

**MODEL HYBRID VECMX - LSTM PADA PERAMALAN HARGA
SAHAM EMAS PT. ANEKA TAMBANG TBK. (ANTAM) DAN HARGA
EMAS DUNIA DENGAN PENGARUH NILAI KURS**

(Tesis)

Oleh

RISKA ANISA APRIANI

2327031001



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

2025

ABSTRACT

HYBRID VECMX - LSTM MODEL ON GOLD STOCK PRICE FORECASTING OF PT. ANEKA TAMBANG TBK. (ANTAM) AND WORLD GOLD PRICE WITH THE INFLUENCE OF EXCHANGE RATE

By

Riska Anisa Apriani

Modeling is one of the important forms of analysis in understanding the pattern of observational data. The approach used is multivariate time series analysis to predict the price of gold stocks of PT. Aneka Tambang Tbk. (ANTAM) and world gold prices. The Vector Error Correction Model with Exogenous (VECMX) model is used to capture linear patterns and long-term relationships between endogenous variables, namely the price of gold stocks of PT ANTAM and the price of gold in the WORLD, with the CURS value as an exogenous variable. Analysis of long-term relationships with nonlinear data patterns using the Long Short-Term Memory (LSTM) model. Each model has limitations in capturing data patterns, so this study proposes a hybrid VECMX-LSTM approach. The results of the models compared are VECMX, LSTM, hybrid VECMX - EP_LSTM, and hybrid VECMX - E_LSTM. The evaluation results using Mean Absolute Percentage Error (MAPE) show that the VECMX – EP_LSTM hybrid provides the best performance with a MAPE of 3.74% for ANTM gold prices and 7.32% for DUNIA gold stock prices. This shows that the integration of linear and nonlinear models can improve forecasting accuracy. In addition, the VECMX model estimation results show that the exchange rate has a significant effect on both endogenous variables in the long term.

Keyword : *VECMX, LSTM, Models Hybrid, Gold Price, Forecasting, MAPE*

ABSTRAK

MODEL HYBRID VECMX - LSTM PADA PERAMALAN HARGA SAHAM EMAS PT. ANEKA TAMBANG TBK. (ANTAM) DAN HARGA EMAS DUNIA DENGAN PENGARUH NILAI KURS

Oleh

Riska Anisa Apriani

Pemodelan merupakan salah satu bentuk analisis penting dalam memahami pola dari data pengamatan. Pendekatan yang digunakan yaitu analisis deret waktu multivariat untuk meramalkan harga saham emas PT. Aneka Tambang Tbk. (ANTAM) dan harga emas dunia. Model *Vector Error Correction Model with Exogenous* (VECMX) digunakan untuk menangkap pola linier dan hubungan jangka panjang antara variabel endogen, yaitu harga saham emas PT ANTAM dan harga emas DUNIA, dengan nilai KURS sebagai variabel eksogen. Analisis hubungan jangka panjang dengan pola data nonlinear model yang digunakan model *Long Short-Term Memory* (LSTM). Masing-masing model memiliki keterbatasan dalam menangkap pola data, sehingga penelitian ini mengusulkan pendekatan *hybrid* VECMX-LSTM. Hasil model yang dibandingkan, yaitu VECMX, LSTM, *hybrid* VECMX – EP_LSTM, dan *hybrid* VECMX – E_LSTM. Hasil evaluasi menggunakan Mean Absolute Percentage Error (MAPE) menunjukkan bahwa *hybrid* VECMX – EP_LSTM memberikan performa terbaik dengan MAPE sebesar 3,74% untuk harga emas ANTAM dan 7,32% untuk harga saham emas DUNIA. Hal ini menunjukkan bahwa integrasi model linier dan nonlinier mampu meningkatkan akurasi peramalan. Selain itu, hasil estimasi model VECMX menunjukkan bahwa nilai tukar berpengaruh signifikan terhadap kedua variabel endogen dalam jangka panjang.

Kata kunci: VECMX, LSTM, Hybrid model, Harga Emas, Peramalan, MAPE

**MODEL HYBRID VECMX - LSTM PADA PERAMALAN HARGA
SAHAM EMAS PT. ANEKA TAMBANG TBK. (ANTAM) DAN HARGA
EMAS DUNIA DENGAN PENGARUH NILAI KURS**

Oleh

Riska Anisa Apriani

Tesis

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

Pada

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



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

Judul Tesis

: MODEL HYBRID VECMX - LSTM PADA
PERAMALAN HARGA SAHAM EMAS PT.
ANEKA TAMBANG TBK. (ANTAM) DAN
HARGA EMAS DUNIA DENGAN PENGARUH
NILAI KURS.

Nama Mahasiswa

: Riska Anisa Apriani

Nomor Pokok Mahasiswa

: 2327031001

Program Studi

: Pascasarjana 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 : **Riska Anisa Apriani**

Nomor Pokok Mahasiswa : **2327031001**

Program Studi : **Magister Matematika**

Jurusan : **Matematika**

Dengan ini menyatakan bahwa tesis saya yang berjudul **“Model Hybrid Vecmx - Lstm Pada Peramalan Harga Saham Emas Pt. Aneka Tambang Tbk. (Antam) Dan Harga Emas Dunia Dengan Pengaruh Nilai Kurs”** 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



Riska Anisa Apriani
NPM. 2327031001

RIWAYAT HIDUP

Penulis memiliki nama Riska Anisa Apriani, yang lahir di Banjar Agung pada tanggal 21 April 2000. penulis merupakan anak keempat dari delapan bersaudara dari pasangan Bapak Jadiono dan Ibu Supatmi.

Penulis memulai pendidikan pertama pada Sekolah Dasar di SDN 1 Jati Agung pada tahun 2006-2012, selanjutnya pada tahun 2013-2015 penulis melanjutkan pendidikan Sekolah Menengah Pertama di SMP Tunas Dharma dan melanjutkan Sekolah Menengah Atas di SMAN 1 Jati Agung pada tahun 2015-2018. Pada tahun 2018 penulis diterima sebagai mahasiswa di program studi S1 Matematika, Jurusan Matematika, Fakultas Sains, Institut Teknologi Sumatera melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN).

Pada tahun 2020 penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Margo Mulyo, Kecamatan Jati Agung, Kabupaten Lampung Selatan sebagai salah satu bentuk pengabdian kepada masyarakat. Pada tahun 2021 penulis juga melakukan kuliah Kerja Praktek (KP) sebagai bentuk pengenalan dalam dunia kerja. Program KP dilakukan selama 40 hari di Badan Penanggulangan Bencana Daerah (BPBD) Provinsi Lampung yang beralamat di Pahoman, Enggal, Kota Bandar Lampung. Pada akhirnya penulis menyelesaikan pendidikan S1 pada tahun 2022.

Pada tahun 2023 penulis diterima sebagai mahasiswa S2 di Jurusan Program Studi Pascasarjana Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

KATA INSPIRASI

“ Sesungguhnya bersama kesulitan ada kemudahan”

(QS. Al-Insyirah:6)

“Nikmati yang sedang kamu jalani, besok belum tentu akan kamu temui lagi”

(Anonym)

“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 dengan ridho-Nya sehingga penulis dapat menyelesaikan tesis ini dengan baik.

Rasa syukur dan bahagia saya persembahkan rasa terima kasih ini untuk:

Ayah, Ibu, Kakak, dan Adik

Terima kasih untuk kedua orang tuaku, kakak – kakak ku dan adik - adikku yang selalu memberikan doa dan dukungan yang tiada hentinya dalam menemani segala proses yang dilalui penulis. Terimakasih atas semua perhatian, semangat dan bantuan dalam membantu kelancaran kuliah selama ini.

Terima kasih kepada dosen-dosen pembimbing tesis, pembimbing akademik dan pembahas tesis yang telah sangat sabar dalam membimbing dan memberikan masukan, krtik serta ide-ide yang sangat membantu sehingga penulis dapat menyelesaikan tesis ini.

Terima kasih kepada teman-teman satu angkatan Ani, Hamzah, Wahyu dan teman lainnya yang tidak dapat 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 Allah SWT yang telah memberikan keberkahan dan kelancaran yang luar biasa sehingga penulis dapat menyelesaikan Tesis dengan judul **“Model Hybrid Vecmx - Lstm Pada Peramalan Harga Saham Emas Pt. Aneka Tambang Tbk. (Antam) Dan Harga Emas Dunia Dengan Pengaruh Nilai Kurs”** sebagai syarat untuk memperoleh gelar Magister Matematika di Universitas Lampung.

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

1. Bapak 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. Ibu 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. Bapak 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. Ibu 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. Ibu Dr. Fitriani, S.Si., M.Sc. selaku dosen Pembimbing akademik yang telah

bersedia membimbing dalam proses perkuliahan, serta memberikan masukan kritik dan saran kepada penulis sehingga menjadi lebih baik lagi.

6. 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.

7. 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 TABEL.....	vi
DAFTAR GAMBAR.....	vii
I. PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
II. TINJAUAN PUSTAKA	6
2.1 Penelitian Terkait.....	6
2.2 <i>Multivariate Time Series</i>	8
2.2.1 <i>Vector Autoregressive (VAR)</i>	9
2.2.2 <i>Vector Error Correction Model (VECM)</i>	10
2.2.3 <i>Vector Error Correction Model with Exogenous (VECMX)</i>	11
2.2.4 Peramalan (<i>Forecasting</i>).....	12
2.3 Uji Asumsi.....	13
2.3.1 Uji Stasioneritas.....	13
2.3.2 Uji Kointegrasi.....	15
2.3.3 Penentuan Lag Optimal	16
2.3.4 Uji <i>Kausalitas Granger</i>	17
2.4 Estimasi Parameter Model.....	18
2.4.1 <i>Maksimum Likelihood Estimator (MLE)</i>	18
2.5 Diagnosis Model.....	19
2.5.1 Uji Normalitas <i>Residual</i>	19
2.5.2 Uji Stabilitas	20
2.5.3 Uji <i>White Noise</i>	21

2.6 <i>Impulse Response Function</i> (IRF).....	22
2.7 <i>Machine Learning</i> (ML).....	23
2.7.1 <i>Scaling Data</i>	23
2.7.2 <i>Hyperparamater Tuning</i>	24
2.7.3 <i>Fungsi Aktivasi</i>	25
2.8 <i>Deep Learning</i>	26
2.8.1 <i>Long Short Term Memory</i> (LSTM)	26
2.9 <i>Hybrid VECMX-LSTM</i>	28
2.10 <i>Evaluasi Model</i>	29
2.10.1 <i>Mean Absolute Percent Error</i> (MAPE).....	29
2.10.2 <i>Root Mean Square Error</i> (RMSE).....	29
2.10.3 <i>Mean Absolute Error</i> (MAE).....	30
III. METODE PENELITIAN	31
3.1 <i>Waktu dan Tempat Penelitian</i>	31
3.2 <i>Data Penelitian</i>	31
3.3 <i>Variabel Penelitian</i>	31
3.4 <i>Metode Pengolahan Data</i>	32
3.4.1 <i>Model VECMX</i>	32
3.4.2 <i>Model LSTM</i>	34
3.4.3 <i>Model Hybrid VECMX-LSTM</i>	34
IV. HASIL DAN PEMBAHASAN	42
4.1 <i>Input Data</i>	42
4.2 <i>Proses Prediksi dan Peramalan Model VECMX</i>	45
4.2.1 <i>Splitting Data</i>	45
4.2.2 <i>Uji Stasioneritas</i>	46
4.2.3 <i>Penentuan Lag Optimal</i>	47
4.2.4 <i>Uji Kointegrasi</i>	49
4.2.5 <i>Prediksi Model VECMX</i>	50
4.2.6 <i>Uji Asumsi</i>	52
4.2.7 <i>Peramalan Model VECMX(3, 1)</i>	53
4.3 <i>Prediksi dan Peramalan Model LSTM</i>	55
4.3.1 <i>Splitting Data</i>	55

