

**PERAMALAN *MULTIVARIATE TIME SERIES* HARGA EMAS DUNIA  
BERBASIS MODEL *HYBRID VECTOR AUTOREGRESSIVE  
INTEGRATED MOVING AVERAGE (VARIMA) – LONG  
SHORT TERM MEMORY (LSTM)***

**Skripsi**

**Oleh**

**LUSI DEWI SARTIKA SITORUS  
NPM. 2217031154**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG**

**2026**

## ABSTRACT

### MULTIVARIATE TIME SERIES FORECASTING OF WORLD GOLD PRICES USING A HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA)–LONG SHORT TERM MEMORY (LSTM) MODEL

By

**Lusi Dewi Sartika Sitorus**

World gold prices are one of the most important indicators in the global financial system, reflecting economic dynamics and monetary stability. Gold price data consisting of the Open, High, Low, and Close (OHLC) variables form a multivariate time series dataset that exhibits both linear and nonlinear patterns. This study aims to develop and compare the VARIMA model, the hybrid VARIMA–E\_LSTM model, and the hybrid VARIMA–EP\_LSTM model in forecasting world gold prices. The data used in this study are daily world gold price data from January 2021 to October 17, 2025, obtained from Yahoo Finance, with a total of 1,212 observations. The research methodology begins with stationarity testing using the Augmented Dickey-Fuller (ADF) test, followed by first-order differencing ( $d = 1$ ). The best VARIMA model obtained is VARIMA (1, 1, 1) based on the smallest BIC value. Furthermore, the residuals from the VARIMA model are used as input values for the E\_LSTM model to construct the hybrid model. Model performance is evaluated using RMSE, MAPE, and the Kolmogorov–Smirnov Goodness of Fit test. The results show that the VARIMA model achieves high accuracy in predicting historical data (MAPE of 0.1218%), but it is less capable of capturing nonlinear patterns in future forecasting. The hybrid VARIMA–E\_LSTM model shows improvement in capturing data patterns, while the hybrid VARIMA–EP\_LSTM model provides the best performance in forecasting the next 30 days by more accurately following gold price trends and patterns. Based on the Goodness of Fit test, the hybrid VARIMA–EP\_LSTM model is the best model for forecasting world gold prices.

**Keywords:** World gold price, Forecasting, VARIMA, LSTM, Hybrid model.

## ABSTRAK

### PERAMALAN *MULTIVARIATE TIME SERIES* HARGA EMAS DUNIA BERBASIS MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA) – LONG SHORT TERM MEMORY (LSTM)*

Oleh

**Lusi Dewi Sartika Sitorus**

Harga emas dunia merupakan salah satu indikator penting dalam sistem keuangan global yang mencerminkan dinamika kondisi ekonomi dan stabilitas moneter. Data harga emas yang terdiri dari variabel *Open*, *High*, *Low*, dan *Close* (OHLC) membentuk data deret waktu multivariat yang memiliki pola linear dan nonlinear. Penelitian ini bertujuan untuk mengembangkan dan membandingkan model VARIMA, model *hybrid* VARIMA–E\_LSTM, dan model *hybrid* VARIMA–EP\_LSTM dalam peramalan harga emas dunia. Data yang digunakan adalah data harga emas dunia harian dari Januari 2021 hingga 17 Oktober 2025, yang diperoleh dari *Yahoo Finance*, dengan total 1.212 pengamatan. Metode penelitian dimulai dengan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF) dan melakukan *differencing* satu kali ( $d = 1$ ). Model VARIMA terbaik yang diperoleh adalah VARIMA (1, 1, 1) berdasarkan nilai BIC terkecil. Selanjutnya, residual dari model VARIMA digunakan sebagai nilai *input* untuk model E\_LSTM untuk membentuk model *hybrid*. Evaluasi model dilakukan menggunakan RMSE, MAPE, dan uji kesesuaian *Kolmogorov–Smirnov*. Hasil menunjukkan bahwa model VARIMA memiliki akurasi tinggi dalam memprediksi data historis (MAPE 0,1218%), tetapi kurang mampu menangkap pola nonlinear dalam peramalan ke depan. Model *hybrid* VARIMA–E\_LSTM menunjukkan peningkatan dalam menangkap pola data, sementara model *hybrid* VARIMA–EP\_LSTM memberikan kinerja terbaik dalam peramalan 30 hari ke depan dengan kemampuan untuk mengikuti pola dan tren harga emas secara lebih akurat. Berdasarkan uji *Goodness of Fit*, model *hybrid* VARIMA–EP\_LSTM adalah model terbaik untuk meramalkan harga emas dunia.

**Kata-kata kunci:** Harga emas dunia, Peramalan, VARIMA, LSTM, Model *hybrid*.

**PERAMALAN *MULTIVARIATE TIME SERIES* HARGA EMAS DUNIA  
BERBASIS MODEL *HYBRID VECTOR AUTOREGRESSIVE  
INTEGRATED MOVING AVERAGE (VARIMA) – LONG  
SHORT TERM MEMORY (LSTM)***

**LUSI DEWI SARTIKA SITORUS**

**Skripsi**

Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG**

**2026**

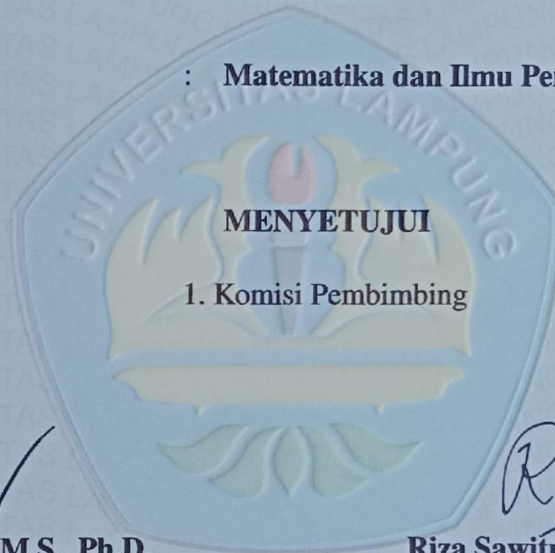
Judul Skripsi : **PERAMALAN *MULTIVARIATE TIME SERIES* HARGA EMAS DUNIA BERBASIS MODEL *HYBRID VECTOR AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (VARIMA) – LONG SHORT TERM MEMORY (LSTM)***

Nama Mahasiswa : **Lusi Dewi Sartika Sitorus**

Nomor Pokok Mahasiswa : **2217031154**

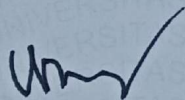
Program Studi : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

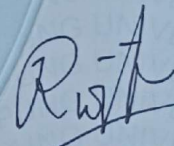


**MENYETUJUI**

**1. Komisi Pembimbing**

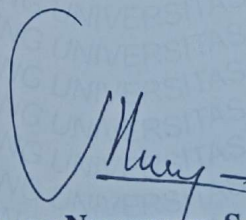


**Ir. Warsono, M.S., Ph.D.**  
**NIP 196302161987031003**



**Riza Sawitri, S.Pd., M.Sc.**  
**NIP 198905042024062001**

**2. Ketua Jurusan Matematika**



**Dr. Aang Nuryaman, S.Si., M.Si.**  
**NIP. 197403162005011001**

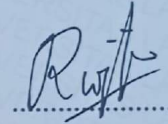
MENGESAHKAN

1. Tim Penguji

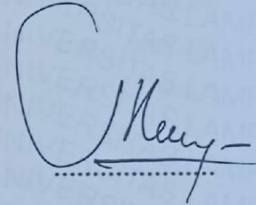
Ketua : Ir. Warsono, M.S., Ph.D.



Sekretaris : Riza Sawitri, S.Pd., M.Sc.



Penguji  
Bukan Pembimbing : Dr.Aang Nuryaman, S.Si.,M.Si.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



**Dr. Eng. Heri Satria, S.Si., M.Si.**  
NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: 17 April 2026

## PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Lusi Dewi Sartika Sitorus**  
Nomor Pokok Mahasiswa : **2217031154**  
Jurusan : **Matematika**  
Judul Skripsi : **Peramalan *Multivariate Time Series* Harga Emas Dunia Berbasis Model *Hybrid Vector Autoregressive Integrated Moving Average (VARIMA) – Long Short Term Memory (LSTM)***

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 17 April 2026

Penulis



Lusi Dewi Sartika Sitorus

## **RIWAYAT HIDUP**

Penulis memiliki nama lengkap Lusi Dewi Sartika Sitorus yang lahir di Lumban Nabolon pada tanggal 05 September 2003. Penulis merupakan anak keempat dari enam bersaudara dari pasangan Bapak Amir Sitorus dan Ibu Risma.

Penulis pertama kali menempuh pendidikan di Paud Pargodungan pada tahun 2009-2010. Kemudian menempuh pendidikan Sekolah Dasar (SD) di SD Negeri 173675 Lumban Nabolon, Kecamatan Uluan, Kota Balige, Provinsi Sumatera Utara pada tahun 2010-2016. Lalu penulis melanjutkan jenjang pendidikan ke Sekolah Menengah Pertama (SMP) di SMP Negeri 1 Porsea, Kecamatan Porsea, Kota Balige, Provinsi Sumatera Utara pada tahun 2016-2019, dan Sekolah Menengah Atas (SMA) di SMA Negeri 1 Uluan, Kecamatan Uluan, Kota Balige, Provinsi Sumatera pada tahun 2019-2022.

Pada tahun 2022 penulis melanjutkan pendidikan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis pernah menjadi bagian dari UKM U SAINTEK Universitas Lampung dan FORKOM BIDIKMISI KIP-K Universitas Lampung pada tahun 2024.

Penulis melaksanakan Kerja Praktik (KP) di PT. PLN (Persero) Unit Induk Distribusi (UID) Lampung, Kecamatan Rajabasa, Provinsi Lampung, pada bulan Desember 2024 hingga Februari 2025, sebagai bentuk pengaplikasian ilmu yang diperoleh selama duduk di bangku perkuliahan. Kemudian, pada bulan Juni hingga Agustus 2025, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Bilabong Jaya, Kecamatan Langkapura, Kota Bandar Lampung, Provinsi Lampung.

## KATA INSPIRASI

### *In the Name Of Jesus Christ*

”Direndahkan dimata manusia, ditinggikan dimata Tuhan, *Prove Them Wrong*”

”Orang-orang yang menabur dengan mencururkan air mata, akan menuai dengan bersorak-sorai.”

**(Mazmur 126 : 5)**

”Kuatkan dan teguhkanlah hatimu, janganlah takut dan jangan gemetar karena mereka, sebab TUHAN, Allahmu, Dialah yang berjalan menyertai engkau; Ia tidak akan membiarkan engkau dan tidak akan meninggalkan engkau.”

**(Ulangan 31 : 6)**

”Terbang yang tinggi dek, kejar apa yang kamu cita-citakan. Jangan takut, Kakak dan abang akan selalu menemanimu.”

**(Kakak dan Abang)**

”Orang tua di rumah menanti kepulanganmu dengan hasil yang membanggakan, jangan kecewakan mereka. Simpan keluhmu, sebab letihmu tak sebanding dengan perjuangan mereka menghidupimu.”

**(Ika df)**

”Perang telah usai, aku bisa pulang Kubaringkan panah dan berteriak MENANG!”

**(Nadin Amizah)**

## **PERSEMBAHAN**

Dengan mengucapkan syukur kepada Tuhan Yang Maha Esa atas kasih, berkat, dan penyertaan-Nya, sehingga skripsi ini dapat diselesaikan dengan baik dan tepat pada waktunya. Dengan penuh rasa syukur dan sukacita, penulis mempersembahkan ucapan terima kasih kepada:

### **Ayah dan Ibuku Tercinta**

Terimakasih kepada orang tuaku atas segala pengorbanan, motivasi, doa dan ridho serta dukungannya selama ini. Terimakasih telah memberikan pelajaran berharga kepada anakmu ini tentang makna perjalanan hidup yang sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi banyak orang.

### **Dosen Pembimbing dan Pembahas**

Terimakasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang berharga.

### **Sahabat-sahabatku**

Terimakasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasinya, serta doa-doanya dan senantiasa memberikan dukungan dalam hal apapun.

### **Almamater Tercinta**

Universitas Lampung

## SANWACANA

Puji dan syukur penulis panjatkan kepada Tuhan Yang Maha Esa atas kasih karunia dan penyertaan-Nya, sehingga penulis dapat menyelesaikan skripsi ini yang berjudul "Permalan *Multivariate Time Series* Harga Emas Dunia Berbasis Model *Hybrid Vector Autoregressive Integrated Moving Average (VARIMA) – Long Short Term Memory (LSTM)*" dengan baik dan lancar serta tepat pada waktu yang telah ditentukan.

Dalam proses penyusunan skripsi ini, banyak pihak yang telah membantu memberikan bimbingan, dukungan, arahan, motivasi serta saran sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dalam kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Ir. Warsono, M.S., Ph.D., selaku Pembimbing 1 yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Riza Sawitri, S.Pd., M.Sc., selaku Pembimbing II yang telah memberikan arahan, bimbingan dan dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Bapak Dr. Aang Nuryaman. S.Si., M.Si., selaku Penguji yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Ibu Dr. Khoirin Nisa, M.Si., selaku dosen pembimbing akademik.
6. Teristimewa untuk kedua orang tua, terima kasih penulis ucapkan atas segala pengorbanan dan ketulusan yang diberikan. Meskipun papa dan mama tidak

sempat merasakan pendidikan di bangku perkuliahan, tetapi selalu senantiasa memberikan yang terbaik, tak kenal lelah mendoakan, memberi dukungan moral dan motivasi yang tidak ternilai harganya, semoga dengan adanya skripsi ini dapat membuat papa dan mama lebih bangga karena melihat anaknya ini menjadi yang pertama menyandang gelar sarjana di keluarga ini. Besar harapan penulis semoga papa dan mama selalu sehat, panjang umur, dan bisa menyaksikan keberhasilan lainnya yang akan penulis raih di masa yang akan datang.

