

**ANALISIS METODE *HYBRID VECTOR AUTOREGRESSIVE MOVING
AVERAGE EXOGENOUS – LONG SHORT-TERM MEMORY*
(VARMAX-LSTM) UNTUK PERAMALAN EKSPOR IMPOR DENGAN
VARIABEL EKONOMI MAKRO**

Skripsi

Oleh

**ERWIN KESUMA
NPM. 2117031057**



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

2025

ABSTRACT

ANALYSIS OF HYBRID VECTOR AUTOREGRESSIVE MOVING AVERAGE EXOGENOUS - LONG SHORT-TERM MEMORY (VARMAX-LSTM) METHOD FOR EXPORT IMPORT FORECASTING WITH MACROECONOMIC VARIABLES

By

Erwin Kesuma

Forecasting export and import values has a strategic role in supporting Indonesia's monetary policy and economic stability. This research aims to build a forecasting model based on a hybrid approach by combining the linear VARMAX model and the non-linear Long Short-Term Memory (LSTM) model to improve the forecasting accuracy of export and import values. This model is designed to overcome the limitations of VARMAX in capturing non-linear patterns, as well as the shortcomings of LSTM in understanding the linear structure of the data as a whole. In this study, three approaches were built for comparison. The first approach is the VARMAX model, the second is the VARMAX-E_LSTM hybrid model, which combines the VARMAX prediction results with the residuals of the VARMAX model, which are further processed in the LSTM model. The third approach is the VARMAX-EP_LSTM hybrid model, which combines VARMAX predictions and residuals, both of which are further processed in the LSTM model. The data used is monthly data from January 2010 to September 2024, including export, import, and exogenous variables such as exchange rates, inflation, interest rates, and money supply. The forecasting results show that the best model used for the forecasting process of export and import values is the hybrid VARMAX-E_LSTM model with the smallest RMSE and MAPE values. The RMSE is 1.1254E+09 for export variables and 1.4746E+09 for import variables, while the MAPE value is 0.0425 for export variables and 0.0591 for import variables.

Keywords: exports, imports, hybrid VARMAX-LSTM, forecasting.

ABSTRAK

ANALISIS METODE *HYBRID VECTOR AUTOREGRESSIVE MOVING AVERAGE EXOGENOUS – LONG SHORT-TERM MEMORY* (VARMAX-LSTM) UNTUK PERAMALAN EKSPOR IMPOR DENGAN VARIABEL EKONOMI MAKRO

Oleh

Erwin Kesuma

Peramalan nilai ekspor dan impor memiliki peran strategis dalam mendukung kebijakan moneter dan stabilitas ekonomi Indonesia. Penelitian ini bertujuan untuk membangun model peramalan berbasis pendekatan *hybrid* dengan menggabungkan model linear VARMAX dan model non-linear *Long Short-Term Memory* (LSTM) untuk meningkatkan akurasi peramalan nilai ekspor dan impor. Model ini dirancang untuk mengatasi keterbatasan VARMAX dalam menangkap pola non-linear, serta kekurangan LSTM dalam memahami struktur linier data secara utuh. Pada penelitian ini dibangun melalui tiga pendekatan untuk perbandingan. Pendekatan pertama yaitu model VARMAX, kedua model *hybrid* VARMAX-E_LSTM yang menggabungkan hasil prediksi VARMAX dengan residual model VARMAX yang diproses lebih lanjut pada model LSTM. Pendekatan ketiga yaitu model *hybrid* VARMAX-EP_LSTM, yang menggabungkan antara prediksi dan residual VARMAX yang keduanya diproses lebih lanjut pada model LSTM. Data yang digunakan merupakan data bulanan dari Januari 2010 hingga September 2024, mencakup variabel ekspor, impor, serta variabel eksogen seperti nilai tukar, inflasi, suku bunga, dan jumlah uang beredar. Hasil peramalan diperoleh bahwa model terbaik yang digunakan untuk proses peramalan terhadap nilai ekspor dan impor yaitu model *hybrid* VARMAX-E_LSTM dengan nilai RMSE dan MAPE terkecil. Diperoleh RMSE sebesar 1,1254E+09 untuk variabel ekspor dan 1,4746E+09 untuk variabel impor, sedangkan nilai MAPE 0,0425 untuk variabel ekspor dan 0,0591 untuk variabel impor.

Kata-kata kunci: ekspor, impor, *hybrid* VARMAX-LSTM, peramalan.

**ANALISIS METODE *HYBRID VECTOR AUTOREGRESSIVE MOVING
AVERAGE EXOGENOUS – LONG SHORT-TERM MEMORY*
(VARMAX-LSTM) UNTUK PERAMALAN EKSPOR IMPOR DENGAN
VARIABEL EKONOMI MAKRO**

ERWIN KESUMA

Skripsi

Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika

Fakultas Matematika dan Ilmu Pengetahuan Alam



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

2025

**Judul Skripsi : ANALISIS METODE *HYBRID VECTOR*
AUTOREGRESSIVE MOVING AVERAGE
EXOGENOUS - LONG SHORT-TERM
MEMORY (VARMAX-LSTM) UNTUK
PERAMALAN EKSPOR IMPOR DENGAN
VARIABEL EKONOMI MAKRO**

Nama Mahasiswa : Erwin Kesuma

Nomor Pokok Mahasiswa : 2117031057

Program Studi : Matematika

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

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

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


2. Ketua Jurusan Matematika

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


MENGESAHKAN

1. tim penguji

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



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



Penguji

Bukan Pembimbing : **Prof. Dra. Wamiliana, MA., Ph.D.**




2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002



Tanggal Lulus Ujian Skripsi: 18 Juli 2025

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Erwin Kesuma**
Nomor Pokok Mahasiswa : **2117031057**
Jurusan : **Matematika**
Judul Skripsi : **Analisis Metode *Hybrid Vector Autoregressive Moving Average Exogenous – Long Short-Term Memory* (VARMAX-LSTM) untuk Peramalan Ekspor Impor dengan Variabel Ekonomi Makro**

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

Bandar Lampung, 18 Juli 2025

Penulis,



Erwin Kesuma

RIWAYAT HIDUP

Penulis bernama lengkap Erwin Kesuma, lahir di Mesuji pada 13 Agustus 2002. Penulis merupakan anak pertama dari tiga bersaudara dari pasangan Bapak Ardi dan Ibu Eli Pujiati. Penulis mempunyai adik bernama Rizka Khumairoh dan Rizki Khumairoh.

Penulis menempuh pendidikan Sekolah Dasar (SD) Negeri 01 Sinar Laga pada tahun 2009-2015, kemudian melanjutkan pendidikan ke Sekolah Menengah Pertama (SMP) Negeri 01 Tanjung Raya pada tahun 2015-2018, dan Sekolah Menengah Atas (SMA) Negeri 01 Tanjung Raya tahun 2018-2021.

Pada tahun 2021 penulis melanjutkan pendidikan di Strata Satu (S1) di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung, melalui jalur SBMPTN dengan *support* biaya pendidikan dari Dompot Dhuafa, yaitu melalui Beasiswa Etos Id. Selama menjadi mahasiswa, penulis aktif di beberapa organisasi internal maupun eksternal kampus. Di internal kampus penulis aktif sebagai Kepala Biro Pembinaan Rois FMIPA Unila dan Anggota Bidang Eksternal HIMATIKA FMIPA Unila tahun 2022, Ketua HIMATIKA FMIPA Unila tahun 2023, Ketua BEM FMIPA Unila tahun 2024, dan Satuan Pengendali Internal (SPI) BEM U KBM Unila tahun 2025. Sedangkan di eksternal kampus, penulis aktif di gerakan sosial sebagai *Informative Officer* Kuliah Tak Gentar (KTG) tahun 2022 dan *Head of Public Relations and Media* Lampung Sikam tahun 2023.

Sebagai bentuk pengaplikasian ilmu yang didapat selama perkuliahan, pada bulan Desember 2023 hingga Februari 2024, penulis melaksanakan Kerja Praktik (KP) di Unit Pelaksana Teknis Daerah Kesatuan Pengelolaan Hutan Konservasi Taman

Hutan Raya Wan Abdul Rachman (UPTD KPHK Tahura WAR). Kemudian, pada bulan Juni hingga Agustus 2024, penulis melaksanakan Kuliah Kerja Nyata (KKN) Bilateral di Desa Tebing Kaning, Kecamatan Arma Jaya, Kabupaten Bengkulu Utara, Provinsi Bengkulu.

Selain itu sebagai bentuk komitmen penulis untuk terus belajar dan meningkatkan *softskill*, penulis berkesempatan mengikuti program Magang dan Studi Independen Bersertifikat (MSIB) di RevoU Tech Academy di bidang *Data Analytics & Software Development* pada Februari hingga Juni 2024. Kemudian mengikuti MSIB kembali di Bangkit Academy dengan bidang *Machine Learning* pada Agustus hingga November 2024.

KATA INSPIRASI

”Sesungguhnya bersama kesulitan ada kemudahan. Maka apabila engkau telah selesai (dari suatu urusan), tetaplah bekerja keras (untuk urusan yang lain). Dan hanya kepada Tuhanmulah engkau berharap”

(Q.S. Al-Insyirah: 6-8)

”Dan kehidupan dunia ini hanyalah permainan dan senda gurau...”

(Q.S. Al-An’am: 32)

”Hidup itu tidak sederhana, hidup itu harus hebat, kuat, besar, dan jadi bermanfaat. Karena yang sederhana adalah sikap.”

”Be The Best Version Your Self”

PERSEMBAHAN

Puji dan syukur kehadiran Allah Subhanahu Wata'ala atas limpahan nikmat serta hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi ini. Shalawat serta salam senantiasa tercurahkan kepada junjungan kita Nabi Muhammad Shallallahu 'Alaihi Wassalam. Dengan penuh syukur, penulis persembahkan karya ini kepada:

Ayah, Ibu, dan Adikku Tercinta

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

Dosen Pembimbing dan Pembahas

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

Sahabat dan Rekan Perjuangan

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

Almamater Tercinta

Universitas Lampung

SANWACANA

Alhamdulillah, puji dan syukur penulis panjatkan kepada Allah SWT atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini yang berjudul "Analisis Metode *Hybrid Vector Autoregressive Moving Average Exogenous – Long Short-Term Memory* (VARMAX-LSTM) untuk Peramalan Ekspor Impor dengan Variabel Ekonomi Makro". Skripsi ini disusun sebagai salah satu syarat memperoleh gelar Sarjana Matematika (S.Mat.) pada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Terselesaikannya skripsi ini tidak lepas dari dukungan, bimbingan, saran, motivasi, dan do'a dari berbagai pihak. Untuk itu, dalam kesempatan ini penulis mengucapkan rasa hormat dan terima kasih kepada :

1. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku Pembimbing I dan dosen pembimbing akademik penulis yang dengan penuh dedikasi membimbing penulis melalui setiap tahap penulisan skripsi ini. Bimbingan, motivasi, dan ilmu yang diberikan sangat membantu penulis dalam menyelesaikan skripsi ini.
2. Bapak Ir. Warsono, M.S., Ph.D. selaku Pembimbing II yang telah memberikan arahan, bimbingan, dan dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Ibu Prof. Dra. Wamiliana, MA., Ph.D. selaku Penguji yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

5. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Seluruh dosen dan staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung yang telah memberikan wawasan, ilmu, dan pengetahuan yang sangat berharga bagi penulis selama menjalani proses perkuliahan.
7. Kedua orang tua penulis tersayang, Bapak Ardi dan Ibu Eli Pujiati, adik-adik penulis, Rizka Khumairoh dan Rizki Khumairoh, serta keluarga besar penulis yang tidak pernah lelah memberikan doa, dukungan moral, serta materiil yang tidak ternilai harganya, sehingga penulis dapat menyelesaikan skripsi ini.
8. Lembaga amal zakat Dompot Dhuafa, Great Edunesia, dan Etos Id yang telah memberikan *support* secara materiil dan memberikan wadah terbaik untuk mengembangkan diri, memperjelas mimpi, dan memotivasi penulis bahwa kita adalah bagian pemuda yang harus terus bergerak dan berdampak untuk sekitar. Terimakasih sudah menjadi lembaga yang menghantarkan mimpi salah satu anak petani ini menjadi sarjana.
9. Fasilitator Etos Id Lampung, Kakak Pujo Prasetyo, Mba Endah, Kakak Dani Windarto, Kakak Amiza Rezika, Kakak Eko Wiyanto, dan Mba Sri Rahayu yang terus membina, memotivasi, dan sumber inspirasi penulis dalam menghadapi kehidupan ini yang serba tidak pasti, terimakasih sudah menjadi lentera dalam membantu menerangi jalan di dunia kampus.
10. Sahabat seperjuangan Etoser Lampung 2021, yaitu para Amoeba, Anita Fitria, Intan Suly Ciwing, Ririn Destiana, Ulfa Novitasari, dan Tiara Tabita, yang sudah berjuang hebat dengan mimpinya sampai hari ini. Terimakasih sudah menjadi pendengar, penasehat, dan penguat langkah selama ini. Terimakasih sudah mengingatkan bahwa mimpi kita terlalu kecil jika hanya untuk diri sendiri.
11. Keluarga Besar Etos Id nasional Arshaka Ghazi, yang menginspirasi penulis untuk terus bertumbuh dan berkembang. Dan kepada Keluarga Besar Etos Id Lampung, kakak dan adik Etoser yang sudah kebersamaan serta menjadi inspirasi penulis untuk terus selangkah lebih maju.

12. Bidang Eksternal HIMATIKA FMIPA Unila Periode 2022, Bang Yazid, Yunda Callista, Yunda Rani, Yunda Salsa, Yunda Demi, Yunda Lia, Margel, Rara, Ridho, Arvi, Falen, Eri, dan Najia yang selalu menerima dan memberikan dukungan dalam segala kondisi, menemani sekaligus menghibur hingga membuat dunia perkuliahan menjadi sangat menyenangkan.
13. Pimpinan Rois FMIPA Unila Periode 2022, yang sudah memberi arti kepada penulis untuk tetap berada dalam jalan kebaikan dan memberikan manfaat untuk sesama.
14. Pimpinan HIMATIKA FMIPA Unila Periode 2023, Ilham, Isty, Aini, Munadiya, Zafira, Zanzabil, Ilma, Randia, Esti, Eri, Arvi, Ridho, Arsie, Jumi, Anggun, Safina, dan Annisa yang telah menjadi teman tumbuh dan belajar, memberikan ruang untuk berkembang, serta menjadi teman seperjuangan dalam menghadapi dinamika organisasi dan kehidupan kampus.
15. Pimpinan BEM FMIPA Unila Periode 2024, Abe, Ririn, Talfa, Diah, Ceni, dan pimpinan lainnya yang selalu memberi inspirasi dan motivasi, serta mengajarkan arti kepemimpinan yang bijak serta penuh tanggung jawab.
16. Pimpinan BEM U KBM Unila Periode 2025, Ammar, Aiman, Aqilah, Almahda dan pimpinan lainnya yang telah memberikan saran masukan dan panutan dalam memperjuangkan aspirasi mahasiswa, serta turut membentuk semangat kolektif dalam menebar kebermanfaatan bagi kampus tercinta.
17. Sahabat penulis para PANDAWA, Anam, Govin, Ariz, dan Sayyid, yang senantiasa hadir dalam suka dan duka, menjadi tempat berbagi cerita, bertukar pikiran, dan tumbuh bersama dalam setiap langkah perjuangan perkuliahan maupun kehidupan.
18. Keluarga Madani 2021, tempat berteduh dari lelahnya dunia akademik, serta menjadi bagian penting dalam perjalanan penuh makna dan perjuangan selama menjadi mahasiswa.
19. Salahudin Al Ayyubi, Aiman, Anam, Anang, Ariz, Govindo, Fatir, Ihsan, Nabil, Rafly, Syarif, dan Wildan, rekan *quality control* dalam kebaikan, skripsi, dan karir. Terimakasih sudah kebersamaan penulis menjadi pribadi yang lebih baik.

20. Teman-teman seperbimbingan Bu Dian dan Pak Warsono, Andi, Anggy, Ariz, Dita, Maya, Mey, Nabila, Sherina, Adinda, Anastasia, Dina, Fathan, Lusiana, Rhea, dan Yulina, yang selalu menemani, membantu, dan saling memberi dukungan satu sama lain selama proses penyelesaian skripsi ini.
21. Teman-teman Jurusan Matematika angkatan 2021 serta Abang Yunda yang telah membantu selama proses perkuliahan.
22. Seluruh pihak terkait yang telah membantu menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu persatu.