4.3.2 <i>Scaling</i> Data.....	55
4.3.3 Membangun model LSTM.....	56
4.3.4 Prediksi Model LSTM	57
4.3.5 Peramalan Model LSTM	58
4.4 Prediksi dan Peramalan Model <i>Hybrid</i> VECMX – LSTM	59
4.4.1 <i>Input</i> Dan <i>Scaling</i> Data Residual VECMX	60
4.4.2 Membangun Model E_LSTM.....	60
4.4.3 <i>Hyperparameter Tuning</i> Model E_LSTM.....	61
4.4.4 Prediksi Model E_LSTM.....	61
4.4.5 Peramalan Model E_LSTM.....	63
4.4.6 Prediksi Model <i>Hybrid</i> VECMX – E_LSTM.....	64
4.4.7 Peramalan Model <i>Hybrid</i> VECMX – E_LSTM	65
4.4.8 <i>Input</i> Dan <i>Scaling</i> Data Prediksi VECMX	66
4.4.9 Membangun Model P_LSTM.....	67
4.4.10 <i>Hyperparameter Tuning</i> Model P_LSTM.....	68
4.4.11 Prediksi Model P_LSTM.....	68
4.4.12 Peramalan Model P_LSTM	70
4.4.13 Prediksi Model <i>Hybrid</i> VECMX - EP_LSTM	70
4.4.14 Peramalan Model <i>Hybrid</i> VECMX - EP_LSTM.....	72
4.5 <i>Goodness Off Fit</i>	73
V. KESIMPULAN DAN SARAN	75
5.1 Kesimpulan.....	75
5.2 Saran.....	76
DAFTAR PUSTAKA.....	77
LAMPIRAN.....	81

DAFTAR TABEL

Tabel 1 Penelitian Terkait	6
Tabel 2 Statistika Deskriptif harga emas PT. ANTM, DUNIA dan KURS.....	42
Tabel 3 Splitting Data	45
Tabel 4 Hasil Uji ADF pertama	46
Tabel 5 Hasil Uji ADF kedua.....	47
Tabel 6 Nilai AIC pada masing-masing lag dari variabel endogen	47
Tabel 7 Nilai AIC terkecil untuk variabel eksogen.....	48
Tabel 8 Hasil model VECMX(p, s).....	48
Tabel 9 Hasil Uji Kointegrasi antar variabel endogen	49
Tabel 10 Evaluasi hasil prediksi VECMX(3, 1)	51
Tabel 11 Hasil Uji <i>Ljung-Box</i> Residual prediksi VECMX(3, 1)	53
Tabel 12 Parameter untuk model LSTM.....	56
Tabel 13 Hasil <i>Hyperparameter tuning</i> model LSTM.....	56
Tabel 14 Metrik Evaluasi Model LSTM.....	58
Tabel 15 Parameter Model E_LSTM.....	60
Tabel 16 Hasil <i>Hyperparameter Tuning</i> Model E_LSTM.....	61
Tabel 17 Evaluasi Model E_LSTM	63
Tabel 18 Hasil Evaluasi Model <i>Hybrid</i> VECMX - E_LSTM.....	65
Tabel 19 Parameter Model P_LSTM	67
Tabel 20 Hasil <i>Hyperparameter Tuning</i> Model P_LSTM.....	68
Tabel 21 Evaluasi Hasil Prediksi P_LSTM	69
Tabel 22 Evaluasi Model <i>Hybird</i> VECMX - EP_LSTM.....	71
Tabel 23 Hasil <i>Goodness Of Fit</i> ANTM.....	73
Tabel 24 Hasil <i>Goodness Of Fit</i> DUNIA.....	74

DAFTAR GAMBAR

Gambar 1	Arsitektur LSTM (Yurtsever, 2021).....	27
Gambar 2	Diagram Alir Model VECMX.....	38
Gambar 3	Diagram Alir Model LSTM	39
Gambar 4	Diagram Alir Model <i>Hybrid</i> VECMX-E_LSTM.....	40
Gambar 5	Diagram Alir Model <i>Hybrid</i> VECMX - EP_LSTM.....	41
Gambar 6	Plot Harga Emas ANTM	43
Gambar 7	Plot harga emas DUNIA	44
Gambar 8	Plot nilai tukar rupiah (KURS).....	44
Gambar 9	Plot Aktual vs Prediksi model VECMX(3, 1).....	50
Gambar 10	Residual data prediksi ANTM.....	51
Gambar 11	Residual data prediksi DUNIA	52
Gambar 12	Plot peramalan harga emas ANTM.....	54
Gambar 13	Plot peramalan harga emas DUNIA.....	54
Gambar 14	Grafik perbandingan data aktual dan prediksi LSTM.....	57
Gambar 15	Visualisasi peramalan model LSTM	59
Gambar 16	Visualisasi prediksi residual model VECMX dan model E_LSTM .	62
Gambar 17	Visualisasi Peramalan Model E_LSTM.....	63
Gambar 18	Visualisasi Hasil Prediksi Model <i>Hybrid</i> VECMX - E_LSTM	64
Gambar 19	Visualisasi Peramalan Model <i>Hybrid</i> VECMX - E_LSTM.....	66
Gambar 20	Visualisasi Prediksi VECMX dan Prediksi LSTM	69
Gambar 21	Visualisasi peramalan model P_LSTM.....	70
Gambar 22	Visualisasi Hasil Prediksi Model <i>Hybrid</i> VECMX - EP_LSTM.....	71
Gambar 23	Visualisasi Hasil Peramalan Model <i>Hybrid</i> VECMX - EP_LSTM..	72

I. PENDAHULUAN

1.1 Latar Belakang

Pemodelan merupakan salah satu analisis yang dilakukan dengan pembentukan model dari suatu data pengamatan yang digunakan. Pada bidang statistik pemodelan sering dilakukan di berbagai jenis data, salah satunya yaitu data deret waktu. Data deret waktu merupakan kumpulan data yang dihasilkan secara teratur dalam interval waktu yang sama. Meskipun dalam pengurutan data biasanya dilakukan dalam waktu yang sama dan dimensi yang berbeda, seperti dimensi waktu (Wei, 2006). Analisis data deret waktu sering digunakan pada data *univariat* dan data *multivariat*. Pada data *univariat* salah satu model yang digunakan adalah *Autoregressive integrated Moving Average* (ARIMA). Model ARIMA digunakan pada data tidak stasioner untuk satu variabel yang diamati dan tidak mempertimbangkan pengaruh dari variabel luar, seperti penelitian yang sudah dilakukan Sunyanti dan Mukhaiyar (2019) yaitu memprediksi harga emas dengan menggunakan model ARIMA, pada fenomena dunia nyata, data deret waktu dipengaruhi oleh faktor. Sehingga untuk mengetahui hubungan atau pengaruh antar variabel lain menggunakan analisis *multivariat*. Model analisis multivariat yang digunakan yaitu *Vector Autoregressive* (VAR).

Model VAR merupakan model yang sering digunakan pada data multivariat untuk memprediksi data stasioner dan menganalisis hubungan antar variabel – variabel serta menganalisis dampak dari faktor *error* yang terdapat pada sistem variabel tersebut. Ketika data deret waktu tidak stasioner serta mengalami kointegrasi maka model VAR akan terestriksi dalam memprediksi model untuk jangka panjang, sehingga untuk menganalisis hubungan jangka panjang dan pendek pada variabel

data yang tidak stasioner menggunakan model *Vector Error Correction Model* VECM (Warsono et al., 2020., Usman et al., 2022., Fahria et al., 2023). Model VECM pertama kali diperkenalkan oleh Engle dan Granger, (1987) digunakan untuk mengatasi data yang mengalami kointegrasi atau hubungan jangka panjang antar variabel. Model VECM digunakan untuk mengoreksi ketidakseimbangan jangka panjang serta data yang tidak stasioner (Fahria et al., 2023., Shubha dan Sushma., 2019). Model VECM merupakan model yang semua variabelnya dapat digunakan sebagai variabel endogen, dan variabel endogen juga dapat dipengaruhi oleh variabel eksogen lainnya. Variabel eksogen adalah variabel yang dianggap memiliki pengaruh terhadap variabel endogen tetapi tidak dipengaruhi oleh variabel lain dalam model. Sebaliknya, variabel endogen adalah variabel yang dianggap memiliki pengaruh terhadap variabel lain dan dipengaruhi oleh variabel lain dalam model. Jika variabel eksogen ditambahkan ke dalam model VECM, maka model yang digunakan adalah model *Error Correction Model* dengan variabel eksogen disebut *Vector Error Correction Model with Exogenous* (VECMX) (Usman et al., 2022). Pada penelitian yang telah dilakukan Usman et al. (2022) yaitu menganalisis hubungan harga bensin dan jumlah uang beredar sebagai variabel endogen dengan konsumsi import dan ekspor minyak dan gas sebagai variabel eksogen, diperoleh hasil model terbaik VECMX(3,1) pada rank kointegrasi = 1. Pada tahapan prediksi, model VECM dapat mengidentifikasi struktur linear dalam data deret waktu multivariat. Namun, model stokastik adalah model linear dengan kemampuan terbatas untuk memprediksi data dengan pola nonlinear. Beberapa tahun terakhir muncul peneliti dengan menggunakan model *Recurrent Neural Network* (RNN) oleh para akurasi prediksi untuk mengatasi pola data nonlinear, karena model berbasis data tradisional tidak dapat memprediksi data *nonlinear* dengan baik (Xu et al., 2022).

Recurrent Neural Network adalah jenis rancangan *deep learning* yang sangat baik dalam memprediksi harga karena kemampuannya dalam menangani data berurutan, seperti deret waktu harga. Menurut Bhandari et al. (2022), RNN dapat digunakan untuk menggambarkan keterkaitan temporal yang kompleks dalam data keuangan dengan menghasilkan estimasi harga yang tepat. Namun, RNN tidak dapat bekerja

dengan baik untuk informasi jangka panjang sehingga muncul *Long Short Term Memory* (LSTM) (Primananda dan Isa, 2021). *Long Short Term Memory* adalah sebuah turunan dari algoritma RNN yang dirancang khusus untuk mengolah data sekuensial seperti teks, ucapan, atau data deret waktu dalam bentuk model nonlinear (Zhang et al., 2020., E, Jianwei et al., 2019). Pada penelitian Bhandari et al. (2022) melakukan prediksi terhadap indeks harga saham emas menggunakan LSTM, untuk mengatasi masalah data sekuensial serta mempelajari hubungan yang kompleks dan nonlinear. Penelitian lain yang dilakukan Dalimunthe et al. (2025) memprediksi pergerakan harga emas menggunakan LSTM dengan hasil bahwa perkiraan pergerakan harga emas secara akurat, menghasilkan MAE sebesar 19,81, yang menunjukkan bahwa prediksi rata-rata menyimpang sekitar 19,81 unit dari nilai aktual dan nilai MAPE sebesar 0,83%. Pada proses peramalan serta prediksi model LSTM hanya dapat digunakan pada model nonlinear sehingga tidak dapat memprediksi untuk data dengan model linear.

