

**PERAMALAN *MULTIVARIATE TIME SERIES* HARGA PENUTUPAN
SAHAM PT KALBE FARMA TBK DAN NILAI TUKAR RUPIAH
BERBASIS MODEL *HYBRID VECM-LSTM***

(Skripsi)

Oleh

MAWAR ALHANI

(2017031029)



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRACT

FORECASTING MULTIVARIATE TIME SERIES OF CLOSING STOCK PRICES OF PT KALBE FARMA TBK AND THE EXCHANGE RATE OF THE RUPIAH BASED ON THE HYBRID VECM-LSTM MODEL

By

MAWAR ALHANI

The Indonesian capital market has significantly progressed, especially in stock instruments. Stock prices reflect market expectations for a company's future. Pharmaceutical stock prices not only depend on internal factors but also on external variables like the exchange rate of the rupiah to the dollar, forming a long-term relation. Analysis involves multivariate time series data with complex linear and non-linear patterns. Thus, a forecasting model is needed to handle both data patterns. One approach is to combine the strengths of the classical statistical Vector Error Correction Model (VECM) with deep learning Long Short Term Memory (LSTM) into a hybrid VECM-LSTM model. The combined results show an excellent model evaluation, with an 80% training and 20% testing data split yielding an RMSE of 202.65, MAPE of 0.016%, and forecasts following the latest data trends. This affirms the strong kinerjance of the hybrid VECM-LSTM model in both prediction and forecasting.

Keywords: Stocks, Exchange Rate, Prediction, Forecasting, VECM, LSTM, Hybrid VECM-LSTM.

ABSTRAK

PERAMALAN *MULTIVARIATE TIME SERIES* HARGA PENUTUPAN SAHAM PT KALBE FARMA TBK DAN NILAI TUKAR RUPIAH BERBASIS MODEL *HYBRID VECM-LSTM*

Oleh

MAWAR ALHANI

Pasar modal Indonesia telah mengalami perkembangan yang signifikan, terutama dalam instrument saham. Harga saham mencerminkan ekspektasi pasar terhadap perusahaan di masa mendatang. Harga saham farmasi biasanya tidak hanya bergantung pada faktor internal tetapi juga variabel eksternal seperti kurs rupiah terhadap dolar dengan hubungan jangka panjang. Analisis yang dilakukan dapat berupa *multivariate time series* dan memiliki pola kompleks yang mengandung pola linier dan non linier. Sehingga, diperlukan pengembangan model peramalan yang mampu menangani kedua jenis pola data tersebut. Salah satu pendekatan yang dapat digunakan adalah dengan mengintegrasikan model statistika klasik *Vector Error Correction Model* (VECM) dengan *deep learning Long Short Term Memory* (LSTM) menjadi model *hybrid* VECM-LSTM. Hasil dari penggabungan ini menunjukkan evaluasi model yang sangat baik, dengan *splitting* data 80% data *training* dan 20% data *testing* menghasilkan RMSE sebesar 202,65, MAPE sebesar 0,016%, dan hasil peramalan yang mengikuti pola data terbaru. Hal ini membuktikan bahwa pendekatan model *hybrid* VECM-LSTM memiliki kinerja model yang kuat dalam melakukan prediksi maupun peramalan.

Kata kunci: Saham, Kurs Rupiah terhadap Dolar, Prediksi, Peramalan, VECM, LSTM, *Hybrid* VECM-LSTM

**PERAMALAN *MULTIVARIATE TIME SERIES* HARGA PENUTUPAN
SAHAM PT KALBE FARMA TBK DAN NILAI TUKAR RUPIAH
BERBASIS MODEL *HYBRID* VECM-LSTM**

Oleh

Mawar Alhani

Skripsi

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA**

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

Judul Skripsi : **PERAMALAN *MULTIVARIATE TIME SERIES* HARGA PENUTUPAN SAHAM PT KALBE FARMA TBK DAN NILAI TUKAR RUPIAH BERBASIS MODEL *HYBRID VECM-LSTM***

Nama Mahasiswa : **Mawar Alhani**

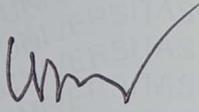
Nomor Pokok Mahasiswa : **2017031029**

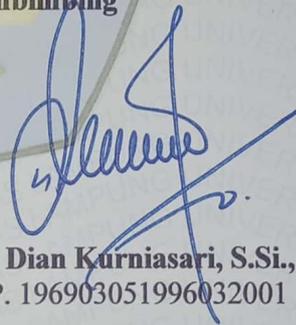
Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