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

Bandar Lampung, 18 Juli 2025

Erwin Kesuma

DAFTAR ISI

	Halaman
DAFTAR TABEL	ix
DAFTAR GAMBAR	xi
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
II TINJAUAN PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 Ekonomi Makro	9
2.3 Deret Waktu	11
2.3.1 Analisis Deret Waktu	11
2.3.2 Peramalan	12
2.4 Model Deret Waktu Multivariat	14
2.4.1 <i>Vector Autoregressive</i> (VAR)	14
2.4.2 <i>Vector Moving Average</i> (VMA)	15
2.4.3 <i>Vector Autoregressive Moving Average</i> (VARMA)	15
2.4.4 <i>Vector Autoregressive Moving Average with Exogenous Variable</i> (VARMAX)	16
2.5 Kestasioneran Data	17
2.6 Kausalitas Granger	18
2.7 Uji Asumsi Residual	19
2.8 <i>Machine learning</i>	22
2.9 <i>Scaling Data</i>	23

2.10	Normalisasi dan Denormalisasi Data	24
2.11	Fungsi Aktivasi	26
2.12	<i>Hyperparameter</i> dan <i>Parameter Training</i>	28
2.13	<i>Deep Learning</i>	30
2.13.1	<i>Recurrent Neural Network</i> (RNN)	31
2.13.2	<i>Long Short-Term Memory</i> (LSTM)	33
2.14	<i>Hybrid VARMAX – LSTM</i>	37
2.15	Evaluasi Model	39
III	METODE PENELITIAN	41
3.1	Tempat dan Waktu Penelitian	41
3.1.1	Tempat Penelitian	41
3.1.2	Waktu Penelitian	41
3.2	Data dan Alat	41
3.2.1	Data	41
3.2.2	Alat	42
3.3	Metode Penelitian	44
IV	HASIL DAN PEMBAHASAN	48
4.1	<i>Input</i> Data	48
4.2	Visualisasi Data	49
4.3	<i>Splitting</i> data	50
4.4	Prediksi dan Peramalan dengan Model VARMAX	51
4.4.1	<i>Preprocessing</i> Data	51
4.4.2	Uji Stasioneritas	52
4.4.3	Uji Kausalitas Granger	52
4.4.4	Identifikasi Model	53
4.4.5	Estimasi Parameter	55
4.4.6	Prediksi Model VARMAX	56
4.4.7	Residual Model VARMAX	58
4.4.8	Uji Asumsi Residual Model VARMAX	60
4.4.9	Peramalan Model VARMAX	60
4.5	Prediksi dan Peramalan Model <i>Hybrid</i> VARMAX-E_LSTM	62
4.5.1	<i>Scaling</i> Data	63
4.5.2	<i>Hyperparameter Tuning</i> Model E_LSTM	63
4.5.3	Membangun Model E_LSTM	64

4.5.4	Prediksi Model E_LSTM	65
4.5.5	Prediksi Model <i>Hybrid</i> VARMAX-E_LSTM	68
4.5.6	Peramalan Model E_LSTM	70
4.5.7	Peramalan Model <i>Hybrid</i> VARMAX-E_LSTM	71
4.6	Prediksi dan Peramalan Model Hybrid VARMAX-EP_LSTM	73
4.6.1	<i>Scaling</i> Data Prediksi Model VARMAX	74
4.6.2	<i>Hyperparameter Tuning</i> Model P_LSTM	74
4.6.3	Membangun Model P_LSTM	75
4.6.4	Prediksi Model P_LSTM	75
4.6.5	Prediksi Model <i>Hybrid</i> VARMAX-EP_LSTM	78
4.6.6	Peramalan Model P_LSTM	80
4.6.7	Peramalan Model <i>Hybrid</i> VARMAX-EP_LSTM	81
4.7	<i>Goodness of Fit</i>	83
V	KESIMPULAN DAN SARAN	85
5.1	Kesimpulan	85
5.2	Saran	86
	DAFTAR PUSTAKA	87

DAFTAR TABEL

Tabel	Halaman
1 Penelitian Terkait.....	7
2 Transformasi <i>Box-Cox</i>	18
3 Data Penelitian.....	42
4 Data Penelitian.....	48
5 <i>Splitting</i> Data.....	50
6 <i>Preprocessing</i> Data	51
7 <i>Preprocessing</i> Data	51
8 Hasil Uji Kausalitas Granger terhadap Variabel Ekspor.....	52
9 Hasil Uji Kausalitas Granger terhadap Variabel Impor	52
10 Pemilihan Model VARMAX Terbaik.....	55
11 Hasil Prediksi Model VARMAX.....	56
12 Hasil Prediksi Data Aktual dan Prediksi Menggunakan Model VARMAX	56
13 Evaluasi Model VARMAX(3,0,1).....	58
14 Nilai Residual Model VARMAX	58
15 Hasil Uji <i>Ljung-Box</i>	60
16 Data Hasil Peramalan Model VARMAX.....	61
17 <i>Hyperparameter Tuning</i> Model E_LSTM.....	64
18 Hasil <i>Hyperparameter Tuning</i> Model E_LSTM.....	65
19 Prediksi Model E_LSTM	65
20 Hasil Prediksi Model E_LSTM	66
21 Evaluasi Model E_LSTM.....	67
22 Hasil Prediksi Model <i>Hybrid</i> VARMAX-E_LSTM.....	68
23 Evaluasi Model <i>Hybrid</i> VARMAX-E_LSTM	70
24 Hasil Peramalan Residual Model E_LSTM	70
25 Data Hasil Peramalan Model <i>Hybrid</i> VARMAX-E_LSTM	72

26	<i>Hyperparameter Tuning Model P_LSTM</i>	74
27	Hasil <i>Hyperparameter Tuning Model P_LSTM</i>	75
28	Prediksi Model P_LSTM	76
29	Hasil Prediksi Model P_LSTM	76
30	Evaluasi Model P_LSTM.....	78
31	Hasil Prediksi Model VARMAX-EP_LSTM	78
32	Evaluasi Model <i>Hybrid VARIMA-EP_LSTM</i>	80
33	Hasil Peramalan Model P_LSTM.....	80
34	Hasil Peramalan Model VARMAX-EP_LSTM.....	82
35	<i>Goodness of Fit</i> Ekspor	83
36	<i>Goodness of Fit</i> Impor	83

DAFTAR GAMBAR

Gambar	Halaman
1 Pola Data Deret Waktu (Sumber: Softscients, 2020)	12
2 Fungsi Aktivasi <i>Sigmoid</i>	27
3 Fungsi Aktivasi <i>Tangen Hiperbolik</i>	28
4 Arsitektur RNN (Sumber: Syahram dkk., 2020).....	32
5 Arsitektur LSTM (Sumber: Syahram dkk., 2020)	34
6 <i>Flowchart</i> Model <i>Hybrid</i> VARMAX-E_LSTM	46
7 <i>Flowchart</i> peramalan model <i>hybrid</i> VARMAX-EP_LSTM.....	47
8 Plot Data Historis Ekspor Indonesia	49
9 Plot Data Historis Impor Indonesia.....	49
10 Plot ACF dan PACF Ekspor.....	53
11 Plot ACF dan PACF Impor	54
12 Plot Hasil Prediksi Model VARMAX.....	57
13 Plot Data Residual Hasil Prediksi Model VARMAX	59
14 Plot Hasil Peramalan Model VARMAX	61
15 Plot Residual Prediksi E_LSTM.....	67
16 Plot Hasil Prediksi Model <i>Hybrid</i> VARMAX-E_LSTM.....	69
17 Plot Hasil Peramalan Residual Model E_LSTM	71
18 Plot Hasil Peramalan Model <i>Hybrid</i> VARMAX-E_LSTM.....	73
19 Plot Hasil Prediksi Model P_LSTM	77
20 Plot Hasil Prediksi Model <i>Hybrid</i> VARMAX-EP_LSTM.....	79
21 Plot Hasil Peramalan Model P_LSTM.....	81
22 Plot Hasil Peramalan Model <i>Hybrid</i> VARMAX-EP_LSTM.....	82

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Deret waktu adalah serangkaian observasi suatu variabel yang direkam secara berurutan pada interval waktu tetap, seperti harian, bulanan, atau tahunan (Box et al., 2015). Dalam konteks ekonomi, analisis deret waktu menjadi alat krusial untuk memahami dinamika variabel makro seperti ekspor dan impor, yang memiliki pola temporal seperti tren, musiman, dan fluktuasi acak (Hyndman & Athanasopoulos, 2018). Analisis ini bertujuan untuk mengidentifikasi pola historis, memprediksi nilai masa depan, dan merancang strategi pengendalian berbasis data (Makridakis et al., 1999). Sebagai contoh, prediksi ekspor dan impor yang akurat dapat membantu pemerintah merencanakan kebijakan moneter atau antisipasi defisit perdagangan. Namun, keberhasilan analisis ini bergantung pada dua faktor utama: pertama pemilihan variabel yang relevan, dan kedua kecocokan model dengan karakteristik data (Zahra & Lazaar, 2019). Meskipun banyak metode tersedia seperti ARIMA, VAR, atau *machine learning*, tidak ada model universal yang cocok untuk semua jenis data. Model tradisional seperti ARIMA atau VAR efektif menangkap pola linear dan stasioner, tetapi sering gagal memodelkan hubungan non-linear dan efek variabel eksogen seperti nilai tukar atau inflasi (Zhang, 2019). Oleh karena itu, pemilihan model harus didasarkan pada uji statistik dan validasi empiris (Hyndman & Koehler, 2006).

Pemodelan deret waktu dapat diklasifikasikan menjadi dua jenis berdasarkan jumlah variabel, univariat dan multivariat (Lutkepohl, 2020). Model multivariat diperlukan ketika variabel-variabel saling memengaruhi secara dinamis, seperti hubungan ekspor dan impor yang dipengaruhi faktor makro (Tsay, 2022). Salah satu metode multivariat yang banyak digunakan adalah *Vector Autoregressive Moving Average Exogenous* (VARMAX), yang merupakan kasus khusus dari model VARMA dengan penambahan variabel eksogen ke dalam model yang melibatkan

variabel endogen (Pratama & Saputro, 2018). Variabel eksogen, seperti nilai tukar dan inflasi, memungkinkan model ini menjelaskan pengaruh faktor eksternal terhadap variabel endogen (Hyndman & Athanasopoulos, 2021). Namun, model VARMAX memiliki keterbatasan utama, ia hanya efektif untuk pola linear dan stasioner, sehingga kurang mampu menangkap hubungan non-linear atau gangguan eksternal mendadak seperti gejolak geopolitik (Panigrahi & Behera, 2022). Hal ini menjadi tantangan krusial dalam analisis data ekonomi modern yang sering kali kompleks dan bersifat non-stasioner (Wang & Zhang, 2023).

Perkembangan teknologi yang bergerak cepat telah mendorong kemajuan dalam peramalan suatu nilai dengan menggunakan metode *deep learning*. Salah satu jenis dari metode *deep learning* adalah *Long Short-Term Memory* (LSTM). Metode LSTM ini merupakan salah satu arsitektur *Recurrent Neural Network* (RNN) yang diperkenalkan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997 (Hochreiter dan Schmidhuber, 1997). Model RNN adalah salah satu jenis jaringan saraf tiruan yang dirancang untuk menangani data sekuensial. Pada RNN, mampu menangkap hubungan temporal dalam data dengan menggunakan mekanisme umpan balik (*feedback loop*) yang memungkinkan informasi dari langkah waktu sebelumnya digunakan untuk memprediksi langkah waktu berikutnya. Namun, RNN memiliki kelemahan yang signifikan, yaitu kesulitan dalam mempelajari dependensi jangka panjang pada data. Hal ini disebabkan oleh masalah *vanishing gradient*, di mana nilai gradien menjadi sangat kecil selama proses pelatihan, sehingga jaringan sulit untuk memperbarui bobot secara efektif dan kehilangan informasi dari langkah waktu sebelumnya.

Untuk mengatasi keterbatasan ini, dikembangkan arsitektur LSTM untuk mengatasi permasalahan *vanishing gradient* tersebut, yaitu dengan adanya *cell state* dan *gate unit* yang mengatur memori pada setiap masukannya (Aldi dkk., 2018). LSTM menggunakan struktur khusus yang disebut *memory cell* dan tiga gerbang utama *input gate*, *forget gate*, dan *output gate* yang memungkinkan jaringan untuk memilih informasi mana yang harus disimpan, dilupakan, atau dikeluarkan pada setiap langkah waktu. Dengan demikian, LSTM lebih unggul dibandingkan RNN dalam mempelajari pola jangka panjang pada data sekuensial, khususnya data dengan pola non-linear dan kompleks.

Meskipun LSTM memiliki kemampuan yang sangat baik dalam menangkap pola non-linear dan hubungan jangka panjang dalam data deret waktu, metode ini tetap memiliki beberapa kelemahan. Salah satu kelemahannya adalah kebutuhan akan waktu komputasi yang tinggi karena struktur modelnya yang kompleks. Selain itu, LSTM tidak dirancang untuk menangani pola musiman, tren, atau hubungan linier antar variabel, yang sering menjadi karakteristik penting dalam data ekonomi makro. Di sisi lain, metode seperti VARMAX sangat baik dalam menangkap pola linier dan struktur musiman dalam data deret waktu. Namun, VARMAX kurang mampu menangani pola data yang bersifat non-linear atau hubungan kompleks antar variabel. Salah satu cara untuk meningkatkan kinerja model dan mengatasi kelemahan masing-masing metode ini adalah dengan menggunakan pendekatan *hybrid* untuk meningkatkan akurasi peramalan (Zhang, 2003).

Pengembangan prediksi model multivariat dengan menggunakan model VARMAX dan menggunakan model LSTM adalah metode *hybrid* VARMAX – LSTM. Metode LSTM digunakan untuk menyempurnakan kelemahan VARMAX, yang kurang mampu menangkap pola non-linear dalam data deret waktu seperti data ekspor dan impor. Kombinasi kedua metode ini memungkinkan VARMAX menangkap hubungan linear antar variabel endogen dan eksogen, sementara LSTM melengkapi dengan memodelkan komponen non-linear yang ada. Dengan demikian, *hybrid* VARMAX-LSTM menjadi solusi komprehensif untuk data ekonomi yang kompleks, menggabungkan kekuatan model linear dan non-linear secara sinergis.

Adaptasi ini menjadi semakin krusial mengingat prediksi ekspor dan impor Indonesia tidak hanya bertujuan untuk akurasi statistik, tetapi juga mendukung target pertumbuhan ekonomi 8% di era pemerintahan Presiden Prabowo Subianto, sebagaimana tertuang dalam Rencana Pembangunan Jangka Menengah Nasional (RPJMN) 2025-2029 (Badan Perencanaan Pembangunan Nasional, 2024). Sejalan dengan ini, Kepala Badan Kebijakan Perdagangan (BKPerdag) Fajarini Puntodewi menegaskan bahwa pertumbuhan ekspor merupakan pengungkit utama pertumbuhan ekonomi dengan kontribusi mencapai USD 405,69 miliar dengan pertumbuhan 9,64% (Kementerian Perdagangan RI, 2024). Di sisi lain, tantangan makroekonomi seperti fluktuasi nilai tukar yang mencapai Rp 16.200/USD pada 2024, inflasi 1,57%, dan suku bunga acuan 6% (Bank Indonesia, 2025) menuntut pendekatan prediksi yang tidak hanya responsif, tetapi juga holistik. Dengan *hybrid* VARMAX-LSTM, diharapkan akurasi prediksi tidak hanya ditingkatkan, tetapi

juga menjadi basis rekomendasi kebijakan moneter yang lebih terukur.

Penelitian terdahulu menggunakan metode VARMAX telah dilakukan Boddu et al. (2024), yang menganalisis kinerja model VARMAX metaheuristik ganda iteratif yang dibandingkan dengan tiga metode yang ada, yang diidentifikasi sebagai *Fuzzy C Means* (FCM), *Variational Model Decomposition* (VMD), dan *Empirical Mode Decomposition* (EMD). Perbandingan ini dilakukan menggunakan *dataset* penutupan hutan, dan hasil evaluasi menunjukkan bahwa hasil RMSE pada keempat model tersebut adalah VARMAX 0,0347, FCM 0,0501, VMD 0,0458, dan EMD 0,0458. Selanjutnya penelitian metode LSTM oleh Nugraha et al. (2021), yaitu memprediksikan harga saham PT. Astra International Tbk., dengan hasil model terbaik, yaitu model 1 yang memiliki ukuran *batch* 4 dan jumlah *epoch* 50 dengan nilai MAPE 2,3%. Penelitian tentang *hybrid* pernah dilakukan oleh Aji & Surjandari (2020), menggunakan metode *hybrid* VAR–LSTM untuk meramalkan harga transaksi bahan bakar yang menghasilkan MAPE sebesar 1,02%. Peramalan lain mengenai model *hybrid* juga sudah pernah dilakukan oleh Caliwag & Lim (2019), menggunakan metode *hybrid* VARMA–LSTM untuk meramalkan status pengisian dan tegangan keluaran baterai *lithium-ion* dalam aplikasi sepeda motor listrik. Hasil penelitian ini menunjukkan bahwa model *hybrid* VARMA-LSTM memiliki kinerja terbaik dengan nilai RMSE sebesar 0,161 dibandingkan dengan model VARMA 3,836 dan model LSTM 0,4032.

Penelitian dengan metode *hybrid* VARMAX-LSTM masih terbatas diaplikasikan pada prediksi ekspor dan impor di negara berkembang seperti Indonesia. Padahal, ekspor dan impor tidak hanya menjadi sumber devisa, tetapi juga penopang stabilitas makroekonomi dan daya saing global. Dalam dinamika ekonomi yang dipengaruhi fluktuasi nilai tukar, inflasi, suku bunga, dan jumlah uang beredar, prediksi akurat menjadi kunci penyusunan strategi perdagangan yang responsif. Berdasarkan urgensi ini, penelitian bertujuan menguji keefektifan *hybrid* VARMAX-LSTM dalam memodelkan hubungan kompleks antara variabel moneter dan kinerja perdagangan. Hasilnya diharapkan menjadi acuan bagi pemerintah dalam merumuskan kebijakan moneter berbasis data, serta pelaku usaha untuk mitigasi risiko fluktuasi pasar. Dengan demikian, penelitian ini tidak hanya berkontribusi pada pengembangan metodologi deret waktu, tetapi juga mendukung percepatan target pertumbuhan ekonomi Indonesia sebesar 8%.

1.2 Rumusan Masalah

Adapun rumusan masalah penelitian ini adalah sebagai berikut:

1. Bagaimana cara membangun model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM untuk meramalkan nilai ekspor dan impor di Indonesia?.
2. Bagaimana hasil peramalan nilai ekspor dan impor menggunakan model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM?.
3. Bagaimana perbandingan kinerja model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM dalam melakukan peramalan nilai ekspor dan impor di Indonesia?.
4. Bagaimana implikasi hasil peramalan menggunakan model *hybrid* VARMAX-LSTM terhadap perumusan kebijakan moneter dan strategi perdagangan Indonesia?.

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Mengembangkan model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM dalam peramalan ekspor dan impor Indonesia dengan mempertimbangkan variabel eksogen seperti nilai tukar, inflasi, suku bunga, dan jumlah uang beredar.
2. Mengetahui hasil peramalan nilai ekspor dan impor yang dihasilkan oleh model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM.
3. Membandingkan kinerja model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM dalam melakukan peramalan nilai ekspor dan impor.

4. Memberikan rekomendasi berbasis data kepada pemerintah dan pelaku usaha mengenai kebijakan moneter dan strategi perdagangan yang lebih efektif dalam menghadapi dinamika ekonomi global.

1.4 Manfaat Penelitian

Hasil penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Manfaat Akademik

- Berkontribusi pada pengembangan metode peramalan dengan pendekatan *hybrid* VARMAX–LSTM, yang menggabungkan keunggulan model linear dan non-linear dalam analisis deret waktu.
- Menambah referensi bagi peneliti dalam bidang matematika, statistika, ekonomi dan *data science* terkait pemodelan ekspor dan impor dengan pendekatan multivariat dan *deep learning*.

2. Manfaat Praktis

- Memberikan *insight* kepada pemerintah dalam menyusun kebijakan moneter dan perdagangan berbasis data yang lebih akurat dan responsif terhadap dinamika ekonomi global.
- Membantu pelaku usaha dan pemangku kepentingan dalam memahami tren ekspor dan impor sehingga dapat merancang strategi bisnis yang lebih adaptif terhadap fluktuasi ekonomi.

3. Manfaat Kebijakan

- Mendukung target pertumbuhan ekonomi Indonesia sebesar 8% sebagaimana diamanatkan dalam RPJMN 2025-2029 dengan pendekatan peramalan yang lebih presisi.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian terdahulu yang telah dilakukan digunakan sebagai bahan acuan untuk meningkatkan pemahaman tentang topik penelitian yang dipakai dalam penelitian ini. Ringkasan mengenai beberapa penelitian terdahulu akan dijelaskan pada Tabel 1 berikut:

Tabel 1. Penelitian Terkait

No	Penelitian	Data	Metode	Hasil
1.	<i>Design of an Iterative Dual Metaheuristic VARMAX Model Enhancing Efficiency of Time Series Predictions</i> (Boddu et al., 2024).	Persentase tutupan hutan yang sebenarnya dan yang diprediksi di wilayah Kerala tahun 2018-2022.	VARMAX, FCM, VMD, EMD	RMSE: 0,0347 (VARMAX), 0,0501 (FCM), 0,0458 (VMD), 0,0480 (EMD)
2.	<i>Forecasting the Stock Price of PT. Astra International Using the LSTM Method</i> (Nugraha et al., 2021).	Harga saham penutupan harian PT. Astra International Tbk., 2 Januari 2015 - 30 Desember 2020.	LSTM	MAPE: 2,3%, RMSE: 151.910
3.	<i>Hybrid Vector Autoregression-Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price</i> (Aji & Surjandari , 2020).	Data harga transaksi bahan bakar jet, Januari 2018 – April 2020.	Hybrid VAR-LSTM	MAPE: 1,02%, RMSE: 81,52
4.	<i>Hybrid VARMA and LSTM Method for Lithium-ion Battery State-of-Charge and Output Voltage Forecasting in Electric Motorcycle Applications</i> (Caliwag & Lim, 2019).	Data indikator keamanan baterai pada kendaraan berbasis listrik.	VARMA, LSTM, Hybrid VARMA-LSTM	RMSE: 3,836 (VARMA), 0,4032 (LSTM), 0,161 (VARMA-LSTM)

Berikut adalah penjelasan penelitian pada Tabel 1:

1. Penelitian Boddu et al. (2024)

Penelitian yang dilakukan oleh Boddu et al. (2024) bertujuan untuk menganalisis ketepatan model dalam meramalkan perubahan lingkungan, dengan menunjukkan persentase tutupan hutan yang sebenarnya dan yang diprediksi setiap tahunnya di daerah Kerala dari tahun 2018-2022.

Penelitian ini membandingkan VARMAX dengan tiga metode yang ada, yang diidentifikasi sebagai *Fuzzy C Means* (FCM), *Variational Model Decomposition* (VMD), dan *Empirical Mode Decomposition* (EMD). Hasil evaluasi menunjukkan bahwa hasil RMSE pada keempat model tersebut adalah VARMAX 0,0347, FCM 0,0501, VMD 0,0458, dan EMD 0,0458.

2. Penelitian Nugraha et al. (2021)

Penelitian yang dilakukan oleh Nugraha et al. (2021) berfokus pada peramalan harga saham PT. Astra International Tbk. menggunakan metode *Long Short-Term Memory* (LSTM). *Dataset* penutupan harga saham diambil dari 2 Januari 2015-30 Desember 2020, dengan total pengamatan 1506. Sumber data penelitian ini adalah data sekunder dari *website Yahoo Finance*.

Penelitian ini mencakup pengembangan model LSTM, dengan menggunakan perubahan parameter dalam data pelatihan, terdapat ukuran *batch* 4, 16, dan 64, dan *epoch* 50, 100, 200, dan 400. Didapatkan hasil model terbaik adalah model yang memiliki ukuran *batch* 4 dan jumlah *epoch* 50, dengan nilai RMSE 151.910 dan MAPE 2,3%.

3. Penelitian Aji & Surjandari (2020)

Penelitian yang dilakukan oleh Aji & Surjandari (2020) berfokus pada peramalan harga transaksi bahan bakar jet di Bandara CGK Tangerang dengan menerapkan model *hybrid VAR-LSTM*. Data yang digunakan mencakup periode Januari 2017-April 2020 dan terdiri dari delapan variabel yang diperoleh dari lima sumber berbeda, yaitu data terbuka *platts's website*, *pertamina's website*, Bank Indonesia *website*, dan maskapai penerbangan Indonesia.

Tahapan awal dalam penelitian ini melibatkan penerapan metode VAR, yang mencakup transformasi data, pengujian asumsi, dan penentuan *lag* optimal. Selanjutnya, model VAR-LSTM dikembangkan dengan memanfaatkan hasil prediksi dari model VAR. Hasil penelitian menunjukkan bahwa model *hybrid VAR-LSTM* menghasilkan nilai evaluasi model dengan MAPE sebesar 1,02%

dan RMSE sebesar 81,52, yang menunjukkan tingkat akurasi yang tinggi dalam peramalan harga bahan bakar jet.

4. Penelitian Caliwag & Lim (2019)

Penelitian yang dilakukan oleh Caliwag & Lim, (2019) berfokus pada peramalan status pengisian dan tegangan keluaran baterai lithium-ion dalam aplikasi sepeda motor listrik. Data yang digunakan berasal dari pengukuran aktual sepeda motor listrik yang dikendarai di bawah siklus penggerak CVS-40 dengan suhu operasi 0°C dan 25°C

Penelitian ini diawali dengan seleksi variabel independen menggunakan analisis korelasi Pearson, yang kemudian dilanjutkan dengan dekomposisi data historis baterai ke dalam komponen linier dan nonlinier. Model VARIMA diterapkan untuk menangkap karakteristik linier, sementara model LSTM digunakan untuk memodelkan pola nonlinier. Evaluasi kinerja model dilakukan berdasarkan nilai RMSE pada berbagai kondisi suhu. Hasil penelitian menunjukkan bahwa pendekatan *hybrid* VARIMA-LSTM menghasilkan nilai RMSE yang lebih rendah dibandingkan penerapan model tunggal. Pada suhu 25°C, nilai RMSE untuk peramalan tegangan keluaran tercatat sebesar 0,161.

2.2 Ekonomi Makro

Ekonomi makro merupakan cabang ilmu ekonomi yang mempelajari perilaku keseluruhan perekonomian, termasuk faktor-faktor yang memengaruhi perdagangan internasional seperti ekspor dan impor. Ekspor dan impor, yang merupakan komponen utama dari neraca perdagangan, dipengaruhi oleh berbagai faktor makroekonomi seperti kurs mata uang, suku bunga, inflasi, dan jumlah uang beredar (Mankiw, 2020).

1. Ekspor dan Impor

Ekspor adalah penjualan barang dan jasa dari suatu negara ke negara lain, sedangkan impor merupakan pembelian barang dan jasa dari negara lain. Volume ekspor dan impor suatu negara sangat bergantung pada stabilitas perekonomian domestik dan internasional, termasuk kebijakan perdagangan, fluktuasi nilai tukar, serta kondisi pasar global (Bank Dunia, 2022). Menurut Putri dkk. (2023), pergerakan ekspor dan impor tidak hanya mencerminkan kinerja ekonomi domestik tetapi juga menjadi indikator keterkaitan suatu negara dalam perdagangan internasional.

2. Kurs Rupiah

Kurs mata uang atau nilai tukar adalah harga relatif mata uang domestik terhadap mata uang asing. Perubahan kurs dapat memengaruhi daya saing harga barang di pasar internasional, sehingga berdampak langsung pada ekspor dan impor (Madhani et al., 2021). Depresiasi Rupiah, misalnya, dapat meningkatkan daya saing ekspor karena barang menjadi lebih murah bagi pembeli asing, tetapi secara bersamaan dapat meningkatkan biaya impor (Bank Indonesia, 2023).

3. Suku Bunga

Suku bunga adalah harga dari penggunaan uang yang dipinjamkan atau disimpan dalam jangka waktu tertentu. Perubahan suku bunga berpengaruh terhadap investasi dan tabungan, yang secara tidak langsung dapat memengaruhi aktivitas ekspor dan impor. Suku bunga yang tinggi dapat mengurangi konsumsi domestik, tetapi juga menarik investasi asing yang memperkuat kurs mata uang domestik (Kasmir, 2023). Hubungan antara suku bunga dan perdagangan internasional sering kali terlihat melalui mekanisme aliran modal internasional (Raharjo dkk., 2022).

4. Inflasi

Inflasi mengacu pada kenaikan umum dalam harga barang dan jasa dalam suatu perekonomian dalam jangka waktu tertentu. Tingkat inflasi yang tinggi dapat mengurangi daya saing barang domestik di pasar internasional karena harga yang lebih tinggi dibandingkan barang dari negara lain (Rosita dkk., 2023). Menurut Ahmad dkk. (2022), inflasi yang terkendali dapat menjaga stabilitas harga barang untuk ekspor, sementara inflasi yang tinggi cenderung meningkatkan biaya impor karena melemahnya nilai mata uang domestik.

5. Jumlah uang beredar

Jumlah uang beredar mencerminkan jumlah total uang dalam perekonomian, termasuk uang tunai, tabungan, dan deposito. Menurut teori kuantitas uang, peningkatan jumlah uang beredar dapat mendorong inflasi, yang pada akhirnya memengaruhi daya saing barang domestik di pasar global (Friedman, 2023). Studi penelitian Ifdaniyah & Syafri (2024), menunjukkan bahwa jumlah uang beredar memiliki pengaruh positif dan signifikan terhadap inflasi dalam jangka panjang. Inflasi yang tinggi dapat memengaruhi daya saing produk domestik di pasar internasional, yang pada gilirannya berdampak pada volume ekspor dan impor.

Kurs Rupiah, suku bunga, inflasi, dan jumlah uang beredar memiliki hubungan sebab-akibat yang kompleks terhadap ekspor dan impor. Kurs Rupiah secara langsung memengaruhi harga barang di pasar internasional, sedangkan suku bunga dan inflasi menentukan tingkat daya beli serta daya saing ekonomi domestik. Jumlah uang beredar, yang berkaitan erat dengan inflasi, memengaruhi stabilitas ekonomi secara keseluruhan, yang pada akhirnya memengaruhi kinerja ekspor dan impor (Kementerian Keuangan RI, 2023). Dengan memahami interaksi variabel-variabel ini, model ekonomi dapat dirancang untuk memprediksi tren perdagangan internasional dengan lebih akurat.

2.3 Deret Waktu

Menurut Box & Jenkins (1970), deret waktu adalah sekelompok nilai pengamatan yang didapatkan pada titik waktu berbeda dengan selang waktu yang sama dan diasumsikan saling berhubungan satu sama lain. Hal tersebut menunjukkan bahwa data deret waktu adalah rangkaian nilai pengamatan yang memiliki ketergantungan antara kejadian masa kini terhadap masa lalu atau lebih dikenal dengan autokorelasi antara Z_t dan Z_{t-k} yang diukur selama kurun waktu tertentu, berdasarkan waktu dengan interval sama.

2.3.1 Analisis Deret Waktu

Analisis deret waktu adalah proses mengidentifikasi, memodelkan, dan menginterpretasi pola dalam data yang direkam secara kronologis pada interval waktu tetap. Tujuannya adalah untuk memahami struktur data (seperti horizontal, tren, musiman, atau siklis) dan membangun model matematis yang merepresentasikan hubungan antarobservasi (Box & Jenkins, 1970). Analisis ini menjadi dasar untuk peramalan (*forecasting*), yang memproyeksikan nilai masa depan berdasarkan pola historis (Hyndman & Athanasopoulos, 2018).

Langkah penting dalam memilih suatu metode deret waktu adalah dengan mempertimbangkan pola kecenderungan data, sehingga dapat memilih metode yang tepat dengan pola tersebut. Pola data dibedakan menjadi empat yaitu (Makridakis et al., 1999):

1. Pola Horizontal

Pola ini terjadi ketika data berfluktuasi di sekitar rata-rata. Hal ini berarti data

sudah stasioner terhadap rata-rata.

2. Pola *Trend*

Pola ini terjadi ketika ada peningkatan atau penurunan jangka panjang dalam data deret waktu untuk suatu periode tertentu.