Permasalahan pada data penelitian yang memiliki pola data linear dan non linear, sehingga muncul persepektif model *hybrid* yang pertama kali dikenalkan oleh (Zhang, 2003). Pada penelitian Zhang, (2003) mengenalkan model *hybrid* pada prediksi data deret waktu dengan menggunakan model ARIMA dan ANN. Selain dalam menangani pola data linear dan nonlinear, model *hybrid* juga dapat mengurangi ketidakpastian model yang biasanya terjadi dalam inferensi statistik dan peramalan deret waktu. Seperti pada penelitian Caliwag dan Lim. (2019) telah melakukan *hybrid* model *Vector Autoregressive Moving Average – Long Short Term Memory* (VARMA-LSTM) pada peramalan status pengisian dan tegangan keluaran baterai lithium-ion pada aplikasi sepeda motor listrik dengan hasil nilai RMSE sebesar 0,161 dan 0,193. Pada penellitian lain yaitu Bayu dan Surjandari, (2020) melakukan *hybrid* model antara VAR-RNN untuk memprediksi permasalahan deret waktu multivariat, menghasilkan peramalan dengan akurasi sebesar 98,98%, dan 99,40%. Sehingga, pada penelitian ini bertujuan melakukan analisis model *hybrid* antara VECMX – LSTM untuk proses prediksi dan peramalan.

Peramalan adalah proses yang dilakukan untuk meramalkan suatu harga atau kejadian yang akan terjadi dimasa mendatang berdasarkan informasi masa lalu. Peramalan merupakan peran penting yang dibutuhkan oleh suatu perusahaan atau seorang individu dalam berinvestasi (Ye et al., 2024). Investasi adalah suatu kegiatan penanaman modal atau penyimpanan uang yang dilakukan dengan tujuan untuk mendapatkan keuntungan di masa depan (Bhandari et al., 2022). Emas merupakan salah satu investasi yang paling diminati, karena emas memiliki harga relatif sama dan tidak terlalu dipengaruhi oleh fluktuasi pasar lain (Dalimunthe et al., 2025). PT. ANTM adalah salah satu perusahaan tambang di Indonesia yang berjalan dalam bidang eksplorasi, pengolahan serta pemasaran emas dan saham emas. Pergerakan harga saham emas PT. ANTM dipengaruhi beberapa faktor lain salah satunya nilai tukar rupiah (Kurs). Fluktuasi nilai tukar kurs berpengaruh pada nilai saham sehingga menjadi bahan pertimbangan bagi investor untuk berinvestasi (Feren dan Sihwahjoeni, 2022). Selain pengaruh dari nilai kurs pergerakan harga saham emas PT. ANTM di analisis hubungan dengan harga emas Dunia. Sehingga pada penelitian ini dilakukan analisis data harga saham emas PT. ANTM dan harga saham emas dunia dengan pengaruh nilai kurs menggunakan model *hybrid* VECMX-LSTM untuk mengatasi masalah pada peramalan harga emas PT. ANTM dan harga saham emas dunia yang memiliki pola data linear dan pola data nonlinear.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah di uraikan diatas maka muncullah rumusan masalah dalam penelitian ini adalah:

1. Bagaimana struktur model VECMX, model LSTM dan model *hybrid* VECMX-LSTM dalam meramalkan harga saham emas PT. ANTM dan harga saham emas dunia dengan pengaruh nilai kurs?
2. Bagaimana kinerja model VECMX, model LSTM dan model *hybrid* VECMX-LSTM dalam memprediksi harga saham emas PT. ANTM dan harga saham emas dunia dengan pengaruh nilai kurs?

3. Bagaimana hasil prediksi dan peramalan menggunakan model VECMX, model LSTM, dan model hybrid VECM – LSTM harga saham emas PT. ANTM dan harga saham emas dunia dengan pengaruh nilai kurs?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah maka tujuan dari penelitian ini adalah:

1. Membangun model VECMX, model LSTM, dan model *hybrid* VECMX – LSTM
2. Mengetahui dan membandingkan hasil kinerja model *hybrid* VECMX – LSTM dengan model VECMX dan model LSTM.
3. Mengetahui dan membandingkan hasil prediksi dan peramalan model *hybrid* VECMX – LSTM dengan model VECMX dan model LSTM.pada harga saham emas PT. ANTM dan harga saham emas dunia dengan pengaruh nilai kurs.

1.4 Manfaat Penelitian

Pada penelitian yang akan dilakukan, peneliti berharap bahwa penelitian dapat:

1. Memberikan kontribusi literatur tentang pemodelan pada data deret waktu multivariat dengan mengkombinasikan model statistik klasik (VECMX) dengan *deep learning* (LSTM).
2. Menambah wawasan serta dapat menjadi bahan referensi dalam pendekatan pemodelan *hybrid*.
3. Meningkatkan kualitas analisis big data.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Kajian literatur merupakan tahapan awal dalam melakukan sebuah penelitian. Kajian ini bertujuan untuk mengetahui materi dalam bidang yang diteliti, mengidentifikasi metode yang telah digunakan, serta melihat hasil dan kesimpulan yang diperoleh oleh penelitian terdahulu.

Beberapa penelitian terkait yang digunakan disajikan dalam Tabel 1 sebagai berikut:

Tabel 1 Penelitian Terkait

Judul	Penulis	Model	Hasil
Dynamic Modeling Using Vector Error-correction Model: Studying the Relationship among Data Share Price of Energy PGAS Malaysia, AKRA, Indonesia, and PTT PCL-Thailand	Warsono et al., (2020)	VECM	Diperoleh bahwa model terbaik untuk peramalan yaitu VECM(2) dengan rank kointegrasi $r=3$
Analysis of Some Energy and Economics Variables by Using VECMX Model in Indonesia	Usman et al., (2022)	VECMX	Diperoleh model terbaik VECMX(3,1), dengan nilai $AIC=34,5018$
Gold Price Prediction Using Long-Short Term Memory Algorithm Based on Web Application	Dalimunthe et al., (2025)	LSTM	Diperoleh model LSTM dengan nilai MAPE 0,83%, menunjukkan tingkat akurasi prediksi tinggi.

Tabel 1 Penelitian Terkait Lanjutan

Judul	Penulis	Model	Hasil
Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications	Caliwag dan lim., (2019)	VARMA-LSTM	Diperoleh hasil peramalan menggunakan model hybrid dengan nilai RMSE 0,161 dan 0,193 pada suhu 25 dan 0 ^o C untuk masing-masing suhu.

Penelitian terkait yang digunakan, pertama pada penelitian Warsono et al. (2020) menganalisis hubungan antara perusahaan energi Malaysia (PGAS), Indonesia (AKRA) dan Thailand (PCL PTT) dengan menggunakan model VECM, diperoleh bahwa model VECM(2) dengan rank = 3 stabil dalam menganalisis hubungan harga saham energi di ASEAN, serta memberikan prediksi yang cukup akurat untuk ketiga perusahaan tersebut. Penelitian selanjutnya dilakukan oleh Usman et al. (2022) dengan menggunakan data deret waktu harga bensin (*Gasoline_P*), jumlah uang beredar (*M2*) sebagai variabel endogen dan konsumsi *import* (*import_COSNP*), *eksport* minyak dan gas (*export_OG*) sebagai variabel eksogen dengan menggunakan model VECMX. Diperoleh hasil model terbaik yaitu VECMX(3,1) dengan *rank* kointegrasi = 1 yang digunakan untuk menganalisis hubungan antar variabel yang digunakan.

Penelitian terkait dengan model LSTM telah dilakukan oleh Dalimunthe et al. (2025) tentang memprediksi harga emas dengan menggunakan model LSTM. Penelitian ini menggunakan data historis harga emas harian dengan variabel yang digunakan yaitu harga pembukaan, penutupan, harga tertinggi dan harga terendah. Hasil yang diperoleh yaitu model LSTM dapat digunakan untuk mengidentifikasi pola serta memprediksi harga saham emas dengan mempertimbangkan nilai MAE dan MAPE yang menunjukkan bahwa akurasi yang cukup tinggi, nilai MAE sebesar 19,81 dan nilai MAPE sebesar 0,83%. Penelitian selanjutnya dilakukan oleh Caliwag dan Lim. (2019) meramalkan status pengisian dan tegangan keluaran

baterai *lithium ion* pada aplikasi sepeda motor listrik dengan menggunakan model *hybrid VARMA-LSTM*. Hasil pada peramalan pertama diperoleh nilai RMSE sebesar 0,161 dan 0,193 untuk masing-masing variabel. Namun seiring berjalannya siklus yang dilakukan menunjukkan bahwa variasi dari kecepatan sepeda motor listrik menyebabkan variasi dari status pengisian *lithium ion* pada baterainya.

2.2 Multivariate Time Series

Time Series atau sering disebut dengan deret waktu adalah urutan pengamatan yang diambil secara urut dalam rentang waktu tertentu. Deret waktu merupakan kumpulan data yang dihasilkan secara terurut dalam interval waktu yang sama. Meskipun dalam pengurutan data biasanya dilakukan dalam waktu yang sama dan dimensi yang berbeda, seperti dimensi ruang (Wei., 2006). Deret waktu dari suatu pengamatan secara umum di simbolkan Y_t , dimana t menunjukkan representasi waktu terhadap variabel Y . Jika $t = 1, 2, \dots, T$ maka $t = 1$ merupakan pengamatan pertama terhadap variabel Y , apabila $t = T$ merupakan pengamatan terakhir terhadap Y . Pada deret waktu pengamatan dilakukan pada waktu yang sama seperti menit, jam, harian, mingguan, bulanan atau tahunan. Urutan pada pengamatan bertujuan untuk mengetahui bagaimana perubahan variabel Y terhadap seiring berjalannya waktu (Mills, 2019).

Analisis deret waktu digunakan untuk memahami pola dalam data pengamatan, seperti tren, musiman, atau fluktuasi acak, serta untuk membuat prediksi masa depan atau peramalan (Wei, 2006). Berdasarkan Box et al. (2016) analisis deret waktu dibedakan menjadi deret waktu univariat dan deret waktu multivariat. Analisis deret waktu univariat hanya melibatkan satu variabel sedangkan multivariat melibatkan lebih dari satu variabel yang secara simultan digunakan untuk memodelkan tentang bagaimana antar variabel dalam deret waktu saling berhubungan. Analisis multivariat deret waktu sudah banyak digunakan di berbagai bidang seperti energi, klimatologi dan keuangan. Analisis multivariat deret waktu dapat digunakan untuk peramalan diberbagai bidang aplikasi, termasuk dalam

perencanaan produksi, ekonomi bisnis, dan optimalisasi pada proses produksi (Box et al., 2016). Analisis multivariat deret waktu bertujuan untuk memahami dinamis antara satu variabel dapat mempengaruhi variabel lainnya atau adanya hubungan dan dapat meningkatkan akurasi dalam peramalan data (Widiarti et al., 2024). Beberapa pendekatan yang dapat dilakukan untuk melakukan peramalan data deret waktu multivariat adalah metode *Vector Autoregressive* (VAR), *Vector Error Correction Models* (VECM) dan lainnya.

2.2.1 *Vector Autoregressive* (VAR)

Model VAR adalah model statistik yang digunakan untuk menganalisis data deret waktu lebih dari satu variabel. Model VAR merupakan kombinasi dari model *autoregressive* pada data *deret* waktu univariat menjadi data deret waktu multivariat. Model VAR digunakan untuk menganalisis hubungan antar variabel secara simultan pada data *time series*. Semua variabel dalam VAR disusun simetris dengan menyertakan persamaan yang menjelaskan perkembangan setiap variabel berdasarkan lag-nya sendiri dan lag dari semua variabel lain dalam model (Putri et al., 2021).

Pada model VAR, data deret waktu $Y_1, Y_2, \dots, Y_n$ menunjukkan bahwa lebih dari satu variabel yang digunakan. Bentuk umum model VAR (p) untuk dua variabel yang digunakan pada Persamaan (2. 1) (Wei, 2006):

$$Y_t = \begin{bmatrix} Y_{1t} \\ Y_{2t} \end{bmatrix} = \Phi_0 + \Phi_1 \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \end{bmatrix} + \dots + \Phi_p \begin{bmatrix} Y_{1,t-p} \\ Y_{2,t-p} \end{bmatrix} + \varepsilon_t \quad (2.1)$$

Keterangan:

- Y_t : vektor Y dengan variabel Y_{1t}, Y_{2t} pada waktu ke t
- Φ_0 : vektor konstanta berukuran (2×1)
- $\Phi_1, \dots, \Phi_p$: matriks nonsingular berukuran (2×2)
- ε_t : nilai residual pada saat t berukuran (2×1)

dengan $\Phi_0 = \begin{bmatrix} \Phi_{01} \\ \Phi_{02} \end{bmatrix}$, $\Phi_1 = \begin{bmatrix} \Phi_{1,11} & \Phi_{1,12} \\ \Phi_{1,21} & \Phi_{1,22} \end{bmatrix}$, dan $\Phi_p = \begin{bmatrix} \Phi_{1,11} & \Phi_{1,12} \\ \Phi_{1,21} & \Phi_{1,22} \end{bmatrix}$.

Model VAR digunakan pada variabel yang bersifat stasioner dan tidak mengandung trend stokastik. Data deret waktu yang mengandung trend stokastik dan terdapat hubungan jangka panjang (*long term*) dan jangka pendek (*short term*) tidak dapat menggunakan model VAR, sehingga muncul konsep kointegrasi dan *error correction* yang dikembangkan oleh (Engle & Granger, 1987). Oleh sebab itu, model yang digunakan untuk mengatasi masalah tersebut adalah model VECM, yang dapat digunakan untuk menganalisis data deret waktu yang kointegrasi dan *nonstasioner* (Fahria et al., 2023).

2.2.2 Vector Error Correction Model (VECM)

Model VECM adalah model VAR yang terbatas, dimana model tersebut pertama kali di kembangkan dari konsep kointegrasi dan *error correction* oleh Engle dan Granger. (1987). Berdasarkan konsep tersebut kemudian dikembangkan lagi menjadi konsep VECM, yaitu konsep yang digunakan untuk memisahkan komponen jangka panjang dan jangka pendek dari proses pembentukan model pada data, sehingga model VECM digunakan untuk memodelkan data deret waktu yang terkointegrasi dan tidak stasioner (Nugroho et al., 2021). Persamaan model VECM(p) variabel endogen pada Persamaan (2. 2) sebagai berikut :

$$\Delta Y_t = \Pi Y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-i} + \varepsilon_t \quad (2.2)$$

dengan

$$\Pi = \alpha\beta'$$

Keterangan :

- ΔY_t : vektor *differencing* variabel Y pada waktu ke- t
- ΔY_{t-i} : vektor *differencing* variabel Y pada waktu ke $t - i$, ($i = 1, 2, \dots p$)
- Π : matriks koefisien kointegrasi ($n \times n$)
- α : matriks *adjustment* ($n \times r$)

β'	: matriks kointegrasi ($r \times n$)
Γ_i	: matriks koefisien ($n \times n$)
Y_{t-1}	: vektor variabel endogenus pada $lag - 1$
p	: panjang lag variabel endogenus
ε_t	: vektor residual berukuran ($n \times 1$)

Misalkan terdapat 2 variabel endogen yang digunakan Y_1 dan Y_2 , maka untuk model VECM(1) pada Persamaan (2. 3) sebagai berikut:

$$\Delta Y_t = \begin{bmatrix} \Delta Y_{1t} \\ \Delta Y_{2t} \end{bmatrix} = \begin{bmatrix} \Pi_{11} & \Pi_{12} \\ \Pi_{21} & \Pi_{22} \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \end{bmatrix} + \begin{bmatrix} \Gamma_{1,11} & \Gamma_{1,12} \\ \Gamma_{1,21} & \Gamma_{1,22} \end{bmatrix} \begin{bmatrix} \Delta Y_{1,t-1} \\ \Delta Y_{2,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix} \quad (2.3)$$

2.2.3 Vector Error Correction Model with Exogenous (VECMX)

Model VECMX merupakan model multivariat deret waktu yang digunakan untuk menganalisis hubungan antar variabel endogen dengan pengaruh variabel luar atau eksogen. Pada model VECM semua variabel yang digunakan merupakan variabel endogen, apabila ditambahkan pengaruh variabel luar atau variabel eksogen maka model yang digunakan adalah model VECMX (Usman et al., 2022). Model VECMX juga dikenal sebagai model persamaan simultan yang memiliki lebih dari satu persamaan, bentuk umum model VECMX(p, s) pada Persamaan (2. 4) sebagai berikut (Seo., 1998):

$$\Delta Y_t = \Pi Y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-i} + \sum_{j=0}^s \Phi_j \Delta X_{t-j} + \varepsilon_t \quad (2.4)$$

dengan

$$\Pi = \alpha \beta'$$

Keterangan

ΔY_t	: vektor <i>differencing</i> variabel Y pada waktu ke- t
ΔY_{t-i}	: vektor <i>differencing</i> variabel Y pada waktu ke $t - i$, ($i = 1, 2, \dots p$)
Π	: matriks koefisien kointegrasi ($n \times n$)
α	: matriks <i>adjustment</i> ($n \times r$)
β'	: matriks kointegrasi ($r \times n$)
Γ_i	: matriks koefisien ($n \times n$)
Y_{t-1}	: vektor variabel endogenus pada <i>lag</i> - 1
p	: panjang <i>lag</i> variabel endogenus
ε_t	: vektor residual berukuran ($n \times 1$)
Φ_j	: matriks koefisien ($n \times r$), variabel eksogenus ke- j
ΔX_t	: vektor <i>differencing</i> variabel eksogenus pada waktu ke- t
s	: panjang lag variabel eksogenus

Misalkan terdapat 2 variabel endogen dengan 1 variabel eksogen, sehingga untuk model VECMX(1,1) pada Persamaan (2. 5) sebagai berikut:

$$\begin{aligned} \Delta Y_t = \begin{bmatrix} Y_{1t} \\ Y_{2t} \end{bmatrix} &= \begin{bmatrix} \Pi_{11} & \Pi_{12} \\ \Pi_{21} & \Pi_{22} \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \end{bmatrix} + \begin{bmatrix} \Gamma_{1,11} & \Gamma_{1,12} \\ \Gamma_{1,21} & \Gamma_{1,22} \end{bmatrix} \begin{bmatrix} \Delta Y_{1,t-1} \\ \Delta Y_{2,t-1} \end{bmatrix} \\ &+ \begin{bmatrix} \Phi_{1,11} \\ \Phi_{1,21} \end{bmatrix} [\Delta X_{t-1}] + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix} \end{aligned} \quad (2.5)$$

2.2.4 Peramalan (*Forecasting*)

Peramalan adalah proses yang dilakukan untuk memprediksi dan meramalkan suatu harga atau kejadian yang akan terjadi dimasa mendatang berdasarkan informasi dari masa lalu (Ye et al., 2024). Proses peramalan melibatkan data historis lalu di analisis menggunakan beberapa metode matematika untuk diproyeksikan ke masa yang akan datang. Metode peramalan diklasifikasikan kedalam dua kategori yaitu metode kualitatif dan kuantitatif. Metode kualitatif

didasarkan pada pemikiran berupa pendapat, pengetahuan, dan pengalaman dari masa lalu. Sedangkan metode kuantitatif menggunakan data dari masa lampau. Hasil dari peramalan dipengaruhi oleh metode matematika yang digunakan (Makridakis et al., 1997).

2.3 Uji Asumsi

Analisis pada deret waktu dilakukan dengan beberapa uji asumsi yang harus dilakukan sebelum masuk ke tahap pemodelan. Pada uji asumsi dilakukan untuk mengetahui informasi dari suatu data penelitian dengan melakukan beberapa uji.

2.3.1 Uji Stasioneritas

Analisis data deret waktu ada beberapa asumsi yang harus dipenuhi yaitu kestasioneran data. Stasioner merupakan suatu proses pada data deret waktu yang tidak mengalami perubahan secara signifikan terhadap rata – rata dan varians di periode waktu tertentu (Makridakis et al., 1997). Menurut Wei. (2006), pada pembahasan Widiarti et al. (2024) kestasioneran data dapat diperiksa dengan melihat plot data, apakah data tersebut memiliki pola tertentu yang mengarah pada data yang tidak stasioner. Data *nonstasioner* tidak berfluktuasi pada sekitar angka tertentu. Kestasioneran data dapat dilihat dengan menggunakan plot *Autocorrelation Function* (ACF) yaitu apabila dalam plot tidak terdapat tren atau pola musiman, tetapi dalam pengambilan Keputusan pada plot ACF bisa menimbulkan perbedaan Keputusan. Sehingga, Kestasioneran juga dapat dilihat pada uji *root test* menggunakan uji *Augmented Dickey Fuller* (ADF-test) dengan menggunakan hipotesis nol bahwa data tidak stasioner (Widiarti et al. 2024).

Data deret waktu yang tidak stasioner dalam rata-rata dapat dilakukan transformasi yaitu dengan melakukan *differencing*. *Differencing* merupakan suatu proses yang digunakan untuk mencari selisih antara periode satu ke periode yang lain. Proses

differencing pertama yaitu pada $d = 1$ dapat didefinisikan pada Persamaan (2. 6) sebagai berikut:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (2.6)$$

Menunjukkan bahwa *differencing* pada orde ke-1 terhadap waktu ke- t dengan data pengamatan ke- t yaitu Y_t dan data pengamatan ke- $(t - 1)$ yaitu Y_{t-1} . Proses tersebut dapat didefinisikan sebagai perbedaan antara pengamatan pada periode ke- t dan periode ke- $(t - 1)$ (Cryer., 2008). Sehingga dapat dikatakan bahwa pada data yang tidak stasioner akan memiliki akar-akar unit atau selisih nilai antar periode. Sedangkan data yang stasioner tidak memiliki akar unit (Box et al., 2016). Uji ADF dilakukan untuk mengetahui keberadaan akar unit sebagai berikut:

Menurut Wei. (2006) parameter *Autoregressive* yang akan diuji diperoleh berdasarkan model AR(1) yang ditulis dengan Persamaan (2.7) sebagai berikut:

$$\begin{aligned} Y_t &= \phi Y_{t-1} + \varepsilon_t \\ Y_t - Y_{t-1} &= \phi Y_{t-1} - Y_{t-1} + \varepsilon_t \\ \Delta Y_t &= (\phi - 1)Y_{t-1} + \varepsilon_t \\ \Delta Y_t &= \phi Y_{t-1} + \varepsilon_t \end{aligned} \quad (2.7)$$

Langkah pengujian uji ADF yang dilakukan sebagai berikut:

1. Hipotesis :

$$H_0: \phi \geq 0 \text{ (data tidak stasioner)}$$

$$H_1: \phi \leq 0 \text{ (data stasioner)}$$

2. Uji statistik :

Uji statistik dijabarkan pada persamaan (2.8)

$$\tau_{hitung} = \frac{\phi}{SE(\phi)} \quad (2.8)$$

dengan

$$SE(\phi) = S \left(\sum_{t=1}^n (Y_{t-1})^2 \right)^{\frac{1}{2}}$$

$$S = \sqrt{\sum_{t=1}^n \frac{(1 - \phi)Y_{t-1}}{n - 1}}$$

3. Kriteria pengujian:

Pengambilan keputusan dilakukan dengan membanding nilai τ_{hitung} dengan nilai kritis dari tabel *Augmented Dicky Fuller* $(-2,57)$. H_0 ditolak apabila $\tau_{hitung} > (-2,57)$ atau jika $p - value < \alpha$ (Brockwell & Davis., 2003).

2.3.2 Uji Kointegrasi

Uji kointegrasi merupakan uji yang digunakan untuk menganalisis data deret waktu yang tidak stasioner dan memiliki hubungan jangka panjang antar variabel endogen (Shubha & Sushma., 2019). Konsep kointegrasi pertama kali dikenalkan oleh Engle dan Granger. (1987) apabila data deret waktu mengalami kointegrasi ini menunjukkan bahwa data tersebut memiliki hubungan jangka panjang diantara variabel – variabel endogen. Metode yang dapat digunakan untuk menguji kointegrasi salah satunya uji *Johansen Cointegration*. Adapun pengujian statistik menggunakan uji trace dan uji maksimum nilai eigen (Fahria et al., 2023).

1. Uji Hipotesis:

H_0 = Tidak ada hubungan kointegrasi ($r = 0$)

H_1 = Ada hubungan kointegrasi ($r > 0$)

2. Uji statistik:

Uji *trace* dijabarkan dengan Persamaan (2.9) sebagai berikut:

$$Tr(r) = -n \sum_{i=r+1}^k \ln (1 - \lambda_i) \quad (2.9)$$

Uji statistik maksimum nilai eigen pada Persamaan (2.10)

$$\lambda_{maks} = -n \ln (1 - \lambda_i) \quad (2.10)$$

dengan

n : jumlah pengamatan

λ_i : estimasi nilai eigen

k : jumlah variabel pengamatan

3. Kriteria pengujian:

Apabila pada uji trace dan uji *eigen value* lebih besar dari nilai kritis pada taraf signifikansi α atau jika $p - value < \alpha$, maka H_0 ditolak.

2.3.3 Penentuan Lag Optimal

Penentuan lag optimal dalam analisis data deret waktu sangat diperlukan untuk mengetahui hubungan antar variabel satu dengan variabel lain. Penentuan lag optimal paling banyak menggunakan informasi *Akaike's Information Criterion* (AIC) dengan kriteria pemilihan yaitu berdasarkan nilai AIC terkecil (Cryer., 2008). rumus AIC ditulis pada Persamaan (2.11) sebagai berikut:

$$AIC = -2 \ln L + 2k \quad (2.11)$$

dengan

$$L = \prod_{t=1}^n \frac{1}{(2\pi)^{k/2} |\Sigma|^{1/2}} \exp \left(-\frac{1}{2} e_t' \Sigma^{-1} e_t \right)$$

keterangan:

k : jumlah parameter dalam model

n : jumlah observasi

e_t : residual pada waktu ke- t

Σ : matriks kovarians residual

Penentuan lag optimal selain menggunakan informasi AIC beberapa peneliti menggunakan informasi dari *Bayesian Information Criterion* (BIC) dengan menggunakan nilai BIC terkecil untuk pemilihan lag terbaik.

2.3.4 Uji *Kausalitas Granger*

Uji *Kausalitas Granger* merupakan uji yang digunakan untuk memahami ketergantungan antara variabel pada data multivariat. Pada dasarnya uji kausalitas digunakan untuk mengetahui apakah Y_t mempengaruhi X_t , begitupun sebaliknya apakah X_t mempengaruhi Y_t . Jika kedua variabel saling mempengaruhi maka dapat dikatakan bahwa kedua variabel tersebut memiliki hubungan timbal balik (Granger., 1969). Untuk mengetahui hubungan atau ketergantungan antar variabel dapat mempertimbangkan model kausalitas pada Persamaan (2. 12) sebagai berikut (Usman et al., 2022):

$$Y_t = \begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} B_{11,1} & B_{12,1} \\ B_{21,1} & B_{22,1} \end{bmatrix} \begin{bmatrix} y_{1t-1} \\ y_{2t-1} \end{bmatrix} + \dots + \begin{bmatrix} B_{11,p} & B_{12,p} \\ B_{21,p} & B_{22,p} \end{bmatrix} \begin{bmatrix} y_{1t-p} \\ y_{2t-p} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} \quad (2.12)$$

Y_t merupakan vektor yang terdiri dari vektor y_{1t} dan y_{2t} . Pada vektor y_{2t} dikatakan bukan *granger kausalitas* dari y_{1t} jika koefisien matriks dari parameter $B_{21,i} = 0$, untuk $i = 1, 2, \dots, p$. Dengan kata lain, y_{2t} dikatakan *Granger Kausalitas* y_{1t} jika nilai masa lalu dan masa sekarang y_{2t} dapat memprediksi nilai dari y_{1t} . Jika sebuah variabel X_t adalah *kausalitas Granger* dari variabel Y_t dan Y_t bukan kausalitas dari X_t , maka ini disebut *kausalitas Granger* langsung (*unidirectional causality*). Jika *Kausalitas Granger* ada di kedua variabel, dari X_t ke Y_t dan dari Y_t ke X_t , maka disebut *kausalitas Granger* dua arah (*budirectional causality*).

2.4 Estimasi Parameter Model

Setelah menentukan orde dan mengidentifikasi bentuk model, langkah selanjutnya yaitu estimasi parameter model. Beberapa metode yang dapat digunakan untuk estimasi parameter dalam kasus multivariat yaitu ada metode langsung tipe yule-walker dan *maksimum likelihood estimation* (MLE) (Florens et al., 2007).

2.4.1 Maksimum Likelihood Estimator (MLE)

Metode MLE dianggap dapat memberikan hasil terbaik dari perspektif statistik. Hal ini berlaku untuk model yang mendekati nonstasioneritas atau observasi urutan singkat. Proses MLE memiliki keakuratan yang lebih besar daripada kuadrat terkecil. Ketika parameternya mendekati batas wilayah stabilitas, ini mencegah ketidakstabilan log konvergen hingga batas tertentu. Beberapa estimator yang dilakukan telah diusulkan sebagai asimtotik yang efisien dan didasarkan pada maksimalisasi fungsi probabilitas log yang diperkirakan (multivariat) (Florens et al., 2007).

Misalkan $\{Y_t\}$ suatu proses multivariat yang dibangun dari model VECM dengan bentuk persamaan pada Persamaan (2. 13):

$$\Delta Y_t = \Pi Y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta Y_{t-1} + \varepsilon_t \quad (2.13)$$

dengan

$$\Pi = \alpha\beta'$$

Diasumsikan bahwa ε_t berdistribusi *independent and identically distributed* normal atau dengan nilai *mean* 0 dan *varians* Σ , untuk memperoleh nilai estimasi parameter model VECM akan menggunakan metode MLE dengan fungsi *likelihood* pada Persamaan (2. 14) sebagai berikut (Lutkepohl., 2005):

$$\begin{aligned}
L(\Theta|X) = & -\frac{KT}{2} \ln 2\pi - \frac{T}{2} \ln |\Sigma_u| \\
& - \frac{1}{2} \text{tr}[(\Delta Y - \alpha\beta'Y_{t-1} - \Gamma\Delta X)' \Sigma_u^{-1} (\Delta Y - \alpha\beta'Y_{t-1} \\
& - \Gamma\Delta X)]
\end{aligned} \tag{2.14}$$

Diasumsikan $rk(\Pi) = r$, $\Pi = \alpha\beta'$, dengan α dan β merupakan matriks berukuran $(K \times r)$. Hasil estimasi untuk parameter maksimum sebagai berikut:

$$\begin{aligned}
\beta &= \hat{\beta} = [v_1, \dots, v_r]' S_{11}^{-\frac{1}{2}} \\
\alpha &= \hat{\alpha} = S_{01} \hat{\beta} (\hat{\beta}' S_{11} \hat{\beta})^{-1} \\
\Gamma &= \hat{\Gamma} = (\Delta Y - \hat{\alpha} \hat{\beta}' Y_{t-1}) \Delta X' (\Delta X \Delta X')^{-1} \\
\Sigma_u &= \widehat{\Sigma}_u = (\Delta Y - \hat{\alpha} \hat{\beta}' Y_{t-1} - \hat{\Gamma} \Delta X) (\Delta Y - \hat{\alpha} \hat{\beta}' Y_{t-1} - \hat{\Gamma} \Delta X)' / T
\end{aligned}$$

2.5 Diagnosis Model

Setelah penentuan bentuk model yang telah diperoleh selanjutnya perlu dilakukan analisis kelayakan model terhadap data yang digunakan yaitu dengan mendiagnosis model. Diagnosis model berfungsi untuk memastikan bahwa model yang diperoleh sudah sesuai dengan asumsi yang diperlukan untuk analisis dengan tepat. Beberapa langkah yang dilakukan dalam diagnosis model.

2.5.1 Uji Normalitas *Residual*

Uji normalitas *residual* merupakan uji statistik yang digunakan untuk mengetahui apakah suatu model berdistribusi normal atau tidak. Berdasarkan dengan namanya bahwa uji normalitas residual dilakukan tidak langsung terhadap data deret waktu tetapi uji ini dilakukan terhadap nilai residual dari suatu model yang diperoleh. Pada uji normalitas residual, statistik uji yang biasa dilakukan yaitu uji *Jarque-Bera* (Usman et al., 2022). Uji *Jarque-Bera* merupakan uji normalitas dengan

menggunakan uji *skewness* dan *kurtosis*. Secara umum persamaan uji *Jarque-Bera* pada Persamaan (2.15) sebagai berikut:

$$JB = \left[\frac{N}{6} b_1^2 + \frac{N}{24} (b_2 - 3)^2 \right] \quad (2.15)$$

Keterangan:

- N : banyaknya ukuran sampel
 b_1 : koefisien *skewness*
 b_2 : koefisien *kurtosis*

Uji *Jarque-Bera* merupakan uji normalitas yang berdistribusi χ^2 dengan derajat bebas 2 (Usman et al., 2022). Residual berdistribusi normal jika nilai uji *Jarque-Bera* lebih besar dari nilai kritis pada tabel *chi-kuadrat* atau nilai $p - value < \alpha$ pada taraf signifikansi.

2.5.2 Uji Stabilitas

Kestabilan model VECMX dapat diamati menggunakan sistem VAR yang terlihat dari akar-akar *invers* karakteristik polynomial AR. Uji stabilitas dilakukan untuk mengetahui apakah suatu model sudah stabil atau belum. Apabila model yang digunakan tidak stabil akan berpengaruh terhadap hasil peramalan yang tidak akurat dan tidak konsisten. Suatu model dikatakan stabil (stasioner terhadap rata-rata dan varian) jika semua akar root memiliki modulus kurang dari atau sama dengan satu (≤ 1) dan semua terletak dalam satuan lingkaran (*unit circle*). Pengujian kestabilan dapat dilakukan dengan mempertimbangkan model VAR(p) pada Persamaan (2.16) (Elliot., 2006):

$$Y_t = c + \Phi_1 Y_{t-1} + \dots + \Phi_p Y_{t-p} + \varepsilon_t \quad (2.16)$$

model dikatakan stabil jika dituliskan pada Persamaan (2.17) :

$$\det(I_{Kp} - \Phi_z) = \det(I_K - \Phi_1 Z - \dots - \Phi_p Z^p) \quad (2.17)$$

Memiliki nilai modulus kurang dari atau sama satu dan semua berada dalam lingkaran satuan (Usman et al., 2022).

2.5.3 Uji *White Noise*

Uji *White Noise* merupakan uji yang digunakan untuk mengetahui residual dari masing – masing data dalam model saling independen atau tidak. Uji yang digunakan dalam uji *white noise* adalah uji multivariat *portmanteau*, yaitu generalisasi dari uji *Ljung – Box* yang digunakan untuk menguji residual model dengan statistik uji sebagai berikut (Boubacar & Saussereau., 2018):

1. Hipotesis:

H_0 : Residual tidak memiliki *autokorelasi (White Noise)*

H_1 : Residual memiliki paling sedikit 1 *autokorelasi (tidak White Noise)*

2. Statistik uji:

Dijabarkan pada Persamaan (2.18)

$$Q_m^c = n \sum_{h=1}^m Tr \left(\hat{\Gamma}'(h) \hat{\Gamma}^{-1}(0) \hat{\Gamma}(h) \hat{\Gamma}^{-1}(0) \right) \quad (2.18)$$

Keterangan:

$\hat{\Gamma}(h)$: fungsi matrik *autocovarian* residual

n : ukuran sampeldengan m banyak *lag*

3. Kriteria pengujian:

Tolak H_0 jika $Q_m^c \geq \chi_{m^2 h, \alpha}^2$ atau jika $p - value > \alpha$ yaitu residual memenuhi asumsi uji *White Noise*.

2.6 Impulse Response Function (IRF)

Impulse Respon Function merupakan suatu analisis yang digunakan untuk menganalisis respon dari suatu variabel endogen karena guncangan akibat dari variabel lain (Hamilton, 1994). *Impulse Respon Function* digunakan untuk memahami struktur model yaitu dengan menggambarkan bagaimana respon variabel endogen terhadap guncangan dalam *error term* yang diukur dengan menggunakan standar deviasi dalam model. Grafik IRF digunakan untuk mengetahui interaksi antar variabel dalam model dapat dilakukan analisis yang memungkinkan respon variabel dalam *system* model terhadap guncangan. Menurut (Wei, 2006) dalam penelitian (Usman et al., 2022) menyatakan bahwa model umum VAR dapat dinyatakan dalam bentuk *vector* MA(∞) yang ditulis pada Persamaan (2.19):

$$X_t = \mu + \mu_t + \Psi_1\mu_{t-1} + \Psi_2\mu_{t-2} \quad (2.19)$$

Bentuk matriks diperoleh dengan menggunakan Persamaan (2.20) sebagai berikut:

$$\frac{\partial X_{t+s}}{\partial \mu_t} = \Psi_s \quad (2.20)$$

Elemen pada baris ke- i dan kolom ke- j menunjukkan bahwa konsekuensi terhadap peningkatan setiap satu unit dari variabel j pada waktu ke t (μ_{jt}) dan untuk variabel i pada waktu ke- $t + s$ (X_{t+s}) serta semua informasi lainnya tetap. Jika pada setiap elemen dari μ_t mengalami perubahan sebesar δ_i , maka secara umum semua perubahan yang terjadi dalam vector tersebut menjadi Persamaan (2.21):

$$\Delta X_{t+s} = \frac{\partial X_{t+s}}{\partial \mu_{1t}} \delta_1 + \dots + \frac{\partial X_{t+s}}{\partial \mu_{nt}} \delta_n = \Psi_s \delta \quad (2.21)$$

Sehingga bentuk plot dari baris ke- i dan kolom ke- j pada fungsi Ψ_s disebut dengan IRF.

2.7 Machine Learning (ML)

Machine Learning adalah pengembangan dari sistem AI yang memungkinkan sistem belajar dan membuat keputusan berdasarkan data secara mandiri tanpa harus diprogram secara *eksplisit*. Algoritma dalam *machine learning* dilatih untuk mengenali pola data, memprediksi serta dapat mengambil keputusan dari analisis data tersebut. Komponen dalam *machine learning* yaitu data, model, algoritma, data *training* dan data *testing*. Pengguna *Machine Learning* membutuhkan data yang valid sebagai bahan belajar ketika melakukan proses training dan sebelum digunakan ketika testing untuk hasil yang optimal (Cholissodin & Soebroto., 2021).

2.7.1 Scaling Data

Scaling data adalah normalisasi data dengan teknik yang digunakan untuk mengubah data dalam dataset ke bentuk skala umum. *Scaling* data digunakan tanpa memanipulasi perbedaan dalam interval data. Normalisasi data digunakan untuk mempercepat proses dalam pemodelan, metode yang digunakan yaitu:

4. Min-max scaller

Min-max scaller digunakan untuk mengubah ukuran pada data dari rentang asli, sehingga nilai pada data berada pada interval 0 dan 1. Bentuk umum persamaan *min-max scaller* yang disajikan pada Persamaan (2.22) sebagai berikut (Ambarwari et al., 2020)

$$v_{norm} = \left(\frac{v_i - v_{min}}{v_{max} - v_{min}} \right) \quad (2.22)$$

Keterangan:

v_{norm} : data normalisasi

v : data asli

v_{min} : data minimum dari data asli

v_{max} : data maksimum dari data asli

5. *Standart scaller (Zero mean)*

Standar scaller dilakukan berdasarkan nilai dari standar deviasi. *Standar scaller* yaitu suatu proses yang mengubah skala distribusi data, sehingga nilai rata – rata yang akan diamati adalah 0 dan nilai standar deviasi adalah 1. *Standar scaller* dihitung dengan menggunakan Persamaan (2.23) (Ambarwari et al., 2020)

:

$$x_{std} = \sqrt{\frac{1}{N-1} \sum_{l=1}^N (x_l - x_{mean})^2} \quad (2.23)$$

Normalisasi data dapat dihitung dengan menggunakan Persamaan (2.24):

$$x'_i = \frac{x_i - x_{mean}}{x_{std}} \quad (2.24)$$

2.7.2 *Hyperparamater Tuning*

Hyperparameter merupakan upaya optimisasi dalam *machine learning* . Proses dalam optimisasi dilakukan dengan memodifikasi nilai *hyperparameter* secara berkala untuk meminimalkan kesalahan dalam pengujian (Primananda & Isa., 2021). Beberapa *hyperparameter* yang digunakan dalam proses pengujian:

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

2.7.3 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang terdapat didalam *deep learning* digunakan untuk mengubah nilai *input* menjadi *output*. Beberapa fungsi aktivasi dalam *deep learning* yaitu (Xu et al., 2022):

- Fungsi *sigmoid* (σ)
- *Tangen Hiperbolik* ($\tanh$)
- *Rectified Linier Unit* (ReLU)

Semua model dalam *deep learning* menggunakan fungsi aktivasi berdasarkan kebutuhan dari model yang digunakan. Fungsi aktivasi dalam model LSTM yang digunakan untuk mengaktifkan serta menonaktifkan *neuron* pada jaringan *cell* LSTM. Fungsi aktivasi dalam model LSTM yaitu *sigmoid* (σ) dan *tangen hiperbolik* ($\tanh$).

Fungsi *sigmoid* (σ) mentransformasikan nilai dari fungsi $\tanh$ menjadi luaran nilai antara 0 sampai 1. Fungsi *sigmoid* ditulis pada Persamaan (2.25) adalah sebagai berikut (E, Jianwei et al., 2019):

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.25)$$

Keterangan:

x = informasi yang masuk

e = bilangan *euler*

Fungsi $\tanh$ merupakan fungsi *nonlinear* yang memiliki rentang nilai lebih luas dan lebih efektif pada pemodelan *nonlinear*. Fungsi $\tanh$ memiliki luaran nilai antara -1 sampai 1 dengan Persamaan (2.26) sebagai berikut (Lasijan et al., 2023):

$$\begin{aligned} \tanh(x) &= \frac{e^x - e^{-x}}{e^x + e^{-x}} \\ \tanh(x) &= \frac{\sinh(x)}{\cosh(x)} \end{aligned} \quad (2.26)$$


2.8 Deep Learning

Salah satu cabang dalam *machine learning* yaitu *deep learning*. *Deep learning* merupakan pembelajaran secara mendalam yang terdiri dari algoritma pemodelan abstraksi pada data dengan menggunakan sekumpulan fungsi transformasi non-linear yang ditata berlapis-lapis dan mendalam. *Deep Learning* dapat diterapkan pada *supervised learning*, *unsupervised learning* dan *semi-supervised learning* maupun untuk *reinforcement learning* dalam berbagai aplikasi seperti pengenalan citra, suara, klasifikasi teks, dan sebagainya (Cholissodin & Soebroto, 2021). Salah satu model *deep learning* yang banyak digunakan yaitu *recurrent neural network* (RNN). Model RNN dirancang untuk memodelkan ketergantungan pada data *time series*, akan tetapi ada kelemahan pada masalah *gradien* yang membatasi model dalam menganalisis ketergantungan jangka panjang. Sehingga pada tahun 1997 model RNN dikembangkan menjadi model *long short term memory* (LSTM) (Yurtsever., 2021).

2.8.1 Long Short Term Memory (LSTM)

Model LSTM pertama kali dikenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 (Dalimunthe et al., 2025). Model LSTM merupakan pengembangan dari model RNN, yang mana model LSTM dirancang untuk menangani ketergantungan jangka panjang dengan pemanfaatan umpan balik pada koneksi. Model LSTM menggunakan sel memori untuk mengatasi masalah pada gradien yang hilang. Model LSTM terdiri dari *input gate*, *forget gate*, dan *output gate*. Komponen utama arsitektur LSTM adalah status sel yang berjalan melalui rantai, dengan hanya interaksi linear, menjaga aliran informasi tidak berubah. Mekanisme gerbang LSTM menghapus atau mengubah informasi status sel. Ini adalah cara untuk menyampaikan informasi secara selektif yang terdiri dari

lapisan *sigmoid*, lapisan *tangen hiperbolik*, dan operasi perkalian titik demi titik. Arsitektur LSTM diilustrasikan pada Gambar 1 sebagai berikut:



Gambar 1 Arsitektur LSTM (Yurtsever, 2021)

Fungsi dari model LSTM adalah sebagai berikut:

Beberapa fungsi gate dari model LSTM terdiri dari *forget gate*, *input gate*, dan *output gate* (Bhandari et al., 2022).

Forget gate

Pada *forget gate* berfungsi untuk mengatur informasi masa lalu yang harus dihilangkan atau harus disimpan pada *memory cell* dituliskan pada Persamaan (2.27):

$$f_t = \sigma(W_f x_t + W_{hf} h_{t-1} + b_f) \quad (2.27)$$

Input gate

Dalam *input gate* berfungsi untuk menentukan apakah informasi yang di input akan disimpan kedalam *memory cell*. *Input gate* akan memeriksa informasi mana yang akan di perbarui dan menghitung informasi baru yang akan di input ke *memory cell* dituliskan pada Persamaan (2.28), (2.29) dan (2.30):

$$i_t = \sigma(W_i x_t + W_{hi} h_{t-1} + b_i) \quad (2.28)$$

$$\hat{c}_t = \tanh(W_c x_t + W_{hc} h_{t-1} + b_c) \quad (2.29)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \hat{c}_t \quad (2.30)$$

Output gate

Output gate digunakan untuk memutuskan informasi apa yang akan di keluarkan dari *memory cell* dituliskan dalam Persamaan (2.31):

$$o_t = \sigma(W_o x_t + W_{ho} h_{t-1} + b_o) \quad (2.31)$$

2.9 Hybrid VECMX-LSTM

Metode *hybrid* merupakan metode gabungan dari 2 model atau lebih yang bertujuan untuk menghasilkan peramalan yang lebih akurat dari model tunggal. Metode *hybrid* pertama kali dikenalkan oleh (Zhang., 2003) yaitu untuk mengatasi data yang memiliki pola *linear* dan pola *nonlinear*. Secara umum persamaan model *hybrid* pada Persamaan (2.32) sebagai berikut:

$$y_t = L_t + N_t \quad (2.32)$$

Keterangan:

y_t : data pengamatan pada waktu ke- t

L_t : komponen pola *linear* ke- t

N_t : komponen pola *nonlinear* ke- t

t : waktu pengamatan

Hybrid yang akan dilakukan yaitu menggunakan model VECMX dan model LSTM. Kedua model tersebut memiliki kelemahan dan kelebihan masing-masing dalam memproses hasil peramalan. Model VECMX digunakan untuk mengatasi pola data *linear* yang tidak stasioner dan mengalami kointegrasi tetapi tidak dapat mengatasi pola data *nonlinear*, sedangkan model LSTM mengatasi

pola data *nonlinear* pada pengamatan yang diperoleh tetapi tidak dapat menangkap pola data *linear*. Sehingga model *hybrid* VECMX-LSTM digunakan untuk saling melengkapi dalam proses peramalan supaya menghasilkan data yang lebih akurat.

2.10 Evaluasi Model

Proses peramalan setelah memperoleh model terbaik Langkah yang harus dilakukan selanjutnya yaitu melakukan proses evaluasi model. Tujuan dari evaluasi model yaitu untuk mengetahui tingkat keakuratan model yang kita peroleh. Beberapa indikator untuk menentukan keakuratan model yaitu:

2.10.1 Mean Absolute Percent Error (MAPE)

MAPE digunakan untuk menghitung nilai absolut kesalahan rata-rata, yang digunakan untuk melihat bagaimana selisih antara hasil prediksi dan nilai aktual. Rumus MAPE disajikan pada Persamaan (2.33) sebagai berikut (Yurtsever, 2021):

$$MAPE = \left(\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \frac{100}{n} \quad (2.33)$$

Kriteria model terbaik apabila memiliki nilai *MAPE* terkecil.

2.10.2 Root Mean Square Error (RMSE)

MSE digunakan untuk mengukur selisih antar nilai yang diamati, sedangkan RMSE (*Root Mean Square Error*) adalah nilai akar dari MSE, yaitu untuk mengukur ukuran akurasi dari peramalan yang dilakukan, sehingga sering digunakan untuk mengukur kinerja model. Apabila nilai RMSE kecil hal ini

menunjukkan bahwa kinerja model cukup baik untuk digunakan. Bentuk persamaan RMSE disajikan pada Persamaan (2.34) sebagai berikut (Nagata et al., 2024):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.34)$$

2.10.3 Mean Absolute Error (MAE)

MAE digunakan untuk menghitung perbedaan antara 2 variabel kontinu. Model terbaik apabila nilai MAE untuk model mendekati nol atau sama dengan nol. Bentuk persamaan dari MAE adalah pada Persamaan (2.35) sebagai berikut (Yurtsever, 2021) :

III. METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun ajaran 2024/2025, di jurusan Magister Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung.

3.2 Data Penelitian

Data penelitian yang digunakan yaitu data harga saham emas PT. ANTM, harga saham emas dunia dan nilai kurs USD/IDR yang diperoleh dari sumber *investing.com*. Link yang digunakan untuk memperoleh data yaitu <https://id.investing.com/equities/aneka-tambang-historical-data> untuk data harga saham emas PT. ANTM, <https://id.investing.com/currencies/xau-usd-historical-data> untuk memperoleh harga saham emas dunia, dan <https://id.investing.com/currencies/usd-idr-historical-data> untuk nilai tukar kurs.

Data yang digunakan merupakan data harian dengan rentang waktu dari bulan Juli 2015 sampai bulan Desember 2024, yang disajikan dalam Tabel yang dilampirkan pada lampiran 1.

3.3 Variabel Penelitian

Variabel *endogenous* : harga saham emas PT. ANTM dan harga emas dunia.

Variabel *eksogenous* : nilai kurs USD/IDR

3.4 Metode Pengolahan Data

Tahapan analisis pada proses pengolahan data yang dilakukan untuk membentuk model yaitu sebagai berikut:

3.4.1 Model VECMX

1. Pengumpulan data

Mengumpulkan data harga saham emas PT. Aneka Tambang Tbk. (ANTM), harga emas dunia dan nilai tukar (KURS).

2. Melakukan *Splitting* data

Splitting data dilakukan untuk membagi data menjadi 2 bagian, 80% data *training* dan 20% data *testing*.

3. *Preprocessing* data

Melakukan deskripsi data, membuat plot deret waktu pada variabel data harga saham PT. ANTM, harga saham emas dunia dan nilai tukar (KURS).

4. Uji stasioneritas

Melakukan uji stasioneritas dengan menggunakan uji ADF, uji *stasioneritas* dilakukan untuk mengetahui apakah data stasioner pada tingkat *differencing* 1 kali, sedangkan pada pembentukan model VECMX data yang digunakan merupakan data nonstasioner.

5. Uji kointegrasi

Pengujian selanjutnya yaitu uji kointegrasi untuk menguji hubungan jangka panjang antar variabel endogen untuk membentuk model yang akan digunakan VECMX atau VAR dengan menggunakan *Johansen's Cointegration test* yang bertujuan untuk menentukan *rank* kointegrasi.

6. Uji Kausalitas Granger

Uji kausalitas granger dilakukan untuk menganalisis pengaruh kausalitas antar variabel serta mengetahui hubungan timbal balik antar variabel *endogen*.

7. Identifikasi model

Pengidentifikasian model dilakukan dengan menentukan *lag* optimal berdasarkan nilai AIC terkecil.

8. Estimasi model

Pendugaan model dilakukan dengan menggunakan metode MLE yang dilakukan untuk pembentukan matrik *koefisien kointegrasi* (Π), pembentukan koefisien variabel *diffrencing* (Γ) dan pembentukan matrik koefisien (c) serta matrik *eksogen* (Φ) untuk model VECMX.

8. Diagnosis model

Setelah pembentukan model selanjutnya akan dilakukan uji kelayakan model dengan melakukan uji stabilitas, uji normalitas residual dan uji *white noise*

a. Uji Stabilitas

Uji stabilitas dilakukan untuk mengevaluasi kestabilan model yang digunakan, model dikatakan stabil apabila nilai modulus atau nilai karakteristik *root* AR berada pada radius ≤ 1 .

b. Uji *normalitas residual*

Pada uji *normalitas residual* digunakan untuk mengetahui apakah residual model memenuhi asumsi berdistribusi normal dengan menggunakan uji *jarque berra*.

c. Uji *white noise*

Pengujian *white noise* dilakukan untuk mengetahui apakah residual pada model saling *independent*.

9. Evaluasi model

Setelah dilakukan semua pengujian, langkah selanjutnya yaitu melakukan Evaluasi model yaitu untuk menentukan model terbaik dengan berdasarkan nilai MAE, MAPE dan RMSE terkecil.

10. Melakukan peramalan menggunakan model terbaik VECMX.

Pada proses peramalan akan diperoleh hasil prediksi dan nilai residual dari model VECMX.

3.4.2 Model LSTM

1. Input data

Melakukan input data harga saham PT. ANTM, harga emas dunia dan nilai tukar rupiah kedalam LSTM.

2. Melakukan *Splitting* data

Splitting data dilakukan untuk membagi data menjadi 2 bagian, 80% data *training* dan 20% data *testing*.

3. *Scaling* data

Scaling data dilakukan dengan menggunakan *MinMaxscaler* untuk menyesuaikan skala dari setiap variabel data yang akan digunakan dalam model LSTM.

4. Pembentukan model LSTM

Pembentukan model LSTM dilakukan menggunakan data *scaling* dengan menentukan jumlah *hidden layer* dalam LSTM *layer*.

5. Melakukan *hyperparameter*

Hyperparameter dilakukan untuk mengeneralisasi pola data yang akan digunakan dalam model LSTM

6. Pelatihan model LSTM

Pelatihan model dilakukan dengan menggunakan 80% data *training* untuk mengetahui kinerja model.

7. Evaluasi model

Evaluasi model dilakukan untuk mengetahui kinerja model dengan menentukan nilai MAPE, RMSE dan MAE.

8. Peramalan menggunakan model LSTM terbaik

3.4.3 Model *Hybrid* VECMX-LSTM

Pembentukan model *hybrid* VECMX – LSTM dilakukan dengan membentuk 2 model dengan 2 metode. Pertama model *hybrid* VECMX – E_LSTM dibangun dengan input residual VECMX ke dalam model LSTM. Kemudian hasil prediksi

residual LSTM dijumlahkan dengan hasil prediksi VECMX. Kedua model *hybrid* VECMX – EP_LSTM dibangun dengan input residual dan prediksi VECMX kemodel LSTM. Setelah itu, hasil residual LSTM dijumlahkan dengan prediksi LSTM.

3.4.3.1 Model *Hybrid* VECMX – E_LSTM

1. Input data residual

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

2. *Scaling* data

Scaling data residual VECMX 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 VECMX 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* VECMX – E_LSTM

Model *hybrid* dibangun dengan menjumlahkan hasil prediksi VECMX dengan hasil prediksi residual LSTM (E_LSTM).

7. *Unscaling* data

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

8. Evaluasi model

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

9. Peramalan

Langkah selanjutnya yaitu peramalan menggunakan model *hybrid* VECMX – E_LSTM pada data harga saham emas PT. ANTM dan harga emas dunia.

3.4.3.2 Model *Hybrid* VECMX – EP_LSTM

1. Input data prediksi

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

2. *Scaling* data

Scaling data prediksi VECMX 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 VECMX 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 di gunakan.

5. Prediksi model P_LSTM

Selanjutnya melakukan prediksi LSTM dengan menggunakan model P_LSTM terbaik.

6. Membentuk model *hybrid* VECMX – 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* VECMX – EP_LSTM untuk mengembalikan data dalam skala yang sebenarnya untuk dilakukan evaluasi model.