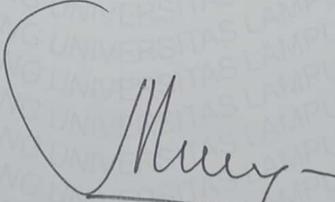


1. Komisi Pembimbing


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


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

2. Ketua Jurusan Matematika



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

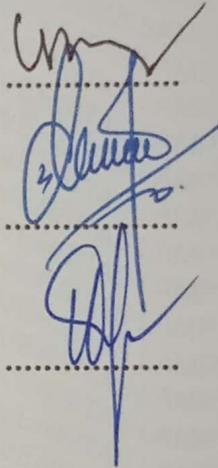
MENGESAHKAN

1. Tim Penguji

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

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

Penguji
Bukan Pembimbing : Prof. Dra. Wamiliana, M.A., Ph.D.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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

Tanggal Lulus Ujian Skripsi : 08 Mei 2024

PERNYATAAN

Yang bertandatangan di bawah ini:

Nama : **Mawar Alhani**
Nomor Pokok Mahasiswa : **2017031029**
Jurusan : **Matematika**
Judul Skripsi : **Peramalan *Multivariate Time Series* Harga
Penutupan Saham PT Kalbe Farma Tbk dan
Nilai Tukar Rupiah Berbasis Model *Hybrid*
VECM- LSTM**

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

Bandar Lampung, 17 Mei 2024

Yang menyatakan,



Mawar Alhani

NPM. 2017031029

RIWAYAT HIDUP

Penulis bernama lengkap Mawar Alhani lahir di Talang Padang, 29 April 2002. Penulis merupakan putri dari Bapak Samsul Hidayat dan Ibu Emarina. Penulis merupakan anak kedua dari tiga bersaudara, memiliki kakak yang bernama Dinda Putri Sabrina dan adik yang bernama Bintang Arzi Ahmad Dinezat.

Penulis menempuh pendidikan awal di Paud ABATA pada tahun 2007 sampai 2008. Pendidikan sekolah dasar di SD Negeri 1 Banding Agung pada tahun 2008 sampai 2014. Pendidikan menengah pertama di SMP Negeri 1 Talang Padang pada tahun 2014 sampai 2017. Pendidikan menengah atas di SMA Negeri 1 Pringsewu pada tahun 2017 sampai 2020.

Pada tahun 2020 penulis terdaftar sebagai Mahasiswi Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN). Selama menjadi mahasiswi penulis aktif di beberapa organisasi yaitu sebagai Anggota Bidang Eksternal Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) tahun 2021 dan Staff Ahli Dinas Kominfo Badan Eksekutif Mahasiswa FMIPA Unila tahun 2022. Selama menjadi mahasiswi penulis aktif dalam kegiatan kepanitiaan Dies Natalis Jurusan Matematika (DINAMIKA) yaitu sebagai Koordinator Divisi Lomba Cerdas Cermat Matematika (LCCM) DINAMIKA XXIII pada tahun 2022 dan sebagai *Steering Committee* (SC) Divisi Lomba Cerdas Cermat Matematika (LCCM) DINAMIKA XXIV pada tahun 2023.

Pada awal tahun 2023, penulis melakukan Kerja Praktik (KP) di kantor Dinas Ketahanan Pangan, Tanaman Pangan, dan Hortikultura Provinsi Lampung.

Setelah kegiatan KP selesai, penulis mengikuti kegiatan Studi Independen (SI) Kampus Merdeka selama selama semester 6. Penulis juga aktif dalam mengikuti berbagai lomba dengan capaian prestasi yang diperoleh yaitu, finalis lomba *Statistics Infographic Competition* (SIC) Satria Data pada tahun 2022, finalis lomba Karya Tulis Ilmiah TIK Gemastik pada tahun 2023, finalis lomba Musabaqah Karya Tulis Ilmiah Al-Qur'an (MKTIQ) MTQMN pada tahun 2023, juara 2 lomba Karya Tulis Ilmiah Nasional (KTIN) HIMAGHRO pada tahun 2023, dan harapan 1 lomba Kompetisi Infografis Statistika (KIS) 2024 di Universitas Gadjah Mada.

