal2.um.ac.id Internet Source	<1 %
154	jurnal.itscience.org Internet Source	<1 %
155	kabarcoin.com Internet Source	<1 %
156	repository.unhas.ac.id Internet Source	<1 %
157	repository.widyamataram.ac.id Internet Source	<1 %
158	www.dutaangadarealty.com Internet Source	<1 %
159	www.grafiati.com Internet Source	<1 %
160	www.irjet.net Internet Source	<1 %
161	www.jurnal.stie-aas.ac.id Internet Source	<1 %
162	www.packtpub.com Internet Source	<1 %
163	www.tradingview.com Internet Source	<1 %
164	Ahmadi Yuli Ananta, Rudy Ariyanto, Imam Fahrur Rozi, Rakhmat Arianto. "Analisis Performa Metode Extreme Learning Machine dan Multiple Linear Regression dalam Prediksi Produksi Gula", Edumatic: Jurnal Pendidikan Informatika, 2025	<1 %

Publication		
165	Alfataniah Nur Fajrina, Zein Hanni Pradana, Sevia Indah Purnama, Shinta Romadhona. "Penerapan Arsitektur EfficientNet-B0 Pada Klasifikasi Leukimia Tipe Acute Lymphoblastik Leukimia", Jurnal Riset Rekayasa Elektro, 2024	<1 %
Publication		
166	Andreas Anditya Purnama, Yuan Lukito, Nugroho Agus Haryono. "Analisis Kinerja Support Vector Machine dan Moving Averages Convergence Divergence Untuk Saham-Saham Perbankan Indonesia", Jurnal Komtika (Komputasi dan Informatika), 2025	<1 %
Publication		
167	Cindy Novi Syahputri, Muhammad Siddik Hasibuan. "OPTIMASI KLASIFIKASI DECISION TREE DENGAN TEKNIK PRUNING UNTUK MENGURANGI OVERFITTING", JSil (Jurnal Sistem Informasi), 2024	<1 %
Publication		
168	Doddi Yuniardi, Rani Puspita, Ridwan Ridwan. "MENINGKATKAN EFISIENSI PENGENDALIAN SUHU BOILER PADA PLTSa BURANGKENG MELALUI ANALISIS KOMPREHENSIF BERBASIS MACHINE LEARNING", Jurnal Teknik dan Science, 2023	<1 %
Publication		
169	Febriansyah Febriansyah, Alun Sujjada, Falentino Sembiring. "Prediksi Harga Bitcoin Menggunakan Algoritma Long Short Term Memory (LSTM)", INOVTEK Polbeng - Seri Informatika, 2024	<1 %
Publication		

- 170** Fitrah Amelia Ramelan, Lukman Hakim. "Perbandingan Prediksi terhadap Peningkatan Jumlah Pelanggan Iconnet dengan Algoritma Regresi Linear dan Random Forest pada Wilayah Jabodetabek dan Banten", Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi), 2025
Publication <1%
-
- 171** Raisya Nadzira Zahiratush Shafa, Asti Herliana. "ANALISIS SENTIMEN PENGGUNA APLIKASI SAPAWARGA - JABAR SUPER APPS MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE", Djtechno: Jurnal Teknologi Informasi, 2025
Publication <1%
-
- 172** Rosyiqoh Badzlin, Kiki Setiawan. "Implementasi Data Mining Prediksi Penjualan Produk Semen Menggunakan Metode Linear Regression (Studi Kasus PT. Toyo Mortar Indonesia)", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2024
Publication <1%
-
- 173** Submitted to Universitas Negeri Semarang - iTh
Student Paper <1%
-
- 174** Yulifda Elin Yuspita, Riri Okra, Muhammad Rezeki. "PENERAPAN ALGORITMA KLASIFIKASI UNTUK PREDIKSI TINGKAT KELULUSAN MAHASISWA MENGGUNAKAN RAPPIDMINER", Djtechno: Jurnal Teknologi Informasi, 2025
Publication <1%
-
- 175** adoc.pub
Internet Source <1%

176	arxiv.org Internet Source	<1%
177	digilib.unila.ac.id Internet Source	<1%
178	docobook.com Internet Source	<1%
179	elitalks.org Internet Source	<1%
180	franciskopanjaitan.wordpress.com Internet Source	<1%
181	journal.actual-insight.com Internet Source	<1%
182	jurnal.unigal.ac.id Internet Source	<1%
183	jurnal.unsil.ac.id Internet Source	<1%
184	management.ifrel.org Internet Source	<1%
185	nasulianas.blogspot.com Internet Source	<1%
186	repository.uhamka.ac.id Internet Source	<1%
187	repository.upnvj.ac.id Internet Source	<1%
188	rudyct.com Internet Source	<1%
189	sesctv.net Internet Source	<1%
190	wesleyacademy.net Internet Source	

		<1 %
191	www.coursehero.com Internet Source	<1 %
192	www.libichava.sk Internet Source	<1 %
193	www.nepjol.info Internet Source	<1 %
194	Mauizatun Hasanah, Mega Ramatika Putri, Khairil Anwar Notodiputro, Yenni Angraini, Laily Nissa Atul Mualifah. "Peramalan Harga Emas Berjangka Menggunakan Metode ARIMA-GARCH", Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi, 2025 Publication	<1 %
195	Santoso, Adi. "Peran Budaya Organisasi Dalam Mewujudkan Peningkatan Kinerja Bisnis Melalui Pendekatan Berbasis Ta'awun Ambidexterity", Universitas Islam Sultan Agung (Indonesia), 2024 Publication	<1 %
196	Sirisha Charugulla, Shaiku Shahida Saheb. "Gold Futures Price Prediction Using Transformer Deep Learning Models with Data Scraped via UiPath", Journal of Visualized Experiments, 2025 Publication	<1 %
197	Tiffany Anis Fitria, Riskayanto Riskayanto, Maulana Syarif Hisayatullah. JURNAL EKONOMI SAKTI (JES), 2024 Publication	<1 %
198	ptrifanfinancindoberjangkajakartadbs.weebly.com Internet Source	<1 %

199 Dara Sawitri. "PERAN DEEP LEARNING DAN BIG DATA DALAM MENDEKTEKSI MASALAH KEUANGAN", Djtechno: Jurnal Teknologi Informasi, 2025 <1%
Publication

200 Muhammad Wisnu Nugroho. "Analisis Performa Algoritma Random Forest dalam Mengatasi Overfitting pada Model Prediksi", Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi), 2025 <1%
Publication

Exclude quotes Off

Exclude matches Off

Exclude bibliography Off