8. Evaluasi model

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


10. Peramalan

Langkah selanjutnya yaitu peramalan menggunakan model *hybrid* VECMX – EP_LSTM pada data harga saham emas PT. ANTM dan harga emas dunia


Berikut merupakan diagram alir yang menjelaskan alur pembentukan model VECMX yang disajikan dalam Gambar 2. Alur pembentukan model LSTM yang disajikan pada Gambar 3. Alur pembentukan model *hybrid* VECMX – LSTM disajikan pada Gambar 4 dan Gambar 5.




Gambar 2 Diagram Alir Model VECMX



Gambar 3 Diagram Alir Model LSTM



Gambar 4 Diagram Alir Model *Hybrid* VECMX-E_LSTM



Gambar 5 Diagram Alir Model *Hybrid* VECMX - EP_LSTM

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah dilakukan pada harga emas PT. ANTM dan harga emas DUNIA diperoleh kesimpulan sebagai berikut:

1. Diperoleh model VECMX(3,1) dengan lag endogenus $p = 3$ dan lag eksogenus $s = 1$ dengan *rank* kointegrasi = 1 sebagai model terbaik untuk proses prediksi dan peramalan. Model LSTM terbaik dengan 16 LSTM unit, 64 *dense unit* dan 16 *batch size* serta *epoch* yang digunakan 100. Model *hybrid* 1 yaitu model *hybrid* VECMX – E_LSTM diperoleh hasil parameter dari model E_LSTM yaitu 64 LSTM unit, 32 *dense unit*, *dropout* 0,2 dan 16 *batch size* dengan *epoch* 100. Model *hybrid* 2 yaitu model *hybrid* VECMX – EP_LSTM, gabungan dari model E_LSTM dan P_LSTM dengan kombinasi parameter yaitu 64 LSTM unit, 64 *dense unit* dan 16 *batch size* dengan *epoch* 100.
2. Hasil kinerja dari masing – masing model diperoleh sebagai berikut:
 - a. Model VECMX
Peramalan menggunakan model VECMX(3, 1) diperoleh nilai RMSE sebesar 439,33 dengan nilai MAPE 19,09 %. Pengaruh nilai kurs terhadap variabel ANTM sebesar -0,0043 sedangkan pada variabel DUNIA sebesar 0.0006.
 - b. Model LSTM
Peramalan dengan model LSTM murni dengan kombinasi parameter yang dihasilkan yaitu 16 LSTM unit, 64 *dense unit* dan 16 *batch size* dihasilkan nilai RMSE sebesar 111,63 dengan nilai MAPE 4,47 %.
 - c. Model *hybird* VECMX – E_LSTM

Hasil peramalan dengan menggunakan model *hybrid* VECMX – E_LSTM memiliki nilai RMSE sebesar 426,52 dengan MAPE 18,12 %

d. Model *Hybrid* VECMX - EP_LSTM

Peramalan dengan menggunakan model *hybrid* VECMX - EP_LSTM menghasilkan nilai RMSE sebesar 78,38 dengan MAPE 3,74 %.

3. Berdasarkan hasil peramalan model VECMX, model LSTM, model *hybrid* VECMX – E_LSTM, dan model *hybrid* VECMX – EP_LSTM, diperoleh model terbaik yang digunakan untuk proses peramalan terhadap harga saham emas PT. ANTM dan harga emas DUNIA yaitu model *hybrid* VECMX – EP_LSTM dengan nilai RMSE dan MAPE terkecil. Diperoleh RMSE sebesar 78,38 untuk variabel ANTM dan 272,58 untuk variabel DUNIA, sedangkan nilai MAPE 3,74% untuk variabel ANTM dan 7,32% untuk variabel DUNIA.

5.2 Saran

Berdasarkan hasil yang didapatkan diharapkan pada penelitian selanjutnya dapat mengembangkan bentuk model dengan menggunakan beberapa kombinasi model – model statistika klasik yang lain, serta dapat menambahkan beberapa pengaruh luar sebagai variabel eksogen.

DAFTAR PUSTAKA

- Ambarwari, A., Adrian, Q. J., & Herdiyeni, Y. (2020). Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning untuk Identifikasi Tanaman. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 4(1), 117–122.
- Bayu Aji, A., & Surjandari, 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).
- Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. C. (2022). Predicting Stock Market Index Using LSTM. *Machine Learning with Applications*, 9, 100320.
- Boubacar Maïnassara, Y., & Sausseureau, B. (2018). Diagnostic Checking in Multivariate ARMA Models With Dependent Errors Using Normalized Residual Autocorrelations. *Journal of the American Statistical Association*, 113(524), 1813–1827.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C. & Ljung, G. M. (2016). *Time Series Analysis Forecasting and control*. WILEY.
- Brockwell, P. J., & Davis, R. A. (2003). Introduction to Time Series and Forecasting. In *Technometrics* (Vol. 45, Issue 1).
- 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>
- Cholissodin, I., & Soebroto, A. A. (2021). *Ai , Machine Learning & Deep Learning (Teori & Implementasi)*.
- Cryer, J. D. (2008). Time series analysis. In *European Journal of Operational Research* (Vol. 20, Issue 2). [https://doi.org/10.1016/0377-2217\(85\)90052-9](https://doi.org/10.1016/0377-2217(85)90052-9)
- Dalimunthe, R. A., Adek, R. T., & Agusniar, C. (2025). *Gold Price Prediction Using Long-Short Term Memory Algorithm Based on Web Application*. 5(1), 329–339.

- E, Jianwei., Ye, J., & Jin, H. (2019). A novel hybrid model on the prediction of time series and its application for the gold price analysis and forecasting. *Physica A: Statistical Mechanics and Its Applications*, 527, 121454. <https://doi.org/10.1016/j.physa.2019.121454>
- Elliot, G. (2006). Handbook Of Economic Forecasting. In *Sustainability (Switzerland)* (Vol. 11, Issue 1).
- Engle, R. F., & Granger, W. J. (1987). EngleGranger1987.pdf. In *Econometrica* (Vol. 55, Issue 2, pp. 251–276).
- Fahria, I., Dalimunthe, D. Y., Amelia, R., Sulistiana, I., & Prayanti, B. D. A. (2023). Prediksi Spot Price Komoditas Emas Berjangka dengan Pendekatan Vector Error Correction Model. *Jambura Journal of Mathematics*, 5(2), 339–350. <https://doi.org/10.34312/jjom.v5i2.18737>
- Feren, J. ., & Sihwahjoeni. (2022). Pengaruh Suku Bunga, Kurs Rupiah, dan Harga Emas Terhadap Return Harga Saham Sektor Pertambangan di Bursa Efek Indonesia. *Prosiding Seminar Nasional Ekonomi-Bisnis*, 29–41.
- Florens, J. P., Marimoutou, V., & Péguin-Feissolle, A. (2007). Econometric modeling and inference. In *Econometric Modeling and Inference*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511805592>
- Granger, C. W. J. (1969). 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.
- Hamilton, J. D. (1994). Time-Series Analysis. In *Chemical Engineering (New York)* (Vol. 92, Issue 12, pp. 85–90). <https://doi.org/10.2307/2984138>
- Lasijan, T. G., Santoso, R., & Hakim, A. R. (2023). Prediksi Harga Emas Dunia Menggunakan Metode Long-Short Term Memory. *Jurnal Gaussian*, 12(2), 287–295. <https://doi.org/10.14710/j.gauss.12.2.287-295>
- Lutkepohl, H. (2005). New Introduction to Multiple Time Series Analysis. In *New Introduction to Multiple Time Series Analysis*. <https://doi.org/10.1007/3-540-27752-8>
- Makridakis S, Wheelwright S. C, & Hyndman. R. J. (1997). *Forecasting Methods and Applications*, Wiley
- Mills, T. C. (2019). Time Series and Their Features. *Applied Time Series Analysis*, 1–12. <https://doi.org/10.1016/b978-0-12-813117-6.00001-6>
- Nagata, A. B., Hidajat, M. S., Wibowo, D. A., Widyatmoko, & Yaacob, N. B. M. (2024). Predicting Gold Price Movement Using Long Short-Term Memory

- Model. *Journal of Applied Intelligent System*, 9(1), 19–28.
- Nugroho, W. S., Astuti, A. B., & Astutik, S. (2021). Vector Error Correction Model to Forecasting Spot Prices for Coffee Commodities during Covid-19 Pandemic. *Journal of Physics: Conference Series*.
- Primananda, S. B., & Isa, S. M. (2021). Forecasting Gold Price in Rupiah using Multivariate Analysis with LSTM and GRU Neural Networks. *Advances in Science, Technology and Engineering Systems Journal*, 6(2), 245–253. <https://doi.org/10.25046/aj060227>
- Putri, A. R., Usman, M., Warsono, Widiarti, & Virginia, E. (2021). Application of Vector Autoregressive with Exogenous Variable: Case Study of Closing Stock Price of PT INDF.Tbk and PT ICBP.Tbk. *Journal of Physics: Conference Series*, 1751(1), 0–10. <https://doi.org/10.1088/1742-6596/1751/1/012012>
- Seo, B. (1998). Statistical inference on cointegration rank in error correction models with stationary covariates. *Journal of Econometrics*, 85(2), 339–385. [https://doi.org/10.1016/S0304-4076\(97\)00105-X](https://doi.org/10.1016/S0304-4076(97)00105-X)
- Shubha, D., & Sushma, P. (2019). *Think India Journal A Study on Gold Price through Vector Error Correction Model*. 43, 41–45.
- Sunyanti., & Mukhaiyar, U. (2019). Gold Price Prediction Using ARIMA Time Series Model Approach. *Procuratio: Jurnal Ilmiah Manajemen*, 7(4), 379–390.
- Usman, M., L., Russel, E., Ansori, M., Warsono, W., Widiarti, W., & Wamiliana, W. (2022). Analysis of Some Energy and Economics Variables by Using VECMX Model in Indonesia. *International Journal of Energy Economics and Policy*, 12(2), 91–102.
- 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/ijeeep.8946>
- Wei, W. W. . (2006). Time Series Analysis Univariate and Multivariate Methods. In *Pearson Education Inc*. <https://doi.org/10.1201/b11459-9>
- Widiarti, Usman, M., Putri, A. R., & Russel, E. (2024). Modeling and Analysis Data Production of Oil, and Oil and Gas in Indonesia by Using Threshold Vector Error Correction Model. *Science and Technology Indonesia*, 9(1), 189–197. <https://doi.org/10.26554/sti.2024.9.1.189-197>
- 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.

- Ye, L., Xie, N., Boylan, J. E., & Shang, Z. (2024). Forecasting seasonal demand for retail : A Fourier time-varying grey model Forecasting seasonal demand for retail : A Fourier time-varying grey model. *International Journal of Forecasting*, October. <https://doi.org/10.1016/j.ijforecast.2023.12.006>
- Yurtsever, M. (2021). Gold Price Forecasting Using LSTM, Bi-LSTM and GRU. *European Journal of Science and Technology*, 31(31), 341–347. <https://doi.org/10.31590/ejosat.959405>
- Zhang, D., Li, Q., Muger, A. W., & Ling, L. (2020). A hybrid model considering cointegration for interval-valued pork price forecasting in China. *Journal of Forecasting*, 39(8), 1324–1341. <https://doi.org/10.1002/for.2688>
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.