3. Pola Musiman

Pola ini terjadi ketika suatu deret dipengaruhi faktor musiman (misal kuartal tahun tertentu, bulanan atau hari-hari pada minggu tertentu).

4. Pola Siklis

Pola ini terjadi ketika data menunjukkan peningkatan dan penurunan yang tidak memiliki periode waktu yang tetap.

Bentuk pola kecondongan data disajikan dalam Gambar 1 berikut:



Gambar 1. Pola Data Deret Waktu (Sumber: Softscients, 2020)

2.3.2 Peramalan

Peramalan merupakan suatu ilmu yang melibatkan data historis yang kemudian diproyeksikan ke masa yang akan datang dengan menggunakan suatu bentuk model matematika. Ada beberapa pendapat mengenai definisi dari peramalan (*forecasting*) menurut para ahli, antara lain:

1. Menurut Buffa (1996), definisi peramalan adalah penggunaan teknik-teknik statistik dalam bentuk gambaran masa depan berdasarkan pengolahan angka-angka

historis.

2. Menurut Biegel (1999), definisi peramalan adalah kegiatan memperkirakan tingkat permintaan produk yang diharapkan untuk suatu produk atau beberapa produk dalam periode waktu tertentu di masa yang akan datang.
3. Menurut Makridakis et al. (1999), peramalan adalah dasar berdasarkan segala jenis perencanaan dimana hal ini sangat diperlukan buat lingkungan yang nir stabil yaitu menjembatani antara sistem dengan lingkungan.

Dari definisi peramalan di atas, maka dapat disimpulkan peramalan adalah suatu kegiatan yang bertujuan untuk memperkirakan atau memprediksi masa yang akan datang berdasarkan data historis, untuk estimasi atau proyeksi mengenai berbagai hal dalam menjembatani antara sistem dengan lingkungan.

Menurut Makridakis et al. (1999), metode peramalan secara umum terbagi menjadi dua kategori, yakni peramalan kuantitatif dan peramalan kualitatif :

1. Peramalan Kuantitatif, merupakan peramalan yang menggunakan data-data kuantitatif masa lalu yang diperoleh dari pengamatan nilai-nilai sebelumnya. Metode yang digunakan sangat mempengaruhi hasil dari pengamatan, sehingga setiap metode memiliki hasil peramalan yang berbeda pula.
2. Peramalan Kualitatif, merupakan metode yang pengambilan datanya didasarkan pada kualitatif yang diambil pada masa lalu, seperti intuisi pengambilan keputusan, emosi, pengalaman pribadi, dan sistem nilai. Hasil dari peramalan kualitatif didasarkan pada pengamatan kejadian-kejadian di masa lalu yang digabung dengan pemikiran dari penyusunnya.

Berdasarkan horizon waktu, Putra dkk. (2020) menyatakan bahwa peramalan atau *forecasting* dapat dibagi menjadi tiga jenis, yaitu:

1. Peramalan jangka panjang, yaitu yang mencakup waktu lebih besar dari 18 bulan.
2. Peramalan jangka menengah, yaitu mencakup waktu antara 3 sampai 18 bulan.
3. Peramalan jangka pendek, yaitu mencakup jangka waktu kurang dari 3 bulan.

2.4 Model Deret Waktu Multivariat

Peramalan deret waktu multivariat merupakan pendekatan yang menganalisis beberapa variabel yang berubah secara dinamis seiring waktu (Zahara & Sugianto, 2021). Dibandingkan dengan model univariat yang hanya menggunakan satu variabel, metode ini memungkinkan peneliti untuk mempertimbangkan lebih banyak faktor, sehingga meningkatkan akurasi prediksi melalui integrasi informasi yang komprehensif (Sarfo et al., 2015). Keunggulan utamanya terletak pada kemampuannya mengungkap hubungan kompleks antarvariabel seperti interdependensi atau pengaruh kausal yang sering kali tidak terdeteksi dalam analisis univariat. Hal ini tidak hanya memperkaya pemahaman terhadap faktor-faktor pendorong perubahan data, tetapi juga menghasilkan prediksi yang lebih stabil dan kontekstual.

Pada praktiknya, penggunaan model multivariat sering kali menjadi pilihan yang bijak dalam situasi di mana peramalan dengan tingkat akurasi yang tinggi sangat diharapkan. Sehingga dengan menggabungkan data dari berbagai variabel yang relevan, peramalan berbasis deret waktu multivariat memungkinkan pengambilan keputusan yang lebih terinformasi dan memperkuat analisis peramalan di berbagai bidang, termasuk keuangan, ekonomi, ilmu sosial, dan lain-lain. Selanjutnya, untuk memahami kerangka metodologisnya, akan dibahas beberapa model kunci dalam analisis multivariat.

2.4.1 *Vector Autoregressive (VAR)*

Model VAR merupakan bentuk multivariat model *autoregressive* (AR). Pada model VAR semua variabel dianggap sebagai variabel endogen dan saling berhubungan. Setiap variabel endogen dalam model ini dijelaskan oleh nilai-nilai masa lalu (*lagged*) serta nilai-nilai *lagged* dari semua variabel endogen lain dalam model tersebut. Menurut Wei (2006), persamaan model VAR dengan orde p ditunjukkan pada Persamaan (1) berikut:

$$\mathbf{Y}_t = \phi_0 + \sum_{i=1}^p \phi_i \mathbf{Z}_{t-i} + \mathbf{a}_t \quad (1)$$

dengan:

- $\mathbf{Y}_t$ = vektor variabel periode ke- t berukuran $n \times 1$.
- ϕ_0 = vektor *intersep* berukuran $n \times 1$.
- ϕ_p = matriks koefisien variabel berukuran $n \times n$.
- $\mathbf{Z}_{t-1}$ = vektor variabel pada *time lag* ke- $(t - i)$ berukuran $n \times 1$.
- $\mathbf{a}_t$ = vektor sisaan.
- p = panjang *lag*.
- n = banyak variabel.

2.4.2 Vector Moving Average (VMA)

Menurut Wei (2006), VMA adalah perluasan dari Metode MA. Model VMA beroperasi sebagai suatu sistem persamaan dinamis, di mana perkiraan pada suatu periode waktu diubah berdasarkan kesalahan variabel dan kesalahan variabel lain yang terlibat dalam sistem pada periode sebelumnya. Setiap variabel endogen dalam model ini dijelaskan oleh nilai-nilai masa lalu (*lagged*) serta nilai-nilai *lagged* dari semua variabel endogen lain dalam model tersebut. Persamaan Model VMA dengan order q ditunjukkan pada Persamaan (2) berikut:

$$\mathbf{Y}_t = \mathbf{a}_t - \sum_{q=1}^q \theta_q \mathbf{a}_{t-q} \quad (2)$$

dengan:

- $\mathbf{Y}_t$ = vektor variabel periode ke- t berukuran $n \times 1$.
- θ_q = matriks koefisien berukuran $n \times n$ dengan $\theta_q \neq 0$.
- $\mathbf{a}_t$ = vektor sisaan yang bersifat *white noise*.

2.4.3 Vector Autoregressive Moving Average (VARMA)

Model VARMA merupakan suatu metode analisis deret waktu multivariat yang berbentuk simultan, di mana variabel yang digunakan berjumlah lebih dari satu dan antar variabel memiliki hubungan dua arah. Menurut Lütkepohl (2021), model VARMA merupakan kombinasi dari model Vector Autoregressive (VAR) dengan orde p dan model Vector Moving Average (VMA) dengan orde q , sehingga

membentuk model VARMA (p, q) yang mampu menangkap hubungan dinamis antar variabel dalam analisis deret waktu multivariat. Persamaan model VARMA dengan orde p dan q dapat ditunjukkan pada Persamaan (3) berikut (Wei, 2006):

$$\mathbf{Y}_t = \phi_0 + \sum_{i=1}^p \phi_i Z_{t-i} + \mathbf{a}_t - \sum_{q=1}^q \theta_q a_{t-q} \quad (3)$$

dengan:

$\mathbf{Y}_t$ = vektor variabel periode ke- t berukuran $n \times 1$.

ϕ_0 = vektor *intersep* berukuran $n \times 1$.

ϕ_p = matriks koefisien variabel berukuran $n \times n$.

θ_q = matriks koefisien berukuran $n \times n$ dengan $\theta_q \neq 0$.

$\mathbf{a}_t$ = vektor sisaan berukuran $n \times 1$.

2.4.4 Vector Autoregressive Moving Average with Exogenous Variable (VARMAX)

Model VARMAX merupakan kasus khusus dari model VARMA dengan penambahan variabel eksogen ke dalam model VARMAX yang memuat variabel endogen. Model VARMAX diasumsikan bersifat asumsi stasioner dan beresidual *white noise*, rumus umum menurut Spliid (1983) model VARMAX (p, q, r) dituliskan pada Persamaan (4) berikut:

$$\Phi(B)\mathbf{y}_t = \beta(B)x_t + \theta(B)a_t \quad (4)$$

dengan:

$\Phi(B)$ = $I - \Phi_1 B - \dots - \Phi_p B^p$, polinomial autoregressive (AR) orde- p

$\theta(B)$ = $I + \theta_1 B + \dots + \theta_q B^q$, polinomial moving average (MA) orde- q

$\beta(B)$ = $\beta_0 + \beta_1 B + \dots + \beta_{r-1} B^{r-1}$, polinomial dengan matriks ukuran $k \times m$

θ_q = matriks nonsingular ukuran $k \times k$

$\mathbf{y}_t$ = vektor runtun waktu multivariat yang telah dikoreksi rata-ratanya

x_t = variabel eksogen

a_t = *white noise* dengan kovarians Σ yang definit positif

2.5 Kestasioneran Data

Analisis deret waktu memiliki syarat yakni datanya harus stasioner dalam *mean* dan stasioner dalam *varians*. Stasioneritas adalah suatu keadaan pada data deret waktu di mana data berfluktuasi dengan ragam konstan dan di sekitar rata-rata yang konstan (Makridakis et al., 1999). Dalam deret waktu ada kemungkinan data tersebut tidak stasioner baik dalam mean maupun varians. Hal ini dikarenakan mean tidak konstan atau variansnya tidak konstan sehingga untuk menghilangkan ketidakstasioneran terhadap mean, maka menggunakan metode perbedaan atau *differencing*. *Differencing* didefinisikan sebagai proses menghitung perubahan atau selisih nilai observasi. Proses *differencing* dituliskan pada Persamaan (5), (6), dan (7) sebagai berikut:

1. *Differencing* orde pertama

$$\Delta Z_t = Z_t - Z_{t-1} \quad (5)$$

2. *Differencing* orde kedua

$$\Delta^2 Z_t = (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) = Z_t - 2Z_{t-1} + Z_{t-2} \quad (6)$$

3. Dengan demikian bentuk umum *differencing*

$$W_t = (1 - B)^d Z_t = \Delta^d Z_t, \quad \text{dengan} \quad \Delta^d Z_t = Z_{t-d} \quad (7)$$

dengan:

Z_t = Nilai deret waktu pada waktu ke- t .

Z_{t-1} = Nilai deret waktu satu periode sebelumnya (waktu ke- $t - 1$).

d = orde *differencing* (1, 2, ...).

B = *backshift* operator yang didefinisikan sebagai $B^d Z_t = Z_{t-d}$.

Sedangkan untuk mengatasi ketidakstasioneran dalam varians, dapat dilakukan transformasi data. Transformasi yang umum digunakan adalah transformasi *Box-cox*. Tabel 2 menunjukkan rumus transformasi *Box-Cox* berdasarkan nilai transformasi *rounded value* (λ) yang didapatkan sebagai berikut:

Tabel 2. Transformasi *Box-Cox*

Nilai λ	Transformasi
-1.0	$\frac{1}{Z_t}$
-0.5	$\frac{1}{\sqrt{Z_t}}$
0.0	$\ln(Z_t)$
0.5	$\sqrt{Z_t}$
1.0	Z_t

Adapun beberapa ketentuan dalam menstabilkan *varians*:

1. Transformasi bisa dilakukan hanya untuk deret Z_t positif.
2. Nilai λ dipilih berdasarkan *Sum of Square Error* (SSE) dari deret hasil transformasi. Nilai SSE terkecil memberikan hasil *varians* paling konstan, $SSE(\lambda) = \sum_{t=1}^n (Z_t^{(\lambda)} - \mu)^2$.
3. Transformasi tidak hanya menstabilkan *varians*, tetapi juga dapat menormalkan distribusi.

2.6 Kausalitas Granger

Pada analisis ekonomi dan bidang lainnya, hubungan timbal balik antar variabel sering kali terjadi, yang dikenal sebagai hubungan kausalitas. Salah satu metode yang dapat digunakan untuk mengidentifikasi hubungan sebab-akibat tersebut adalah uji kausalitas Granger (Juanda & Junaidi, 2012). Uji ini menggunakan pendekatan pengujian *F*-statistik untuk mengevaluasi apakah perubahan pada suatu variabel dapat dijelaskan oleh perubahan variabel lain. Secara konseptual, suatu variabel X dikatakan memiliki kausalitas Granger terhadap variabel Y apabila nilai historis dari X mampu memberikan informasi yang signifikan dalam memprediksi nilai Y pada periode waktu tertentu. Untuk menerapkan uji ini, terdapat beberapa tahapan prosedural yang perlu diikuti secara sistematis sebagai berikut:

1. Hipotesis

H_0 : Variabel X tidak memiliki pengaruh kausalitas Granger ke variabel Y.

H_1 : Variabel X memiliki pengaruh Granger ke variabel Y.

2. Statistik uji dituliskan pada Persamaan (8):

$$F = \left(\frac{n - k}{q} \right) \left(\frac{SSE_{\text{terbatas}} - SSE_{\text{penuh}}}{SSE_{\text{penuh}}} \right) \quad (8)$$

dimana SSE_{terbatas} adalah *Sum of Square* dipenuhi dari regresi yang dilakukan terhadap Y tanpa melibatkan *lag* variabel X seperti Persamaan (9) berikut:

$$Y_t = \sum \alpha_t Y_{t-i} + \varepsilon_t \quad (9)$$

SSE_{penuh} adalah *Sum of Square* dipenuhi dari regresi yang dilakukan terhadap Y dengan melibatkan *lag* variabel X seperti Persamaan (10) berikut:

$$Y_t = \sum \alpha_t Y_{t-i} + \sum \beta_t X_{t-i} + \varepsilon_t \quad (10)$$

dengan:

n = banyaknya data pengamatan.

k = banyaknya parameter model penuh.

q = banyaknya parameter model terbatas.

3. Kriteria Pengujian

$F\text{-hitung} > F\text{-tabel} (\alpha)$, tolak H_0 berarti terdapat pengaruh yang signifikan secara statistik.

2.7 Uji Asumsi Residual

Uji asumsi residual adalah proses penting dalam statistika, khususnya dalam analisis deret waktu yang bertujuan untuk menilai kelayakan pada model. Asumsi residual mencakup dua aspek utama, yaitu nilai residual (kesalahan) yang dihasilkan oleh model statistik harus memiliki karakteristik *white noise*, dan distribusi residual tersebut harus sesuai dengan distribusi normal multivariat.

1. Uji Asumsi Residual *White Noise*

Residual dikatakan memenuhi asumsi *white noise* jika residual bersifat acak, tidak memiliki pola tertentu, dan variansnya konstan. Hal ini penting dalam

model deret waktu untuk memastikan bahwa semua informasi dalam data telah diakomodasi oleh model (Ljung & Box, 1978). Adapun ciri-ciri Residual *White Noise* sebagai berikut:

- a) Nilai ekspektasi residual adalah nol: $E(e_t) = 0$;
- b) Varians residual konstan: $Var(e_t) = \sigma^2$;
- c) Tidak ada autokorelasi pada residual: $Cov(e_t, e_{t-k}) = 0$, untuk $k \neq 0$.

Menurut Wei (2006), pengujian asumsi residual *white noise* dapat dilakukan menggunakan metode *Ljung-Box*, metode ini menguji apakah residual memiliki autokorelasi signifikan pada *lag* tertentu. Residual memenuhi *white noise* jika nilai $p - value > 0.05$, dengan prosedur analisis statistika sebagai berikut:

- a) Hipotesis
 - H_0 : residual memenuhi syarat *white noise*
 - H_1 : residual tidak memenuhi syarat *white noise*
- b) Taraf Signifikasi
 - $\alpha = 0.05$
- c) Daerah Kritis
 - Jika $p - value < \alpha$, maka tolak H_0
 - Jika $p - value > \alpha$, maka terima H_0
- d) Statistik uji dituliskan pada Persamaan (11) berikut:

$$Q = n(n+2) \sum_{k=1}^h \frac{\rho_k^2}{n-k} \quad (11)$$

dengan:

n = banyaknya data pengamatan.

ρ_k = autokorelasi *lag* ke- k .

h = jumlah *lag*.

- e) Keputusan

Keputusan diambil berdasarkan perbandingan nilai $p - value$ dengan taraf signifikansi $\alpha = 0.05$:

- Jika $p - value < \alpha$, maka tolak H_0 (residual bukan *white noise*).
- Jika $p - value > \alpha$, maka terima H_0 (residual *white noise*).

f) Kesimpulan

Berdasarkan hasil pengujian, jika residual memenuhi asumsi *white noise*, maka dapat disimpulkan bahwa model yang digunakan tidak memiliki autokorelasi, sehingga residual acak dan model layak digunakan untuk peramalan.

2. Uji Asumsi Residual Distribusi Normal Multivariat

Dalam model multivariat, residual dianggap memenuhi asumsi distribusi normal multivariat jika vektor residual berdistribusi normal secara bersama-sama. Hal ini penting karena banyak metode statistik bergantung pada asumsi normalitas multivariat untuk validitas hasilnya (Mardia, 1970). Pengujian residual distribusi normal multivariat dapat dilakukan menggunakan metode *Jarque-Bera Test of Normality*. Residual memenuhi uji asumsi residual distribusi normal multivariat jika nilai $JB_{hitung} < X^2_{kritis}$ atau $p - value > 0.05$, dengan prosedur analisis statistika sebagai berikut:

a) Hipotesis

H_0 : residual berdistribusi normal multivariat

H_1 : residual tidak berdistribusi normal multivariat

b) Taraf Signifikasi

$\alpha = 0.05$

c) Daerah Kritis

Jika $JB_{hitung} > X^2_{kritis}$ atau $p - value < 0.05$, maka tolak H_0

Jika $JB_{hitung} < X^2_{kritis}$ atau $p - value > 0.05$, maka terima H_0

d) Statistik uji dituliskan pada Persamaan (12):

$$JB_{hitung} = \left[\frac{N}{6} b_1^2 + \frac{N}{24} (b_2 - 3)^2 \right] \quad (12)$$

dengan:

JB_{hitung} = statistik *Jarque-Bera* untuk normalitas multivariat.

N = banyaknya data pengamatan.

b_1 = *skewness* multivariat (mengukur derajat asimetri data).

b_2 = *kurtosis* multivariat.

e) Keputusan

Keputusan diambil berdasarkan nilai statistik uji JB_{Baring} atau $p - value$ sebagai berikut:

- Jika $JB_{\text{Baring}} > \chi^2_{\text{tabel}}$ atau $p\text{-value} < 0,05$, maka tolak H_0 (residual tidak berdistribusi normal multivariat).
- Jika $JB_{\text{Baring}} < \chi^2_{\text{tabel}}$ atau $p\text{-value} > 0,05$, maka terima H_0 (residual berdistribusi normal multivariat).

f) Kesimpulan

Jika residual model berdistribusi normal multivariat, maka model memenuhi salah satu asumsi penting dalam analisis multivariat. Sebaliknya, jika tidak normal, maka perlu dilakukan transformasi data atau pendekatan alternatif yang tidak mensyaratkan normalitas.

2.8 Machine learning

Machine Learning merupakan cabang dari kecerdasan buatan (*Artificial Intelligence*) yang fokus pada bagaimana komputer dapat mempelajari pola dari data untuk meningkatkan kinerjanya secara otomatis. Teknologi ini dirancang agar komputer mampu belajar sendiri tanpa arahan eksplisit dari penggunaannya. Ciri khas dari *machine learning* adalah adanya proses pembelajaran atau *training*, di mana model dilatih menggunakan *training data*. Kualitas *training data* sangat penting, karena data yang tidak mewakili populasi secara akurat dapat menghasilkan model dengan kinerja buruk (Mitchell, 1997).

Tujuan utama *machine learning* adalah mengembangkan metode yang dapat secara otomatis mendeteksi pola tersembunyi dalam data dan menggunakan pola tersebut untuk membuat prediksi atau mendapatkan wawasan baru. Ada tiga pendekatan utama dalam *machine learning* berdasarkan jenis data yang digunakan, yaitu *supervised learning*, *semi-supervised learning*, dan *unsupervised learning* (Goodfellow et al., 2016):

1. Supervised Learning

Dalam *supervised learning*, algoritma dilatih menggunakan data yang telah diberi label, di mana pasangan *input* dan *output* diketahui. Tujuannya adalah memprediksi *output* dengan akurasi tinggi untuk data baru yang belum pernah dilihat sebelumnya. Contoh algoritma yang sering digunakan adalah regresi linier, pohon keputusan (*decision tree*), dan jaringan saraf tiruan (*neural networks*).

2. Semi-Supervised Learning

Semi-supervised learning menggunakan kombinasi data berlabel dan tidak

berlabel. Pendekatan ini biasanya diterapkan ketika jumlah data berlabel jauh lebih sedikit dibandingkan data yang tidak berlabel. Algoritma seperti metode *Expectation-Maximization* (EM) dan *Co-Training* sering digunakan dalam pendekatan ini.

3. *Unsupervised Learning*

Unsupervised learning bekerja dengan data tanpa label, bertujuan untuk menemukan pola, struktur, atau kategori tersembunyi dalam data. Contoh algoritma dalam pendekatan ini meliputi *K-means clustering*, *hierarchical clustering*, dan *Principal Component Analysis* (PCA).

machine learning terus berkembang dengan diterapkannya berbagai algoritma dan teknik canggih, terutama dalam pengolahan data besar (*big data*) dan permasalahan dunia nyata, seperti pengenalan wajah, pengolahan bahasa alami, dan peramalan deret waktu.

2.9 *Scaling Data*

Menurut Ambarwari et al. (2020), *scaling data* merupakan teknik mengubah nilai numerik dalam kumpulan data ke skala umum, tanpa mendistorsi perbedaan dalam rentang nilai. Tujuan utama dari teknik ini adalah untuk mengurangi kesalahan atau ketidakcocokan data. *Scaling data* juga bermanfaat dalam mengurangi proporsi ukuran dataset tanpa mempengaruhi nilai aktualnya dan membantu dalam mempercepat proses pembelajaran pada *machine learning*. Teknik yang dapat digunakan pada *scaling data* sebagai berikut:

1. *Min-Max Scaler*

Min-Max scaler adalah metode normalisasi yang melakukan transformasi linier terhadap data dengan menskalakan nilai ke dalam rentang tertentu, teknik ini memastikan bahwa distribusi data tetap terjaga tanpa mengubah pola hubungan antar variabel (Patel et al., 2023). Metode ini mengubah nilai-nilai asli pada *dataset* menjadi rentang dalam interval $[0, 1]$. Persamaan *Min-Max Scaler* dapat ditulis dengan Persamaan (13) sebagai berikut:

$$X' = \frac{(x - \min_x)}{(\max_x - \min_x)} \quad (13)$$

dengan:

X' = data hasil normalisasi.

X = data asli.

min_x = nilai minimum dari data x .

max_x = nilai maximum dari data x .

2. *Standardscaler*

Standardscaler ini didasarkan pada *mean* dan standar deviasi. Standarisasi suatu kumpulan data melibatkan pengubahan skala distribusi nilai, sehingga nilai rata-rata yang diamati adalah 0 dan standar deviasi adalah 1 (Ambarwari et al., 2020). Pendekatan ini ideal digunakan saat ada asumsi bahwa data mengikuti distribusi normal. Persamaan *standardscaler* dapat ditulis dengan Persamaan (14) sebagai berikut:

$$x' = \frac{(x - X_{mean})}{(x_{std})} \quad (14)$$

dengan:

X' = data hasil normalisasi.

x = data asli.

min_x = nilai minimum dari data x .

max_x = nilai maximum dari data x .

2.10 Normalisasi dan Denormalisasi Data

Tahapan normalisasi data dalam penelitian ini adalah proses mentransformasi data asli ke dalam rentang tertentu (misalnya, antara 0 hingga 1) agar sesuai dengan kebutuhan model prediksi. Normalisasi bertujuan untuk meningkatkan kinerja model dengan membuat nilai *input* memiliki skala yang seragam, sehingga dapat membantu mencegah masalah seperti *vanishing gradient* atau *exploding gradient* pada jaringan saraf tiruan (*neural network*). Sedangkan denormalisasi data, adalah tahap pengembalian data yang telah dinormalisasi ke skala aslinya, sehingga hasil prediksi dapat dimaknai dalam konteks nilai nyata.

Tahapan awal dalam pemrosesan data adalah normalisasi, di mana data asli ditransformasikan ke dalam skala tertentu agar meningkatkan stabilitas dan kinerja

model selama proses pelatihan, terutama dalam jaringan saraf tiruan (Zhang et al., 2022). Metode *min-max scaling* merupakan salah satu teknik normalisasi yang digunakan untuk mengonversi data ke dalam rentang tertentu, biasanya $[0,1]$ atau $[-1,1]$. Teknik ini membantu dalam mengurangi skala yang berlebihan dalam *dataset* sehingga model *machine learning* dapat beroperasi dengan lebih stabil dan konvergen lebih cepat selama proses pelatihan (Han et al., 2022). Proses normalisasi menggunakan Persamaan (15) berikut:

$$x' = \frac{(x - x_{min})}{x_{max} - x_{min}} \quad (15)$$

dengan:

x' = Nilai baru hasil normalisasi.

x = Nilai pada variabel x yang akan dinormalisasi.

x_{max} = Nilai maksimal variabel x .

x_{min} = Nilai minimal variabel x .

Dalam proses normalisasi, nilai data diubah ke dalam skala yang lebih seragam untuk meningkatkan stabilitas pelatihan model. Salah satu pendekatan yang digunakan adalah transformasi skala, di mana data dinormalisasi dalam rentang tertentu agar lebih tahan terhadap masalah *vanishing gradient* dan *exploding gradient* selama proses pembelajaran model (Goodfellow et al., 2016). Setelah proses prediksi dilakukan, langkah selanjutnya adalah mengonversi kembali nilai hasil prediksi yang telah dinormalisasi ke dalam skala aslinya melalui proses denormalisasi. Proses ini bertujuan agar hasil prediksi dapat diinterpretasikan secara akurat dalam konteks data awal yang digunakan (Wijaya dkk., 2022). Denormalisasi dilakukan dengan menggunakan Persamaan (16) berikut:

$$x = x_{min} + (x'(x_{max} - x_{min})) \quad (16)$$

dengan:

x' = Nilai baru hasil normalisasi.

x = Nilai pada variabel x yang akan dinormalisasi.

x_{max} = Nilai maksimal variabel x .

x_{min} = Nilai minimal variabel x .

Dalam rumus ini, nilai x' merupakan hasil prediksi yang telah dinormalisasi,

sedangkan x_{min} dan x_{max} adalah nilai minimum dan maksimum asli dari *dataset*. Proses denormalisasi memastikan bahwa hasil prediksi dapat dievaluasi dan dibandingkan dengan data aktual.

Normalisasi bertujuan untuk menyesuaikan skala data sebelum pelatihan model, sedangkan denormalisasi digunakan untuk mengembalikan hasil prediksi ke skala aslinya agar lebih mudah diinterpretasikan. Pendekatan ini penting dalam model prediktif untuk menjaga stabilitas dan meningkatkan akurasi, terutama dalam analisis data deret waktu (Putra dkk., 2024).

2.11 Fungsi Aktivasi

Fungsi aktivasi merupakan elemen penting dalam jaringan saraf tiruan yang berfungsi untuk menentukan apakah sebuah neuron akan diaktifkan atau tidak. Peran utama fungsi ini adalah membantu jaringan saraf tiruan dalam menangani data non-linear, karena data yang diolah oleh jaringan saraf tiruan umumnya jarang bersifat linear. Cara kerja fungsi aktivasi adalah mengubah data non-linear menjadi *output* yang linear dalam rentang tertentu sehingga mempermudah proses pembelajaran model. Karakteristik jaringan saraf tiruan dipengaruhi oleh kombinasi bobot, *input*, dan *output* dari fungsi aktivasi yang digunakan. Beberapa fungsi aktivasi yang sering digunakan dijelaskan sebagai berikut (Pasaribu et al., 2020):

1. Fungsi Sigmoid

Fungsi *sigmoid* merupakan fungsi aktivasi yang menghasilkan output dalam rentang 0 hingga 1, dengan input berupa bilangan real. Persamaan fungsi *sigmoid* dituliskan pada Persamaan (17) berikut:


$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (17)$$

dengan:

x = data *input*.

e = bilangan Euler.

Gambar fungsi *sigmoid* direpresentasikan pada Gambar 2:



Gambar 2. Fungsi Aktivasi *Sigmoid*

Output dari fungsi *sigmoid* akan membentuk grafik *sigmoid*, di mana nilai *output* mendekati nol saat nilai *input* sangat kecil, dan mendekati satu saat nilai *input* sangat besar. *Sigmoid* memiliki rentang, $0 < \sigma(x) \leq 0.5$ untuk nilai mendekati nol, dan $0.5 < \sigma(x) \leq 1$ untuk nilai mendekati satu (Siegel, 2016). Fungsi *sigmoid* sering digunakan dalam jaringan saraf tiruan untuk masalah klasifikasi biner, namun memiliki kelemahan berupa gradien yang melemah (*vanishing gradient*) saat nilai *input* berada di ujung rentang.

2. Fungsi Tangen Hiperbolik (*tanh*)

Fungsi *tangen hiperbolik* (*tanh*) merupakan fungsi aktivasi non-linear yang memiliki rentang *output* lebih luas dibandingkan *sigmoid*, yaitu dari -1 hingga 1. Fungsi ini lebih efektif untuk pemodelan data non-linear yang kompleks karena sifatnya yang menghasilkan perubahan *output* yang lebih halus terhadap perubahan *input*. Persamaan fungsi *tanh* dapat dituliskan dalam Persamaan (18) dan (19) berikut:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (18)$$

atau

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} \quad (19)$$

dengan:


x = data *input*.

e = bilangan Euler.

$\sinh(x)$ = fungsi *sinus hiperbolik*

$\cosh(x)$ = fungsi *cosinus hiperbolik*

Grafik fungsi *tanh* direpresentasikan pada Gambar 3:



Gambar 3. Fungsi Aktivasi *Tangen Hiperbolik*

Fungsi *tanh* memiliki derivatif yang lebih konsisten dibandingkan *sigmoid*, sehingga dapat mencegah gradien yang terlalu kecil selama proses pelatihan (Nwankpa et al., 2018). Grafik fungsi *tanh* menunjukkan *output* yang simetris terhadap nol, menjadikannya pilihan ideal untuk data yang memiliki nilai positif dan negatif.

2.12 Hyperparameter dan Parameter Training

Hyperparameter adalah parameter yang digunakan untuk mengonfigurasi model *machine learning* dan tidak dipelajari langsung dari data pelatihan. Nilai-nilai *hyperparameter* ditentukan sebelum pelatihan dimulai dan secara signifikan memengaruhi proses pelatihan serta kinerja model dalam menghasilkan prediksi yang optimal (Yang & Shami, 2020). *Hyperparameter* juga dikenal sebagai variabel konfigurasi di luar model, yang nilainya sulit diperkirakan hanya berdasarkan kumpulan data. Oleh karena itu, diperlukan penentuan nilai *hyperparameter*

sebelum proses pelatihan dimulai, sehingga model dapat menghasilkan nilai prediksi terbaik (Hikmaturokhman et al., 2022).

Proses eksplorasi terhadap berbagai kombinasi *hyperparameter* untuk menciptakan model *machine learning* yang optimal disebut *hyperparameter tuning*. Tahap ini merupakan elemen penting dalam membangun model yang efektif, terutama pada model berbasis *deep learning*, di mana banyak *hyperparameter* perlu dipertimbangkan untuk meningkatkan kinerja model dan akurasi. Menurut Hikmaturokhman et al. (2022), beberapa *hyperparameter* yang penting dalam *deep learning* meliputi jumlah lapisan tersembunyi, jumlah neuron pada setiap lapisan tersembunyi, ukuran *batch*, jumlah *epoch*, tingkat pembelajaran, dan parameter regulasi. Selain itu, beberapa komponen konfigurasi model pelatihan, seperti fungsi aktivasi, fungsi *loss*, dan *optimizer*, juga memiliki peran yang krusial:

1. Fungsi aktivasi bertugas untuk mengaktifkan atau menonaktifkan neuron dalam jaringan saraf.
2. Fungsi *loss* menghitung kesalahan model selama proses optimasi.
3. *Optimizer* digunakan untuk memperbarui bobot jaringan berdasarkan data pelatihan agar model dapat meminimalkan kesalahan.

Eksplorasi *hyperparameter* dianggap sebagai salah satu langkah terpenting dalam membangun model *machine learning*, khususnya *deep learning*, karena *hyperparameter* dapat memengaruhi kinerja dan keakuratan model (Hikmaturokhman et al., 2022). Proses ini sering kali dilakukan dengan metode manual atau menggunakan algoritma optimasi seperti *grid search*, *random search*, dan pendekatan yang lebih canggih seperti *Bayesian optimization*. *Grid search*, misalnya, mengevaluasi kombinasi *hyperparameter* dalam ruang parameter yang telah ditentukan, tetapi metode ini menjadi tidak efisien untuk ruang parameter yang berdimensi tinggi (Yang & Shami, 2020).

Hutter et al. (2019) menekankan bahwa ada beberapa alasan penting untuk melakukan optimasi *hyperparameter*:

1. Mengurangi upaya manual, mengurangi waktu yang dihabiskan oleh pengembang untuk menyesuaikan konfigurasi *hyperparameter*, terutama dalam kasus model dengan banyak parameter dan data yang besar.

2. Meningkatkan kinerja model, memastikan model dapat mencapai kinerja terbaik pada masalah tertentu dengan konfigurasi optimal.
3. Memastikan replikasi penelitian, dengan menerapkan proses optimasi yang seragam, berbagai algoritma *machine learning* dapat dibandingkan secara adil.

Dengan mempertimbangkan faktor-faktor ini, *hyperparameter tuning* menjadi komponen yang tak terpisahkan dalam desain model *machine learning*. Hal ini memastikan bahwa fungsi aktivasi, *loss*, dan *optimizer* yang dipilih dapat bekerja sinergis untuk menghasilkan model dengan evaluasi kesalahan yang kecil dan hasil prediksi yang mendekati target (Hikmaturokhman et al., 2022).

2.13 Deep Learning

Deep learning adalah subdisiplin dalam domain *machine learning* yang fokus pada jaringan saraf buatan dengan kemampuan untuk mempelajari pola-pola kompleks dari data (Minh et al., 2018). Pada dasarnya, *deep learning* terdiri dari jaringan saraf dengan minimal tiga lapisan, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*, yang bekerja menyerupai cara kerja otak manusia. Teknologi ini dirancang untuk belajar dan beradaptasi dengan data dalam jumlah besar, memungkinkan pengenalan hubungan nonlinier, mengekstraksi fitur-fitur signifikan dari data kompleks, serta menangani data yang bersifat *noisy* tanpa bergantung pada pengetahuan manusia atau asumsi tertentu.

Keunggulan *deep learning*, terletak pada kemampuannya dalam menciptakan representasi data yang hierarkis melalui berbagai lapisan pemrosesan. Representasi ini memungkinkan model untuk mempelajari pola tersembunyi yang sulit diidentifikasi oleh algoritma *machine learning* tradisional. Oleh karena itu, algoritma *deep learning* semakin banyak digunakan dalam berbagai aplikasi analisis data kompleks, termasuk prediksi data deret waktu, klasifikasi, dan pengenalan pola yang melibatkan hubungan antar periode yang signifikan.


Dalam konteks data yang memerlukan analisis lebih mendalam, seperti data deret waktu, jaringan saraf tiruan sederhana memiliki keterbatasan karena tidak dapat menyimpan atau menghubungkan informasi baru dengan informasi sebelumnya. Untuk mengatasi hal ini, algoritma seperti *Recurrent Neural Network* (RNN) dan *Long Short Term Memory* (LSTM) dikembangkan.

2.13.1 *Recurrent Neural Network (RNN)*

Recurrent Neural Network (RNN) adalah salah satu jenis jaringan saraf tiruan yang dirancang untuk menangani data sekuensial atau deret waktu. Karakteristik utama RNN terletak pada koneksi sikliknya, yang memungkinkan informasi dari langkah sebelumnya dipertahankan dan digunakan dalam memproses data pada langkah berikutnya. Fitur ini membuat RNN unggul dalam menganalisis data berurutan, seperti teks, sinyal, atau data deret waktu lainnya (Elman, 1990). Struktur dasar RNN melibatkan tiga komponen utama, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Lapisan tersembunyi memiliki peran penting sebagai memori internal yang merekam dan mengintegrasikan informasi dari masa lalu untuk digunakan pada langkah waktu berikutnya (Siami et al., 2018).

RNN memproses data berurutan melalui sel berulang yang menjalankan operasi matematis serupa untuk setiap elemen dalam urutan data. Sel-sel ini menggunakan fungsi aktivasi seperti *tanh* untuk mengolah data *input* sekaligus memperbarui keadaan jaringan. Namun, meskipun memiliki keunggulan dalam memproses data deret waktu, RNN sering menghadapi masalah *vanishing gradient* dan *exploding gradient* selama proses pelatihan. Masalah *vanishing gradient* terjadi ketika gradien yang dihitung selama *backpropagation* menjadi sangat kecil sehingga bobot tidak dapat diperbarui dengan efektif, sedangkan *exploding gradient* terjadi ketika gradien menjadi terlalu besar, menyebabkan pembaruan bobot tidak stabil (Salehinejad et al., 2018).

Untuk mengatasi keterbatasan ini, Hochreiter dan Schmidhuber (1997) mengembangkan varian RNN yang dikenal sebagai *Long Short-Term Memory (LSTM)*. LSTM dirancang dengan mekanisme khusus seperti *forget gates* dan *cell states*, yang memungkinkan jaringan untuk menyimpan informasi penting lebih lama dan meningkatkan kemampuan RNN dalam menangani data sekuensial yang kompleks. Dengan kemampuan ini, LSTM dapat mengatasi keterbatasan RNN tradisional, terutama dalam aplikasi yang melibatkan hubungan jangka panjang antar data (Hochreiter dan Schmidhuber, 1997). Adapun arsitektur dari RNN diilustrasikan pada Gambar 4 sebagai berikut:



Gambar 4. Arsitektur RNN (Sumber: Syahram dkk., 2020)

Berikut ini merupakan penjelasan untuk setiap gerbang dan komponen yang ada pada RNN:

1. *Input* (x_t)

Data masukan pada waktu ke- t . *Input* ini dapat berupa elemen dalam urutan, seperti kata dalam teks, harga dalam data deret waktu, atau langkah-langkah sinyal lainnya.

2. *Hidden State* (h_{t-1}) dan (h_t)

Hidden state adalah memori internal jaringan yang menyimpan informasi tentang langkah-langkah sebelumnya. Pada waktu t , *hidden state* h_t diperbarui menggunakan informasi dari *input* saat ini (x_t) dan *hidden state* sebelumnya (h_{t-1}). Proses ini diatur oleh fungsi aktivasi non-linear, seperti *tanh*. Rumus untuk menghitung *hidden state* disajikan pada Persamaan (20):

$$h_t = \tanh(W_h h_{t-1} + W_x x_t + b_h) \quad (20)$$

dengan:

W_h = bobot yang menghubungkan *hidden state* sebelumnya ke *hidden state* saat ini.

W_x = bobot yang menghubungkan *input* ke *hidden state*.

b_h = bias untuk *hidden state*.

3. *Output* (y_t)

Output dihasilkan berdasarkan *hidden state* h_t pada waktu t . Rumus untuk menghitung *output* disajikan pada Persamaan (21):

$$y_t = \text{softmax}(W_y h_t + b_y) \quad (21)$$

dengan:

W_h = bobot yang menghubungkan *hidden state* sebelumnya ke *hidden state* saat ini.

W_x = bobot yang menghubungkan *input* ke *hidden state*.

b_h = bias untuk *hidden state*.

Rumus $\tanh(z)$ diberikan pada Persamaan (22):

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (22)$$


4. Koneksi Berulang

Bagian penting dari RNN adalah koneksi berulang dari *hidden state* sebelumnya (h_{t-1}) ke *hidden state* saat ini (h_t), yang memungkinkan jaringan mempertimbangkan informasi sebelumnya untuk membuat keputusan.

2.13.2 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 sebagai pengembangan dari *Recurrent Neural Network* (RNN). LSTM dirancang untuk mengatasi kelemahan RNN yang tidak mampu menangani masalah *vanishing gradient*, sehingga sulit untuk memproses hubungan data jangka panjang (Tian et al., 2018). Kelemahan utama RNN adalah ketidakmampuannya dalam menghubungkan informasi baru dengan informasi lama karena memori lama yang tersimpan sering tertimpa oleh memori baru. Sebaliknya, LSTM mampu menangani kompleksitas data dengan mempertahankan memori jangka panjang melalui penggunaan *memory cell* dan *gate units* yang dirancang khusus untuk mengelola aliran informasi (Arfan & Lusiana, 2019).

Struktur LSTM berbeda dengan RNN pada lapisan tersembunyinya. Pada RNN, lapisan tersembunyi terdiri dari fungsi aktivasi *tanh* tunggal, sedangkan LSTM menggunakan dua fungsi aktivasi, yaitu *tanh* dan *sigmoid*, yang bekerja bersama untuk mengontrol dan melindungi memori pada setiap langkah waktu (Felix et al., 2000). LSTM memiliki tiga jenis gerbang utama: gerbang *forget*, gerbang *input*, dan gerbang *output*, yang masing-masing memiliki peran penting dalam mengontrol *cell state*, yaitu jalur horizontal yang menghubungkan semua lapisan *output* di dalam jaringan LSTM (Tian et al., 2018). Adapun arsitektur dari LSTM diilustrasikan pada Gambar 5 sebagai berikut:



Gambar 5. Arsitektur LSTM (Sumber: Syahram dkk., 2020)

Berikut ini merupakan penjelasan untuk setiap gerbang dan komponen yang ada pada RNN:

1. *Forget Gate*

Gerbang awal yang dikenal sebagai *forget gate* berfungsi untuk memutuskan informasi dari langkah sebelumnya yang perlu dihapus. Gerbang ini menggunakan fungsi aktivasi *sigmoid*, sehingga *output* dari operasi *forget gate*, yang dilambangkan dengan f_t , bernilai antara 0 hingga 1 (Le et al., 2019). Nilai tersebut menunjukkan sejauh mana informasi sebelumnya akan dihapus dari sel memori. Ketika nilainya 1, semua informasi akan dipertahankan, sedangkan jika nilainya 0, seluruh informasi akan dihapus. Persamaan untuk *forget gate* disajikan pada Persamaan (23) sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (23)$$

dengan:

f_t = *forget gate*.

σ = fungsi *sigmoid*.

W_f = nilai *weight* untuk *forget gate*.

h_{t-1} = nilai *output* sebelum orde ke-t.

x_t = nilai *input* pada orde ke-t.

b_f = nilai bias pada *forget gate hidden state*.

2. *Input Gate*

Input Gate (i_t) adalah gerbang yang berfungsi untuk memproses *input* menggunakan fungsi aktivasi (*sigmoid* dan *tanh*) guna memilih nilai-nilai *input* yang akan diperbarui. Pertama, lapisan *sigmoid* menentukan nilai *input* mana yang akan diperbarui, menghasilkan i_t . Selanjutnya, fungsi aktivasi *tanh* memberikan

bobot pada nilai-nilai yang lolos. Dengan cara ini, gerbang *input* memberikan bobot pada nilai-nilai *input* yang sesuai, sehingga dapat menentukan tingkat pentingnya sebuah informasi dalam memperbarui $\tilde{c}_t$, yang kemudian ditambahkan ke *cell state*.

Tujuan utama gerbang *input* adalah menentukan seberapa banyak bagian dari *input* saat ini (X_t) yang akan disimpan dalam *cell state* ($\tilde{c}_t$), sehingga dapat mencegah informasi yang tidak sesuai masuk ke dalam *memory cell*. Gerbang *input* memiliki dua fungsi utama, yaitu menentukan bagian dari *cell state* yang perlu diperbarui dan memperbarui *cell state* tersebut. Persamaan untuk *input gate* disajikan pada Persamaan (24) dan (25) sebagai berikut:

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (24)$$

$$\tilde{c}_t = \phi(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (25)$$

dengan:

i_t = *input gate*.

$\tilde{c}_t$ = nilai baru yang ditambahkan ke *cell state*.

σ = fungsi *sigmoid*.

ϕ = fungsi *tangen hiperbolik*.

W_i = nilai *weight* untuk *input gate*.

W_c = nilai *weight* untuk *cell state*.

h_{t-1} = nilai *output* sebelum orde ke- t .

X_t = nilai *input* pada orde ke- t .

b_i = nilai bias pada *input gate*.

b_c = nilai bias pada *cell state*.

Fungsi kedua dari *input gate* adalah memperbarui informasi di dalam *cell state*. Pembaruan *cell state* ($\tilde{c}_t$) dilakukan melalui lapisan *tanh* yang berperan mengontrol seberapa banyak informasi baru yang akan ditambahkan. Persamaan untuk *cell state* yang telah diperbarui pada Persamaan (26) berikut:

$$\tilde{c}_t = \tanh(W_c \cdot x_t + W_c \cdot h_{t-1} + b_c) \quad (26)$$

dengan:

- $\tilde{c}_t$ = nilai baru yang ditambahkan ke *cell state*.
- $\tanh$ = fungsi *tanh*.
- W_c = nilai *weight* untuk *cell state*.
- h_{t-1} = nilai *output* sebelum orde ke-t.
- x_t = nilai *input* pada orde ke-t.
- b_c = nilai bias pada *cell state*.

Setelahnya, *cell state* lama akan diperbarui dengan mengalikan nilai *cell state* lama dengan *output* dari *forget gate* (f_t) untuk menghapus informasi yang telah ditentukan sebelumnya di gerbang *forget*. Selanjutnya, hasil tersebut ditambahkan dengan ($i_t \cdot \tilde{c}_t$), yaitu nilai baru yang ditambahkan untuk memperbarui *cell state*. Proses ini menghasilkan persamaan *cell state* seperti yang dirumuskan dalam Persamaan (27) berikut:

$$c_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{c}_t \quad (27)$$

dengan:

- C_t = *cell state*.
- f_t = gerbang *forget*.
- C_{t-1} = *cell state* sebelum orde ke-t.
- i_t = nilai *output* sebelum orde ke-t.
- x_t = gerbang *input*.
- b_i = nilai baru yang dapat ditambahkan ke *cell state*.

3. Output Gate

Output Gate (O_t) adalah gerbang terakhir dalam struktur LSTM yang memiliki fungsi untuk menentukan informasi apa yang akan dihasilkan. Proses pertama dilakukan dengan menjalankan lapisan neuron *sigmoid* untuk menentukan bagian dari *cell state* yang akan dihasilkan pada O_t . Setelah itu, nilai ini dikalikan dengan *cell state* yang telah diproses melalui lapisan neuron *tanh*, menghasilkan keluaran h_t , yang kemudian diteruskan ke *cell state*. Gerbang ini menjadi pembeda antara *cell state* C_t dan keluaran aktual h_t . Persamaan gerbang *output* dirumuskan pada Persamaan (28) berikut:

$$O_t = \sigma(W_o.x_t + W_o.h_{t-1} + b_o) \quad (28)$$

dengan:

O_t = gerbang *output*.

σ = fungsi *sigmoid*.

W_o = nilai *weight* untuk gerbang *output*.

h_{t-1} = nilai *output* sebelum orde ke- t .

x_t = nilai *input* pada orde ke- t .

b_o = nilai bias pada gerbang *output*.

Setelah nilai dari gerbang *output* diperoleh, *cell state* diproses melalui fungsi *tanh*, dan hasilnya dikalikan dengan nilai dari lapisan *sigmoid* pada gerbang *output*. Persamaan untuk nilai keluaran pada waktu ke- t dirumuskan pada Persamaan (29) berikut:

$$h_t = O_t * \tanh(C_t) \quad (29)$$

dengan:

h_t = nilai *output* orde ke- t .

O_t = gerbang *output*.

$\tanh$ = fungsi *tanh*.

C_t = *cell state*.

2.14 Hybrid VARMAX – LSTM

Pendekatan *hybrid* dalam peramalan deret waktu bertujuan untuk menggabungkan kemampuan model statistik tradisional dan model pembelajaran mendalam guna menangkap pola kompleks dalam data. Secara umum, penggabungan model deret waktu dengan struktur autokorelasi linear dan non-linear dapat dijelaskan melalui Persamaan (30) (Zhang, 2003):

$$y_t = L_t + N_t \quad (30)$$

dengan:

y_t = data pengamatan deret waktu ke-t.

L_t = komponen linear ke-t.

N_t = komponen non-linear ke-t.

Metode *hybrid* VARMAX-LSTM dirancang untuk memanfaatkan kekuatan masing-masing model dalam memproses komponen linear dan non-linear. VARMAX memiliki keunggulan dalam memodelkan pola linear dengan mempertimbangkan pengaruh variabel eksogen, tetapi kurang efektif dalam menangani pola non-linear yang sering muncul pada data deret waktu (Caliwag & Lim, 2019). Sebaliknya, LSTM sangat kuat dalam menangkap pola non-linear dan ketergantungan jangka panjang dalam data. Namun, LSTM memiliki keterbatasan dalam memproses pola linear tanpa adanya tahap *preprocessing* (Zhang, 2003), sehingga berdasarkan kondisi tersebut maka metode *hybrid* dapat diterapkan.

Tahapan pemodelan *hybrid* ini dimulai dengan menggunakan VARMAX untuk menangkap komponen linear L'_t dari data deret waktu. Setelah model VARIMAX diterapkan, residual e_t dihitung sebagai perbedaan antara data aktual y_t dan nilai peramalan komponen linear L'_t , seperti dijelaskan oleh Zhang (2003) pada Persamaan (31) berikut:

$$e_t = y_t - L'_t \quad (31)$$

dengan:

y_t = data pengamatan deret waktu ke-t.

L'_t = nilai peramalan dari komponen linear ke-t.

N_t = data residual deret waktu ke-t.

Residual e_t yang mencerminkan pola non-linear digunakan sebagai *input* untuk model LSTM. Model ini kemudian mempelajari pola non-linear N'_t pada residual tersebut, menghasilkan prediksi non-linear yang optimal. Akhirnya, peramalan *hybrid* dilakukan dengan menggabungkan hasil dari kedua komponen, seperti yang diformulasikan dalam Persamaan (32) (Zhang, 2003):

$$y'_t = L'_t + N'_t \quad (32)$$

dengan:

y'_t = nilai peramalan dari model *hybrid* ke-t.

L'_t = nilai peramalan dari komponen linear ke-t.

N'_t = nilai peramalan dari komponen non-linear ke-t.

Pendekatan *hybrid* VARMAX-LSTM sangat efektif untuk data deret waktu dengan karakteristik kompleks, seperti data ekonomi, keuangan, dan cuaca. Penelitian terbaru menunjukkan bahwa metode ini mampu menghasilkan akurasi peramalan yang lebih tinggi dibandingkan metode konvensional atau individu, karena memanfaatkan kekuatan dari analisis statistik klasik dan pembelajaran mendalam secara simultan. Keunggulan ini menjadikan *hybrid* VARMAX-LSTM sebagai metode yang sangat potensial untuk diterapkan dalam berbagai domain penelitian berbasis data deret waktu.

2.15 Evaluasi Model

Evaluasi model dilakukan untuk menilai tingkat akurasi model dengan mengukur besar atau kecilnya kesalahan yang muncul selama proses prediksi (Madhika et al., 2023). Penelitian ini menggunakan dua metrik evaluasi, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE), yang dijelaskan sebagai berikut:

1. *Root Mean Square Error* (RMSE)

RMSE digunakan untuk mengukur rata-rata tingkat kesalahan antara nilai prediksi dengan nilai aktual. Secara sederhana, RMSE menunjukkan rata-rata jarak vertikal antara nilai aktual dan nilai hasil prediksi terhadap garis *fitting*. Perhitungan RMSE dilakukan dengan mengambil akar kuadrat dari *Mean Squared Error* (MSE), sesuai Persamaan (33):

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \tilde{Y}_t)^2} \quad (33)$$

dengan:

n = banyaknya data yang diamati.

Y_t = nilai data aktual pada periode ke- t .

$\tilde{Y}_t$ = nilai data aktual pada periode ke- t .

2. *Mean Absolute Percentage Error (MAPE)*

MAPE merupakan metrik evaluasi yang populer untuk mengukur persentase kesalahan antara nilai prediksi dan nilai aktual. MAPE dihitung dengan mengambil rata-rata nilai absolut dari kesalahan prediksi, lalu mengonversinya ke dalam bentuk persentase (Pertwi et al., 2021). Rumus untuk MAPE dijabarkan pada Persamaan (34) (Yao et al., 2023):

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100\% \quad (34)$$

dengan:

n = banyaknya data yang diamati.

Y_t = nilai data aktual pada periode ke- t .

$\tilde{Y}_t$ = nilai data aktual pada periode ke- t .

Dengan menggunakan kedua metrik ini, penelitian dapat mengevaluasi akurasi model secara lebih komprehensif, baik dari segi kesalahan absolut maupun persentasenya.

BAB III

METODE PENELITIAN

3.1 Tempat dan Waktu Penelitian

3.1.1 Tempat Penelitian

Penelitian ini dilakukan melalui studi literatur yang bertempat di Jurusan Matematika, Fakultas Matematika, dan Ilmu Pengetahuan Alam, Universitas Lampung. Berlokasi di Jalan Prof. Dr. Soemantri Brojonegoro No.1, Gedong Meneng, Bandar Lampung.

3.1.2 Waktu Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2024/2025 tepatnya bulan Oktober 2024. Proses pengerjaan terbagi menjadi tiga tahap. Tahap pertama melakukan studi literatur, penentuan tema penelitian, dan pengumpulan data. Tahap kedua merupakan tahap pengerjaan program yang dimulai dari *preprocessing* data, melakukan pemodelan VARMAX, melakukan *hyperparameter tuning* model LSTM, membangun model *hybrid* VARMAX – LSTM, dan evaluasi kinerja model. Tahap ketiga adalah penyusunan hasil penelitian dan kesimpulan penelitian.

3.2 Data dan Alat

3.2.1 Data

Data yang digunakan pada penelitian ini merupakan data sekunder yang diperoleh dari dua sumber utama. Data pertama adalah data kurs rupiah terhadap dolar dan in-

flasi yang diperoleh melalui situs resmi Bank Indonesia (<https://www.bi.go.id>). Data kedua adalah data jumlah uang beredar, suku bunga (BI Rate), ekspor dan impor yang diperoleh melalui situs resmi Badan Pusat Statistik (<https://www.bps.go.id>). Data yang digunakan mencakup rentang waktu dari Januari 2010 hingga September 2024, dengan masing-masing jumlah data sebanyak 177 data, yang disajikan pada Tabel 3 berikut:

Tabel 3. Data Penelitian

Periode	Ekspor (US\$)	Impor (US\$)	Kurs Dolar	Inflasi (%)	BI Rate (%)	Uang Beredar (Rp)
Jan-2010	1.15E+10	9.54E+09	9.276	3.72	6.50	2.06E+15
Feb-2010	1.11E+10	9.49E+09	9.348	3.81	6.50	2.11E+15
Mar-2010	1.27E+10	1.10E+10	9.174	3.43	6.50	2.11E+15
Apr-2010	1.20E+10	1.15E+10	9.027	3.91	6.50	2.14E+15
Mei-2010	1.26E+10	1.06E+10	9.183	4.16	6.50	2.23E+15
...	...	...	...	...	...	...
Sept-2024	2.20E+10	1.88E+10	15.342	1.84	6.00	9.05E+15

(Sumber data: <https://www.bi.go.id> dan <https://www.bps.go.id>)

3.2.2 Alat

Peralatan yang digunakan dalam menunjang penelitian ini adalah:

1. Perangkat Keras (*Hardware*), perangkat yang digunakan dalam penelitian ini adalah laptop dengan merk *VI4-ADA Laptop (Lenovo) - Type 82C6* dengan 64-bit *operating system*, *x64-based processor*. Spesifikasi *hardware* tersebut adalah sebagai berikut:

- *Processor*: AMD 3020e with *Radeon Graphics*, 1200 Mhz, 2 Core(s), 2
- *Logical Processor(s)*
- RAM: 8,00 GB

2. Perangkat Lunak (*Software*), perangkat yang digunakan untuk mendukung penelitian ini adalah:

- Sistem Operasi Windows
Windows 11 Pro adalah versi sistem operasi Windows 11 profesional dengan keunggulan berupa keamanan lebih canggih, efisiensi tinggi, antarmuka modern, dan dukungan *multitasking* yang lebih responsif,

sehingga mampu mengoptimalkan kinerja perangkat untuk kebutuhan profesional.

- *Library Pandas 2.2.2*
Pandas adalah *library Python* yang digunakan untuk pengolahan dan analisis data.
- *Library NumPy 1.26.4*
NumPy adalah *library Python* yang digunakan untuk proses komputasi numerik. *NumPy* menyediakan objek *array* multidimensi serta berbagai fungsi matematika yang dapat dioperasikan pada *array* tersebut.
- *Library Matplotlib 3.8.0*
Matplotlib adalah *library Python* yang digunakan untuk memvisualisasikan data dengan grafis yang menarik dan informatif. *Matplotlib* dapat menghasilkan berbagai jenis plot seperti *line plot*, *scatter plot*, *bar plot*, *histogram*, dan *pie chart*.
- *Library Seaborn 0.13.2*
Seaborn adalah *library Python* yang digunakan untuk menghasilkan grafik statistik yang informatif seperti *box plot*, *violin plot*, *pair plot*, dan *heat map*.
- *Scikit-learn 1.6.0*
Scikit-learn adalah *library Python* untuk pembelajaran mesin yang menyediakan berbagai algoritma seperti klasifikasi, regresi, dan *clustering*. *Library* ini mendukung pemrosesan data dan memiliki antarmuka yang mudah digunakan.
- *Statsmodels 0.14.4*
Statsmodels adalah *library Python* yang digunakan untuk analisis statistik dan ekonometri. *Library* ini menyediakan berbagai alat untuk estimasi model statistik, pengujian hipotesis, dan eksplorasi data.
- *Tensorflow 2.17.1*
TensorFlow adalah *framework open-source* untuk pembelajaran mesin dan *deep learning*. *Framework* ini dirancang untuk membangun, melatih, dan mengimplementasikan model AI, baik di perangkat lokal maupun di *cloud*.
- *Scipy 1.13.1*
SciPy adalah *library Python* yang digunakan untuk komputasi ilmiah. *Library* ini menyediakan modul untuk optimasi, integrasi, aljabar linear, statistik, dan berbagai fungsi matematika lanjutan lainnya.


3.3 Metode Penelitian

Penelitian ini dilakukan dengan langkah awal studi literatur artikel, jurnal dan buku yang mengenai metode *hybrid* VARMAX – LSTM. Studi literatur dilakukan untuk mendapatkan data dan informasi untuk mendukung penulisan proposal penelitian ini. Setelah itu dipelajari dengan melakukan simulasi sebagai aplikasi untuk menjelaskan teori yang didapat. Langkah-langkah yang dilakukan dalam melakukan peramalan menggunakan *hybrid* VARMAX – LSTM adalah sebagai berikut:

1. Melakukan *input* data penelitian ke dalam perangkat lunak *Python*. Data yang digunakan adalah data ekspor, impor, kurs rupiah terhadap dolar, inflansi, data jumlah uang beredar, dan suku bunga yang telah dilakukan *merging dataset* sehingga memiliki waktu (bulan dan tahun) yang sama.
2. Melakukan visualisasi data untuk melihat dan mengidentifikasi tren dan pola dalam data.
3. Melakukan *splitting* data menjadi data pelatihan dan data pengujian dengan skema 90% data latih dan 10% data uji.
4. Melakukan *preprocessing* data pada data pelatihan berupa pengecekan terhadap *missing value*, untuk melihat ada atau tidak *missing value* dalam *dataset*.
5. Melakukan uji kestasioneritasan pada data pelatihan dengan menggunakan uji *Augmented Dickey-Fuller* (ADF). Jika data tidak stasioner maka perlu dilakukan proses *differencing*.
6. Setelah data stasioner dilakukan uji hubungan sebab akibat variabel satu dengan variabel lainnya menggunakan uji kausalitas granger.
7. Mengidentifikasi model VARMAX yang memiliki orde p , d , q yang dapat dilihat pada plot ACF, PACF, dan proses *differencing* serta memasukkan variabel eksogen kedalam model VARMAX.
8. Melakukan estimasi parameter model VARMAX untuk mengetahui apakah model sudah cukup baik untuk digunakan dalam prediksi dan peramalan.
9. Menentukan model VARMAX terbaik berdasarkan nilai *Bayesian Information Criterion* (BIC) terkecil untuk digunakan dalam peramalan.


10. Melakukan prediksi untuk data latih dan data uji dengan menggunakan model VARMAX terbaik yang telah diperoleh.
11. Menghitung nilai residual yang dihasilkan dari model VARMAX, kemudian dilanjutkan dengan menguji asumsi residual *white noise* dengan uji *Ljung-Box*.
12. Mengevaluasi model VARMAX dengan menghitung nilai RMSE, MAPE, dan akurasi.
13. Melakukan peramalan dengan model VARMAX.
14. Menyiapkan data residual VARMAX yang akan digunakan sebagai data input model E_LSTM dan data prediksi VARMAX sebagai data input model P_LSTM.
15. Melakukan *scaling* data pada data prediksi dan residual VARMAX dengan *Standard Scaler*.
16. Melakukan *hyperparameter tuning* pada model E_LSTM dan model P_LSTM.
17. Membangun model E_LSTM dan model P_LSTM dengan menggunakan parameter terbaik yang diperoleh.
18. Melakukan prediksi dan peramalan dengan menggunakan model E_LSTM dan model P_LSTM.
19. Melakukan *unscaling* pada data hasil prediksi dan peramalan model E_LSTM dan model P_LSTM.
20. Menggabungkan data hasil prediksi dan peramalan dari model VARMAX dan E_LSTM melalui proses penjumlahan sebagai model *hybrid* VARMAX-E_LSTM, serta menggabungkan data hasil prediksi dan peramalan dari model E_LSTM dan P_LSTM melalui proses penjumlahan sebagai model *hybrid* VARMAX-EP_LSTM.
21. Mengevaluasi model *hybrid* dengan menghitung nilai RMSE, MAPE, dan akurasi.

Flowchart peramalan dengan model *hybrid* VARMAX-E_LSTM, direpresentasikan pada Gambar 6:



Gambar 6. Flowchart Model Hybrid VARMAX-E_LSTM

Flowchart peramalan dengan model *hybrid* VARMAX-EP_LSTM, direpresentasikan pada Gambar 7:



Gambar 7. Flowchart peramalan model *hybrid* VARMAX-EP_LSTM

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan mengenai penerapan model *hybrid* VARMAX-LSTM dalam peramalan nilai ekspor dan impor, maka dapat disimpulkan beberapa hal sebagai berikut:

1. Model *hybrid* VARMAX-LSTM dikembangkan melalui dua pendekatan utama. Pendekatan pertama, yaitu VARMAX-E_LSTM, merupakan hasil penggabungan model VARMAX dengan model E_LSTM. Sementara itu, pendekatan kedua, VARMAX-EP_LSTM, dibentuk dari penggabungan model VARMAX dengan kombinasi model E_LSTM dan P_LSTM. Kedua model LSTM tersebut dirancang menggunakan kombinasi parameter optimal yang diperoleh melalui proses *hyperparameter tuning*, dengan rincian sebagai berikut:
 - Model E_LSTM dioptimalkan menggunakan konfigurasi terbaik yang terdiri dari 16 *unit* LSTM, 64 *unit dense*, *ukuran batch* sebesar 8, dan *dropout* sebesar 0,1.
 - Model P_LSTM dibangun dengan parameter optimal yang meliputi 64 *unit* LSTM, 16 *unit dense*, dan *ukuran batch* sebesar 8.
2. Hasil peramalan yang diperoleh selama periode 6 bulan ke depan (Oktober 2024-Maret 2025) menggunakan model *hybrid* VARMAX-E_LSTM menunjukkan perbedaan yang signifikan dibandingkan model VARMAX maupun model *hybrid* VARMAX-EP_LSTM. Peramalan model VARMAX menunjukkan adanya sedikit fluktuasi, namun masih belum mampu mengikuti fluktuasi data *update* dengan baik. Sementara itu, peramalan model *hybrid* VARMAX-EP_LSTM hanya menunjukkan pola linear sepanjang periode peramalan, sehingga belum mampu mengikuti fluktuasi data *update*. Sebaliknya, peramalan model *hybrid* VARMAX-E_LSTM sudah mampu mengikuti pola

fluktuasi data *update* dengan baik. Sehingga, model *hybrid* VARMAX-E_LSTM merupakan model terbaik dalam melakukan peramalan ekspor dan impor dibandingkan model VARMAX maupun model *hybrid* VARMAX-EP_LSTM.