7. Teruntuk kakak, dan kedua abang yang bernama, Hotma, Daniel, dan Mangoloi, terima kasih telah menjadi sosok luar biasa yang telah menjadi pilar kekuatan dan sumber harapan selama perjalanan pendidikan ini. Kakak dan abang dengan penuh keikhlasan telah memenuhi setiap kebutuhan, fasilitas, dan biaya kuliah penulis tanpa pernah mengeluh sedikit pun. Di balik senyum dan kesederhanaannya, tersimpan perjuangan besar yang memungkinkan penulis menempuh pendidikan hingga tahap ini. Terima kasih telah menggantikan peran pelindung, penyemangat, dan penopang di saat penulis hampir menyerah.
8. Kepada kedua adik penulis yakni, Sari dan Ngolu, yang senantiasa menjadi pelengkap dinamika dalam hidup penulis, yang selalu membuat penulis termotivasi untuk bisa terus belajar menjadi sosok kakak yang dapat memberikan pengaruh positif, baik dalam bidang akademik maupun nonakademik, serta berusaha menjadi panutannya di masa yang akan datang.
9. Sahabat penulis semasa sekolah, Linca dan Sepri, terima kasih selalu mendengarkan keluh kesah penulis selama penulis duduk di bangku perkuliahan ini, selalu memberi saran, memberi dukungan, dan selalu memotivasi penulis.
10. Teman terbaik penulis selama diperkuliahan diantaranya, Rika, Josefa, Yanti, dan Helfrida, yang sudah menemani penulis mulai 2023 sampai saat ini, terima kasih atas segala canda tawa, suka duka, dan kebersamaannya sehingga hari-hari penulis jadi berwarna di masa perkuliahan ini.
11. Teman seperjuangan diperkuliahan dari awal kelas C, diantaranya Yolanda dan Anissa, terimakasih sudah memberikan canda tawa, dukungan, motivasi dan selalu ada di setiap momen suka dan duka selama berada di bangku perkuliahan.

12. Rekan-rekan terbaik penulis selama menjalani perkuliahan mulai dari maba hingga saat ini, teruntuk Geng Pomparan, Mega, Yolanda, Ayu, Gracia, Elisabeth, Winne, Agus, dan Rafael, terimakasih atas kebersamaan yang hangat dan menyenangkan, serta atas saling menguatkan satu sama lain sehingga kita dapat melalui masa perkuliahan ini dengan penuh semangat.
13. Seluruh dosen, staf dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Semoga skripsi ini dapat bermanfaat bagi kita semua. Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menjadikan skripsi ini lebih baik lagi.

Bandar Lampung, 17 April 2026

Lusi Dewi Sartika Sitorus

## DAFTAR ISI

	Halaman
<b>DAFTAR ISI</b> . . . . .	<b>xiv</b>
<b>DAFTAR TABEL</b> . . . . .	<b>xvii</b>
<b>DAFTAR GAMBAR</b> . . . . .	<b>xix</b>
<b>I PENDAHULUAN</b> . . . . .	<b>1</b>
1.1 Latar Belakang Masalah . . . . .	1
1.2 Rumusan Masalah . . . . .	3
1.3 Tujuan Penelitian . . . . .	4
1.4 Manfaat Penelitian . . . . .	4
<b>II TINJAUAN PUSTAKA</b> . . . . .	<b>6</b>
2.1 Penelitian Terkait . . . . .	6
2.2 Deret Waktu . . . . .	9
2.2.1 Analisis Deret Waktu . . . . .	9
2.2.2 Peramalan Deret Waktu . . . . .	10
2.3 Model Deret Waktu Multivariat . . . . .	11
2.3.1 Model <i>Vector Autoregressive</i> (VAR) . . . . .	11
2.3.2 Model <i>Vector Moving Average</i> (VMA) . . . . .	12
2.3.3 Model <i>Vector Autoregressive Moving Average</i> (VARMA) . . . . .	12
2.3.4 Model <i>Vector Autoregressive Integrated Moving Average</i> (VARIMA) . . . . .	13
2.4 Uji Asumsi . . . . .	13
2.4.1 Stasioneritas Data . . . . .	13
2.4.2 Residual <i>White Noise</i> . . . . .	15
2.5 <i>Machine Learning</i> (ML) . . . . .	16
2.5.1 <i>Scaling</i> Data . . . . .	17
2.5.2 <i>Unscaling</i> Data . . . . .	18
2.5.3 Fungsi Aktivasi . . . . .	18

2.6	<i>Deep Learning</i> (DL)	19
2.6.1	<i>Recurrent Neural Network</i> (RNN)	20
2.6.2	<i>Long Short-Term Memory</i> (LSTM)	21
2.6.3	<i>Hyperparameter</i>	24
2.7	<i>Hybrid VARIMA-LSTM</i>	25
2.8	Evaluasi Model	26
2.9	<i>Goodness of Fit</i>	27
<b>III METODOLOGI PENELITIAN</b>		<b>29</b>
3.1	Waktu dan Tempat Penelitian	29
3.1.1	Tempat Penelitian	29
3.1.2	Waktu Penelitian	29
3.2	Data dan Alat	30
3.2.1	Data Penelitian	30
3.2.2	Alat Penelitian	30
3.3	Metode Penelitian	31
<b>IV HASIL DAN PEMBAHASAN</b>		<b>36</b>
4.1	Proses <i>Input</i> Data	36
4.2	Visualisasi Data	36
4.3	<i>Splitting</i> Data	37
4.4	Prediksi dan Peramalan dengan Model VARIMA	38
4.4.1	<i>Preprocessing</i> Data	38
4.4.2	Uji Stasioner Data	39
4.4.3	Identifikasi Model	42
4.4.4	Estimasi Parameter Model	43
4.4.5	Prediksi Model VARIMA	44
4.4.6	Residual Model VARIMA	47
4.4.7	Peramalan Model VARIMA	49
4.5	Prediksi dan Peramalan Model <i>Hybrid</i> VARIMA–E_LSTM	52
4.5.1	<i>Scaling</i> Data Residual Model VARIMA	53
4.5.2	<i>Hyperparameter Tuning</i> Model E_LSTM	54
4.5.3	Membangun Model E_LSTM	55
4.5.4	Prediksi Model E_LSTM	55
4.5.5	Prediksi Model <i>Hybrid</i> VARIMA–E_LSTM	58
4.5.6	Peramalan Model P_LSTM	60
4.5.7	Peramalan Model <i>Hybrid</i> VARIMA–E_LSTM	62

4.6	Prediksi dan Peramalan Model <i>Hybrid</i> VARIMA–EP_LSTM . . . .	66
4.6.1	<i>Scaling</i> Data Hasil Prediksi Model VARIMA . . . . .	66
4.6.2	<i>Hyperparameter Tuning</i> Model P_LSTM . . . . .	67
4.6.3	Membangun Model P_LSTM . . . . .	67
4.6.4	Prediksi Model P_LSTM . . . . .	68
4.6.5	Prediksi Model <i>Hybrid</i> VARIMA–EP_LSTM . . . . .	70
4.6.6	Peramalan Model P_LSTM . . . . .	72
4.6.7	Peramalan Model <i>Hybrid</i> VARIMA–EP_LSTM . . . . .	74
4.7	<i>Goodness of Fit</i> . . . . .	78
<b>V</b>	<b>KESIMPULAN DAN SARAN</b> . . . . .	<b>81</b>
5.1	Kesimpulan . . . . .	81
	<b>DAFTAR PUSTAKA</b> . . . . .	<b>83</b>

## DAFTAR TABEL

Tabel	Halaman
1 Penelitian Terkait . . . . .	6
2 Data Harga Emas Dunia . . . . .	30
3 <i>Missing Value</i> . . . . .	38
4 Nilai Korelasi . . . . .	38
5 Uji Stasioner Awal . . . . .	39
6 Uji Stasioner Setelah <i>Differencing</i> Pertama . . . . .	40
7 Pemilihan Model VARIMA Terbaik . . . . .	44
8 Hasil Prediksi Model VARIMA . . . . .	44
9 Hasil Prediksi Model VARIMA Setelah <i>Undifferencing</i> . . . . .	45
10 Evaluasi Model VARIMA . . . . .	46
11 Residual Model VARIMA . . . . .	47
12 Hasil Uji <i>Ljung-Box</i> . . . . .	48
13 Hasil Peramalan Model VARIMA . . . . .	49
14 Evaluasi <i>Training-Testing</i> Model VARIMA . . . . .	51
15 Evaluasi <i>Forecasting</i> Model VARIMA . . . . .	52
16 Evaluasi <i>Training-Testing-Forecasting</i> Model VARIMA . . . . .	52
17 <i>Hyperparameter Tuning</i> Model E.LSTM . . . . .	54
18 Hasil <i>Hyperparameter Tuning</i> Model E.LSTM . . . . .	55
19 Prediksi Model E.LSTM . . . . .	56
20 Hasil Prediksi Model E.LSTM . . . . .	56
21 Evaluasi Model E.LSTM . . . . .	57
22 Hasil Prediksi Model <i>Hybrid</i> VARIMA–E.LSTM . . . . .	58
23 Evaluasi Model <i>Hybrid</i> VARIMA–E.LSTM . . . . .	59
24 Hasil Peramalan Residual Model E.LSTM . . . . .	60

25 Hasil Peramalan Model <i>Hybrid</i> VARIMA–E_LSTM . . . . .	62
26 Evaluasi <i>Training-Testing</i> Model <i>hybrid</i> VARIMA–E_LSTM . . . . .	65
27 Evaluasi <i>Forecasting</i> Model <i>hybrid</i> VARIMA–E_LSTM . . . . .	65
28 Evaluasi <i>Training-Testing-Forecasting</i> Model <i>hybrid</i> VARIMA–E_LSTM	65
29 <i>Hyperparameter Tuning</i> Model P_LSTM . . . . .	67
30 Hasil <i>Hyperparameter Tuning</i> Model P_LSTM . . . . .	68
31 Prediksi Model P_LSTM . . . . .	68
32 Hasil Prediksi Model P_LSTM . . . . .	69
33 Evaluasi Model P_LSTM . . . . .	70
34 Hasil Prediksi Model <i>Hybrid</i> VARIMA–EP_LSTM . . . . .	71
35 Evaluasi Model <i>Hybrid</i> VARIMA–EP_LSTM . . . . .	72
36 Hasil Peramalan Model P_LSTM . . . . .	72
37 Hasil Peramalan Model <i>Hybrid</i> VARIMA–EP_LSTM . . . . .	74
38 Evaluasi <i>Training-Testing</i> Model <i>hybrid</i> VARIMA–EP_LSTM . . . . .	77
39 Evaluasi <i>Forecasting</i> Model <i>hybrid</i> VARIMA–EP_LSTM . . . . .	77
40 Evaluasi <i>Training-Testing-Forecasting</i> Model <i>hybrid</i> VARIMA–EP_LSTM	77
41 <i>Goodness of fit Open</i> . . . . .	78
42 <i>Goodness of fit High</i> . . . . .	78
43 <i>Goodness of fit Low</i> . . . . .	79
44 <i>Goodness of fit Close</i> . . . . .	79

## DAFTAR GAMBAR

Gambar	Halaman
1 Arsitektur LSTM (Luo dkk., 2021). . . . .	21
2 <i>Flowchart</i> Model <i>Hybrid</i> VARIMA–E.LSTM. . . . .	34
3 <i>Flowchart</i> Model <i>Hybrid</i> VARIMA–EP.LSTM. . . . .	35
4 Plot Data Historis Harga Emas Dunia. . . . .	37
5 Plot Data <i>Differencing</i> Pertama. . . . .	41
6 Plot ACF dan PACF Variabel <i>Open</i> . . . . .	42
7 Plot ACF dan PACF Variabel <i>High</i> . . . . .	42
8 Plot ACF dan PACF Variabel <i>Low</i> . . . . .	43
9 Plot ACF dan PACF Variabel <i>Close</i> . . . . .	43
10 Plot Hasil Prediksi Model VARIMA. . . . .	46
11 Plot Data Residual Hasil Prediksi Model VARIMA. . . . .	48
12 Plot Hasil Peramalan Data <i>Training</i> , Data <i>Testing</i> , dan <i>Forecasting</i> Model VARIMA. . . . .	50
13 Plot Hasil Peramalan Model VARIMA. . . . .	51
14 Plot Residual Prediksi E.LSTM. . . . .	57
15 Plot Hasil Prediksi Model <i>Hybrid</i> VARIMA–E.LSTM. . . . .	59
16 Pola dan Fluktuasi Hasil Peramalan Residual Model E.LSTM. . . . .	61
17 Plot Hasil Peramalan Data <i>Training</i> , Data <i>Testing</i> , dan <i>Forecasting</i> Model <i>Hybrid</i> VARIMA–E.LSTM. . . . .	63
18 Plot Hasil Peramalan Model <i>Hybrid</i> VARIMA–E.LSTM. . . . .	64
19 Plot Hasil Prediksi Model P.LSTM. . . . .	70
20 Plot Hasil Prediksi Model <i>Hybrid</i> VARIMA–EP.LSTM. . . . .	71
21 Plot Hasil Peramalan Model P.LSTM. . . . .	73
22 Plot Hasil Peramalan Data <i>Training</i> , Data <i>Testing</i> , dan <i>Forecasting</i> Model <i>Hybrid</i> VARIMA–EP.LSTM. . . . .	75

23 Plot Hasil Peramalan Model *Hybrid* VARIMA–EP\_LSTM. . . . . 76

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang Masalah**

Emas merupakan salah satu komoditas utama yang memainkan peran penting dalam sistem keuangan global. Harga emas dunia sering kali menjadi indikator kondisi ekonomi dan stabilitas moneter, terutama karena sensitivitasnya terhadap perubahan kebijakan moneter, gangguan ekonomi, dan dinamika pasar keuangan internasional. Baur dan McDermott (2010) menyatakan bahwa emas cenderung mempertahankan nilainya selama periode krisis keuangan, sehingga pergerakan harga emas menjadi fokus utama bagi investor, peserta pasar, dan pembuat kebijakan. Fluktuasi harga emas mencerminkan respons pasar terhadap perubahan kondisi moneter dan keuangan, sehingga peramalan harga emas dunia yang akurat menjadi persyaratan penting untuk pengambilan keputusan investasi dan manajemen risiko.