KATA INSPIRASI

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

(QS. Al-Baqarah : 286)

“Hiduplah seolah-olah Anda akan mati besok. Belajarlah seolah-olah Anda hidup selamanya”

(Mahatma Gandhi)

“Keberhasilan tidak diukur dengan apa yang Anda raih, namun kegagalan yang telah Anda hadapi, dan keberanian yang membuat Anda tetap berjuang melawan rintangan yang datang bertubi-tubi”

(Orison Swett Marden)

“Jangan takut akan kegagalan, namun belajarlah melihat kegagalan sebagai bagian dari sebuah proses yang akan mengantarkanmu pada kesuksesan”

(Mawar Alhani)

PERSEMBAHAN

Dengan mengucapkan syukur kehadirat Allah SWT yang telah memberikan taufik dan hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan sukacita yang tulus, saya persembahkan karya ini kepada:

Baba dan Ibu Tercinta

Yang senantiasa bekerja dengan keras agar penulis dapat menempuh pendidikan dan meraih gelar sarjana, yang tidak kenal lelah untuk selalu mendoakan, memberikan dukungan, nasehat dan kasih sayang yang tidak mungkin terbalas oleh apapun.

Kakak dan Adik Tersayang

Yang telah memberikan semangat, motivasi, doa dan dukungan.

Dosen Pembimbing dan Penguji

Yang senantiasa meluangkan waktu untuk mengarahkan dan memotivasi penulis.

Sahabat-sahabatku

Yang selalu memberikan semangat, doa, motivasi, dan dukungan dalam hal apapun kepada penulis serta canda dan tawa yang telah menemani penulis dalam setiap langkah.

Almamater Tercinta, Universitas Lampung

SANWACANA

Dengan mengucapkan puji dan syukur ke hadirat Tuhan Yang Maha Esa, akhirnya penulis berhasil menyelesaikan skripsi berjudul “Peramalan *Multivariate Time Series* Harga Penutupan Saham PT Kalbe Farma Tbk dan Nilai Tukar Rupiah Berbasis Model *Hybrid* VECM-LSTM”. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Matematika (S.Mat.) di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung. Dengan penuh rasa syukur, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Ir. Warsono, M.S., Ph.D. selaku Dosen Pembimbing I, terima kasih atas bimbingan, arahan, dukungan, dan kesediaan waktunya selama penyusunan skripsi ini.
2. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku Dosen Pembimbing II, terima kasih untuk segala bantuan dan masukannya selama penyusunan skripsi ini.
3. Ibu Prof. Dra. Wamiliana, M.A., Ph.D. selaku Dosen Penguji, terima kasih atas kesediannya untuk menguji, memberikan saran dan kritik yang membangun dalam penyelesaian skripsi ini.
4. Bapak Prof. Drs. Mustofa Usman, M.A., Ph.D selaku Pembimbing Akademik, terima kasih untuk setiap bimbingan dan pembelajarannya selama masa perkuliahan.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh Dosen dan Karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

8. Baba dan Ibu tersayang yang selalu mengerti, menyemangati, dan mengingatkan penulis untuk tetap semangat dalam menyelesaikan tugas akhir serta doa yang selalu terlimpah untuk keberhasilan penulis.
9. Kakak dan Adik yang telah ikhlas memberikan doa dan perhatian kepada penulis.
10. Sahabat-sahabat seperjuangan Matematika 2020.
11. Almamater tercinta Universitas Lampung.
12. Seluruh pihak yang telah membantu yang tidak dapat disebutkan satu persatu.

Bandar Lampung, 17 Mei 2024

Penulis

Mawar Alhani

DAFTAR ISI

Halaman

DAFTAR GAMBAR

DAFTAR TABEL

I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah.....	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
II. TINJAUAN PUSTAKA	6
2.1 Penelitian Terkait.....	6
2.2 Harga Saham.....	9
2.3 Nilai Tukar Mata Uang	10
2.4 Konsep Analisis Deret Waktu	11
2.5 Konsep Peramalan	11
2.6 Peramalan <i>Multivariate Time Series</i>	12
2.7 Stasioneritas	13
2.8 Kausalitas Granger.....	15
2.9 Panjang <i>Lag</i> Optimum	16
2.10 Kointegrasi Johansen	17
2.11 <i>Vector Autoregressive (VAR)</i>	19
2.12 <i>Vector Error Correction Model (VECM)</i>	20
2.13 Uji Asumsi Residual	22
2.14 <i>Machine Learning</i>	22
2.15 <i>Deep Learning</i>	23
2.16 Normalisasi dan Denormalisasi Data.....	23
2.17 <i>Long Short Term Memory</i>	26
2.18 Fungsi Aktivasi	29