3. Berdasarkan hasil peramalan model VARMAX, model *hybrid* VARMAX-E_LSTM, dan model *hybrid* VARMAX-EP_LSTM, diperoleh bahwa model terbaik yang digunakan untuk proses peramalan terhadap nilai ekspor dan impor yaitu model *hybrid* VARMAX-E_LSTM dengan nilai RMSE dan MAPE terkecil. Diperoleh RMSE sebesar 1,1254E+09 untuk variabel ekspor dan 1,4746E+09 untuk variabel impor, sedangkan nilai MAPE 0,0425 untuk variabel ekspor dan 0,0591 untuk variabel impor.

5.2 Saran

Berdasarkan hasil peramalan ekspor dan impor menggunakan model *hybrid* VARMAX-LSTM, khususnya VARMAX-E_LSTM yang terbukti memiliki kinerja terbaik dibandingkan model VARMAX maupun VARMAX-EP_LSTM, disarankan agar pemerintah dan pelaku usaha memanfaatkan hasil prediksi ini sebagai pertimbangan dalam merumuskan kebijakan moneter dan strategi perdagangan yang lebih responsif terhadap dinamika ekonomi global. Model VARMAX-E_LSTM mampu menangkap pola fluktuasi data dengan lebih baik, sehingga dapat dijadikan referensi dalam pengambilan keputusan strategis seperti pengelolaan nilai tukar, pengaturan suku bunga, penentuan waktu ekspor-impor yang tepat, serta optimalisasi rantai pasok industri. Selain itu, hasil ini juga mendorong perlunya integrasi model prediktif berbasis *machine learning* ke dalam sistem perencanaan ekonomi nasional guna meningkatkan efektivitas kebijakan publik secara *data-driven*. Diharapkan, pendekatan berbasis teknologi ini mampu memperkuat ketahanan ekonomi nasional dan meningkatkan daya saing pelaku usaha dalam menghadapi tantangan global.

DAFTAR PUSTAKA

- Ahmad, R., Suryani, T., & Wijaya, A. 2022. Pengaruh Inflasi terhadap Stabilitas Harga Ekspor dan Biaya Impor di Indonesia. *Jurnal Ekonomi dan Keuangan*. **15**(3), 210-225.
- Aji, A. B., & 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), 012079.
- Aldi, M. W. P., Jondri, J., & Aditsania, A. 2018. Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *eProceedings of Engineering*. **5**(2), 3548-3554
- Ambarwari, A., Adrian, Q. J., & Herdiyeni, Y. 2020. Analysis of the effect of data scaling on the performance of the machine learning algorithm for plant identification. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*. **4**(1), 117–122.
- Arfan, A., & Lusiana, E. T. P. 2019. Prediksi Harga Saham di Indonesia Menggunakan Algoritma Long Short-Term Memory (LSTM). *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*. **6**(2), 153-160.
- Badan Perencanaan Pembangunan Nasional. 2024. *Rencana Pembangunan Jangka Menengah Nasional (RPJMN) 2025-2029*. Bappenas. Retrieved from (<https://rpjmn.bappenas.go.id/>).
- Bank Dunia. 2022. *Prospek Ekonomi Indonesia Desember 2022*. World Bank. <https://openknowledge.worldbank.org>
- Bank Indonesia. 2023. *Laporan Perekonomian Indonesia 2023*. Bank Indonesia. <https://www.bi.go.id>
- Bank Indonesia. 2025. *Laporan kebijakan moneter 2025*. Bank Indonesia. <https://www.bi.go.id>
- Biegel, J. E. 1999. *Production control: A quantitative approach*. Prentice Hall.

- Boddu, Y., Manimaran, A., Arunkumar, B., & Ramkumar, D. 2024. Design of an Iterative Dual Metaheuristic VARMAx Model Enhancing Efficiency of Time Series Predictions. *IEEE Access*. **12**, 128.071-128.083
- Box, G. E. P., & Jenkins, G. M. 1970. *Time series analysis: Forecasting and control*. Holden-Day.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C., dan Ljung, G.M. 2015. *Time Series Analysis Forecasting and Control*. 5th Edition. John Wiley & Sons, New Jersey.
- Buffa, E. S. 1996. *Modern production/operations management (8th ed.)*. John Wiley & Sons.
- 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**(10), 59680–59689.
- Dave, E., Leonardo, A., Jeanice, M., & Hanafiah, N. 2021. Forecasting Indonesia exports using a hybrid model ARIMA-LSTM. *Procedia Computer Science*. **179**, 480–487.
- Elman, J. L. 1990. Finding structure in time. *Cognitive Science*. **14**(2), 179-211.
- Fahrmeir, L. dan T. Gerhard. 1994. *Multivariate Statistical Modelling Based on Generalized Linier Models*. John Willey and Sons, New York.
- Felix, A. G., Schmidhuber, J., & Cummins, F. 2000. Learning to forget: Continual prediction with LSTM. *Neural Computation*. **12**(10), 2451–2471.
- Friedman, M. 2023. *Teori Kuantitas Uang dan Pengaruhnya terhadap Daya Saing Ekonomi*. Jakarta: Penerbit Ekonomi Global.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. *Deep Learning*. MIT Press.
- Han, J., Pei, J., & Kamber, M. 2022. *Data Mining: Concepts and Techniques (4th ed.)*. Morgan Kaufmann.
- 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. *J. Commun.*. **17**(9), 769-776.
- Hochreiter, S., & Schmidhuber, J. 1997. Long short-term memory. *Neural Computation*. **9**(8), 1735–1780.

- Hutter, F., Kotthoff, L., & Vanschoren, J. (Eds.). (2019). *Automated Machine Learning: Methods, Systems, Challenges*. Springer.
- Hyndman, R. J., & Athanasopoulos, G. 2018. *Forecasting: Principles and Practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- Hyndman, R. J., & Athanasopoulos, G. 2021. *Forecasting: Principles and Practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- Hyndman, R. J., & Koehler, A. B. 2006. Another look at measures of forecast accuracy. *International Journal of Forecasting*. **22**(4), 679–688.
- Ifdaniyah, I., & Syafri, S. 2024. Pengaruh jumlah uang beredar, suku bunga, nilai tukar rupiah, dan produk domestik bruto terhadap inflasi di Indonesia (1980-2022). *Jurnal Ekonomi dan Keuangan Indonesia*. **15**(1), 45-60.
- Juanda, B. & Junaidi. 2012. *Ekonometrika Deret Waktu Teori dan Aplikasi*. IPB Pres, Bogor.
- Kasmir. 2023. *Manajemen Perbankan*. Jakarta: PT RajaGrafindo Persada.
- Kementerian Keuangan RI. 2023. *Dampak Kebijakan Moneter Higher for Longer terhadap Perekonomian dan Fiskal Indonesia*. Diakses dari <https://anggaran.kemenkeu.go.id/api/Medias/d158b42c-fc3a-47f2-a9b8-c3879a58ffd5>
- Kementerian Perdagangan RI. 2024. Target pertumbuhan ekonomi 8 persen, Kemendag: Pada 2025, ekspor perlu tumbuh 7-10 persen. <https://www.kemendag.go.id/berita/siaran-pers/target-pertumbuhan-ekonomi-8-persen-kemendag-pada-2025-ekspor-perlu-tumbuh-7-10-persen>
- Kolmogorov, A. 1933. Sulla determinazione empirica di una legge di distribuzione. *Giorn Dell'inst Ital Degli Att*. 4: 89-91.
- Le, H., He, X., & Wen, H. 2019. A High-Precision Implementation of the Sigmoid Activation Function for Neuromorphic Computing Systems. *Micromachines*. **12**(10), 1183.
- Ljung, G. M., & Box, G. E. P. 1978. On a measure of lack of fit in time series models. *Biometrika*. **65**(2), 297–303.
- Lütkepohl, H. 2020. *Applied Time Series Econometrics*. Cambridge University Press.

- Lütkepohl, H. 2021. Vector autoregressive models. *In Handbook of Economic Forecasting* (Vol. 2, pp. 139-164).
- Madhani, P. M., Joshi, R., & Patel, S. 2021. Impact of Exchange Rate Fluctuations on Export Competitiveness and Import Costs. *International Journal of Economic Studies*. **15**(3), 112-130.
- Madhika, Y. R., Kusriani, & Hidayat, T. 2023. Gold Price Prediction Using the ARIMA and LSTM Models. *Sinkron: Jurnal dan Penelitian Teknik Informatika*. **8**(3), 1255–1264.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. 1999. *Metode dan Aplikasi Peramalan (2nd ed.)*. Binarupa Aksara.
- Mankiw, N. G. 2020. *Macroeconomics (10th ed.)*. Worth Publishers.
- Mardia, K. V. 1970. Measures of multivariate skewness and kurtosis with applications. *Biometrika*. **57**(3), 519–530.
- Minh, L.D., Niaraki, A.B., Huy, H.D., Min, K., & Moon, A.H. 2018. Deep Learning Approach for Short-Term Stock Trends Prediction Based on Two-Stream Gated Recurrent Unit Network. *Digital Object Identifier*. **6**(1): 1-13.
- Mitchell, T. M. 1997. *Machine Learning*. McGraw-Hill.
- Nugraha, E.S., Alika, Z. & Hamzah, D.A. 2021. Forecasting the Stock Price of PT Astra International Using the LSTM Method. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. **8**(3). pp.431-437.
- Nwankpa, C. E., Ijomah, W., Gachagan, A., & Marshall, S. 2018. Activation functions: Comparison of trends in practice and research for deep learning. arXiv preprint arXiv:1811.03378.
- Panigrahi, D., & Behera, B. 2022. Impacts of Geopolitical Events on Non-Linear Economic Models. *Journal of Economic Dynamics*. **45**(3), 123-145.
- Pasaribu, D. J. M., Kusriani, & Sudarman, S. 2020. Peningkatan Akurasi Klasifikasi Sentimen Ulasan Makanan Amazon dengan Bidirectional LSTM dan BERT Embedding. *Jurnal Teknologi Informasi dan Komunikasi*. **10**(1), 9–20.
- Patel, R., Sharma, V., & Gupta, A. 2023. Data Normalization Techniques in Machine Learning: A Comparative Analysis. *Journal of Artificial Intelligence Research* **15**(2), 45-60.

- Pertiwi, A., Dewi, L. F., Toharudin, T., & Ruchjana, B. N. 2021. Penerapan Model Vector Autoregressive Integrated Moving Average (VARIMA) untuk Prakiraan Indeks Harga Saham Gabungan dan Kurs Rupiah Terhadap USD. *Pattimura Proceeding: Conference of Science and Technology*. 431–442.
- Pratama, R.I.H. and Saputro, D.R.S. 2018. Model Runtun Waktu Vector Autoregressive Moving Average With Exogenous Variable (VARMAX). *Prosiding Konferensi Nasional Penelitian Matematika dan Pembelajarannya*. pp.490-497.
- Putra, P., Yulika, V., & Ruskan, E. L. 2020. Information System of Forecasting the Price of Beef Using Exponential Smoothing Method (Case Study: Dinas Perindustrian Dan Perdagangan Provinsi Sumatera Selatan). *Advances in Intelligent Systems Research*, **172**, 724–727
- Putra, R., Suryadi, H., & Lestari, A. 2024. Pengaruh Normalisasi dan Denormalisasi dalam Model Prediksi Deret Waktu. *Jurnal Data dan Analitika*. **12**(1), 55-70.
- Putri, A. D., Santoso, B., & Wijaya, R. 2023. Peran Ekspor dan Impor sebagai Indikator Keterkaitan Ekonomi dalam Perdagangan Internasional. *Jurnal Ekonomi Internasional*. **12**(1), 45-60.
- Raharjo, S., Santoso, B., & Wijaya, R. 2022. Hubungan antara Suku Bunga dan Perdagangan Internasional melalui Mekanisme Aliran Modal. *Jurnal Ekonomi Internasional*. **15**(2), 123-140.
- Rosita, T., Nugroho, A., & Pratama, I. 2023. Pengaruh Inflasi terhadap Daya Saing Produk Domestik di Pasar Internasional. *Jurnal Ekonomi dan Bisnis Internasional*. **10**(1), 45-60.
- Salehinejad, H., Sankar, S., Barfett, J., Colak, E., & Valaee, S. 2018. Recent advances in recurrent neural networks. arXiv preprint arXiv:1801.01078.
- Sarfo, P.A., Mai, Q., Sanfilippo, F.M., Preen, D.B., Stewart, L.M., & Fatovich, D.M. 2015. A Comparison of Multivariate and Univariate Time Series Approaches to Modelling and Forecasting Emergency Department Demand in Western Australia. *Journal of Biomedical Informatics*. **57**: 62-73
- Siarni-Namini, S., Tavakoli, N., & Namin, A. S. 2018. A comparison of ARIMA and LSTM in forecasting time series. In 2018 *17th IEEE international conference on machine learning and applications (ICMLA)* (pp. 1394-1401).
- Siegel, A. F. 2016. *Practical Business Statistics*. Academic Press.

- Softscients. 2020. *Belajar R – Metode Peramalan Deret Waktu – Forecasting Time Series*. Diakses pada 2 Februari 2025, dari <https://softscients.com/2020/04/23/metode-peramalan-deret-waktu-forecasting-time-series/Model-Pendekatan-Forecasting-dan-Pola-Data>
- Spliid, H. 1983. A Fast Estimation Method for the Vector Autoregressive Moving Average Model with Exogenous Variables. *Journal of the American Statistical Association*, 78(384), 843-849.
- Sutthichaimethee, P. 2017. VARIMAX Model to Forecast the Emission of Carbon Dioxide from Energy Consumption in Rubber and Petroleum Industries Sectors in Thailand. *Journal of Ecological Engineering*. **18**(3), 112–117.
- Syahram, E. F., Effendy, M. M., Setyawan, N. 2020. Sun Position Forecasting Menggunakan Metode RNN–LSTM Sebagai Referensi Pengendalian Daya Solar Cell. *SinarFe7*, 3(1).
- Tian, Z., Zhang, H., Li, Z. 2018. Deep learning with long short-term memory for time series prediction. *IEEE Communications Magazine*. **56**(7), 130–135.
- Tsay, R. S. 2022. *Analysis of Financial Time Series (4th ed.)*. Wiley.
- Wang, J., Li, X., & Zhang, Y. 2023. Challenges in Analyzing Complex and Non-Stationary Economic Data. *Journal of Economic Analysis*. **58**(2), 345-367.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods (2nd ed.)*. Pearson Education.
- Wijaya, A., Rahman, B., & Setiawan, D. 2022. Implementasi Denormalisasi pada Model Prediksi Berbasis Jaringan Saraf Tiruan. *Jurnal Informatika dan Komputasi*. **10**(3), 211-225.
- Yang, L., & Shami, A. 2020. On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*. **415**, 295–316.
- Yao, E., Zhang, L., Li, X., & Yun, X. 2023. Traffic Forecasting of Back Servers Based on ARIMA-LSTM-CF Hybrid Model. *International Journal of Computational Intelligence Systems*. **16**(1), 1–13.
- Zahara, S. & Sugianto. 2021. Peramalan Data Indeks Harga Konsumen Berbasis Time Series Multivariate Menggunakan Deep Learning. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. **5**(1): 24-30.

- Zahra, B., & Lazaar, M. 2019. Integration of Principal Component Analysis and Recurrent Neural Network to Forecast the Stock Price of Casablanca Stock Exchange. *Procedia Computer Science*. **148**, 55–61.
- Zhang, G. P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. **50**, 159–175.
- Zhang, L. 2019. Limitations of traditional models in nonlinear macroeconomic forecasting. *Economic Modelling*. **80**, 120–135.
- Zhang, X., Liu, Y., & Wang, H. 2022. Data Normalization Techniques for Deep Learning: A Comparative Study. *Journal of Machine Learning Research*. **23**(1), 45-67.