Harga emas dunia menunjukkan fluktuasi yang signifikan, yang dipengaruhi oleh sejumlah faktor makroekonomi seperti nilai tukar mata uang, suku bunga, harga minyak dunia, dan kondisi pasar global. Penelitian oleh Zhang dan Wei (2010) menunjukkan bahwa harga emas memiliki hubungan dinamis dengan indikator ekonomi lainnya dan bersifat tidak stasioner, sehingga menghasilkan pola seri waktu yang kompleks. Secara umum, data harga emas disajikan dalam bentuk variabel *Open*, *High*, *Low*, dan *Close* (OHLC), yang menggambarkan perubahan harga selama periode perdagangan. Keempat variabel OHLC ini saling berkaitan dan membentuk struktur deret waktu multivariat, sehingga metode peramalan multivariat lebih sesuai daripada pendekatan univariat.

Metode peramalan deret waktu digunakan untuk memperkirakan nilai masa depan berdasarkan pada pola data historis (Makridakis dkk., 1983). Model deret waktu diklasifikasikan berdasarkan jumlah variabel yang dipertimbangkan, yaitu univariat

dan multivariat (Wei, 2006). Karena data harga emas dunia OHLC melibatkan beberapa variabel yang saling berkaitan, maka pendekatan *multivariate time series* menjadi relevan untuk diterapkan dalam penelitian ini.

Salah satu model statistik klasik yang sering diterapkan dalam peramalan deret waktu multivariat adalah model *Vector Autoregressive* (VAR). Model ini dapat menangkap hubungan dinamis antar beberapa variabel secara simultan dengan memanfaatkan nilai masa lalu dari semua variabel dalam sistem (Lütkepohl, 2005). Namun, VAR hanya mengandalkan komponen autoregresif dan belum mempertimbangkan dampak kesalahan peramalan sebelumnya. Untuk mengatasi keterbatasan ini, model *Vector Autoregressive Integrated Moving Average* (VARIMA) dikembangkan, yang merupakan perluasan dari VARMA dengan penambahan komponen integrasi untuk mengelola data yang tidak stasioner (Rusyana dkk., 2020). Hasil penelitian Wang dkk. (2011) menunjukkan bahwa metode VARIMA cukup efektif dalam memprediksi harga emas, tetapi masih belum mampu menangani pola nonlinear yang kompleks.

Model statistik linear, VARIMA mengasumsikan hubungan linear antara variabel, sehingga kurang efektif dalam memodelkan data harga emas yang dipengaruhi oleh sentimen pasar dan dinamika global nonlinear. Zhang (2003) menyatakan bahwa model berbasis ARIMA, termasuk VARIMA, tidak mampu menangkap pola nonlinear dengan baik. Oleh karena itu, diperlukan pendekatan alternatif yang mampu memodelkan pola nonlinear dan ketergantungan jangka panjang dalam data harga emas dunia.

Metode *deep learning* telah muncul sebagai alternatif untuk mengatasi kelemahan model linear dalam peramalan deret waktu. Salah satu arsitektur *deep learning* yang paling sering diterapkan adalah *Long Short-Term Memory* (LSTM), yang merupakan pengembangan dari *Recurrent Neural Network* (RNN). Model ini dilengkapi dengan mekanisme gerbang yang memungkinkan penyimpanan informasi jangka panjang secara lebih efisien. Penelitian oleh Shah dkk. (2019) menunjukkan bahwa LSTM memberikan hasil peramalan yang lebih baik dibandingkan model statistik klasik dalam memprediksi harga emas dunia.

Meskipun model LSTM unggul dalam mengidentifikasi pola nonlinear, model ini kurang efektif dalam menggambarkan struktur linear dan hubungan eksplisit

antara variabel multivariat. Menurut Zhang (2003), tidak ada model peramalan tunggal yang dapat beroperasi secara optimal pada semua jenis data. Oleh karena itu, pendekatan *hybrid* yang menggabungkan kekuatan model statistik dan *deep learning* menjadi solusi yang menjanjikan. Model *hybrid* VARIMA–LSTM dikembangkan untuk memanfaatkan kemampuan VARIMA dalam menangkap hubungan linear dan interaksi antara variabel harga emas dunia OHLC, sekaligus memanfaatkan kekuatan LSTM dalam menganalisis pola nonlinear dan ketergantungan jangka panjang. Namun, LSTM juga memiliki keterbatasan, terutama dalam menangani pola linear yang kuat, yang dapat dikelola secara lebih stabil oleh model statistik klasik seperti VARIMA. Oleh karena itu, strategi *hybrid* sangat relevan. Menurut Zhang (2003), integrasi model linear dan nonlinear dapat secara signifikan meningkatkan akurasi peramalan dibandingkan dengan penggunaan model tunggal.

Pendekatan *hybrid* telah terbukti efektif dalam beberapa penelitian. Menurut Bayu Aji dan Surjandari (2020) menyatakan bahwa model *hybrid* VAR–LSTM dan VAR–GRU memberikan akurasi peramalan yang lebih tinggi untuk harga bahan bakar jet dibandingkan dengan model tunggal. Penelitian lain oleh Caliwag dan Lim (2019) menunjukkan bahwa *hybrid* VARMA–LSTM menghasilkan prediksi yang lebih akurat untuk data pengisian baterai lithium-ion dibandingkan dengan VARMA atau LSTM saja.

Namun, penggunaan model *hybrid* VARIMA–LSTM untuk menganalisis data harga emas dunia berdasarkan variabel OHLC masih belum banyak diterapkan. Hal ini disebabkan oleh fakta bahwa harga emas dunia dipengaruhi oleh berbagai faktor makroekonomi global, sehingga pendekatan multivariat seperti VARIMA lebih sesuai. Selain itu, karakteristik nonlinear data emas memerlukan penerapan model *deep learning* seperti LSTM. Oleh karena itu, penting untuk mengembangkan model *hybrid* VARIMA–LSTM untuk meramalkan harga emas dunia, dengan tujuan menggabungkan keunggulan model linear dan nonlinear secara bersamaan, sehingga dapat menghasilkan prediksi yang lebih akurat dan dapat diandalkan.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang masalah yang telah dijelaskan, disusun rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana pembentukan model VARIMA, model *hybrid* VARIMA-E\_LSTM, dan model *hybrid* VARIMA-EP\_LSTM untuk meramalkan harga emas dunia berdasarkan komponen harga, yaitu *Open*, *High*, *Low*, dan *Close*?
2. Bagaimana hasil peramalan harga emas dunia (*Open*, *High*, *Low*, dan *Close*) menggunakan model VARIMA, model *hybrid* VARIMA-E\_LSTM, dan model *hybrid* VARIMA-EP\_LSTM?
3. Bagaimana perbandingan kinerja model VARIMA, model *hybrid* VARIMA-E\_LSTM, dan model *hybrid* VARIMA-EP\_LSTM dalam meramalkan harga emas dunia pada variabel *Open*, *High*, *Low*, dan *Close*?

### 1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Membangun model VARIMA, model *hybrid* VARIMA-E\_LSTM, dan model *hybrid* VARIMA-EP\_LSTM untuk meramalkan harga emas dunia berdasarkan komponen harga, yaitu *Open*, *High*, *Low*, dan *Close*.
2. Mengetahui hasil peramalan harga emas dunia (*Open*, *High*, *Low*, dan *Close*) yang dihasilkan oleh model VARIMA, model *hybrid* VARIMA-E\_LSTM, dan model *hybrid* VARIMA-EP\_LSTM.
3. Membandingkan kinerja model VARIMA, model *hybrid* VARIMA-E\_LSTM, dan model *hybrid* VARIMA-EP\_LSTM dalam meramalkan harga emas dunia pada variabel *Open*, *High*, *Low*, dan *Close*.

### 1.4 Manfaat Penelitian

Manfaat yang dapat diperoleh dari penelitian ini antara lain:

1. Memberikan wawasan dan perspektif baru mengenai penerapan model *hybrid* VARIMA-LSTM dalam peramalan harga emas dunia variabel *Open*, *High*, *Low*, dan *Close*.

2. Membantu investor dalam merancang strategi investasi yang lebih efektif terkait pergerakan harga emas dunia berdasarkan variabel *Open*, *High*, *Low*, dan *Close* (OHLC).
3. Berfungsi sebagai bahan referensi dan literatur mengenai peramalan dengan model *hybrid* VARIMA-LSTM untuk penelitian selanjutnya.

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Penelitian Terkait

Penelitian ini merujuk pada berbagai penelitian sebelumnya sebagai landasan teoretis untuk menganalisis hasil yang diperoleh. Berbagai penelitian sebelumnya yang digunakan sebagai referensi utama meneliti penerapan model *multivariate time series* dan *deep learning*, termasuk metode seperti VARIMA, LSTM, VAR–LSTM, dan model *hybrid* VARMA–LSTM. Kinerja model dievaluasi menggunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Ringkasan dan hasil dari penelitian-penelitian sebelumnya yang digunakan sebagai referensi disajikan dalam Tabel 1 di bawah ini:

Tabel 1. Penelitian Terkait

No	Penelitian	Data	Metode	Hasil	
				RMSE	MAPE
1	Penerapan Model <i>Vector Autoregressive Integrated Moving Average</i> dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia (Jusmawati dkk., 2020)	Data bulanan laju inflasi dan suku bunga Indonesia Januari 2009–Desember 2016. Sumber: Situs Resmi Bank Sentra Indonesia	VARIMA	–	6,04% dan 1,84%

No	Penelitian	Data	Metode	Hasil	
				RMSE	MAPE
2	Prediksi Pergerakan Harga Saham pada Sektor Farmasi Menggunakan Algoritma <i>Long Short-Term Memory</i> (Agusta dkk., 2021)	Data Harga Saham. Jumlah: 761 observasi. Sumber: Yahoo Finance	LSTM	27,310	–
3	<i>Hybrid Vector Autoregression–Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price</i> (Bayu Aji & Surjandari, 2020)	Data harga transaksi bahan bakar jet di Bandara CGK, Tangerang, Indonesia, Januari 2017–April 2020. Sumber: Data terbuka, website <i>platts</i> , website <i>pertamina</i> , website Bank Indonesia, maskapai penerbangan Indonesia.	VAR, LSTM, GRU, VAR-LSTM, VAR-GRU	VAR: 62,53 LSTM: 989,95 GRU: 794,270 VAR-LSTM: 81,52 VAR-GRU: 62,53	VAR: 2,52% LSTM: 13,07% GRU: 10,97% VAR-LSTM: 1,02% VAR-GRU: 0,60%
4	<i>Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications</i> (Caliwag & Lim, 2019)	Data indikator keamanan baterai pada kendaraan berbasis listrik.	VARMA, LSTM, VARMA-LSTM	VARMA: 3,836 LSTM: 0,4032 VARMA-LSTM: 0,161	–

Ringkasan penelitian yang tercantum dalam Tabel 1 dapat dijelaskan sebagai berikut:

1. Penerapan Model *Vector Autoregressive Integrated Moving Average* (VARIMA) dalam Peramalan Inflasi dan Suku Bunga di Indonesia (Jusmawati dkk., 2020).

Penelitian yang dilakukan oleh Jusmawati dkk. (2020) menggunakan metode *Vector Autoregressive Integrated Moving Average* (VARIMA) untuk menganalisis dan meramalkan inflasi dan suku bunga di Indonesia. Tujuan

utama penelitian ini adalah mengembangkan model peramalan berdasarkan data *time series* bulanan inflasi dan suku bunga dari Januari 2009 hingga Desember 2016.

Berdasarkan proses identifikasi model menggunakan *Akaike Information Criterion* (AIC), model yang paling optimal adalah VARIMA (0,2,2), dengan nilai AIC sebesar  $-4,2891$ . Model tersebut kemudian diterapkan untuk meramalkan inflasi dan suku bunga di masa depan. Evaluasi menggunakan *Mean Absolute Percentage Error* (MAPE) menunjukkan tingkat akurasi yang memuaskan, yaitu sebesar 6,04% untuk peramalan inflasi dan 1,84% untuk peramalan suku bunga.

2. Memprediksi Pergerakan Harga Saham di Industri Farmasi Menggunakan Algoritma *Long Short-Term Memory* (Agusta dkk., 2021).

Penelitian yang dilakukan oleh Agusta dkk. (2021) bertujuan untuk memprediksi perubahan harga saham di sektor farmasi melalui penerapan algoritma *Long Short-Term Memory* (LSTM). Data yang digunakan dalam penelitian ini terdiri dari 761 observasi harga saham yang diperoleh dari platform *Yahoo Finance* sebagai sumber data historis.

Penelitian dimulai dengan tahap pengumpulan data, yang dilanjutkan dengan tahap prapemrosesan, seperti pembersihan dan persiapan data sebelum analisis. Data kemudian dibagi menjadi 80% untuk pelatihan model dan 20% untuk pengujian. Langkah selanjutnya meliputi pembuatan, pelatihan, dan evaluasi model LSTM. Berdasarkan hasil evaluasi, diperoleh nilai *Root Mean Square Error* (RMSE) sebesar 27,310, yang menunjukkan tingkat kesalahan dalam prediksi model.

3. Penerapan Model *Hybrid VAR-RNN* untuk Memprediksi *Multivariate Time Series* Harga Transaksi Bahan Bakar Jet (Bayu Aji & Surjandari, 2020).

Penelitian yang dilakukan oleh Bayu Aji dan Surjandari (2020) menggunakan model *hybrid VAR-LSTM* dan *VAR-GRU* untuk meramalkan harga transaksi bahan bakar jet di Bandara Soekarno-Hatta, Tangerang. Data yang digunakan mencakup variabel multivariat, seperti harga minyak dunia, harga dasar bahan bakar jet internasional, harga bahan bakar domestik, nilai tukar rupiah terhadap dolar AS, dan tingkat inflasi di Indonesia, dengan rentang pengamatan dari Januari 2017 hingga April 2020.

Langkah-langkah penelitian meliputi pengumpulan, konsolidasi, dan pembersihan data, diikuti dengan transformasi data dan pengembangan model

VAR sebagai langkah awal. Setelah itu, model LSTM dan GRU dilatih, lalu dievaluasi menggunakan ukuran MAD, RMSE, MAPE, dan akurasi. Hasil penelitian menunjukkan bahwa model VAR–GRU mencapai akurasi tertinggi sebesar 99,40%, sementara VAR–LSTM menghasilkan akurasi 98,98%. Peramalan digunakan untuk mengantisipasi perubahan harga yang disebabkan oleh pandemi COVID-19. Secara umum, metode *hybrid* terbukti efektif dalam mengurangi bias dan memberikan hasil prediksi yang lebih akurat dibandingkan dengan penggunaan model tunggal.

4. Metode *Hybrid* VARMA-LSTM untuk Peramalan Tingkat Pengisian dan Tegangan Keluaran Baterai *Lithium-Ion* pada Aplikasi Sepeda Motor Listrik (Caliwag & Lim, 2019).

Dalam penelitian ini, model gabungan VARMA–LSTM diterapkan untuk meramalkan tingkat pengisian dan tegangan keluaran baterai *lithium-ion* yang digunakan pada sepeda motor listrik. Sumber data diperoleh dari pengukuran langsung pada kendaraan yang dioperasikan melalui siklus pengujian CVS-40 pada dua variasi suhu, yaitu 0 °C dan 25 °C.

Proses penelitian dimulai dengan seleksi variabel berdasarkan analisis korelasi Pearson, diikuti dengan pemisahan elemen linear dan nonlinear dari data baterai historis. Model VARMA diterapkan untuk menggambarkan pola linear, sementara LSTM digunakan untuk menangkap pola nonlinear. Kinerja model dievaluasi dengan menghitung nilai RMSE pada setiap kondisi suhu. Hasil penelitian menunjukkan bahwa pendekatan *hybrid* VARMA–LSTM menghasilkan kesalahan peramalan yang lebih rendah dibandingkan dengan model tunggal. Pada suhu 25 °C, nilai RMSE untuk peramalan tegangan keluaran tercatat sebesar 0,161, yang mengonfirmasi keefektifan model gabungan dalam meningkatkan akurasi prediksi.

## 2.2 Deret Waktu

### 2.2.1 Analisis Deret Waktu

Analisis deret waktu adalah pendekatan yang digunakan untuk menganalisis pola hubungan dalam data yang dikumpulkan secara berurutan berdasarkan waktu. Deret

waktu sendiri merujuk pada kumpulan pengamatan yang diperoleh secara kronologis sepanjang waktu (Box dkk., 2015).

Menurut Makridakis dkk. (1983), terdapat empat jenis pola data yang sering ditemukan dalam analisis deret waktu.

1. Pola Horizontal

Pola ini terbentuk ketika nilai-nilai dalam deret waktu berfluktuasi di sekitar rata-rata yang stabil. Hal ini menunjukkan bahwa data bersifat stasioner.

2. Pola Musiman

Pola ini muncul ketika deret waktu dipengaruhi oleh faktor musiman, sehingga pergerakan data berulang pada interval waktu tertentu, seperti tahunan, triwulanan, bulanan, mingguan, atau harian.

3. Pola Siklik

Pola ini ditandai dengan fluktuasi yang tidak terjadi pada interval waktu yang teratur. Dalam ekonomi, pola siklik biasanya terkait dengan dinamika atau perubahan yang mengikuti siklus bisnis.

4. Pola Tren

Pola ini terlihat ketika rangkaian waktu menunjukkan tren naik atau turun dalam jangka waktu yang panjang.

### **2.2.2 Peramalan Deret Waktu**

Peramalan deret waktu adalah proses yang menggunakan data historis dari variabel-variabel tertentu, yang dikumpulkan dan dievaluasi untuk mengembangkan model yang mencerminkan pola atau hubungan mendasar di dalamnya. Model ini kemudian diterapkan untuk memperkirakan nilai deret waktu di masa depan (Zhang, 2003).

Menurut Montgomery dkk. (2015), terdapat dua cara utama untuk melakukan peramalan, yaitu:

1. Metode Peramalan Kualitatif

Metode ini bersifat subjektif dan sangat bergantung pada pendapat ahli. Pendekatan kualitatif umumnya digunakan ketika data historis terbatas atau bahkan tidak tersedia. Meskipun analisis data dapat dilakukan, dasar utama peramalan dalam metode ini tetap didasarkan pada pertimbangan subjektif.

## 2. Metode Peramalan Kuantitatif

Metode ini menggunakan data masa lalu dan berbagai model peramalan untuk mengidentifikasi pola dalam data dan menjelaskan hubungan statistik antara nilai-nilai sebelumnya dan nilai-nilai saat ini dari variabel yang diteliti. Model tersebut kemudian diterapkan untuk memprediksi pola serupa di masa depan, atau dengan kata lain, untuk melanjutkan tren perilaku masa lalu dan saat ini ke periode berikutnya.

## 2.3 Model Deret Waktu Multivariat

### 2.3.1 Model *Vector Autoregressive* (VAR)

Model *Vector Autoregressive* (VAR) merupakan perluasan dari model *Autoregressive* (AR) yang dirancang untuk mengelola beberapa deret waktu secara bersamaan. VAR mencakup sistem persamaan dinamis di mana nilai suatu variabel pada suatu waktu tertentu diperkirakan dengan mempertimbangkan nilai-nilai masa lalunya sendiri serta nilai-nilai masa lalu variabel lain dalam sistem (Rusyana dkk., 2020). Secara umum, model VAR digambarkan dalam Persamaan (2.1) sebagai berikut (Wei, 2006):

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \Phi_2 \mathbf{Z}_{t-2} + \cdots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t \quad (2.1)$$

dengan:

$$\mathbf{Z}_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner berukuran } N \times 1$$

$$\Phi_1, \dots, \Phi_p = \text{matriks parameter } \textit{autoregressive} \text{ berukuran } N \times N$$

$$\mathbf{a}_t = [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor } \textit{error} \text{ berukuran } N \times 1$$

### 2.3.2 Model *Vector Moving Average* (VMA)

Model *Vector Moving Average* (VMA) merupakan perluasan dari model *Moving Average* (MA) yang dirancang untuk menganalisis beberapa deret waktu secara bersamaan. Model ini mencakup sekumpulan persamaan dinamis yang digunakan untuk memperkirakan nilai suatu variabel pada waktu tertentu dengan berdasarkan residual dari variabel itu sendiri atau variabel lain dalam sistem pada periode sebelumnya (Rusyana dkk., 2020). Menurut Wei (2006), bentuk umum model VMA dapat dilihat pada Persamaan (2.2) sebagai berikut:

$$\mathbf{Z}_t = \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \Theta_2 \mathbf{a}_{t-2} - \dots - \Theta_q \mathbf{a}_{t-q} \quad (2.2)$$

dengan:

$$\mathbf{Z}_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner berukuran } N \times 1$$

$$\Theta_1, \dots, \Theta_q = \text{matriks parameter } \textit{moving average} \text{ berukuran } N \times N$$

$$\mathbf{a}_t = [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor } \textit{error} \text{ berukuran } N \times 1$$

### 2.3.3 Model *Vector Autoregressive Moving Average* (VARMA)

Model *Vector Autoregressive Moving Average* (VARMA) merupakan perluasan dari model *Autoregressive Moving Average* (ARMA) yang dirancang untuk menganalisis hubungan antara beberapa deret waktu secara bersamaan. Model ini mencakup serangkaian persamaan dinamis yang digunakan untuk memperkirakan nilai suatu variabel pada waktu tertentu dengan memanfaatkan perubahan dan residual variabel itu sendiri, serta perubahan dan residual dari variabel lain dalam sistem pada periode sebelumnya (Rusyana dkk., 2020). Menurut Wei (2006), bentuk umum model VARMA dapat dilihat pada Persamaan (2.3) sebagai berikut:

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \dots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \dots - \Theta_q \mathbf{a}_{t-q} \quad (2.3)$$

dengan:

$$\begin{aligned}
\mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\
&\quad \text{berukuran } N \times 1 \\
\Phi_1, \dots, \Phi_p &= \text{matriks parameter } \textit{autoregressive} \text{ berukuran } N \times N \\
\Theta_1, \dots, \Theta_q &= \text{matriks parameter } \textit{moving average} \text{ berukuran } N \times N \\
\mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor } \textit{error} \text{ berukuran } N \times 1
\end{aligned}$$

### 2.3.4 Model Vector Autoregressive Integrated Moving Average (VARIMA)

Model *Vector Autoregressive Integrated Moving Average* (VARIMA) merupakan perluasan dari model *Vector Autoregressive Moving Average* (VARMA) yang diperoleh melalui proses *differencing* untuk mengubah data menjadi data stasioner (Rusyana dkk., 2020). Bentuk umum model VARIMA dapat dilihat pada Persamaan (2.4) sebagai berikut (Harvey, 2006):

$$\Delta^d \mathbf{Z}_t = \Phi_1 \Delta^d \mathbf{Z}_{t-1} + \dots + \Phi_p \Delta^d \mathbf{Z}_{t-p} + \mathbf{a}_t - \Theta_1 \mathbf{a}_{t-1} - \dots - \Theta_q \mathbf{a}_{t-q} \quad (2.4)$$

dengan:

$$\begin{aligned}
\mathbf{Z}_t &= [Z_{1,t}, Z_{2,t}, \dots, Z_{N,t}]^T \text{ vektor deret waktu stasioner} \\
&\quad \text{berukuran } N \times 1 \\
\Delta^d &= \text{operator } \textit{differencing} \\
\Phi_1, \dots, \Phi_p &= \text{matriks parameter } \textit{autoregressive} \text{ berukuran } N \times N \\
\Theta_1, \dots, \Theta_q &= \text{matriks parameter } \textit{moving average} \text{ berukuran } N \times N \\
\mathbf{a}_t &= [a_{1,t}, a_{2,t}, \dots, a_{N,t}]^T \text{ vektor } \textit{error} \text{ berukuran } N \times 1
\end{aligned}$$

## 2.4 Uji Asumsi

### 2.4.1 Stasioneritas Data

Stasioneritas adalah kondisi di mana data deret waktu tidak menunjukkan tren naik atau turun. Dalam hal ini, nilai data berfluktuasi di sekitar rata-ratanya dengan varians

yang cenderung konstan dan tidak dipengaruhi oleh waktu tertentu (Makridakis dkk., 1983). Untuk menentukan apakah data bersifat stasioner, dapat dilakukan uji akar unit, salah satunya menggunakan metode *Augmented Dickey-Fuller* (ADF). Uji ADF bertujuan untuk mendeteksi adanya atau tidak adanya akar unit dalam deret waktu. Deret waktu yang stasioner tidak mengandung akar unit, sedangkan deret waktu yang tidak stasioner mengandung akar unit. Prosedur pelaksanaan uji ADF menurut Dickey dan Fuller (1979) sebagai berikut:

1. Hipotesis

$H_0$ : terdapat akar unit (data tidak stasioner)

$H_1$ : tidak terdapat akar unit (data stasioner)

2. Taraf Signifikansi

$\alpha = 5\% = 0,05$

3. Statistik Uji

Uji akar unit ADF menggunakan statistik uji yang ditulis pada Persamaan (2.5) sebagai berikut:

$$ADF_{hitung} = \frac{\hat{\gamma}}{Se(\hat{\gamma})} \quad (2.5)$$

dengan:

$\hat{\gamma}$  = nilai duga parameter *autoregressive*

$Se(\hat{\gamma})$  = standar error dari  $\hat{\gamma}$

4. Kriteria Uji

Tolak  $H_0$  jika statistik uji  $ADF_{hitung} < ADF_{tabel}$  atau  $p\text{-value} < \alpha$

Tidak tolak  $H_0$  jika statistik uji  $ADF_{hitung} > ADF_{tabel}$  atau  $p\text{-value} > \alpha$

5. Keputusan

6. Kesimpulan

Menurut Makridakis dkk. (1983), bahwa jika uji *Augmented Dickey-Fuller* (ADF) menunjukkan bahwa suatu deret waktu tidak stasioner, maka diperlukan transformasi untuk membuat data menjadi stasioner, salah satu caranya melalui proses *differencing*. Bentuk umum proses *differencing* ini dinyatakan dalam Persamaan (2.6) sebagai berikut:

$$\Delta^d Y_t = Y_t - Y_{t-d} \quad (2.6)$$

dengan:

$Y_t$  = pengamatan pada waktu ke- $t$

$Y_{t-d}$  = pengamatan pada waktu ke- $(t - d)$

$d$  = orde *differencing*

### 2.4.2 Residual White Noise

Pengujian asumsi residual bertujuan untuk memastikan bahwa model yang dikembangkan memenuhi persyaratan untuk analisis yang tepat. Salah satu jenis pengujian adalah uji *white noise*, yang bertujuan untuk menentukan apakah residual saling bebas dan tidak menunjukkan pola yang sistematis. Asumsi *white noise* pada residual dapat dievaluasi menggunakan metode *Ljung-Box*. Prosedur pengujian dijelaskan sebagai berikut (Ljung & Box, 1978):

#### 1. Hipotesis

$H_0$ : residual bersifat *white noise*

$H_1$ : residual tidak bersifat *white noise*

#### 2. Taraf Signifikansi

$\alpha = 5\% = 0,05$

#### 3. Statistik Uji

Uji asumsi residual *white noise* menggunakan statistik uji *Ljung-Box* yang ditulis pada Persamaan (2.7) sebagai berikut:

$$Q = n(n + 2) \sum_{k=1}^m \frac{\rho_k^2}{n - k} \quad (2.7)$$

dengan:

$n$  = banyaknya data pengamatan

$\rho_k$  = autokorelasi lag ke- $k$

$k$  = jumlah lag

#### 4. Kriteria Uji

Tolak  $H_0$  jika statistik uji  $Q > \chi_{1-\alpha, m}^2$  atau  $p\text{-value} < \alpha$

Tidak tolak  $H_0$  jika statistik uji  $Q < \chi_{1-\alpha, m}^2$  atau  $p\text{-value} > \alpha$

5. Keputusan
6. Kesimpulan

## 2.5 Machine Learning (ML)

*Machine learning* adalah sistem komputasi yang dirancang untuk belajar secara mandiri tanpa bimbingan langsung dari manusia. Teknologi ini didasarkan pada bidang-bidang seperti statistik, matematika, dan eksplorasi data, sehingga memungkinkan sistem untuk mengidentifikasi pola melalui analisis data tanpa perlu mengubah kode atau memberikan instruksi khusus (Rowan dkk., 2022). *Machine learning* juga dapat dianggap sebagai metode komputasi yang mempelajari pola dari data atau pengalaman untuk meningkatkan kinerja dalam tugas-tugas tertentu serta menghasilkan prediksi yang lebih akurat. Algoritma *machine learning* dikategorikan berdasarkan jenis pengalaman yang diterapkan selama tahap pembelajaran (Alpaydin, 2004):

### 1. Pembelajaran Terawasi

Pembelajaran terawasi (*supervised learning*) adalah metode pembelajaran yang menggunakan data berlabel, di mana setiap *input* dipasangkan dengan *output* atau kategori tertentu. Model dilatih dengan data ini untuk mengenali pola dan membuat prediksi yang akurat pada data baru yang belum pernah dilihat sebelumnya. Data pelatihan ini sangat penting dalam membimbing algoritma selama proses pembelajaran untuk menghasilkan model klasifikasi atau regresi yang optimal (Alpaydin, 2004).

### 2. Pembelajaran Tanpa Pengawasan

Pembelajaran tanpa pengawasan (*unsupervised learning*) adalah proses pembelajaran yang bekerja dengan data yang tidak dilabeli, artinya tidak ada kategori atau *output* yang telah ditentukan sebelumnya. Karena tidak adanya label, algoritma harus secara mandiri menemukan pola, struktur, atau keteraturan dalam data untuk mengelompokkan item ke dalam kelas tertentu. Tujuan utama pendekatan ini adalah untuk mengungkap pola atau hubungan tersembunyi dalam data yang tidak dilabeli (Alpaydin, 2004).

### 3. Pembelajaran Penguatan

Pembelajaran penguatan (*reinforcement learning*) adalah pendekatan pembelajaran di mana agen belajar melalui eksperimen berulang dalam suatu lingkungan dan menerima umpan balik berupa hadiah atau hukuman. Agen secara terus-menerus menyesuaikan perilakunya berdasarkan umpan balik tersebut untuk menemukan strategi terbaik dalam mencapai tujuan. Proses ini sering digunakan dalam sistem pengambilan keputusan otomatis, seperti pada robotika, permainan, dan optimasi proses (Alpaydin, 2004).

#### 2.5.1 *Scaling Data*

*Scaling* data adalah proses yang diterapkan untuk mengubah nilai numerik dalam suatu *dataset* ke dalam skala yang lebih konsisten. Metode ini bertujuan untuk mengurangi risiko kesalahan atau ketidakkonsistenan data serta menyederhanakan kompleksitas tanpa mengubah sifat nilai asli. Proses ini sangat penting untuk mempercepat dan menstabilkan proses pembelajaran dalam *machine learning*. Salah satu metode yang sering digunakan adalah *min-max scaler*, terutama jika data memiliki rentang nilai yang luas. Teknik ini mengubah nilai setiap fitur dari rentang aslinya menjadi interval  $[0, 1]$ , sehingga setiap fitur dapat berkontribusi secara lebih merata selama proses pelatihan (Zhang dkk., 2021). Rumus untuk *min-max scaler* tercantum dalam Persamaan (2.8) sebagai berikut:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.8)$$

dengan:

- $x'$  = nilai hasil *scaling*
- $x$  = nilai data aktual
- $x_{\min}$  = nilai minimum data aktual
- $x_{\max}$  = nilai maksimum data aktual

### 2.5.2 Unscaling Data

*Unscaling* data adalah proses mengembalikan nilai prediksi ke skala aslinya agar sesuai dengan kondisi sebenarnya (Latifa dkk., 2022). Langkah ini penting karena pada tahap *preprocessing*, data telah melalui proses *scaling* untuk meningkatkan kinerja model. Oleh karena itu, *output* prediksi masih berada dalam skala yang telah ditransformasi. Dengan demikian, proses *unscaling* diperlukan untuk mengembalikan nilai-nilai tersebut ke skala aslinya, sehingga memungkinkan perbandingan dengan data asli dan penilaian model yang lebih akurat. Persamaan *unscaling* untuk metode *min-max scaler* dapat dilihat pada Persamaan (2.9) sebagai berikut:

$$x_i = y_i (\max(x) - \min(x)) + \min(x) \quad (2.9)$$

dengan:

- $x_i$  = nilai data aktual
- $y_i$  = nilai hasil *output*
- $\min(x)$  = data dengan nilai minimum
- $\max(x)$  = data dengan nilai maksimum

### 2.5.3 Fungsi Aktivasi

Fungsi aktivasi berperan sebagai elemen kunci dalam jaringan saraf tiruan, yang bertugas mengubah berbagai jenis *input* menjadi *output* tertentu. Data masuk ke jaringan saraf tiruan melalui lapisan *input*, di mana fungsi aktivasi menentukan apakah suatu neuron akan aktif atau tidak. Oleh karena itu, efektivitas jaringan saraf tiruan sangat bergantung pada bobot dan korelasi antara *input* dan *output* yang dihasilkan oleh fungsi aktivasi (Pratiwi dkk., 2020). Mekanisme ini memungkinkan transformasi data yang semula bersifat nonlinear menjadi bentuk yang lebih linear, sehingga memudahkan pemrosesan pada lapisan berikutnya dalam jaringan. Berikut adalah beberapa jenis fungsi aktivasi yang dapat diterapkan:

#### 1. Fungsi *Sigmoid*

Fungsi *sigmoid* adalah salah satu jenis fungsi aktivasi yang digunakan untuk memperbarui data (Ivan & Purmono, 2022). Fungsi ini menerima *input* berupa

bilangan real dan menghasilkan *output* dalam rentang 0 hingga 1. Persamaan fungsi *sigmoid* ditunjukkan dalam Persamaan (2.10) sebagai berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.10)$$

dengan:

$e$  = bilangan *euler*

$x$  = data

## 2. Fungsi *Tanh*

Fungsi *tanh* berfungsi sebagai alat untuk menciptakan vektor nilai baru (Ivan & Purmono, 2022). Fungsi ini dapat menerima bilangan real apa pun sebagai *input* dan menghasilkan *output* yang berkisar antara  $-1$  hingga  $1$ . Rumus fungsi *tanh* disajikan dalam Persamaan (2.11) sebagai berikut:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.11)$$

dengan:

$e$  = bilangan *euler*

$x$  = data

## 2.6 Deep Learning (DL)

*Deep learning* merupakan perkembangan dari *machine learning* yang menggunakan jaringan saraf tiruan dengan setidaknya tiga lapisan, sehingga memungkinkan model untuk belajar dari jumlah data yang besar dan menangani permasalahan kompleks yang sulit dipecahkan oleh algoritma *machine learning* konvensional (Rowan dkk., 2022). Model-model ini terdiri dari lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Salah satu keunggulan utama *deep learning* adalah kemampuannya untuk mentransformasikan data nonlinear menjadi representasi yang lebih linear melalui proses transformasi bertahap pada lapisan tersembunyi (Putra dkk., 2022). Algoritma *deep learning* sering diterapkan dalam analisis pola dan klasifikasi, terutama untuk data gambar, suara, teks, serta deret waktu.

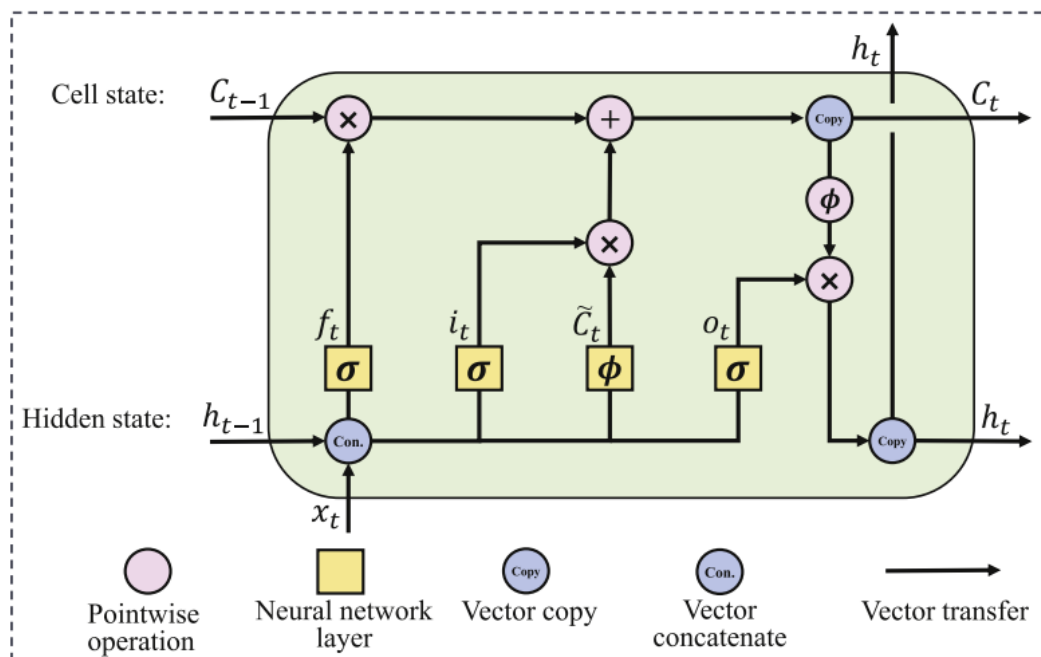
### 2.6.1 *Recurrent Neural Network (RNN)*

Model *Recurrent Neural Network (RNN)* merupakan jenis jaringan saraf tiruan yang mampu mendeteksi hubungan tersembunyi dalam data, terutama untuk aplikasi seperti pengenalan suara, pemrosesan bahasa alami, dan peramalan deret waktu. Keunggulan utama model ini terletak pada kemampuannya untuk memodelkan data berurutan, karena RNN dapat memproses informasi secara bertahap sambil mempertahankan jejak langkah-langkah sebelumnya melalui koneksi rekurensinya (Tian dkk., 2018). Dengan demikian, model RNN dapat menghasilkan prediksi dengan mempertimbangkan tidak hanya *input* pada waktu tertentu, tetapi juga *input* dari periode sebelumnya. Model RNN terdiri dari tiga komponen utama, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Arsitektur ini dirancang agar informasi mengalir dalam satu arah, mulai dari lapisan masukan ke lapisan tersembunyi sebelumnya, kemudian ke lapisan tersembunyi saat ini. Namun demikian, RNN konvensional memiliki keterbatasan dalam menyimpan informasi jangka panjang akibat masalah *vanishing gradient* (Tian dkk., 2018).

Untuk mengatasi keterbatasan tersebut, dikembangkan varian khusus dari *Recurrent Neural Network (RNN)*, yaitu *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)*. Kedua model ini dirancang untuk meningkatkan stabilitas pembelajaran serta efektivitas RNN dalam memproses data berurutan. LSTM menyediakan mekanisme kontrol memori yang lebih komprehensif melalui tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang memungkinkan proses seleksi dan penyimpanan informasi secara lebih mendalam. Struktur gerbang yang lebih kompleks ini membantu LSTM mempertahankan dan memperbarui informasi penting dalam jangka waktu yang lebih panjang, sehingga sangat efektif dalam menangani ketergantungan jangka panjang. Di sisi lain, GRU dirancang sebagai model yang lebih sederhana dengan hanya dua gerbang, sehingga memiliki beban komputasi yang lebih rendah. Meskipun GRU dapat bersaing dengan kinerja LSTM dalam beberapa kondisi, arsitekturnya yang lebih sederhana sering kali membuatnya kurang optimal dalam mempelajari pola ketergantungan jangka panjang yang kompleks. Oleh karena itu, LSTM lebih sering dipilih dalam berbagai studi dan aplikasi yang memerlukan akurasi tinggi serta pemodelan hubungan temporal yang lebih mendalam (Greff dkk., 2017).

### 2.6.2 Long Short-Term Memory (LSTM)

*Long Short-Term Memory* (LSTM) diakui sebagai jenis jaringan saraf tiruan yang menawarkan fleksibilitas tinggi dalam penyesuaian, memungkinkan strukturnya disesuaikan dengan berbagai persyaratan aplikasi (Sanjaya & Heksaputra, 2020). LSTM merupakan pengembangan *Recurrent Neural Network* (RNN) untuk mengatasi masalah gradien yang menghilang (Hochreiter & Schmidhuber, 1997). Masalah gradien yang menghilang ini dapat menyebabkan proses pembelajaran berjalan sangat lambat atau bahkan berhenti sepenuhnya (Yadav dkk., 2020). Untuk mengatasi hal ini, LSTM memperkenalkan komponen sel memori (*memory cell*) yang menyimpan informasi dalam periode waktu tertentu, serta tiga jenis gerbang (*gate*), yaitu *forget gate*, *input gate*, dan *output gate*, yang mengontrol aliran informasi masuk dan keluar dari sel memori. Mekanisme ini memungkinkan LSTM menangkap ketergantungan jangka panjang secara lebih efisien (Minaee dkk., 2020). Arsitektur LSTM ditampilkan pada Gambar 1 di bawah ini:



Gambar 1. Arsitektur LSTM (Luo dkk., 2021).

Menurut penelitian oleh Luo dkk. (2021), model *Long Short-Term Memory* (LSTM) dapat mengelola aliran data masuk dan keluar dari sel memori (*cell state*) dengan presisi melalui mekanisme lapisan gerbang (*gate*). Ada empat komponen utama (tiga lapisan gerbang (*gate*) dan satu lapisan *tanh*) yang mengatur aliran informasi dalam

## LSTM.

1. *Forget Gate*

Gerbang pertama, yang disebut *forget gate*, bertujuan untuk menentukan bagian mana dari informasi dari langkah sebelumnya yang harus dibuang. Gerbang ini menggunakan fungsi aktivasi *sigmoid*, sehingga outputnya yang dilambangkan sebagai  $f_t$ , berkisar antara 0 hingga 1 (Le dkk., 2019). Nilai ini menunjukkan sejauh mana informasi sebelumnya akan disimpan atau dihapus dari sel memori. Jika nilai mendekati 1, informasi cenderung dipertahankan sepenuhnya, sementara nilai mendekati 0 menunjukkan bahwa informasi akan dihapus sepenuhnya. Berikut disajikan Persamaan (2.12) yang menggambarkan cara kerja *forget gate*:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (2.12)$$

dengan:

$$f_t = \text{Forget gate}$$

$$\sigma = \text{Fungsi sigmoid}$$

$$W_f = \text{Nilai bobot untuk forget gate}$$

$$h_{t-1} = \text{Nilai output sebelum orde ke-}t$$

$$X_t = \text{Nilai input pada orde ke-}t$$

$$b_f = \text{Nilai bias pada forget gate}$$

2. *Input Gate*

Gerbang masukan (*input gate*) berfungsi sebagai gerbang yang memutuskan dan menyimpan informasi dari masukan baru ( $X_t$ ) ke dalam keadaan sel (*cell state*), serta memperbaiki keadaan tersebut. Proses ini melibatkan dua elemen utama, yaitu lapisan *sigmoid* dan lapisan *tanh*. Lapisan *sigmoid* pertama-tama menilai apakah informasi baru perlu diperbarui atau diabaikan (nilai 0 atau 1), sementara fungsi *tanh* memberi bobot pada nilai yang diterima, menunjukkan tingkat signifikansinya (rentang -1 hingga 1) (Le dkk., 2019). Persamaan (2.13) dan (2.14) yang terkait dengan *input gate* sebagai berikut:

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (2.13)$$

$$\tilde{C}_t = \varphi(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (2.14)$$

dengan:

$i_t$  = *Input gate*

$\tilde{C}_t$  = Nilai baru yang ditambahkan ke *cell state*

$\sigma$  = Fungsi *sigmoid*

$\varphi$  = Fungsi tangen hiperbolik

$W_i$  = Nilai bobot untuk *input gate*

$W_c$  = Nilai bobot untuk *cell gate*

$h_{t-1}$  = Nilai *output* sebelum orde ke- $t$

$X_t$  = Nilai *input* pada orde ke- $t$

$b_i$  = Nilai bias pada *input gate*

$b_c$  = Nilai bias pada *cell gate*

Selanjutnya, *cell state* sebelumnya diperbarui menjadi *cell state* baru dengan mengalikannya dengan hasil dari *forget gate* ( $f_t$ ), yang memungkinkan penghapusan informasi yang tidak lagi diperlukan. Kemudian, hasil perkalian ditambahkan dengan  $i_t \cdot \tilde{C}_t$ , yang merupakan data baru untuk memperbarui *cell state* (Le dkk., 2019). Berikut Persamaan (2.15) yang menggambarkan proses pembaruan *cell state*:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.15)$$

dengan:

$C_t$  = *Cell state*

$f_t$  = *Forget gate*

$C_{t-1}$  = *Cell state* sebelum orde ke- $t$

$i_t$  = *Input gate*

$\tilde{C}_t$  = Nilai baru yang dapat ditambahkan ke *cell state*

### 3. *Output Gate*

Gerbang terakhir dalam arsitektur LSTM dikenal sebagai *output gate*, yang bertugas menghasilkan nilai keluaran berdasarkan *cell state* yang telah diperbarui. *Cell state* ini terlebih dahulu diproses melalui fungsi aktivasi *tanh*, kemudian dikalikan dengan hasil dari *sigmoid gate* sehingga keluaran yang dihasilkan sesuai dengan keputusan yang diambil pada langkah sebelumnya

(Le dkk., 2019). Berikut Persamaan (2.16) yang menunjukkan rumus untuk *output gate*.

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) * \varphi(C_t) \quad (2.16)$$

dengan:

- $o_t$  = *Output gate*
- $\sigma$  = Fungsi *sigmoid*
- $W_o$  = Nilai bobot untuk *output gate*
- $h_{t-1}$  = Nilai *output* sebelum orde ke- $t$
- $X_t$  = Nilai *input* pada orde ke- $t$
- $b_o$  = Nilai bias pada *output gate*
- $C_t$  = *Cell state*
- $\varphi$  = Fungsi tangen hiperbolik

### 2.6.3 Hyperparameter

Dalam bidang *machine learning* dan algoritma *deep learning*, terdapat berbagai konfigurasi spesifik yang berfungsi untuk mengatur proses pembelajaran, yang dikenal sebagai *hyperparameter*. *Hyperparameter* adalah elemen yang tidak dapat dipelajari secara mandiri oleh algoritma, sehingga nilainya harus ditetapkan secara manual sebelum tahap pelatihan dimulai. Nilai *hyperparameter* dapat ditentukan menggunakan pendekatan pembelajaran bertingkat, di mana satu algoritma digunakan untuk menyempurnakan pemilihan *hyperparameter* dalam algoritma lain (Goodfellow dkk., 2016). Penyesuaian *hyperparameter tuning* memainkan peran krusial karena secara langsung memengaruhi efektivitas model dan membantu mencapai hasil optimal (Putra dkk., 2022). Beberapa *hyperparameter* dalam *deep learning* meliputi jumlah *hidden layer*, jumlah *hidden neuron per-layer*, *batch size*, *epoch*, *dropout*, *optimizer*, dan *learning rate*.

## 2.7 Hybrid VARIMA-LSTM

Model *hybrid* merupakan sistem yang menggabungkan dua atau lebih model menjadi satu kesatuan untuk meningkatkan efektivitas kinerja. Salah satu contohnya adalah kombinasi model VARIMA dan LSTM. Dalam penelitian ini, VARIMA umumnya diterapkan untuk menangani pola linear, seperti ketergantungan antar variabel dan struktur autokorelasi, sementara LSTM digunakan untuk pola nonlinear dan situasi di mana masalah kompleks tidak dapat dimodelkan secara linear.

Menurut Zhang (2003), pembentukan model *hybrid* didorong oleh beberapa pertimbangan utama, sebagai berikut:

1. Karakteristik data yang dapat bersifat linear atau nonlinear. Dalam banyak aktivitas peramalan, sulit untuk menentukan apakah suatu rangkaian waktu bersifat linear atau nonlinear. Hal ini mendorong peneliti untuk menerapkan lebih dari satu model, kemudian membandingkan atau mengintegrasikannya untuk mendapatkan hasil yang lebih akurat. Oleh karena itu, menggabungkan berbagai model, seperti VARIMA dan LSTM, menjadi solusi yang relevan.
2. Data deret waktu yang sepenuhnya linear atau nonlinear jarang ditemukan. Sebagian besar data merupakan kombinasi dari kedua sifat tersebut. Penerapan model tunggal tidak efektif karena tidak dapat menangkap pola gabungan yang ada.
3. Tidak ada model tunggal yang cocok untuk semua jenis data atau kondisi. Dalam praktiknya, data seringkali kompleks dan beragam, sehingga sulit ditangani dengan pendekatan tunggal. Oleh karena itu, menggabungkan model menawarkan pendekatan yang lebih fleksibel dan efisien untuk meningkatkan akurasi peramalan.

Model ini memudahkan pemrosesan data skala besar secara lebih efisien, yang pada akhirnya meningkatkan akurasi perkiraan. Hasil penelitian empiris menunjukkan bahwa kombinasi model secara konsisten memberikan akurasi yang lebih tinggi daripada model tunggal. Seperti yang dijelaskan dalam Persamaan (2.17) di bawah ini (Zhang, 2003), model gabungan untuk deret waktu biasanya mencakup dua komponen utama, yaitu komponen linear dan nonlinear:

$$Y_t = NL_t + a_t \quad (2.17)$$

dengan:

- $Y_t$  = nilai aktual pada periode ke- $t$   
 $L_t$  = komponen linear pada periode ke- $t$   
 $NL_t$  = komponen nonlinear pada periode ke- $t$   
 $a_t$  = *error*

Model *hybrid* VARIMA-LSTM diterapkan melalui dua langkah utama. Langkah pertama melibatkan penggunaan model VARIMA untuk mendeteksi pola linear dalam data multivariat. Langkah kedua melibatkan penggunaan model LSTM, yang umumnya diperoleh dari residual VARIMA, untuk menangkap pola nonlinear. Secara matematis, rumus model *hybrid* VARIMA-LSTM dapat disajikan sebagai berikut (Zhang, 2003):

$$Y'_t = L'_t + NL'_t \quad (2.18)$$

dengan:

- $Y'_t$  = nilai peramalan dari model *hybrid* pada periode- $t$   
 $L'_t$  = nilai peramalan dari komponen linear pada periode- $t$   
 $NL'_t$  = nilai peramalan dari komponen nonlinear pada periode- $t$

## 2.8 Evaluasi Model

Evaluasi model dilakukan untuk menilai akurasi prediksi dengan membandingkannya dengan data observasi atau nilai aktual. Kinerja model dapat diukur menggunakan berbagai indikator, seperti *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE) (Latifa dkk., 2022).

### 1. *Mean Absolute Percentage Error* (MAPE)

*Mean Absolute Percentage Error* (MAPE) digunakan untuk mengevaluasi akurasi model prediksi dengan mengukur kesalahan persentase relatif terhadap nilai aktual. Nilai ini dihitung melalui rata-rata kesalahan absolut selama periode waktu tertentu, yang kemudian dikalikan dengan 100% untuk mendapatkan pengukuran dalam bentuk persentase (Latifa dkk., 2022). Rumus standar untuk menghitung MAPE ditunjukkan dalam Persamaan (2.19) di

bawah ini:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \times 100\% \quad (2.19)$$

dengan:

$n$  = jumlah periode yang diprediksi

$Y_t$  = nilai aktual pada periode- $t$

$\hat{Y}_t$  = nilai prediksi pada periode- $t$

## 2. *Root Mean Square Error (RMSE)*

*Root Mean Square Error (RMSE)* berfungsi sebagai indikator untuk mengukur besarnya kesalahan dalam hasil prediksi. Indikator ini mengukur selisih antara nilai aktual dan nilai prediksi, kemudian menghitung rata-rata kuadrat selisih tersebut, dan akhirnya mengambil akar kuadratnya (Latifa dkk., 2022). Rumus standar untuk menghitung RMSE ditunjukkan dalam Persamaan (2.20) di bawah ini:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{Y}_t - Y_t)^2} \quad (2.20)$$

dengan:

$n$  = jumlah periode yang diprediksi

$Y_t$  = nilai aktual pada periode- $t$

$\hat{Y}_t$  = nilai prediksi pada periode- $t$

## 2.9 *Goodness of Fit*

*Goodness of fit* adalah metode statistik yang bertujuan untuk mengevaluasi seberapa baik distribusi teoretis dapat mewakili pola data yang diamati. Salah satu pendekatan kesesuaian yang sering digunakan adalah uji *Kolmogorov-Smirnov (KS)*. Uji ini mengukur perbedaan maksimum antara fungsi distribusi kumulatif data empiris dan fungsi distribusi kumulatif distribusi teoretis yang digunakan sebagai acuan. Statistik uji KS diformulasikan dalam Persamaan (2.21) sebagai berikut (Kolmogorov, 1933):

$$KS = \max |F_n(x) - F(x)| \quad (2.21)$$

dengan:

$KS$  = statistik uji *Kolmogorov-Smirnov*

$F_n(x)$  = fungsi distribusi kumulatif empiris

$F(x)$  = fungsi distribusi kumulatif teoritis

max = nilai maksimum dari perbedaan antara distribusi

## **BAB III**

### **METODOLOGI PENELITIAN**

#### **3.1 Waktu dan Tempat Penelitian**

##### **3.1.1 Tempat Penelitian**

Penelitian ini menggunakan pendekatan studi literatur dan dilaksanakan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, yang berlokasi di Jalan Prof. Sumantri Brojonegoro No. 1, Gedong Meneng, Bandar Lampung.