2.19 <i>Hybrid</i> VECM - LSTM.....	31
2.20 Evaluasi Model	32
III. METODOLOGI PENELITIAN	34
3.1 Waktu dan Tempat Penelitian	34
3.2 Data dan Alat Penelitian	35
3.3 Metode Penelitian	36
IV. HASIL DAN PEMBAHASAN.....	41
4.1 Input Data.....	41
4.2 Visualisasi Data	41
4.3 Prediksi Data dengan VECM.....	42
4.3.1 Uji Stasioneritas Data	42
4.3.2 Panjang Lag Optimum	43
4.3.3 Uji Kausalitas Granger.....	44
4.3.4 Uji Kointegrasi Johansen	45
4.3.5 Prediksi VECM.....	47
4.3.6 Residual VECM.....	48
4.3.7 Uji Asumsi Residual VECM.....	49
4.3.8 Peramalan VECM	50
4.4 Prediksi <i>Hybrid</i> VECM-LSTM.....	50
4.4.1 Splitting Data	51
4.4.2 Scaling Data.....	52
4.4.3 <i>Hyperparameter Tuning</i> Model 1 LSTM	52
4.4.4 Membangun Model 1 LSTM	53
4.4.5 <i>Hyperparameter Tuning</i> Model 2 LSTM	54
4.4.6 Membangun Model 2 LSTM	55
4.4.7 Prediksi Model 1 LSTM	55
4.4.8 Prediksi Model 2 LSTM	58
4.4.9 Prediksi Model <i>Hybrid</i> VECM-LSTM	61
4.5 Peramalan <i>Hybrid</i> VECM-LSTM.....	63
4.5.1 Peramalan Model 1 LSTM.....	64
4.5.2 Peramalan Model 2 LSTM.....	66
4.5.3 Peramalan Model <i>Hybrid</i> VECM-LSTM.....	67

V. KESIMPULAN.....	71
DAFTAR PUSTAKA.....	72

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur LSTM	26
2. Fungsi Aktivasi <i>Sigmoid</i>	30
3. Fungsi Aktivasi <i>Tanh</i>	30
4. <i>Flowchart</i> Metode <i>Hybrid</i> VECM-LSTM.	37
5. Data Harga Penutupan Saham dan Nilai Tukar Rupiah (USD)	41
6. Plot Perbandingan Data Prediksi dan Data Aktual (a)Variabel <i>Close</i> dan (b)Variabel Kurs rupiah (USD).....	48
7. Plot Perbandingan Data Residual Model VECM (a)Variabel <i>Close</i> dan (b)Variabel Kurs rupiah (USD).....	49
8. Plot Data Peramalan VECM (a)Variabel <i>Close</i> dan (b)Variabel Kurs rupiah (USD).....	50
9. Plot Hasil Prediksi Model 1 LSTM untuk <i>splitting</i> 70:30 (a) variabel <i>Close</i> dan (b)variabel Kurs rupiah (USD).....	56
10. Plot Hasil Prediksi Model 1 LSTM untuk <i>splitting</i> 80:20 (a) variabel <i>Close</i> dan (b)variabel Kurs rupiah (USD).....	57
11. Plot Hasil Prediksi Model 2 LSTM untuk <i>splitting</i> 70:30 (a)variabel <i>Close</i> dan (b)Kurs rupiah (USD).....	59
12. Plot Hasil Prediksi Model 2 LSTM untuk <i>splitting</i> 80:20 (a)variabel <i>Close</i> dan (b)variabel Kurs rupiah (USD).....	60
13. Grafik Estimasi Model Hybrid VECM-LSTM untuk <i>splitting</i> 70:30 (a)variabel <i>Close</i> dan (b) variabel Kurs rupiah (USD).....	61
14. Grafik Estimasi Model Hybrid VECM-LSTM untuk <i>splitting</i> 80:20 (a)variabel <i>Close</i> dan (b) variabel Kurs rupiah (USD).....	62
15. Visualisasi Peramalan Model 1 LSTM untuk <i>splitting</i> 70:30 (a)variabel <i>Close</i> dan (b) variabel Kurs rupiah (USD).....	64
16. Visualisasi Peramalan Model 1 LSTM untuk <i>splitting</i> 80:20 (a)variabel <i>Close</i> dan (b)variabel Kurs rupiah (USD)	65
17. