

**MODEL *HYBRID* MULTIVARIAT VARIMAX-LSTM PADA
PERAMALAN DATA DERET WAKTU DENGAN FAKTOR EKSTERNAL
(Analisis Saham PTBA dan ADRO dengan Faktor Eksternal Nilai Tukar
Rupiah terhadap USD)**

Tesis

Oleh

ANI YULIANITA

NPM. 2327031002



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
LAMPUNG
2025**

ABSTRACT

HYBRID MULTIVARIATE VARIMAX-LSTM MODEL FOR TIME SERIES DATA FORECASTING WITH EXOGENOUS FACTORS (Analysis of PTBA and ADRO Stocks with Exogenous Factors of Rupiah Exchange Rate against USD)

By

Ani Yulianita

The Vector Autoregressive Integrated Moving Average (VARIMAX) and Long ShortTerm Memory (LSTM) hybrid model is a development of the concept of time series data forecasting by combining classical statistical methods and deep learning to improve forecasting accuracy. The VARIMAX-LSTM hybrid model is designed to overcome the limitations of the VARIMAX model in capturing nonlinear patterns of time series data and the limitations of the LSTM model in capturing linear data patterns as a whole. The forecasting process involves the closing price of PT. Bukit Asam (PTBA) and PT. Adaro Energi Indonesia (ADRO) as endogenous variables and the rupiah exchange rate against the USD as an exogenous variable with a data range from January 2016 to December 2024. The VARIMAX-LSTM hybrid model is built with two approaches, starting with prediction and forecasting using the VARIMAX model. The prediction results and residuals of the VARIMAX model are used as input for the prediction and forecasting of the hybrid model. The first approach is the VARIMAX-E_LSTM hybrid model which is built by combining the prediction results of the VARIMAX model and the prediction results of the E_LSTM model with the input of the residual results of the VARIMAX model. The second approach is the hybrid VARIMAX-EP_LSTM model which is a combination of the prediction results of the hybrid P_LSTM model with the input of the prediction results of the VARIMAX model and the E_LSTM model. The final results of the study show that the hybrid VARIMAX-EP_LSTM model has the best ability in the forecasting process when compared to the VARIMAX model, the individual LSTM model, and the hybrid VARIMAX-E_LSTM model which is based on the smallest Kolmogorov Smirnov test statistic value. Thus, the hybrid VARIMAX-EP_LSTM model is the model with the most optimal ability in the process of forecasting the closing prices of PTBA and ADRO shares.

Keywords: *time series, forecasting, hybrid VARIMAX-LSTM, VARIMAX, LSTM, stock market.*

ABSTRAK

MODEL *HYBRID* MULTIVARIAT VARIMAX-LSTM PADA PERAMALAN DATA DERET WAKTU DENGAN FAKTOR EKSTERNAL (Analisis Saham PTBA dan ADRO dengan Faktor Eksternal Nilai Tukar Rupiah terhadap USD)

Oleh

Ani Yulianita

Model *hybrid Vector Autoregressive Integrated Moving Average* (VARIMAX) dan *Long ShortTerm Memory* (LSTM) merupakan pengembangan konsep peramalan data deret waktu dengan penggabungan metode statistika klasik dan *deep learning* dalam meningkatkan akurasi peramalan. Model *hybrid* VARIMAX-LSTM dirancang untuk mengatasi keterbatasan model VARIMAX dalam menangkap pola nonlinier data deret waktu dan keterbatasan model LSTM dalam menangkap pola data linier secara menyeluruh. Proses peramalan melibatkan harga penutupan saham PT. Bukit Asam (PTBA) dan PT. Adaro Energi Indonesia (ADRO) sebagai variabel endogen serta nilai tukar rupiah terhadap USD sebagai variabel eksogen dengan rentang data sejak Januari 2016 hingga Desember 2024. Model *hybrid* VARIMAX-LSTM dibangun dengan dua pendekatan, diawali dengan prediksi dan peramalan menggunakan model VARIMAX. Hasil prediksi dan residual model VARIMAX digunakan sebagai input pada prediksi dan peramalan model *hybrid*. Pendekatan pertama yaitu model *hybrid* VARIMAX-E_LSTM yang dibangun dengan menggabungkan hasil prediksi model VARIMAX dan hasil prediksi model E_LSTM dengan input hasil residual model VARIMAX. Pendekatan kedua yaitu model *hybrid* VARIMAX-EP_LSTM yang merupakan penggabungan hasil prediksi model *hybrid* P_LSTM dengan input hasil prediksi model VARIMAX dan model E_LSTM. Hasil akhir penelitian menunjukkan bahwa model *hybrid* VARIMAX-EP_LSTM memiliki kemampuan terbaik pada proses peramalan apabila dibandingkan dengan model VARIMAX, model LSTM individu, serta model *hybrid* VARIMAX-E_LSTM yang didasarkan pada nilai statistik Kolmogorov Smirnov terkecil. Sehingga, model *hybrid* VARIMAX-EP_LSTM merupakan model dengan kemampuan paling optimal dalam proses peramalan harga penutupan saham PTBA dan ADRO.

Kata kunci: deret waktu, peramalan, *hybrid* VARIMAX-LSTM, VARIMAX, LSTM, saham.

**MODEL *HYBRID* MULTIVARIAT VARIMAX-LSTM PADA
PERAMALAN DATA DERET WAKTU DENGAN FAKTOR EKSTERNAL
(Analisis Saham PTBA dan ADRO dengan Faktor Eksternal Nilai Tukar
Rupiah terhadap USD)**

ANI YULIANITA

Tesis

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
MAGISTER MATEMATIKA**

Pada

**Program Studi Magister Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
LAMPUNG
2025**

Judul Tesis

: **HYBRID MULTIVARIAT VARIMAX-
LSTM PADA PERAMALAN DATA
DERET WAKTU DENGAN FAKTOR
EKSTERNAL (Analisis Saham PTBA
dan ADRO dengan Faktor Eksternal
Nilai Tukar Rupiah terhadap USD)**

Nama Mahasiswa

: **Ani Yulianita**

Nomor Pokok Mahasiswa

: **2327031002**

Program Studi

: **Pascasaarjana Matematika**

Jurusan

: **Matematika**


Fakultas

: **Matematika dan Ilmu Pengetahuan Alam**


MENYETUJUI

1. Komisi Pembimbing


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


Dr. Dian Kurniasari, S.Si., M.Sc.
NIP. 196903051996032001

2. Ketua Program Studi Magister Matematika


Dr. Fitriani, S.Si., M.Sc.
NIP. 198406232006042001

MENGESAHKAN

1. Tim Penguji

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

Sekretaris : **Dr. Dian Kurniasari, S.Si., M.Sc.**

Penguji
Bukan Pembimbing : **1. Prof. Drs. Mustofa Usman, M.A., Ph.D.**

2. Prof. Dra. Wamiliana, M.A., Ph.D.

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

3. Direktur Program Pascasarjana

Prof. Dr. Ir. Murhadi, M.Si.
NIP. 19640326 198902 1 001

4. Tanggal Lulus Ujian Tesis: **20 Juni 2025**

PERNYATAAN TESIS MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Ani Yulianita**
Nomor Pokok Mahasiswa : **2327031002**
Program Studi : **Magister Matematika**
Jurusan : **Matematika**

Dengan ini menyatakan bahwa tesis saya yang berjudul “**MODEL HYBRID MULTIVARIAT VARIMAX-LSTM PADA PERAMALAN DATA DERET WAKTU DENGAN FAKTOR EKSTERNAL (Analisis Saham PTBA dan ADRO dengan Faktor Eksternal Nilai Tukar Rupiah terhadap USD)**” adalah hasil pekerjaan saya sendiri. Semua tulisan yang tertuang dalam tesis ini telah mengikuti kaidah karya penulisan ilmiah Universitas Lampung. Apabila kemudian hari terbukti bahwa tesis ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi dengan ketentuan akademik yang berlaku.

Bandar Lampung, 20 Juni 2025



Ani Yulianita
NPM. 2327031002

RIWAYAT HIDUP

Penulis bernama Ani Yulianita, lahir di Merbau Mataram pada tanggal 03 Juli 2000, dan merupakan anak kedua dari empat bersaudara dari pasangan Bapak Sarjono dan Ibu Triwinengseh.

Penulis menempuh pendidikan Sekolah Dasar di SDN 2 Merbau Mataram pada tahun 2006-2012 selanjutnya pada tahun 2013-2015 penulis melanjutkan pendidikan Sekolah Menengah Pertama di SMPN 2 Merbau Mataram dan pada tahun 2015-2018 penulis melanjutkan Sekolah Menengah Atas di SMAN 1 Tanjung Bintang.

Pada tahun 2018 penulis melanjutkan pendidikan Strata Satu (S1) di Program Studi Matematika, Fakultas Sains Institut Teknologi Sumatera.

Pada tahun 2023 penulis melanjutkan pendidikan Strata Dua (S2) di Program Studi Magister Matematika, Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung. Penulis memulai perkuliahan sejak 19 Agustus 2023, selama empat semester mengikuti berbagai kegiatan yang diadakan jurusan seperti kuliah umum jurusan, melakukan penelitian proyek tugas akhir mata kuliah, dan menyelesaikan studi S2 dengan melakukan penelitian ini hingga selesai.

KATA INSPIRASI

“Allah tidak akan membebani seseorang melainkan sesuai dengan kesanggupannya.”

(QS. Al-Baqarah: 286)

PERSEMBAHAN

Alhamdulillah hirobbil'alamin.

Puji dan syukur tiada hentinya terpanjatkan atas kehadiran Allah SWT atas ridhoNya sehingga penulis dapat menyelesaikan tesis ini. Saya persembahkan karya ini untuk:

Kepada kedua orang tuaku yang selalu memberi doa serta dukungan yang tiada hentinya. Terimakasih atas semua yang telah diperjuangkan, Bapak dan Mamak bebar benar sosok yang luar biasa.

Kepada dosen-dosen Pembimbing dan Pembahas yang telah sangat sabar dalam membimbing dan memberikan masukan, kritik serta ide-ide yang membangun sehingga penulis dapat menyelesaikan tesis ini.

Teman-teman terkasih Upik, Riska, Nesya, Angga dan lainnya yang tidak bisa disebutkan satu persatu, terimakasih atas keceriaan, support, doa dan masukan yang diberikan selama penulis menempuh pendidikan magister ini.

Almamater kebanggan, Universitas Lampung.

SANWACANA

Puji syukur penulis panjatkan atas kehadiran Tuhan Yang Maha Esa yang telah memberikan keberkahan yang luar biasa sehingga penulis dapat menyelesaikan Tesis dengan judul **“Model *Hybrid* Multivariat VARIMAX-LSTM Pada Peramalan Data Deret Waktu dengan Faktor Eksternal (Analisis Saham PTBA dan ADRO dengan Faktor Eksternal Nilai Tukar Rupiah terhadap USD)”** sebagai syarat untuk memperoleh gelar Magister Matematika di Universitas Lampung.

Penulis juga mengucapkan terimakasih atas segala bimbingan, bantuan dan dukungan dari berbagai pihak baik secara langsung maupun tidak langsung. Rasa terimakasih tersebut penulis ucapkan kepada.

1. Ir. Warsono, M.S., Ph.D. selaku Pembimbing I yang telah memberikan waktu, tenaga, ilmu pengetahuan, dan senantiasa memberikan saran, masukan dan bimbingan kepada penulis dalam menyelesaikan tesis ini.
2. Dr. Dian Kurniasari, S.Si., M.Sc. selaku Pembimbing II yang telah memberikan waktu, tenaga, ilmu pengetahuan, dan senantiasa memberikan saran, masukan dan bimbingan kepada penulis dalam menyelesaikan tesis ini.
3. Prof. Drs. Mustofa Usman, M.A., Ph.D. selaku Penguji I yang telah bersedia memberikan kritik, saran serta masukan untuk evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Prof. Dra. Wamiliana, M.A., Ph.D., selaku Penguji II yang telah bersedia memberikan kritik, saran serta masukan untuk evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
5. Bapak dan Ibu dosen Program Studi Magister Matematika yang telah memberikan ilmu dengan ikhlas dan sabar selama penulis menyelesaikan studi

di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

6. Dan pihak-pihak lain yang tidak dapat penulis sebutkan satu persatu.

Semoga tesis ini dapat bermanfaat bagi penulis dan juga bagi pembaca., dalam penulisan tesis ini penulis menyadari bahwa terdapat banyak kekurangan. Oleh karena itu penulis mengharapkan kritik dan saran yang membangun agar penulis dapat menjadi lebih baik lagi untuk kedepannya.

DAFTAR ISI

	Halaman
DAFTAR GAMBAR.....	v
DAFTAR TABEL	vi
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	5
II. TINJAUAN PUSTAKA.....	6
2.1 Penelitian Terkait Analisis Deret Waktu.....	6
2.2 Deret Waktu	9
2.3 Analisis Deret Waktu	9
2.3.1 Analisis Deret Waktu Multivariat.....	9
2.4 Model Multivariat Analisis Deret Waktu	10
2.4.1 <i>Vector Autoregressive</i> (VAR).....	10
2.4.2 <i>Vector Moving Average</i> (VMA)	11
2.4.3 <i>Vector Autoregressive Moving Average</i> (VARMA).....	12
2.4.4 <i>Vector Autoregressive Integrated Moving Average</i> (VARIMA).....	13
2.4.5 <i>Vector Autoregressive Integrated Moving Average with Exogenous</i> (VARIMAX).....	13
2.5 Peramalan	14
2.6 Uji Asumsi Analisis Deret Waktu	15
2.6.1 Stasioneritas	15

2.6.2 Uji Kointegrasi.....	16
2.6.3 <i>Granger Causality</i>	17
2.7 <i>Akaike Information Criteria</i> (AIC).....	18
2.8 Estimasi Parameter Model.....	19
2.8.1 <i>Maximum Likelihood Estimation</i> (MLE).....	19
2.9 Validasi Model	20
2.9.1 Uji <i>White Noise</i>	20
2.9.2 Uji Normalitas Residual.....	20
2.10 <i>Impulse Response Function</i> (IRF)	21
2.11 <i>Scaling Data</i>	22
2.12 <i>Machine Learning</i>	23
2.13 Fungsi Aktivasi.....	23
2.13.1 Fungsi Aktivasi Tanh.....	24
2.13.2 Fungsi Aktivasi Sigmoid	24
2.14 <i>Hyperparameter</i>	25
2.14.1 <i>Hyperparameter tuning</i>	25
2.15 <i>Deep Learning</i>	26
2.15.1 <i>Recurrent Neural Networks</i> (RNN)	26
2.15.2 <i>Long Short-Term Memory</i> (LSTM)	27
2.16 <i>Hybrid VARIMAX-LSTM</i>	29
2.17 Evaluasi Model.....	30
III. METODOLOGI PENELITIAN	32
3.1 Waktu dan Tempat Penelitian	32
3.2 Data Penelitian	32
3.3 Metode Penelitian.....	32
3.3.1 Model VARIMAX.....	33
3.3.2 Model LSTM	33
3.3.3 Model <i>Hybrid VARIMAX-LSTM</i>	34

3.3.3.1 Model <i>Hybrid</i> VARIMAX-E_LSTM	34
3.3.3.2 Model <i>Hybrid</i> VARIMAX-EP_LSTM	35
IV HASIL DAN PEMBAHASAN.....	41
4.1 Input Data	41
4.2 Visualisasi Data	42
4.3 Prediksi dan Peramalan Model VARIMAX.....	44
4.3.1 <i>Splitting</i> Data	44
4.3.2 <i>Preprocessing</i> Data.....	45
4.3.3 Uji Stasioneritas Data	46
4.3.4 Identifikasi Model.....	48
4.3.5 Estimasi Parameter	50
4.3.6 Prediksi Model VARIMAX.....	50
4.3.7 Residual	52
4.3.8 Uji Asumsi Residual <i>White Noise</i>	53
4.3.9 Peramalan Model VARIMAX.....	54
4.4 Prediksi dan Peramalan Model LSTM	55
4.4.1 <i>Scaling</i> Data Model LSTM.....	56
4.4.2 Membangun Model LSTM	56
4.4.3 <i>Hyperparameter Tuning</i> Model LSTM	57
4.4.4 Prediksi Model LSTM	58
4.4.5 Peramalan Model LSTM	59
4.5 Prediksi dan Peramalan Model <i>Hybrid</i> VARIMAX- E_LSTM.....	60
4.5.1 <i>Scaling</i> Data Residual Model VARIMAX	61
4.5.2 Membangun Model E_LSTM.....	62
4.5.3 <i>Hyperparameter Tuning</i> Model E_LSTM.....	62
4.5.4 Prediksi Model E_LSTM.....	63
4.5.5 Prediksi Model <i>Hybrid</i> VARIMAX - E_LSTM.....	65
4.5.6 Peramalan Model E-LSTM.....	66
4.5.7 Peramalan Model <i>Hybrid</i> VARIMAX -E_LSTM	67
4.6 Prediksi dan Peramalan Model <i>Hybrid</i> VARIMAX- EP_LSTM.....	68

4.6.1 <i>Scaling</i> Data Prediksi Model VARIMAX	69
4.6.2 Membangun Model P_LSTM.....	70
4.6.3 <i>Hyperparameter Tuning</i> Model P_LSTM	70
4.6.4 Prediksi Model P_LSTM	71
4.6.5 Prediksi Model <i>Hybrid</i> VARIMAX - EP_LSTM.....	73
4.6.6 Peramalan Model P_LSTM	74
4.6.7 Peramalan Model <i>Hybrid</i> VARIMAX-EP_LSTM	75
4.7 <i>Goodness of Fit</i>	76
V. KESIMPULAN	75
5.1 Kesimpulan.....	75
DAFTAR PUSTAKA	77

DAFTAR GAMBAR

	Halaman
Gambar 1. Arsitektur LSTM (Yong et al., 2019).....	28
Gambar 2. Diagram alir VARIMAX	37
Gambar 3. Diagram Alir Model LSTM	38
Gambar 4. Diagram Alir Model <i>hybrid</i> VARIMAX-E_LSTM.....	39
Gambar 5. Diagram Alir Model <i>hybrid</i> VARIMAX-EP_LSTM.....	40
Gambar 6. Plot Data Deret Waktu	43
Gambar 7. Plot Data Hasil <i>Differencing</i> Orde Pertama	47
<i>Gambar 8. Plot ACF dan PACF PTBA</i>	49
Gambar 9. Plot ACF dan PACF ADRO	49
Gambar 10. Plot Grafik Data Aktual dan Prediksi VARIMAX.....	51
Gambar 11. Plot Grafik Hasil Residual Model VARIMAX	53
Gambar 12. Plot Grafik Forecast VARIMAX	55
Gambar 13 Plot Perbandingan Data Aktual dan Hasil Prediksi LSTM.....	58
Gambar 14. Plot Hasil Peramalan Model LSTM	60
Gambar 15. Plot Hasil Prediksi Model E_LSTM	64
Gambar 16. Plot Hasil Prediksi Model <i>Hybrid</i> VARIMAX-E_LSTM Terhadap Data Aktual	65
Gambar 17. Plot Residual Peramalan <i>Hybrid</i> VARIMAX-E_LSTM.....	67
Gambar 18. Plot Hasil Peramalan Model <i>Hybrid</i> VARIMAX- E_LSTM.....	68
Gambar 19. Plot Perbandingan Data Aktual dan Hasil Prediksi P_LSTM.....	72
Gambar 20. Plot Perbandingan Data Aktual dan Hasil Prediksi Model VARIMAX- EP_LSTM	73
Gambar 21. Plot Hasil Peramalan Model P_LSTM.....	75
Gambar 22. Plot Hasil Peramalan Model <i>Hybrid</i> VARIMAX-EP_LSTM.....	76

DAFTAR TABEL

	Halaman
Tabel 1. Penelitian Terdahulu	6
Tabel 2. Statistika Deskriptif	42
Tabel 3. Data Hilang	45
Tabel 4. Nilai Korelasi antar Variabel Endogen dan Eksogen.....	46
Tabel 5. Uji Stasioneritas Data	47
Tabel 6. Hasil Uji Stasioneritas Data <i>Differencing</i> Orde Pertama.....	48
Tabel 7. Hasil Nilai AIC	50
Tabel 8. Evaluasi Model VARIMAX	52
Tabel 9. Hasil Uji <i>White Noise</i> Residual.....	54
Tabel 10. <i>Hyperparameter</i> Model LSTM.....	56
Tabel 11. Model LSTM Terbaik	57
Tabel 12. Evaluasi Model LSTM.....	59
Tabel 13. <i>Hyperparameter</i> Model E_LSTM	62
Tabel 14. Model E_LSTM Terbaik.....	63
Tabel 15. Evaluasi Model E_LSTM	64
Tabel 16. Evaluasi Model <i>Hybrid</i> VARIMAX-E_LSTM.....	66
Tabel 17. <i>Hyperparameter</i> Model P_LSTM.....	70
Tabel 18. Model P_LSTM Terbaik.....	71
Tabel 19. Evaluasi Model P_LSTM.....	72
Tabel 20. Evaluasi Model <i>Hybrid</i> VARIMAX-EP_LSTM	74
Tabel 21. <i>Goodness of fit</i> PTBA	77
Tabel 22. <i>Goodness of fit</i> saham ADRO	77

I. PENDAHULUAN

1.1 Latar Belakang

Penelitian tentang peramalan data deret waktu secara mendalam telah banyak dilakukan oleh para ahli. Deret waktu merupakan serangkaian data pengamatan yang tersusun dalam rentang waktu tertentu (Wei, 2006). Pendekatan pada peramalan data deret waktu dapat dilakukan dengan analisis univariat dan multivariat. Salah satu model statistik univariat yang umum digunakan pada peramalan yaitu *Autoregressive Integrated Moving Average* (ARIMA), dikembangkan oleh George et al. (2015). Saat ini proses peramalan mempertimbangkan tidak hanya pada faktor waktu namun juga mempertimbangkan variabel lain. Oleh karena itu, penelitian mengalami perluasan untuk analisis deret waktu multivariat, salah model yang dapat digunakan yaitu *Vector Autoregressive Integrated Moving Average* (VARIMA). Model VARIMA dapat mengatasi beberapa masalah dalam kestasioneritasan, regresi dan *moving average* (MA). Model VARIMA menggabungkan parameter *Vector Autoregressive* (VAR), *differencing*, dan *Vector Moving Average* (VMA) yang mempertimbangkan nilai dan juga eror dimasa lalu dalam prediksi. Peramalan data deret waktu multivariat telah mendorong berbagai bidang penelitian seperti keuangan, bisnis, ilmu pengetahuan serta bidang ekonomi (Usman et al., 2023).

Beberapa peneliti telah mengembangkan metode statistika klasik antara lain telah dilakukan oleh Usman et al. (2023) yang membahas mengenai peramalan deret waktu multivariat harga saham PT. Adaro Energi Indonesia (ADRO) dan PT. Bukit Asam (PTBA) menggunakan model *Vector Autoregression-Constant Conditional Correlation Generalized Autoregressive Conditional Heteroskedasticity* (VAR–

CCC GARCH) diperoleh model terbaik yaitu VAR (3)–CCC GARCH (1, 1). Selain itu, Atmaja et al. (2021) meramalkan harga saham Liquid 45 (LQ45) yaitu PT. United Tractors (UNTR), PT. Gudang Garam (GGRM) dan PT. Unilever (UNVR) menggunakan metode *vector autoregressive integrated moving average with exogenous* (VARIMAX). Diperoleh model VARIMAX (0, 1, 2) yaitu model VARIMA dengan penambahan variabel eksogen diperoleh nilai *mean absolute error* (MAE) untuk UNTR (25), GGRM (183), dan UNVR (300). Salah satu upaya dalam peningkatan akurasi model yaitu dengan penambahan variabel eksogen dengan mempertimbangkan faktor eksternal sehingga model dapat menangkap lebih luas hubungan antar variabel.

Statistika klasik merupakan model yang baik digunakan pada prediksi data linier jangka pendek (Mbah dan Long, 2021). Penggunaan metode klasik ini mengalami kesulitan dalam menangkap pola data yang nonlinier. Adanya perkembangan teknologi, peramalan data nonlinier dapat dilakukan dengan metode *deep learning* (Jin et al., 2024). *Recurrent Neural Network* (RNN) merupakan salah satu metode *deep learning* yang dapat digunakan pada peramalan data *deret waktu*. Model RNN mengalami pengembangan untuk mengatasi peramalan jangka panjang dan data deret waktu dengan jumlah besar yaitu *Long ShortTerm Memory* (LSTM). Model LSTM pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber (1997). Tidak seperti VARIMA, model LSTM memiliki kemampuan untuk mengidentifikasi pola nonlinier dalam data, yang menjadikannya kerangka kerja komputasi yang fleksibel untuk memodelkan masalah nonlinier. Model LSTM memiliki arsitektur yang sama seperti RNN dengan penambahan memori sel yang dapat menyimpan informasi dalam jangka panjang. Salah satu penelitian yang menggunakan model LSTM yaitu Chen et al. (2021) diperoleh nilai *root mean square error* (RMSE) adalah 12.089 dengan akurasi 95%.

Pada dasarnya peramalan menggunakan metode klasik maupun *deep learning* memiliki kelemahan dan keunggulannya masing–masing. Setiap metode dibangun dengan pendekatan masing-masing dalam mengatasi persoalan sehingga dikembangkan penggunaan metode *hybrid* antara statistika klasik dan *deep*

learning. Peramalan dengan menggunakan model *hybrid* pertama kali diperkenalkan oleh Zhang (2003). Pada penelitian tersebut peramalan dilakukan dengan menggabungkan konsep statistika klasik univariat *autoregressive integrated moving average* (ARIMA) dan *Artificial Neural Network* (ANN). Aplikasi peramalan dengan menggunakan model *hybrid* ini terus berkembang khususnya di bidang energi (Manowska et al., 2021). Pemodelan *hybrid* antara statistika klasik dan *deep learning* memungkinkan peramalan sektor pasar uang dapat dilakukan dengan lebih akurat (Jin et al., 2024). Perspektif tersebut merupakan sumber motivasi dilakukannya model *hybrid*.

Peramalan *hybrid* antara statistika klasik dan *deep learning* saat ini sangat populer dikalangan akademisi maupun praktisi. Konsep ini memberi dampak positif pada peramalan deret waktu sektor pasar uang (Cui et al., 2023). Perkembangan penerapan model *hybrid* pada data deret waktu mengalami perluasan, saat ini model *hybrid* juga dikembangkan pada kasus data deret waktu multivariat. Penelitian yang membahas mengenai peramalan data deret waktu multivariat menggunakan model *hybrid* telah dilakukan oleh Caliwag dan Lim (2019). Penelitian tersebut menerapkan penggabungan model VARMA-LSTM untuk estimasi dan peramalan baterai pada *electric vehicles* (EV). Hasil peramalan menggunakan metode *hybrid* VARMA-LSTM menghasilkan *root-mean-square error* (RMSE) yang lebih rendah jika dibandingkan dengan peramalan yang dilakukan menggunakan metode VARMA atau LSTM. Hasil RMSE yang diperoleh pada metode *hybrid* tersebut yaitu 0.161. Pendekatan peramalan *hybrid* deret waktu multivariat juga dilakukan dalam penelitian Rambha dan Seshashayee (2022) dengan hasil akurasi terbaik 93.56%, MAE 1.872, RMSE 2.633 menggunakan model VAR-LSTM.

Pada penelitian ini akan dilakukan analisis peramalan dengan menggunakan pendekatan analisis data deret waktu multivariat VARIMAX-LSTM. Data yang digunakan yaitu data deret waktu pada harga saham harian ADRO dan PTBA dengan mempertimbangkan kurs rupiah terhadap USD sejak bulan Januari 2016 hingga Desember 2024.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang yang telah dijelaskan, rumusan masalah pada penelitian ini sebagai berikut:

1. Bagaimana proses membangun struktur model VARIMAX, model LSTM, dan model *hybrid* VARIMAX-LSTM pada peramalan saham ADRO dan PTBA yang melibatkan kurs dollar sebagai variabel eksogen?
2. Bagaimana kinerja model VARIMAX, model LSTM, dan model *hybrid* VARIMAX-LSTM pada peramalan saham ADRO dan PTBA yang melibatkan kurs dollar sebagai variabel eksogenus dalam menangani data linier dan nonlinier secara simultan?
3. Bagaimana hasil prediksi dan peramalan yang diperoleh menggunakan model VARIMAX, model LSTM, dan model *hybrid* VARIMAX-LSTM?

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Membangun struktur model VARIMAX, model LSTM, dan model *hybrid* VARIMAX-LSTM pada peramalan saham ADRO dan PTBA yang melibatkan kurs dollar sebagai variabel eksogen.
2. Mengkaji dan membandingkan kinerja model VARIMAX, model LSTM, dan model *hybrid* VARIMAX-LSTM pada peramalan saham ADRO dan PTBA yang melibatkan kurs dollar sebagai variabel eksogenus dalam menangani data linier dan nonlinier secara simultan?
3. Mengkaji dan membandingkan hasil prediksi dan peramalan yang diperoleh menggunakan VARIMAX, model LSTM, dan model *hybrid* VARIMAX-LSTM?

1.4 Manfaat Penelitian

Manfaat penelitian ini adalah:

1. Menjadi sumber wawasan pembaca mengenai model *hybrid* VARIMAX-LSTM dan penerapannya.
2. Menjadi referensi untuk peneliti yang akan melakukan prediksi dan peramalan model *hybrid* VARIMAX-LSTM.
3. Menambah informasi dan sumber pengetahuan terkait peramalan saham PTBA dan ADRO.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terkait Analisis Deret Waktu

Kajian literatur merupakan tahapan awal penelitian untuk meninjau penelitian terdahulu yang relevan terhadap topik yang diangkat pada penelitian ini. Kajian terhadap literatur penelitian terdahulu membantu peneliti dalam identifikasi keterbatasan topik penelitian terdahulu untuk menemukan gagasan topik yang dapat dikembangkan lebih lanjut. Ringkasan penelitian terdahulu disajikan pada Tabel 1 berikut:

Tabel 1. Penelitian Terdahulu

Judul	Data	Model	Hasil
Forecasting Stock Prices on The LQ45 Index Using the Varimax Method. (Atmaja et al., 2021)	Data harga penutupan harian indeks LQ45 yaitu UNTR, GGRM, dan UNVR.	VARIMAX	Model terbaik yang diperoleh yaitu VARIMAX (0, 1, 2) dengan MAE UNTR 25, GGRM 183, dan UNVR 300.
Dynamic Modeling and Analysis of Some Energy Companies of Indonesia Over the Year 2018 to 2022 By Using VAR(p)-CCC GARCH(r,s) Model. (Usman et al., 2023)	Data harian harga saham ADRO dan PTBA.	VAR-CCC GARCH	Model terbaik yang diperoleh yaitu VAR (3) – CCC- GARCH (1, 1)
Load Forecasting Based on LSTM Neural Network and Applicable to Loads of “Replacement of Coal with Electricity” (Chen et al., 2021)	Data beban listrik yang diperoleh dari jaringan listrik tegangan rendah di berbagai stasiun distrik Changshuiyu.	LSTM	RMSE dari model LSTM adalah 12.089. Akurasi peramalan yang diperoleh yaitu 95%.

Tabel 1. Lanjutan Penelitian Terkait

Judul	Data	Model	Hasil
Deret waktu Augmentation based on Vector Auto Regression and Long ShortTerm Memory method for Air Quality Prediction (Rambha dan Seshashayee, 2022)	Data <i>air quality index</i> di India.	VAR-LSTM	Akurasi terbaik yang diperoleh yaitu 93,56%, MAE 1.872, RMSE 2,633 menggunakan model VAR-LSTM.
Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications (Caliwag dan Lim, 2019).	Data indikator keamanan baterai kendaraan listrik yaitu kesehatan baterai, status daya, pengisian, keamanan, dan status usia baterai.	VARMA-LSTM	Hasil RMSE yang diperoleh pada metode <i>hybrid</i> tersebut yaitu 0.161

Penelitian pertama dilakukan menggunakan model VARIMAX pada peramalan harga saham LQ45. Data yang digunakan pada penelitian Atmaja et al. (2021) yaitu harga penutupan saham UNTR, GGRM, dan UNVR dengan jumlah data sebanyak 585 data. Peramalan dilakukan untuk menentukan model VARIMAX terbaik pada peramalan periode mendatang, diperoleh model terbaik yaitu VARIMAX (0, 1, 2). Hasil peramalan yang diperoleh yaitu harga saham UNTR Rp. 20.575., dengan eror 25, GGRM Rp. 52.095., dengan eror 183 dan UNVR Rp. 46.500., dengan eror 300. Hasil tersebut menunjukkan bahwa VARIMAX dapat memprediksi harga saham yang berfluktuasi seiring berjalannya waktu yang dipengaruhi kondisi perusahaan dan faktor eksternal lainnya.

Penelitian metode statistika klasik selanjutnya dilakukan oleh Usman et al (2023). Pada penelitian tersebut model yang digunakan yaitu VAR(p)-CCC GARCH (r, s), dengan menggunakan data harian harga saham ADRO dan PTBA. Periode data yang digunakan yaitu sejak Januari hingga Desember 2022. Model terbaik yang diperoleh yaitu VAR (3)-CCC GARCH (1,1). Berdasarkan hasil peramalan yang diperoleh untuk 30 hari mendatang, harga penutupan ADRO dan PTBA mengalami penurunan tren.

Penelitian berikutnya dilakukan oleh Chen et al (2021) dengan tujuan untuk mengatasi permasalahan peramalan menggunakan metode statistika klasik yang memiliki keterbatasan dalam peramalan tingkat beban kelistrikan yang tidak stabil. Pengembangan model LSTM dianggap mampu menangkap pola dinamis pada data deret waktu beban listrik dengan mempertimbangkan cuaca, suhu, kekuatan angin sebagai faktor eksternal. Hasil peramalan menggunakan LSTM memberikan peningkatan akurasi dari 83.2% menjadi 95%. Terbukti bahwa model LSTM dapat meningkatkan akurasi jika dibandingkan menggunakan metode klasik.

Selanjutnya merupakan penelitian dengan menggunakan metode *hybrid* statistika klasik dan *deep learning*. Penelitian metode *hybrid* dilakukan oleh Rambha & Seshashayee (2022) pada prediksi kualitas udara. Peramalan terhadap kualitas udara penting dilakukan untuk kepentingan masyarakat juga pemerintah dalam upaya pengambilan keputusan dalam peningkatan kesehatan masyarakat dan kualitas udara. Data penelitian diperoleh dari *central pollution control board* yang tersedia untuk umum. Model *hybrid* VAR-LSTM digunakan dalam penelitian ini untuk meningkatkan kinerja indeks kualitas udara. Hasil prediksi yang diperoleh menunjukkan nilai RMSE 2.633. Hasil tersebut lebih baik jika dibandingkan dengan model SARIMA yaitu 3.832 dan ARIMA yaitu 2.896.

Penelitian model *hybrid* selanjutnya yaitu menggunakan model VARMA-LSTM, dilakukan oleh Caliwag dan Lim (2019). pada peramalan keamanan baterai. Indeks keamanan baterai yang digunakan yaitu status daya baterai, kesehatan baterai, periode baterai, dan keamanan baterai pada kendaraan listrik. Pendekatan menggunakan model VARMA-LSTM menghasilkan nilai evaluasi model RMSE yang lebih rendah, hal tersebut menunjukkan bahwa akurasi prediksi meningkat.

2.2 Deret Waktu

Deret waktu merupakan serangkaian pengamatan yang teratur dan teratur. Urutan pengamatan didasarkan pada waktu dalam suatu interval yang sama. Selain itu, pengamatan dapat dilakukan dengan urutan berdasarkan pada dimensi lain seperti ruang. Deret waktu yang diamati dan dipelajari pada periode tertentu disebut interval waktu. Deret waktu dipelajari untuk beberapa tujuan yaitu memahami dan menjelaskan proses pembangkitan data, prediksi nilai di masa depan, dan mengoptimalkan sistem kendali. Pengamatan deret waktu memiliki sifat yang saling bergantung atau berkorelasi. Kumpulan metode yang dapat digunakan untuk menganalisis data deret waktu disebut analisis deret waktu. (Wei, 2006)

2.3 Analisis Deret Waktu

Analisis deret waktu memiliki tujuan memahami pola data yang konsisten seiring berjalannya waktu. Asumsi terdapat pola tertentu tidak berubah diperlukan dalam prediksi. Selain itu, tujuan dari analisis deret waktu juga untuk memprediksi data di masa yang akan datang. Berdasarkan variabel yang digunakan pada prediksi data, analisis deret waktu dibagi menjadi dua yaitu data deret waktu univariat yang melibatkan hanya satu variabel pengamatan dan deret waktu multivariat melibatkan lebih dari satu variabel pengamatan yang dilakukan secara simultan (Wei, 2006).

2.3.1 Analisis Deret Waktu Multivariat

Analisis deret waktu multivariat merupakan analisis yang mempertimbangkan beberapa deret waktu secara simultan. Analisis deret waktu multivariat adalah cabang dari analisis statistik multivariat tetapi secara khusus berhubungan dengan data yang saling bergantung. Secara umum, analisis deret waktu multivariat jauh lebih rumit dibandingkan dengan analisis deret waktu univariat, terutama ketika jumlah deret yang dipertimbangkan cukup besar.

Analisis statistik yang lebih rumit ini dipelajari karena dalam kehidupan nyata, pengambilan keputusan sering kali melibatkan banyak faktor atau variabel yang saling terkait. Memahami hubungan antara faktor-faktor tersebut dan memberikan prediksi yang akurat terhadap variabel-variabel tersebut sangatlah berharga dalam pengambilan keputusan.

Tujuan dari analisis deret waktu multivariat meliputi:

1. Mempelajari hubungan dinamis antar variabel
2. Meningkatkan akurasi prediksi (Tsay, 2014)

2.4 Model Multivariat Analisis Deret Waktu

Beberapa model deret waktu multivariat yang umum digunakan dalam peramalan sebagai berikut:

2.4.1 *Vector Autoregressive* (VAR)

Model deret waktu multivariat VAR adalah model deret waktu yang sering digunakan terutama dalam bidang ekonometrika. Peramalan model VAR relatif sederhana dan banyak digunakan. (Tsay, 2014). Model VAR merupakan pengembangan lebih luas dari *Autoregressive* (AR) dengan beberapa paralel *deret waktu*. Model VAR memiliki sistem persamaan dinamis yang memberikan estimasi periode waktu modifikasi yang bergantung pada pergerakan variabel dan variabel lain yang terlibat sebelumnya. Model VAR digunakan dalam proyeksi variabel deret waktu dengan analisis dampak dinamis dari faktor gangguan yang terlibat dalam variabel. (Rusyana et al., 2020). Secara umum, persamaan model VAR(p) dapat direpresentasikan dengan Persamaan (2.1) sebagai berikut (Wei, 2006):

$$Y_t = C + \sum_{i=1}^p \Phi_i Y_{t-i} + \epsilon_t \quad (2.1)$$

dengan,

Y_t : $[y_{1t}, y_{2t}]'$ vektor (2×1) variabel pada waktu ke- t

C : vektor konstanta berukuran (2×1)

Φ_p : matriks koefisien berukuran 2×2 , dengan $i = 1, 2, 3, \dots, p$

ϵ_t : vektor error pada waktu ke- t

Sebagai contoh untuk orde $p = 1$, model VAR (1) bivariat dapat dijabarkan pada Persamaan (2.2) sebagai berikut:

$$Y_t = \begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} c_1 \\ c_2 \end{bmatrix} + \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{bmatrix} \begin{bmatrix} y_{1(t-1)} \\ y_{2(t-1)} \end{bmatrix} + \begin{bmatrix} \epsilon_{1t} \\ \epsilon_{2t} \end{bmatrix} \quad (2.2)$$

2.4.2 Vector Moving Average (VMA)

Vector moving average merupakan pengembangan dari analisis data deret waktu univariat *moving average* (MA). Model VMA adalah sistem persamaan dinamis yang memiliki estimasi periode waktu dengan modifikasi yang bergantung pada kesalahan yang terdapat pada variabel dan error pada variabel lain yang terdeteksi dalam periode sebelumnya (Rusyana et al., 2020). Secara umum, persamaan model VMA(q) dapat ditulis pada Persamaan (2.3) sebagai berikut (Wei, 2006):

$$Y_t = \mu + \sum_{j=1}^q \Theta_j \epsilon_{t-j} + \epsilon_t \quad (2.3)$$

dengan:

Y_t : $[y_{1t}, y_{2t}]'$ vektor (2×1) variabel pada waktu ke- t .

μ : $\begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}$ vektor rata-rata berukuran 2×1

Θ_i : matriks koefisien 2×2 , dengan $i = 1, 2, 3 \dots q$

ϵ_t : vektor error pada waktu ke- t

Sebagai contoh untuk orde $q = 1$, model VMA (1) bivariat dapat dijabarkan pada Persamaan (2.4) sebagai berikut:

$$Y_t = \begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} + \begin{bmatrix} \theta_{11} & \theta_{12} \\ \theta_{21} & \theta_{22} \end{bmatrix} \begin{bmatrix} \epsilon_{1,t-1} \\ \epsilon_{2,t-1} \end{bmatrix} + \begin{bmatrix} \epsilon_{1t} \\ \epsilon_{2t} \end{bmatrix} \quad (2.4)$$

2.4.3 Vector Autoregressive Moving Average (VARMA)

Secara umum, model VARMA digunakan dalam peramalan deret waktu multivariat, dengan kerangka kerja sederhana untuk mempelajari hubungan antar variabel yang dinamis. Model VARMA merupakan pengembangan model *autoregressive moving average* (ARMA) dari analisis deret waktu univariat. Model VARMA (p, q) merupakan gabungan dari model VAR(p) dan VMA(q) (Rusyana et al., 2020). Secara umum, persamaan model VARMA(p, q) dapat ditulis pada Persamaan (2.5) sebagai berikut (Wei, 2006):

$$Y_t = C + \sum_{i=1}^p \Phi_i Y_{t-i} - \sum_{j=1}^q \Theta_j \epsilon_{t-j} + \epsilon_t \quad (2.5)$$

dengan:

Y_t : $[y_{1t}, y_{2t}]'$ vektor berukuran (2×1) variabel pada waktu ke- t .

C : vektor konstanta berukuran (2×1)

Φ_i : matriks koefisien berukuran (2×2) , dengan $i = 1, 2, 3, \dots, p$

Θ_j : matriks koefisien berukuran (2×2) , dengan $j = 1, 2, 3 \dots q$

ϵ_t : vektor error pada waktu ke- t

Model VARMA juga dapat di tuliskan dalam Persamaan (2.6), (2.7), dan (2.8) yang lebih sederhana dengan *backshift operator* (B) sebagai berikut:

$$\Phi(B)Y_t = \theta + \Theta(B)\epsilon_t \quad (2.6)$$

$$\Phi(B) = I - \sum_{i=1}^p \Phi_i B^i \quad (2.7)$$

dan

$$\Theta(B) = I - \sum_{j=1}^q \Theta_j B^j \quad (2.8)$$

2.4.4 Vector Autoregressive Integrated Moving Average (VARIMA)

Vector autoregressive integrated moving average merupakan model VARMA yang mengalami proses *differencing* (Rusyana et al., 2020). Secara umum model VARIMA (p, d, q) dapat ditulis pada Persamaan (2.9) berikut (Wei, 2006):

$$\Phi_p(B)\Delta^d Y_t = \Theta_q(B) \epsilon_t \quad (2.9)$$

dengan:

Y_t : $[y_{1t}, y_{2t}]'$ vektor (2×1) variabel pada waktu ke- t .

$\Delta^d Y_t$: $(1 - B)^1 Y_t$, *differencing* orde- d deret waktu Y_t

Φ_i : koefisien matriks berukuran (2×2), dengan $i = 1, 2, 3, \dots, p$

ϵ_t : vektor eror pada waktu ke- t

Sebagai contoh untuk orde $p = 1, d = 1$, dan $q = 1$, model VARIMA (1, 1, 1) bivariat dapat ditulis pada Persamaan (2.10) sebagai berikut:

$$I - \Phi_1(B)(1 - B)^1 Y_t = I + \Theta_1(B) \epsilon_t \quad (2.10)$$

dengan

$$Y_t = \begin{bmatrix} Y_{1t} \\ Y_{2t} \end{bmatrix}, \quad (1 - B)^1 Y_t = \begin{bmatrix} \Delta Y_{1t} \\ \Delta Y_{2t} \end{bmatrix}, \quad \epsilon_t = \begin{bmatrix} \epsilon_{1t} \\ \epsilon_{2t} \end{bmatrix}$$

2.4.5 Vector Autoregressive Integrated Moving Average with Exogenous (VARIMAX)

Metode VARIMAX dikembangkan dari metode VARIMA dengan penambahan variabel eksogen pada model. Penambahan variabel eksogen ke dalam model karena model ini memiliki residual tidak acak (*white noise*) dan tidak memiliki pola rata-rata, sehingga perlu ditambahkan variabel eksogen ke dalam persamaan model. Persamaan umum model VARIMAX dijabarkan pada Persamaan (2.11) sebagai berikut (Atmaja et al., 2021):

$$(I - B)^d \Phi_p(B) Y_t = M + \Theta_q(B) E_t + \Psi(B) X_t \quad (2.11)$$

X_t merupakan vektor variabel eksogen dan $\Psi(B)$ adalah parameter variabel eksogenus yang berbentuk matriks polinomial dengan ukuran variabel eksogen dalam vektor pengukuran berukuran (2×1) (Atmaja et al., 2021).

Sebagai contoh untuk orde $p = 1$, $d = 1$, dan $q = 1$, Model VARIMAX (1, 1, 1) bivariat dapat ditulis pada Persamaan (2.12) sebagai berikut:

$$(I - B)^1(I - \Phi_1 B)Y_t = M + (I + \Theta_1 B)\epsilon_t + \Psi_0 X_t \quad (2.12)$$

dengan komponen-komponen dalam persamaan (2.12) dijabarkan sebagai berikut:

Differencing:

$$(I - B)Y_t = Y_t - Y_{t-1}$$

AR (1):

$$\Phi(B) = I - \Phi_1 B$$

MA (1):

$$\Theta(B) = I + \Theta_1 B$$

2.5 Peramalan

Peramalan merupakan proses ilmiah dengan tujuan prediksi nilai masa depan berdasarkan informasi yang diperoleh dari masa lalu (Makridakis et al., 2020). Peramalan membutuhkan informasi yang tersedia meliputi intuisi, model formal, dan data untuk membuat pernyataan mengenai kemungkinan peristiwa di masa depan (Elliott et al., 2006) Peramalan nilai-nilai pada masa depan merupakan salah satu tujuan penting dalam melakukan analisis deret waktu. Meskipun pada pemodelan deret waktu memiliki tujuan akhir untuk mengendalikan sistem, namun operasinya didasarkan pada peramalan (Wei, 2006).

2.6 Uji Asumsi Analisis Deret Waktu

2.6.1 Stasioneritas

Asumsi penting yang perlu dilakukan dalam membuat kesimpulan mengenai struktur data yang diamati yaitu stasioneritas. Gagasan dasar konsep stasioneritas yaitu hukum peluang yang mengatur perilaku proses tidak berubah seiring berjalannya waktu. Hal ini dapat dikatakan bahwa proses dalam keseimbangan statistik. Suatu proses Y_t secara khusus dapat disebut *strictly stationary*, jika distribusi gabungan $Y_t, Y_{t-1}, \dots, Y_{t-n}$ sama dengan distribusi gabungan $Y_{t-k}, Y_{t-1-k}, \dots, Y_{t-n-k}$ untuk seluruh waktu $t_1, t_2, \dots, t_n$ dan semua lag k (Tsay, 2014).

Terdapat beberapa metode yang dapat digunakan dalam uji stasioneritas data deret waktu, yaitu melalui plot ACF atau pengujian yang dilakukan dengan uji akar unit menggunakan uji *Augmented Dickey Fuller* (ADF). Data tidak stasioner memiliki akar-akar unit sedangkan pada data stasioner tidak terdapat akar-akar unit (Wei, 2006). Proses uji ADF sebagai berikut (Brockwell & Davis, 2003). Misalkan $x_1, x_2, \dots, x_n$ merupakan deret waktu, diasumsikan bahwa $\{X_t\}$ mengikuti model AR(p) dengan rata-rata μ yang dituliskan pada Persamaan (2.13).

$$X_t - \mu = \phi_1(X_{t-1} - \mu) + \dots + \phi_p(X_{t-p} - \mu) + \varepsilon_t \quad (2.13)$$

dengan ε_t adalah *white noise* dengan rata-rata 0, varians σ^2 , dan $\varepsilon_t \sim \text{WN}(0, \sigma^2)$. Model pada Persamaan (2.13) dapat ditulis pada Persamaan (2.14) sebagai berikut:

$$\Delta X_t - \mu = \phi_0^* + \phi_0^* X_{t-1} + \phi_2^* \Delta X_{t-1} + \dots + \phi_2^* \Delta X_{t-p+1} + \varepsilon_t \quad (2.14)$$

dengan,

$$\phi_0^* = \mu(1 - \phi_1 - \dots - \phi_p)$$

$$\phi_1^* = \sum_{i=0}^p \phi_i - 1$$

$$\phi_j^* = \sum_{i=0}^p \phi_i,$$

$$j = 2, 3, \dots, p \text{ dan } \Delta X_t = X_t - X_{t-1}.$$

Langkah pengujian data tidak stasioner dari Persamaan (2.13) menggunakan uji ADF sebagai berikut:

1. Merumuskan hipotesis

Hipotesis nol $H_0: \phi_1^0 = 0$ (data tidak stasioner)

Hipotesis alternatif $H_1: \phi_1^0 < 0$ (data stasioner)

2. Taraf signifikansi

$$\alpha = 5\% = 0.05$$

3. Statistik uji

Statistik uji yang digunakan yaitu uji *Augmented Dickey-Fuller* yang dituliskan pada Persamaan (2.15) berikut:

$$\text{Uji ADF } (\tau) = \frac{\hat{\phi}_1^*}{\hat{se}_{\phi_1^*}} \quad (2.15)$$

dengan:

$\hat{\phi}_1^*$ = nilai duga parameter AR

$\hat{se}_{\phi_1^*}$ = standar error $\hat{\phi}_1^*$

4. Kriteria uji

Tolak H_0 jika nilai $\tau < -2.57$ atau jika nilai peluang $(P) < 0.05$

Tidak tolak H_0 jika nilai $\tau > -2.57$ atau jika nilai peluang $(P) > 0.05$

5. Keputusan

Keputusan diambil berdasarkan hasil nilai τ yang diperoleh dengan keputusan tolak H_0 jika nilai $\tau < -2.57$ atau jika nilai peluang $(P) < 0.05$ dan tidak tolak H_0 jika nilai $\tau > -2.57$ atau jika nilai peluang $(P) > 0.05$.

6. Kesimpulan

Kesimpulan yang diperoleh yaitu jika tolak H_0 maka data telah stasioner dan jika tidak tolak H_0 maka data tidak stasioner

2.6.2 Uji Kointegrasi

Uji kointegrasi merupakan metode statistika dalam analisis deret waktu untuk menentukan apakah terdapat hubungan jangka panjang antar dua variabel atau lebih. Menurut Engle & Granger (1987) variabel X_t dan Y_t dikatakan memiliki kointegrasi jika:

1. Kedua variabel tidak stasioner pada *differencing* ($I(1)$), namun stasioner setelah dilakukan *differencing* pertama.
2. Pada variabel-variabel yang bersifat stasioner mengandung kombinasi linier yang disajikan dalam Persamaan (2.16), yaitu:

$$Z_t = Y_t - \beta X_t \quad (2.16)$$

Z_t = residu regresi antara Y_t dan X_t . X_t dan Y_t dikatakan terkointegrasi apabila Z_t stasioner pada ($I(0)$).

Apabila antara vektor deret waktu terdapat kointegrasi maka dilakukan pengujian rank kointegrasi. Metode pengujian rank kointegrasi yang dapat digunakan yaitu uji *trace* dan uji *maximum eigenvalue* (Warsono et al., 2020).

Uji *trace*, hipotesis yang diuji yaitu:

H_0 : Terdapat paling banyak r nilai eigen positif.

H_1 : Terdapat lebih dari r nilai eigen positif

Statistik uji yang digunakan dijabarkan pada Persamaan (2.17) sebagai berikut:

$$Tr(r) = -T \sum_{i=r+1}^k \ln (1 - \lambda_i) \quad (2.17)$$

Sedangkan untuk uji *maximum eigen value*, hipotesis yang diuji yaitu:

H_0 : Terdapat r nilai eigen positif.

H_1 : Terdapat $r + 1$ nilai eigen Spositif

Statistik uji yang digunakan dijabarkan dalam Persamaan (2.18) sebagai berikut:

$$\lambda_{max}(r, r + 1) = -T \ln(1 - \hat{\lambda}_i) \quad (2.18)$$

$\hat{\lambda}_i$ = estimasi nilai eigen

T = jumlah observasi

k = total variabel endogen.

2.6.3 Granger Causality

Granger Causality merupakan salah satu konsep statistik yang dapat digunakan untuk menentukan apakah perubahan pada suatu variabel dapat memengaruhi

perubahan pada variabel lain dalam sistem dinamis. Granger (1969) mengembangkan konsep keterdugaan suatu deret waktu. Misal terdapat suatu deret waktu X_t . Apabila terdapat deret waktu lain, yaitu Y_t yang memuat informasi nilai masa lalu yang secara signifikan dapat membantu prediksi X_t dan informasi tersebut tidak termuat dalam deret waktu lainnya dalam nilai X_t , maka Y_t dikatakan menyebabkan X_t yang berarti *granger causality*. Persamaan (2.19) berikut merupakan model kausalitas yang dapat digunakan untuk menganalisis ketergantungan antar variabel (Usman et al., 2022):

$$y_t = \begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} B_{11,1} & B_{12,1} \\ B_{21,1} & B_{22,1} \end{bmatrix} \begin{bmatrix} y_{1t-1} \\ y_{2t-1} \end{bmatrix} + \dots + \begin{bmatrix} B_{11,i} & B_{12,i} \\ B_{21,i} & B_{22,i} \end{bmatrix} \begin{bmatrix} y_{1t-i} \\ y_{2t-i} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} \quad (2.19)$$

Model y_t terdiri dari vektor y_{1t} dan y_{2t} , y_{2t} dikatakan tidak *granger causality* untuk y_{1t} jika matriks koefisien parameter $B_{21,i} = 0$ untuk $i = 1, 2, \dots, p$.

2.7 Akaike Information Criteria (AIC)

Nilai *akaike information criteria* merupakan salah satu metode yang digunakan dalam memilih model regresi terbaik, metode ini ditemukan oleh Akaike dan Schwarz. Penentuan nilai AIC dilakukan dengan Persamaan (2.20) sebagai berikut (Jusmawati et al., 2020):

$$AIC_{p,q} = \ln|\Sigma| + \frac{(2k^2(p+q))}{T} \quad (2.20)$$

keterangan:

$\ln$: logaritma natural

T : banyak pengamatan

k : jumlah variabel dalam model

p : orde AR

q : orde MA

Σ : matriks kovarians residual.

2.8 Estimasi Parameter Model

2.8.1 Maximum Likelihood Estimation (MLE)

Maximum likelihood estimation dapat memberikan hasil terbaik dari perspektif statistik terutama untuk model yang mendekati kondisi yang tidak stasioner atau rangkaian observasi pendek. Ketika daya komputasi meningkat, penggunaan MLE menjadi lebih menarik. Peluang logaritmik digunakan untuk membantu mencegah ketidakstabilan nilai ketika parameter model mendekati batas kestabilan yang dapat menyebabkan nilai menuju tak hingga. Estimator MLE untuk parameter distribusi normal multivariat dicari dengan mendiagonalkan matriks kovarians, kemudian elemen *mean* yang telah di transformasi dan akar laten matriks kovarians dipilih untuk memaksimalkan *likelihood*. Berikut merupakan langkah pada metode estimasi MLE.

Jika $x_1, \dots, x_n$ merupakan nilai sampel yang diamati, algoritma *likelihood* dapat dituliskan pada Persamaan (2.21) sebagai berikut (Hall & Nicholls, 1980):

$$l = -\left(\frac{np}{2}\right) \ln(2\pi) - \frac{n}{2} |\Sigma| - \sum_{i=1}^n (x_i - \mu)^T \Sigma \left(\frac{x_i - \mu}{2}\right) \quad (2.21)$$

Estimasi parameter MLE untuk rata-rata sampel dituliskan pada Persamaan (2.22):

$$\hat{\mu} = \hat{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2.22)$$

dan estimasi parameter MLE untuk matriks kovarians diperoleh berdasarkan Persamaan (2.23) berikut:

$$\hat{\Sigma} = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{X})(X_i - \hat{X})^T \quad (2.23)$$

yang merupakan estimator MLE untuk parameter Σ .

2.9 Validasi Model

2.9.1 Uji *White Noise*

Uji *white noise* digunakan pada pengujian awal terhadap data residual analisis deret waktu. Uji *white noise* dilakukan untuk memastikan residual data bersifat acak. Statistik uji untuk model multivariat yaitu statistik Ljung Box-Pierce dengan Persamaan (2.24) sebagai berikut (Jusmawati et al., 2020):

$$Q_k(m) = T^2 \sum_{t=1}^m \frac{1}{T-1} \text{tr}(\hat{\Gamma}_l'' \hat{\Gamma}_0^{-1} \hat{\Gamma}_l \hat{\Gamma}_0^{-1}) \quad (2.24)$$

keterangan:

T : banyak data

m : banyak lag yang diuji

$\hat{\Gamma}_l$: estimasi autokorelasi residual periode m

tr : penjumlahan diagonal utama

Pengambilan keputusan didasarkan dengan kriteria apabila $Q_k(m) < \chi^2$ atau $p - \text{value} > \alpha$ dugaan awal diterima bahwa data bersifat *white noise* yang artinya residual memenuhi asumsi *white noise* dan barisan error tidak memiliki autokorelasi.

2.9.2 Uji Normalitas Residual

Uji normalitas residual digunakan untuk memeriksa apakah residual berdistribusi normal atau tidak. Pemeriksaan normalitas residual dapat dilakukan dengan menggunakan uji statistik Jarque Bera yang memiliki hipotesis nol bahwa data berdistribusi normal. Statistik uji yang digunakan dalam uji Jarque-Bera yaitu *skewness* dan *kurtosis*. Persamaan dalam uji Jarque-Bera dituliskan pada Persamaan (2.25) berikut:

$$JB = \left[\frac{N}{6} B_1^2 + \frac{N}{24} (b_2 - 3)^2 \right] \quad (2.25)$$

N : banyak ukuran sampel

b_1 : koefisien skewness

b_2 : koefisien kurtosi

2.10 Impulse Response Function (IRF)

Salah satu analisis yang dilakukan pada pemodelan dinamis yaitu *impulse response function*. Analisis IRF digunakan untuk menganalisis respon suatu variabel pada guncangan atau shock terhadap variabel lain. Wei (2003) menyebutkan model VAR dapat dinyatakan dalam bentuk VMA (∞) dengan Persamaan (2.26) berikut (Usman et al., 2023):

$$X_t = \mu + \mu_t + \Psi_1\mu_{t-1} + \Psi_2\mu_{t-2} + \dots + \Psi_s\mu_{t-s} \quad (2.26)$$

Matriks Ψ_s memiliki Persamaan (2.27):

$$\Psi_s = \frac{\partial X_{t+s}}{\partial \mu_t} \quad (2.27)$$

Elemen baris ke- i dan kolom ke- j menunjukkan akibat peningkatan satu unit guncangan dari variabel j pada waktu $t(\mu_{jt})$ untuk variabel i pada waktu $t + s(X_{i,t+s})$ dan diasumsikan bahwa guncangan lainnya tidak mengalami perubahan. Apabila elemen ε_t mengalami perubahan sebesar δ_1 , sehingga elemen kedua mengalami perubahan sebesar δ_2 secara bersamaan dan seterusnya hingga elemen ke- n berubah sebesar δ_n . Secara umum akibat keseluruhan dari perubahan terhadap vektor X_{t+s} dinyatakan oleh Persamaan (2.28) sebagai berikut:

$$\Delta X_{t+s} = \frac{\partial X_{t+s}}{\partial \mu_{1t}} \delta_1 + \dots + \frac{\partial X_{t+s}}{\partial \mu_{nt}} \delta_n = \Psi_s \delta \quad (2.28)$$

Plot elemen baris ke- i dan kolom ke- j dari Ψ_s disebut dengan *Impulse Response Function*.

2.11 Scaling Data

Scaling Data atau teknik normalisasi memegang peran penting pada praproses data untuk menyamakan skala data pada rentang nilai 0 dan 1. Normalisasi data adalah metode untuk mengubah nilai dataset ke skala yang lebih besar tanpa mengubah perbedaan dalam rentang nilai data. Proses ini dapat mempercepat proses pembelajaran. Berikut ini merupakan teknik yang dapat dilakukan dalam normalisasi data (Jusmawati et al., 2020).

1. *Min max scaler*

Min max scaler mengubah ukuran data dari rentang awal menjadi semua nilai berada di antara 0 dan 1. Persamaan *min max scaler* dapat dinyatakan pada Persamaan (2.29) sebagai berikut:

$$X' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (2.29)$$

keterangan:

X' : data normalisasi

x : data awal

x_{min} : nilai minimum data x

x_{max} : nilai maksimum data x

2. *Standar scaler (zero mean)*

Metode normalisasi *zero mean* atau *standar scaler* didasarkan pada standar deviasi dan *mean*. Pada standarisasi kumpulan data diperlukan perubahan pada skala distribusi nilai, sehingga mean bernilai 0 dan standar deviasi bernilai 1. Nilai standar deviasi dapat dihitung dengan Persamaan (2.30) sebagai berikut (Jusmawati et al., 2020):

$$x_{std} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - x_{mean})^2} \quad (2.30)$$

x_{mean} merupakan rata-rata data. Standar *scaler* dapat dihitung melalui Persamaan (2.31) berikut (Jusmawati et al., 2020):

$$X' = \frac{(x_i - x_{mean})}{x_{std}} \quad (2.31)$$

2.12 Machine Learning

Machine learning (ML) merupakan salah satu bidang ilmu *Artificial Intelligence* (AI) yang memungkinkan komputer meniru perilaku manusia dan lebih unggul dalam pengambilan keputusan manusia untuk menyelesaikan tugas kompleks secara mandiri atau meminimalkan intervensi manusia. Tujuannya adalah untuk mengotomatiskan proses pembuatan model analitis sehingga dapat melakukan tugas kognitif seperti deteksi objek atau penerjemahan bahasa natural. Hal ini dicapai melalui penggunaan algoritma yang secara berulang belajar dari data pelatihan masalah khusus. Algoritma ini memungkinkan komputer untuk menemukan wawasan tersembunyi dan pola kompleks meskipun tidak diprogram secara eksplisit untuk melakukannya (Janiesch, et al 2023).

Kekuatan utama pada metode ML apabila dibandingkan dengan metode statistik klasik, yaitu dalam metode ini tidak hanya mengatur pembuatan data dasar seperti bentuk tren dan musim, namun memungkinkan pemrosesan hubungan data yang diidentifikasi dan diperkirakan secara otomatis. (Janiesch et al., 2023). Berdasarkan permasalahan data yang tersedia, ML dibedakan menjadi tiga jenis yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning* (Janiesch et al., 2023).


2.13 Fungsi Aktivasi

Fungsi aktivasi merupakan komponen penting pada jaringan saraf tiruan yang digunakan untuk mengaktifkan atau menonaktifkan neuron berdasarkan input yang diterima. Fungsi ini memiliki peran dalam input komponen nonlinier ke dalam model, sehingga memungkinkan jaringan saraf tiruan mengenali serta mempelajari pola data yang kompleks. Dua fungsi aktivasi yang umum digunakan yaitu fungsi aktivasi tanh dan fungsi aktivasi sigmoid dengan penjelasan sebagai berikut:

2.13.1 Fungsi Aktivasi Tanh

Fungsi tanh merupakan fungsi aktivasi nonlinier yang digunakan untuk menangani nilai input positif maupun negatif. Fungsi tanh mengubah input ke dalam rentang nilai -1 hingga 1, proses transformasi dilakukan untuk membantu mempercepat proses pelatihan model. Persamaan fungsi tanh diuraikan dalam Persamaan (2.32) berikut (Zhang et al., 2022):


$$\tanh(x) = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.32)$$



2.13.2 Fungsi Aktivasi Sigmoid

Fungsi sigmoid memiliki input bilangan *real* dan memiliki peran mengubah *input* ke dalam rentang nilai 0 hingga 1, proses transformasi dilakukan untuk membantu mempercepat proses pelatihan model. Persamaan fungsi sigmoid diuraikan dalam Persamaan (2.33) berikut (Zhang et al., 2022):

$$\text{sigmoid}(x) = g(x) = \frac{1}{1 + e^{-x}} \quad (2.33)$$



2.14 Hyperparameter

Hyperparameter yaitu variabel konfigurasi di luar model yang nilainya sulit untuk dihitung dari data. *Hyperparameter* tidak bisa dipelajari secara langsung dari data pada proses pelatihan model, sehingga nilainya harus ditentukan terlebih dahulu sebelum melakukan pelatihan agar mendapatkan prediksi terbaik. Ketika membangun model *hyperparameter* harus diperhitungkan karena dapat memengaruhi kinerja model yang dapat meningkatkan akurasi pemodelan. Beberapa *hyperparameter* dalam *deep learning* sebagai berikut (Hikmaturokhman et al., 2022):

1. Jumlah *hidden layer*
2. Jumlah neuron tersembunyi
3. *Batch size* atau jumlah data dalam setiap epoch
4. Epoch (representasi satu set iterasi)
5. *Learning rate*
6. Parameter regulasi.

2.14.1 Hyperparameter tuning

Sebelum melakukan pelatihan menggunakan dataset untuk membangun model, langkah selanjutnya adalah menetapkan parameter atau aturan pelatihan untuk

model tersebut. Saat membuat set pelatihan model, beberapa elemen penting yang harus dipertimbangkan termasuk:

1. Fungsi aktivasi memungkinkan neuron untuk diaktifkan atau dinonaktifkan.
2. *Loss function* menghitung kesalahan model selama proses optimasi.
3. *Optimizer* secara iteratif memperbarui bobot jaringan berdasarkan data pelatihan.

2.15 Deep Learning

Deep learning merupakan bagian dari pembelajaran *machine learning*, yang merupakan jaringan saraf dengan minimum tiga lapisan jaringan saraf tiruan. *Deep learning* memungkinkan pembelajaran dan adaptasi terhadap data berskala besar serta dapat menyelesaikan masalah yang sulit diselesaikan oleh algoritma pembelajaran mesin lainnya (Janiesch et al., 2023). Jaringan saraf tiruan merupakan bagian dari kecerdasan buatan yang menyerupai cara kerja otak manusia. Model pada jaringan saraf tiruan memiliki tiga lapisan, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Salah satu model *deep learning* yang banyak digunakan yaitu *recurrent neural network* (RNN).

2.15.1 Recurrent Neural Networks (RNN)


Model *deep learning* yang umum digunakan yaitu *recurrent neural network* (RNN), model ini memiliki kemampuan menangani tugas-tugas yang lebih kompleks yang tidak dapat dilakukan oleh model tradisional seperti *Hidden Markov Models* (HMMs) atau *discrete Symbolic Grammar Learning Algorithms* (SGLAs). Model RNN dapat mempelajari pola kompleks dari data urutan terstruktur karena model ini bekerja dalam ruang kontinu.

Model RNN memiliki keterbatasan dalam menangani masalah gradien menghilang (*vanishing gradient*). Keterbatasan ini menghambat model RNN untuk menyimpan informasi sebelumnya dalam jangka waktu yang lama (Gers dan Schmidhuber,

2001). Namun masalah ini dapat ditangani, Hochreiter dan Schmidhuber (1997) mengembangkan model *Long Short-Term Memory* (LSTM) untuk menanganinya keterbatasan model RNN yang dirancang efektif menyimpan informasi sebelumnya dan secara signifikan meningkatkan kinerja model RNN (Anh et al., 2019).

2.15.2 Long Short-Term Memory (LSTM)

Pada tahun 1997, Hochreiter dan Schmidhuber mengusulkan model LSTM. Model LSTM merupakan pengembangan dari model RNN. Model LSTM dirancang untuk melengkapi kelemahan RNN dalam memproses data jangka panjang. Model RNN tidak dapat menghubungkan informasi baru dan informasi terdahulu karena memori lama yang tersimpan akan tertimpa dengan memori baru sehingga menyebabkan memori lama tidak berguna, namun model LSTM dapat mengatasinya dengan mengatur memori dalam setiap input menggunakan *memory cell* dan *gate unit* (Manowska & Bluszczyk, 2022). Model LSTM memiliki tiga jenis *gate* yaitu *forget gate*, *input gate*, dan *output gate*. Ketiga *gate* tersebut memiliki fungsi untuk melindungi dan mengontrol *cell state*. *Cell state* yaitu garis horizontal yang berfungsi menghubungkan semua lapisan *output* pada LSTM. Gambar 1 merupakan ilustrasi dari arsitektur LSTM.



Gambar 1. Arsitektur LSTM (Yong et al., 2019)

Gambar 1 menyajikan koneksi internal pada arsitektur LSTM dengan tiga *gate* (*forget gate*, *input gate*, dan *output gate*). Berdasarkan koneksi yang ditunjukkan, *memory cell* LSTM secara matematis dapat dinyatakan sebagai berikut:

Forget Gate (f_t)

Forget gate (f_t) merupakan *gate* awal yang dilalui dalam *memory cell* LSTM. *Forget gate* berfungsi mengatur informasi masa lalu yang akan dilupakan atau disimpan pada *memory cell*. Persamaan *forget gate* dituliskan pada Persamaan (2.34) berikut:

$$f_t = \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f) \quad (2.34)$$

Input gate (i_t)

Input gate (i_t) berfungsi menentukan seberapa banyak informasi saat ini yang akan disimpan ke dalam *memory cell*. *Input gate* berfungsi menentukan *cell state* mana yang harus diperbarui dan digunakan untuk melakukan *update cell state* tersebut. Persamaan *input gate* dan *cell state* dituliskan dalam Persamaan, (2.35), (2.36) dan (2.37) berikut:

$$i_t = \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i) \quad (2.35)$$

$$\tilde{c}_t = \tanh(W_{\tilde{c}h}h_{t-1} + W_{\tilde{c}x}x_t + b_{\tilde{c}}) \quad (2.36)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (2.37)$$

Output gate (o_t)

Output gate (o_t) merupakan *gate* terakhir pada arsitektur LSTM yang berfungsi menentukan *output* yang dihasilkan dari *memory cell*. Persamaan *output gate* dituliskan pada Persamaan (2.38) dan (2.39) berikut:

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (2.38)$$

$$h_t = o_t * \tanh(c_t) \quad (2.39)$$

2.16 Hybrid VARIMAX-LSTM

Metode *hybrid* merupakan metode dengan penggabungan beberapa metode peramalan berbeda untuk meningkatkan akurasi peramalan. Metode *hybrid* dibangun dengan memanfaatkan kekuatan masing-masing metode untuk mengatasi keterbatasan yang dimiliki masing-masing metode secara individual guna meningkatkan kinerja peramalan (Zhang, 2003). Kombinasi model deret waktu terdiri dari komponen autokorelasi linier dan nonlinier yang dijabarkan pada Persamaan (2.40) sebagai berikut:

$$y_t = L_t + N_t \quad (2.40)$$

keterangan:

y_t : data deret waktu ke- t

L_t : komponen linier ke- t

N_t : komponen nonlinier ke- t

Komponen linier dan nonlinier pada Persamaan (2.40) digunakan dalam peramalan data deret waktu. Model VARIMAX digunakan untuk meramalkan data linier, kemudian residual pada model linier menghasilkan hubungan nonlinier. Residual komponen nonlinier dimisalkan sebagai e_t , maka residual e_t dapat dituliskan pada Persamaan (2.41):

$$e_t = y_t - L'_t \quad (2.41)$$

L'_t merupakan nilai peramalan dari komponen linier ke- t . Pada diagnosis model linier residu menjadi faktor penting. Hal ini disebabkan oleh keberadaan korelasi linier yang tersisa dalam residu menunjukkan model belum menangkap pola data

yang ada secara menyeluruh. Namun, proses analisis residu tidak dapat menangkap pola nonlinier dalam data. Keterbatasan dalam menangkap pola nonlinier ini menunjukkan keterbatasan pemodelan dengan statistika klasik. Analisis residu selanjutnya dilakukan dengan menggunakan *deep learning* model LSTM, sehingga hubungan nonlinier dapat ditangkap. Kombinasi komponen linier dan nonlinier peramalan tersebut dapat dituliskan dalam Persamaan (2.42) berikut:

$$y_t' = L_t' + N_t' \quad (2.42)$$

keterangan:

y_t' : nilai peramalan *hybrid* model ke- t

L_t' : nilai peramalan komponen linier ke- t

N_t' : nilai peramalan komponen non linier ke- t

2.17 Evaluasi Model

Evaluasi model dilakukan untuk menentukan baik atau tidaknya model yang dibangun. Evaluasi akurasi ketepatan model dapat dilakukan dengan metode *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE). Statistik uji tersebut dinyatakan pada Persamaan (2.43) dan (2.44) berikut (Pangaribuan et al., 2023):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_t)^2}{n}} \quad (2.43)$$

$$MAPE = \left(\sum_{t=1}^n \left| \frac{(Y_i - \hat{Y}_t)}{\hat{Y}_t} \right| \times 100\% \right) \quad (2.44)$$

Nilai RMSE menghitung selisih kuadrat antara nilai data aktual dan data prediksi dalam setiap pengamatan, kemudian menghitung rata-rata dari perbedaan kuadrat tersebut dan selanjutnya menghitung akar kuadrat dari rata-rata. Sedangkan MAPE mengukur rata-rata persentase eror absolut dari nilai sebenarnya dan nilai prediksi dalam bentuk persentase. Variabel Y dalam persamaan (2.42) dan (2.43) merupakan nilai aktual, dan $\hat{Y}$ adalah nilai prediksi, serta n jumlah observasi data. Semakin kecil nilai RMSE dan nilai MAPE yang diperoleh maka prediksi yang diperoleh semakin akurat.

2.18 *Goodness of Fit*

Goodness of fit merupakan ukuran statistik yang digunakan dalam evaluasi kebaikan model yang diperoleh melalui data pengamatan. Nilai *Kolmogorov-Smirnov* (KS) digunakan dalam membandingkan antara data sampel dengan data distribusi yang diharapkan. Nilai statistik KS menghitung jarak antara distribusi data peramalan dan data aktual. Nilai yang semakin kecil menunjukkan bahwa model mampu menangkap pola tren data dengan baik. Pengukuran nilai KS dijabarkan dalam Persamaan (2.45) berikut ini (Kolmogorov, 1933):

$$D = \max|F_n(x) - F(x)| \quad (2.45)$$

keterangan:

D = statistik uji *Kolmogorov-Smirnov*

$F_n(x)$ = fungsi distribusi kumulatif empiris

$F(x)$ = fungsi distribusi kumulatif teoritis

$\max$ = maksimum nilai perbedaan distribusi

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian dilaksanakan pada semester ganjil tahun ajaran 2024/2025, bertempat di jurusan Magister Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Pada penelitian ini data yang peneliti gunakan terbagi menjadi dua jenis yaitu data sebagai variabel endogen dan data sebagai variabel eksogen. Data harga harian penutupan saham PTBA dan ADRO sebagai variabel endogen yang diperoleh dari website <https://finance.yahoo.com> dan data historis kurs rupiah terhadap USD sebagai variabel eksogen yang diperoleh dari website <https://id.investing.com/>. Data yang digunakan sejak bulan Januari 2016 hingga Desember 2022 berjumlah 2288 pada masing masing variabel dengan data terlampir.

3.3 Metode Penelitian

Berikut ini merupakan langkah-langkah pada penelitian peramalan menggunakan *hybrid* VARIMAX-LSTM:

3.3.1 Model VARIMAX

1. Melakukan studi literatur melalui artikel, jurnal, dan buku mengenai peramalan menggunakan *hybrid* model VARIMAX-LSTM.
2. Mengumpulkan data harian saham PTBA dan ADRO serta data kurs rupiah terhadap USD.
3. *Input* data penelitian ke dalam Python.
4. Melakukan visualisasi data untuk melihat pola dan tren pada data.
5. Melakukan *splitting* data menjadi data *training* dan data *testing* dengan skema *splitting* yaitu 80% data *training* dan 20% data *testing*.
6. Melakukan *preprocessing* data untuk menangani data hilang dan duplikat data.
7. Melakukan uji stasioneritas data dengan menggunakan uji ADF. Apabila data tidak stasioner maka dilakukan proses *differencing*.
8. Menentukan model VARIMAX orde p, d, q melalui plot ACF, PACF, dan *differencing* data. Lalu *input* variabel eksogen ke dalam model VARIMAX.
9. Melakukan estimasi parameter untuk menentukan model terbaik yang didasarkan pada nilai AIC terkecil.
10. Pelatihan menggunakan model VARIMAX terbaik.
11. Melakukan prediksi dengan model VARIMAX terbaik untuk data *testing*.
12. Menghitung residual data dengan mengurangi data aktual dan data hasil prediksi.
13. Mengevaluasi model VARIMAX berdasarkan nilai MAPE dan RMSE.
14. Melakukan peramalan untuk 70 periode mendatang.

3.3.2 Model LSTM

1. *Input* data penelitian ke dalam pemrograman Python.
2. Melakukan visualisasi data untuk melihat pola dan tren pada data.
3. Melakukan *splitting* data menjadi data *training* dan data *testing* dengan skema *splitting* yaitu 80% data *training* dan 20% data *testing*.
4. Melakukan *scaling* data, dengan normalisasi data.

5. Membangun model LSTM dengan menggunakan parameter terbaik hasil dari proses *hyperparameter tuning*.
6. Melakukan prediksi model LSTM.
7. Melakukan denormalisasi data.
8. Melakukan evaluasi model dengan menghitung akurasi terbaik berdasarkan nilai MAPE dan RMSE.
9. Melakukan peramalan untuk 70 periode mendatang menggunakan model LSTM.

3.3.3 Model *Hybrid* VARIMAX-LSTM

Model *hybrid* VARIMAX-LSTM yang dibangun dibagi menjadi dua model yaitu, model *hybrid* VARIMAX- E_LSTM dan model *hybrid* VARIMAX-EP_LSTM.

3.3.3.1 Model *Hybrid* VARIMAX-E_LSTM

1. Input data residual

Melakukan input data residual VARIMAX ke dalam program LSTM untuk membentuk model E_LSTM

2. *Scaling* data

Scaling data residual VARIMAX untuk mengubah data dalam rentang 0 sampai 1 dengan menggunakan *MinMaxScaler*.

3. Pembentukan model E_LSTM

Pembentukan model E_LSTM dibangun dengan menggunakan data residual VARIMAX yang sudah di *scaling* dengan menentukan jumlah *hidden layer* dalam LSTM *layer*.

4. *Hyperparameter* model E_LSTM

Hyperparameter dilakukan untuk menentukan hasil model E_LSTM terbaik yang akan di gunakan.

5. Prediksi model E_LSTM

Selanjutnya melakukan prediksi residual LSTM dengan menggunakan model E_LSTM terbaik.

6. Membentuk model *hybrid* VARIMAX – E_LSTM

Model *hybrid* dibangun dengan menjumlahkan hasil prediksi VARIMAX dengan hasil prediksi residual E_LSTM.

7. *Unscaling* data

Selanjutnya melakukan proses *unscaling* dari hasil prediksi model *hybrid* VARIMAX – E_LSTM untuk mengembalikan data dalam skala yang sebenarnya untuk dilakukan evaluasi model.

8. Evaluasi model

Melakukan Evaluasi model untuk mengetahui seberapa besar kinerja model yang digunakan.

9. Peramalan

Langkah selanjutnya yaitu peramalan menggunakan model *hybrid* VARIMAX – E_LSTM.

3.3.3.2 Model *Hybrid* VARIMAX-EP_LSTM

1. Input data prediksi

Melakukan input data prediksi VARIMAX ke dalam program LSTM untuk membentuk model P_LSTM

2. *Scaling* data


Scaling data prediksi VARIMAX untuk mengubah data dalam rentang 0 sampai 1 dengan menggunakan *MinMaxScaler*.

3. Pembentukan model P_LSTM


Pembentukan model P_LSTM dibangun dengan menggunakan data prediksi VARIMAX yang sudah di *scaling* dengan menentukan jumlah *hidden layer* dalam LSTM *layer*.

4. *Hyperparameter* model P_LSTM
Hyperparameter dilakukan untuk menentukan hasil model P_LSTM terbaik yang akan digunakan.
5. Prediksi model P_LSTM
Selanjutnya melakukan prediksi LSTM dengan menggunakan model P_LSTM terbaik.
6. Membentuk model *hybrid* VARIMAX – EP_LSTM
Model *hybrid* dibangun dengan menjumlahkan hasil prediksi P_LSTM dengan hasil prediksi residual E_LSTM.
7. *Unscaling* data
Selanjutnya melakukan proses *unscaling* dari hasil prediksi model *hybrid* VARIMAX – EP_LSTM untuk mengembalikan data dalam skala yang sebenarnya untuk dilakukan evaluasi model.
8. Evaluasi model
Melakukan Evaluasi model untuk mengetahui seberapa besar kinerja model yang digunakan.
9. Peramalan
Langkah selanjutnya yaitu peramalan menggunakan model *hybrid* VARIMAX – EP_LSTM.


Berikut merupakan gambar diagram alir dalam penelitian ini:




Gambar 2. Diagram alir VARIMAX



Gambar 3. Diagram Alir Model LSTM



Gambar 4. Diagram Alir Model *hybrid* VARIMAX-E_LSTM



Gambar 5. Diagram Alir Model *hybrid* VARIMAX-EP_LSTM

V. KESIMPULAN

5.1 Kesimpulan

Berdasarkan uraian hasil dan pembahasan peramalan harga penutupan saham PTBA dan ADRO menggunakan 4 model yang berbeda yaitu model VARIMAX, model LSTM, model *hybrid* VARIMAX-EP_LSTM, model *hybrid* VARIMAX E_LSTM dapat ditarik kesimpulan sebagai berikut:

1. Model *hybrid* VARIMAX-LSTM memiliki dua pendekatan yaitu model *hybrid* VARIMAX-EP_LSTM yang dibangun melalui penjumlahan hasil model P_LSTM dengan data masukan hasil prediksi VARIMAX (2,1,0) dan hasil prediksi model E_LSTM dengan data masukan data residual model VARIMAX (2,1,0). Kombinasi parameter terbaik pada masing-masing model adalah:
 - a. Model P_LSTM, memiliki kombinasi parameter terbaik yaitu 64 *LSTM unit*, 16 *dense unit*, dan 16 *batch size*.
 - b. Model E_LSTM memiliki kombinasi parameter terbaik yaitu 64 *LSTM unit*, 32 *dense unit*, 16 *batch size*, dan 0,1 *dropout*.
 - c. Model LSTM memiliki kombinasi parameter terbaik yaitu 32 *LSTM unit*, 64 *dense unit*, 32 *batch size*, dan 0,1 *dropout*.
2. Peramalan terbaik harga penutupan saham PTBA dan ADRO untuk 70 periode mendatang berdasarkan nilai Kolmogorov Smirnov ditunjukkan oleh model *hybrid* VARIMAX-EP_LSTM. Hasil yang diperoleh menunjukkan nilai yang signifikan apabila dibandingkan dengan model lainnya yaitu model VARIMAX (2,1,0) yang cenderung konstan meskipun hasil prediksi model VARIMAX sangat baik. Selanjutnya model *hybrid* VARIMAX- E_LSTM memiliki hasil yang sedikit fluktuatif demikian juga dengan model LSTM individu yang memiliki hasil tidak

jauh lebih baik dibandingkan dengan peramalan yang diperoleh model VARIMAX-EP_LSTM.

3. Prediksi model *hybrid* VARIMAX-EP_LSTM menunjukkan nilai evaluasi yang sangat baik yaitu nilai RMSE sebesar 154,852 dan MAPE 0,04. Hasil peramalan yang diperoleh juga menunjukkan hasil yang sangat baik berdasarkan nilai nilai statistik Kolmogorov Smirnov apabila dibandingkan dengan hasil peramalan model VARIMAX (2,1,0), model *hybrid* VARIMAX- E_LSTM, dan model LSTM individu.

DAFTAR PUSTAKA

- Anh, D. T., Van, S. P., Dang, T. D., & Hoang, L. P. (2019). Downscaling rainfall using deep learning long short-term memory and feedforward neural network. *International Journal of Climatology*, 39(10), 4170–4188. <https://doi.org/10.1002/joc.6066>
- Atmaja, D. D., Widowati, W., & Warsito, B. (2021). Forecasting Stock Prices on the Lq45 Index Using the Varimax Method. *Media Statistika*, 14(1), 98–107. <https://doi.org/10.14710/medstat.14.1.98-107>
- Box, E. P. G., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis*.
- Brockwell, P. J., & Davis, R. A. (2003). Introduction to Time Series and Forecasting. In *Technometrics* (Vol. 45, Issue 1). <https://doi.org/10.1198/tech.2003.s31>
- Caliwag, A. C., & Lim, W. (2019). Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications. *IEEE Access*, 7, 59680–59689. <https://doi.org/10.1109/ACCESS.2019.2914188>
- Chen, Z., Zhang, D., Jiang, H., Wang, L., Chen, Y., Xiao, Y., Liu, J., Zhang, Y., & Li, M. (2021). Load Forecasting Based on LSTM Neural Network and Applicable to Loads of “Replacement of Coal with Electricity.” *Journal of Electrical Engineering and Technology*, 16(5), 2333–2342. <https://doi.org/10.1007/s42835-021-00768-8>
- Cui, C., Wang, P., Li, Y., & Zhang, Y. (2023). McVCsB: A new hybrid deep learning network for stock index prediction. *Expert Systems with Applications*, 232(June), 120902. <https://doi.org/10.1016/j.eswa.2023.120902>
- Elliott, G., Granger, C. W. ., & Timmermann, A. (2006). *Handbook Of Economic forecasting*.
- Engle, R. F., & Granger, W. J. (1987). Co-Integration and Error Correction Representation, Estimation, and Testing. In *Econometrica* (Vol. 55, Issue 2, pp. 251–276).
- Gers, F. A., & Schmidhuber, J. (2001). LSTM recurrent networks learn simple

- context-free and context-sensitive languages. *IEEE Transactions on Neural Networks*, 12(6), 1333–1340. <https://doi.org/10.1109/72.963769>
- Granger, C. W. J. (2008). Investigating Causal Relations by Econometric Models and Cross-Spectral Methods. *Essays in Econometrics Vol II: Collected Papers of Clive W. J. Granger*, 37(3), 31–47. <https://doi.org/10.1017/ccol052179207x.002>
- Hall, A. D., & Nicholls, D. F. (1980). The Evaluation of Exact Maximum Likelihood Estimates for VARMA Models. *Journal of Statistical Computation and Simulation*, 10(3–4), 251–262. <https://doi.org/10.1080/00949658008810373>
- Hikmaturokhman, A., Nafi'ah, H., Larasati, S., Wahyudin, A., Ariprawira, G., & Pramono, S. (2022). Deep Learning Algorithm Models for Spam Identification on Cellular Short Message Service. *Journal of Communications*, 17(9), 769–776. <https://doi.org/10.12720/jcm.17.9.769-776>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Janiesch, C., Zschech, P., & Heinrich, K. (2023). Machine learning and deep learning. *Quantum Computing and Artificial Intelligence: Training Machine and Deep Learning Algorithms on Quantum Computers*, 71–84. <https://doi.org/10.1515/9783110791402-004>
- Jin, X., Song, A., & He, M. (2024). Short-term Thermal Coal Price Forecasting Based on EL-CLSTM Model. *IEEE Access*, PP, 1. <https://doi.org/10.1109/ACCESS.2024.3474730>
- Jusmawati, Hadijati, M., & Fitriyani, N. (2020). Penerapan Model Vector Autoregressive Integrate Moving Average dalam Peramalan Laju Inflasi dan Suku Bunga di Indonesia. *Eigen Mathematics Journal*, 03(02), 73–82. <https://doi.org/10.29303/emj.v3i2.62>
- Makridakis, S., Hyndman, R. J., & Petropoulos, F. (2020). Forecasting in social settings: The state of the art. *International Journal of Forecasting*, 36(1), 15–28. <https://doi.org/10.1016/j.ijforecast.2019.05.011>
- Manowska, A., & Bluszcz, A. (2022). Forecasting Crude Oil Consumption in Poland Based on LSTM Recurrent Neural Network. *Energies*, 15(13). <https://doi.org/10.3390/en15134885>
- Manowska, A., Rybak, A., Dylong, A., & Pielot, J. (2021). Forecasting of natural gas consumption in poland based on ARIMA-LSTM hybrid model. *Energies*, 14(24). <https://doi.org/10.3390/en14248597>
- Mbah, T. J., & Long, M. (2021). *Using LSTM and ARIMA to Simulate and Predict*

Limestone Price Variations. 913–926.

- Pangaribuan, J. J., Fanny, F., Barus, O. P., & Romindo, R. (2023). Prediksi Penjualan Bisnis Rumah Properti Dengan Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). *Jurnal Sistem Informasi Bisnis*, 13(2), 154–161. <https://doi.org/10.21456/vol13iss2pp154-161>
- Rambha, U. B., & Seshashayee, M. (2022). Time Series Augmentation based on Vector Auto Regression and Long Short Term Memory method for Air Quality Prediction. *International Journal of Mechanical Engineering*, 7(4), 974–5823.
- Rusyana, A., Tatsara, N., Balqis, R., & Rahmi, S. (2020). Application of Clustering and VARIMA for Rainfall Prediction. *IOP Conference Series: Materials Science and Engineering*, 796(1). <https://doi.org/10.1088/1757-899X/796/1/012063>
- TSAY, R. S. (2014). Multivariate Time Series Analysis. In *Journal of Physics A: Mathematical and Theoretical* (Vol. 44, Issue 8). <https://doi.org/10.1088/1751-8113/44/8/085201>
- Usman, M., Komarudin, M., Nurhanurawati, Russel, E., Sidiq, A., Warsono, & Elfaki, F. A. M. (2023). Dynamic Modeling and Analysis of Some Energy Companies of Indonesia Over the Year 2018 to 2022 By Using VAR(p)-CCC GARCH(r,s) Model. *International Journal of Energy Economics and Policy*, 13(4), 542–554. <https://doi.org/10.32479/ijeep.14364>
- Usman, M., Loves, L., Russel, E., Ansori, M., Warsono, W., Widiarti, W., & Wamiliana, W. (2022). Analysis of Some Energy and Economics Variables by Using VARIMAX Model in Indonesia. *International Journal of Energy Economics and Policy*, 12(2), 91–102. <https://doi.org/10.32479/ijeep.11897>
- Warsono, Russel, E., Putri, A. R., Wamiliana, Widiarti, & Usman, M. (2020). Dynamic modeling using vector error-correction model: Studying the relationship among data share price of energy PGAS Malaysia, AKRA, Indonesia, and PTT PCL-Thailand. *International Journal of Energy Economics and Policy*, 10(2), 360–373. <https://doi.org/10.32479/ijeep.8946>
- Wei, W. W. S. (2006). Time Series Analysis: Univariate and Multivariate Methods. In *Technometrics* (Vol. 33, Issue 1, pp. 108–109). <https://doi.org/10.1080/00401706.1991.10484777>
- Xu, D., Zhang, Q., Ding, Y., & Zhang, D. (2022). Application of a hybrid ARIMA-LSTM model based on the SPEI for drought forecasting. *Environmental Science and Pollution Research*, 29(3), 4128–4144. <https://doi.org/10.1007/s11356-021-15325-z>
- Yong Yu, Xiaosheng Si, Jianxun Zhang, C. H. (2019). *A Review of Recurrent*

Neural Networks: LSTM Cells and Network Architectures Yong. March, 1235–1270. <https://doi.org/10.1162/NECO>

Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)