##### **3.1.2 Waktu Penelitian**

Penelitian ini dilakukan pada semester ganjil tahun akademik 2025/2026, dengan kegiatan dimulai pada bulan September 2025. Penelitian ini dibagi menjadi tiga tahap utama. Tahap awal dimulai dengan tinjauan pustaka, yang meliputi pengumpulan jurnal dan buku yang berkaitan dengan topik penelitian, dan digunakan sebagai referensi dalam penyusunan proposal hingga tahap akhir. Tahap berikutnya melibatkan pengumpulan data sebagai bahan penelitian dan penyusunan desain proposal awal. Tahap kedua mencakup pengembangan program, termasuk pra-pemrosesan data, pembentukan model VARIMA, pemisahan data, pembentukan model *hybrid* VARIMA-LSTM, dan penilaian kinerja model. Tahap akhir penelitian ini berfokus pada penyusunan hasil uji coba dan analisis dalam bentuk draf laporan, yang akan dipresentasikan pada seminar hasil dan ujian komprehensif.

## 3.2 Data dan Alat

### 3.2.1 Data Penelitian

Penelitian ini menggunakan data sekunder berupa harga emas dunia, yang diperoleh dari situs web <https://finance.yahoo.com/quote/GC%3DF/history/>. Data tersebut mencakup periode dari 4 Januari 2021 hingga 17 Oktober 2025, dengan total 1.212 pengamatan. Variabel yang digunakan terdiri dari empat variabel, yaitu *Open*, *High*, *Low*, dan *Close*, yang disajikan dalam Tabel 2 sebagai berikut:

Tabel 2. Data Harga Emas Dunia

<i>Date</i>	<i>Open</i>	<i>High</i>	<i>Low</i>	<i>Close</i>
2021-01-04	1.912,20	1.945,10	1.912,20	1.944,70
2021-01-05	1.941,70	1.952,70	1.941,30	1.952,70
2021-01-06	1.952,00	1.959,90	1.901,50	1.906,90
2021-01-07	1.922,60	1.926,70	1.912,00	1.912,30
2021-01-08	1.908,00	1.908,00	1.834,10	1.834,10
⋮	⋮	⋮	⋮	⋮
2025-10-17	4.354,70	4.358,00	4.182,20	4.189,90

### 3.2.2 Alat Penelitian

Adapun alat yang digunakan dalam penelitian ini yaitu sebagai berikut:

#### 1. Perangkat keras (*hardware*)

Perangkat keras yang digunakan pada penelitian ini yaitu:

- *Processor*: Intel(R) Celeron(R) N5100 @ 1.10GHz (4 CPUs), 1.1 GHz
- *Installed RAM*: 4096MB

#### 2. Perangkat lunak (*Software*)

Perangkat lunak yang digunakan dalam penelitian ini adalah sebagai berikut:

- Sistem Operasi Windows 10 Pro 64-bit
- *Google Colaboratory*

Adapun *package* yang digunakan dalam penelitian ini yang terdiri dari sebagai berikut:

- *TensorFlow* 2.12.0  
*TensorFlow* memainkan peran penting dalam berbagai aspek pemodelan *hybrid*, seperti penerapan model *machine learning* terbaru, pemrosesan data, dan pelatihan jaringan saraf.
- *Scikit-learn* 1.2.2  
*Scikit-learn* digunakan dalam pemrosesan data, evaluasi model, dan penentuan *hyperparameter*.
- *NumPy* 1.23.5  
*NumPy* berfungsi sebagai alat untuk melakukan operasi matematis pada data numerik.
- *Pandas* 1.5.3  
*Pandas* digunakan untuk mengonversi data ke format *datetime* dan analisis data.
- *Matplotlib* 3.7.1  
*Matplotlib* digunakan untuk membuat berbagai jenis grafik dan visualisasi data, termasuk grafik garis, diagram pencar, histogram, diagram batang, dan jenis lainnya.
- *Statsmodels* 0.14.0  
*Statsmodels* adalah *package* yang menyediakan berbagai alat untuk pemodelan statistik dan pengujian hipotesis.

### 3.3 Metode Penelitian

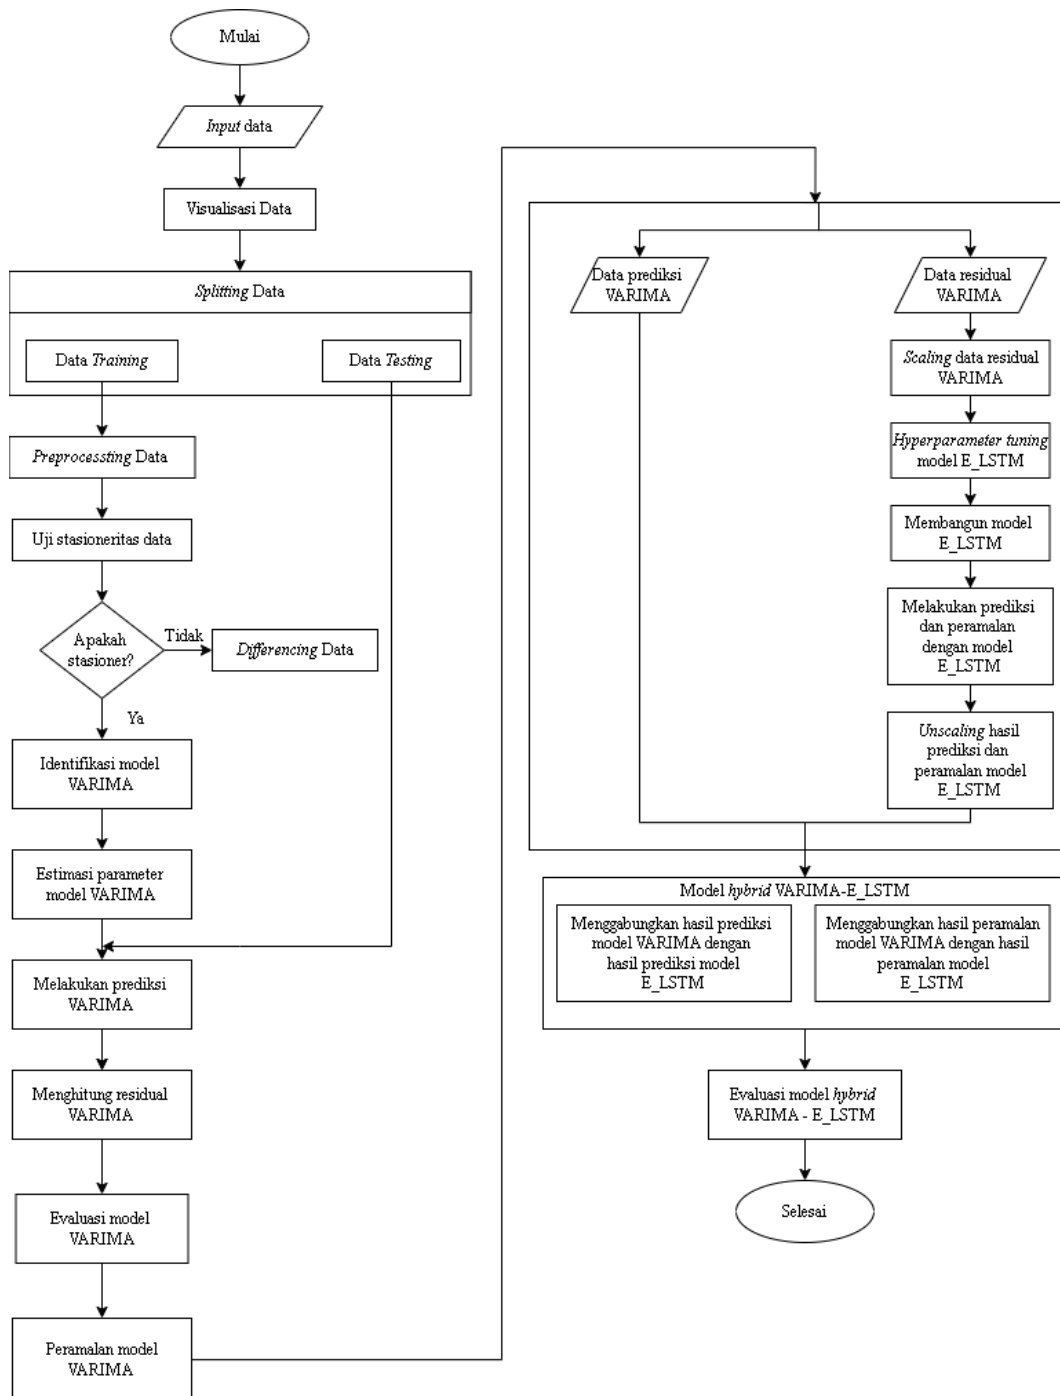
Langkah-langkah yang diterapkan dalam proses peramalan harga emas dunia menggunakan model *hybrid* VARIMA-LSTM dalam penelitian ini adalah sebagai berikut:

1. Menginput data ke dalam bahasa pemrograman *Python* melalui platform *Google Colaboratory*.
2. Membuat visualisasi data untuk mengamati pola tren dan variasi harian harga emas dunia berdasarkan komponen *Open*, *High*, *Low*, dan *Close*.

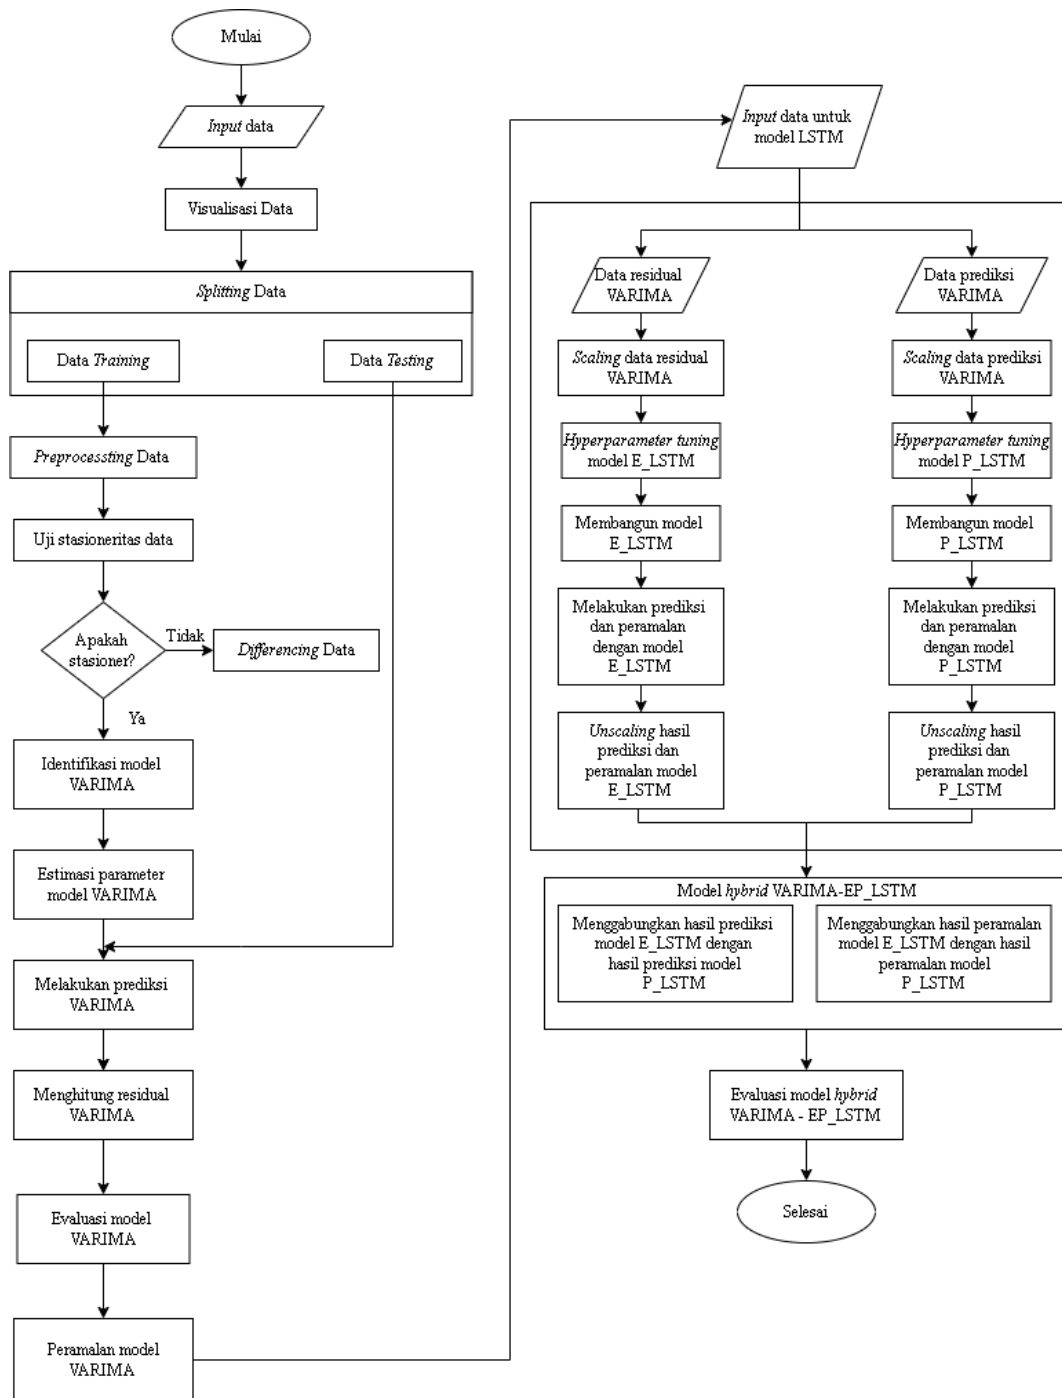
3. Membagi (*splitting*) data menjadi data *training* dan data *testing* dengan rasio 80% untuk *training* dan 20% untuk *testing*. Rasio ini dipilih karena 80% data cukup untuk menangkap pola dan kompleksitas, sementara 20% sisanya mewakili data baru untuk mengevaluasi kinerja model. Pendekatan ini juga membantu menjaga keseimbangan agar model tidak mengalami *overfitting* atau *underfitting*, sehingga efektif pada data yang tidak dikenal.
4. Melakukan *preprocessing* pada data *training*, yang meliputi pengecekan nilai yang hilang (*missing value*) dan analisis korelasi antara variabel harga emas dunia (*Open, High, Low, Close*).
5. Menguji stasioneritas data menggunakan uji *Augmented Dickey-Fuller* (ADF). Jika data tidak stasioner, dilakukan proses *differencing* hingga stasioneritas tercapai.
6. Identifikasi struktur model VARIMA melalui analisis *lag* signifikan berdasarkan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), serta urutan *differencing* untuk membuat data menjadi stasioner.
7. Estimasi parameter model VARIMA menggunakan metode *Maximum Likelihood Estimation* (MLE). Model terbaik kemudian dipilih berdasarkan nilai *Bayesian Information Criterion* (BIC) terendah. Kriteria BIC dipilih karena memberikan penalti yang lebih besar terhadap model yang lebih rumit dibandingkan kriteria lain seperti *Akaike Information Criterion* (AIC), sehingga mengurangi risiko *overfitting* dan mendorong pemilihan model yang lebih sederhana tetapi tetap akurat dalam prediksinya.
8. Memprediksi harga emas dunia pada data *training* dan *testing* menggunakan model VARIMA terbaik.
9. Menghitung residual dari hasil prediksi VARIMA, lalu menguji asumsi residual *white noise* dengan uji *Ljung-Box*.
10. Mengevaluasi model VARIMA dengan menghitung nilai RMSE, MAPE, dan akurasi.
11. Meramalkan harga emas dunia menggunakan model VARIMA.
12. Mempersiapkan residual dari model VARIMA sebagai *input* untuk model *Error LSTM* (E\_LSTM), dan mempersiapkan nilai prediksi VARIMA sebagai *input* untuk model *Prediction LSTM* (P\_LSTM).

13. Melakukan *scaling* data pada residual dan prediksi VARIMA menggunakan metode *Min-Max Scaler*.
14. Menyesuaikan *hyperparameter tuning* pada model E\_LSTM dan P\_LSTM.
15. Membangun model E\_LSTM dan P\_LSTM dengan parameter optimal yang diperoleh dari penyesuaian *hyperparameter tuning*.
16. Melakukan prediksi dan peramalan menggunakan model E\_LSTM dan P\_LSTM.
17. Mengembalikan (*unscaling*) hasil prediksi dan peramalan yang dihasilkan oleh model E\_LSTM dan P\_LSTM ke skala aslinya.
18. Menggabungkan hasil prediksi dan peramalan dari model VARIMA dengan model E\_LSTM melalui penjumlahan untuk membentuk model *hybrid* VARIMA–E\_LSTM, dan menggabungkan hasil prediksi dari model E\_LSTM dan P\_LSTM untuk menciptakan model *hybrid* VARIMA–EP\_LSTM.
19. Evaluasi kinerja model *hybrid* VARIMA–E\_LSTM dan VARIMA–EP\_LSTM dengan menghitung nilai RMSE, MAPE, dan akurasi.

Flowchart peramalan dengan model *hybrid* VARIMA-LSTM sebagai berikut:



Gambar 2. Flowchart Model Hybrid VARIMA-E\_LSTM.



Gambar 3. Flowchart Model Hybrid VARIMA–EP\_LSTM.

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan hasil dan analisis peramalan harga emas dunia, dengan mempertimbangkan variabel *Open*, *High*, *Low*, dan *Close* menggunakan model *hybrid* VARIMA–LSTM, dapat ditarik kesimpulan sebagai berikut:

1. Model *hybrid* VARIMA–LSTM yang diterapkan untuk peramalan dibangun melalui dua pendekatan. Model *hybrid* VARIMA–E\_LSTM dibentuk dengan menggabungkan hasil peramalan model VARIMA dan model E\_LSTM (dengan nilai residual model VARIMA sebagai data *input*). Sementara itu, model *hybrid* VARIMA–EP\_LSTM dibangun dengan menggabungkan model E\_LSTM (berdasarkan nilai residual model VARIMA sebagai data *input*) dan model P\_LSTM (berdasarkan hasil prediksi model VARIMA sebagai data *input*). Komponen LSTM dalam kedua pendekatan dibangun menggunakan konfigurasi parameter optimal yang diperoleh melalui proses penyesuaian *hyperparameter tuning*, dengan rincian sebagai berikut:
  - (a) Model E\_LSTM, yang dibangun dengan parameter terbaik berupa 32 *unit* LSTM, 64 *dense unit*, 64 *batch size*, dan 0, 2 *dropout*.
  - (b) Model P\_LSTM, yang dibangun dengan parameter terbaik berupa 64 *unit* LSTM, 32 *dense unit*, dan 32 *batch size*.
2. Peramalan harga emas dunia, yang mencakup variabel *Open*, *High*, *Low*, dan *Close*, telah dilakukan untuk 30 hari ke depan (20 Oktober 2025 hingga 30 November 2025) menggunakan model VARIMA, model *hybrid* VARIMA–E\_LSTM, dan model *hybrid* VARIMA–EP\_LSTM. Hasil peramalan menunjukkan perbedaan yang mencolok dibandingkan dengan model VARIMA dan model *hybrid* VARIMA–E\_LSTM. Peramalan yang dihasilkan

oleh model VARIMA hanya menggambarkan pola linear sepanjang periode tersebut, sehingga gagal menyesuaikan dengan fluktuasi data terbaru. Situasi serupa juga terjadi pada hasil peramalan model *hybrid* VARIMA–E.LSTM, yang mirip dengan *output* model VARIMA secara independen. Selanjutnya, model *hybrid* VARIMA–EP.LSTM berhasil menangkap pola dan tren pergerakan harga emas dunia sambil mempertahankan kualitas evaluasi terbaik.

3. Berdasarkan uji *Goodness of Fit* menggunakan uji *Kolmogorov–Smirnov*, model *hybrid* VARIMA–EP.LSTM menunjukkan nilai statistik KS terendah dibandingkan dengan model VARIMA dan model *hybrid* VARIMA–E.LSTM, terutama dalam konteks peramalan harga emas dunia. Hal ini menunjukkan bahwa model *hybrid* VARIMA–EP.LSTM memiliki kemampuan terbaik untuk menyesuaikan distribusi hasil peramalan dengan distribusi data *update*. Oleh karena itu, dapat disimpulkan bahwa model *hybrid* VARIMA–EP.LSTM menunjukkan kinerja terbaik dalam peramalan dibandingkan dengan model VARIMA dan model *hybrid* VARIMA–E.LSTM.

## DAFTAR PUSTAKA

- Agusta, A., Ernawati, I., & Muliawati, A. 2021. Prediksi Pergerakan Harga Saham pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory. *Informatik: Jurnal Ilmu Komputer*. **17**(2): 164–173.
- Alpaydin, E. 2004. *Introduction to Machine Learning*. MIT Press.
- Baur, D. G., & McDermott, T. K. 2010. Is Gold a Safe Haven? International Evidence. *Journal of Banking & Finance*. **34**(8): 1886–1898.
- Bayu Aji, A., & Suriandari, I. 2020. Hybrid Vector Autoregression-Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price. *IOP Conference Series: Materials Science and Engineering*. **909**(1).
- Box, GE. Jenkins, GM, Reinsel, GC, & Ljung, GM. 2015. *Analisis Deret Waktu: Peramalan dan Pengendalian*. John Wiley & Sons.
- Caliwag, AC, & Lim, W. 2019. Metode Hibrida VARMA dan LSTM untuk Peramalan Status Pengisian dan Tegangan Keluaran Baterai Litium-Ion pada Aplikasi Sepeda Motor Listrik. *IEEE Access*. **7**: 59680–59689.
- Dickey, D. A., & Fuller, W. A. 1979. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*. **74**(366): 427–431.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. *Deep Learning*. The MIT Press, London.
- Greff, K., Srivastava, R. K., Koutnik, J., Steunebrink, B. R., & Schmidhuber, J. 2017. LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*. **28**(10): 2222–2232.
- Harvey, A. 2006. Forecasting with Unobserved Components Time Series Models. *Handbook of Economic Forecasting*. **1**(7): 327–412.
- Hochreiter, S., & Schmidhuber, J. 1997. Long Short-Term Memory. *Neural Computation*. **9**(8): 1735–1780.
- Ivan, E. & Purmono, H. D. 2022. Forecasting Prices of Fertilizer Raw Materials Using Long Short-Term Memory. *Jurnal Teknik Informatika (Jutif)*. **3**(6): 1663–1673.

- Jusmawati, J., Hadiat, M., & Fitriyani, N. 2020. Penerapan Model Vector Autoregressive Integrated Moving Average dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia. *EIGEN Mathematics Journal*. 73–82.
- Kolmogorov, A. 1933. Sulla Determinazione Empirica di una Legge di Distribuzione. *Giornale dell'Istituto Italiano degli Attuari*. **4**: 89–91.
- Latifa, T., Buana, P. W., & Rusiyanto, N. K. D. 2022. Model Prediksi Cuaca Menggunakan Metode LSTM. *Jurnal Ilmu Teknologi dan Komputer (JITTER)*. **3**(1): 994–1000.
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. 2019. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water*. **11**(7): 1–19.
- Ljung, G. M. & Box, G. E. P. 1978. On a Measure of Lack of Fit in Time Series Models. *Biometrika*. **65**(2): 297–303.
- Luo, X., Zhang, D., & Zhu, X. 2021. Deep Learning-Based Forecasting of Photovoltaic Power Generation by Incorporating Domain Knowledge. *Energy*. **225**.
- Lütkepohl, H. 2005. *New Introduction to Multiple Time Series Analysis*. Springer.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. 1983. *Forecasting: Methods and Applications*. Second Edition. John Wiley & Sons, New York.
- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. 2020. *Deep Learning-Based Text Classification: A Comprehensive Review*. **1**(1): 1–43.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. Second Edition. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Pratiwi, H., Windarto, A. P., Susilansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., & Rahadiang, I. 2020. Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks. *Journal of Physics: Conference Series*. **1471**(1): 1–7.
- Putra, T. I. Z. M., Suprpto, & Rukhoni, A. F. 2022. Model Klasifikasi Berbasis Multiclass Classification dengan Kombinasi IndoBERT Embedding dan Long Short-Term Memory untuk Tweet Berbahasa Indonesia. *Jurnal Ilmu Siber dan Teknologi Digital (JISTED)*. **1**(1): 1–28.
- Rowan, Muflikhah, L., & Cholissodin, I. 2022. Peramalan Kasus Positif COVID-19 di Jawa Timur Menggunakan Metode Hybrid ARIMA-LSTM. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. **6**(9): 4146–4153.
- Rusyana, A., Tatsara, N., Balcis, R., & Rahmi, S. 2020. Application of Clustering and VARIMA for Rainfall Prediction. *IOP Conference Series: Materials Science and Engineering*. **796**(1): 1–9.

- Sanjaya, F. I., & Heksaputra, D. 2020. Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short-Term Memory. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*. **7**(2): 163–174.
- Shah, D., Isah, H., & Zulkernine, F. 2019. Gold Price Forecasting Using LSTM Neural Network. *arXiv preprint arXiv:1907.03798*.
- Tian, C., Ma, J., Zhang, C., & Zhan, C. 2018. A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network. *Energies*. **11**(12): 1–13.
- Wang, J., Wang, J., Zhang, Z., & Guo, S. 2011. Forecasting Stock Indices with Back Propagation Neural Network. *Expert Systems with Applications*. **38**(11): 14346–14355.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. Second Edition. Temple University, New York.
- Yadav, A., Jha, C. K., & Sharan, A. 2020. Optimizing LSTM for Time Series Prediction in Indian Stock Market. *Procedia Computer Science*. **167**: 2091–2100.
- Zhang, G. P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. **50**: 159–175.
- Zhang, Y., & Wei, Y. 2010. The Crude Oil Market and the Gold Market: Evidence for Cointegration, Causality and Price Discovery. *Resources Policy*. **35**(3): 168–177.
- Zhang, Z., Dong, Z., Lin, H., He, Z., Wang, M., He, Y., & Gao, M. 2021. An Improved Bidirectional Gated Recurrent Unit Method for Accurate State-of-Charge Estimation. *IEEE Access*. **9**: 11252–11263.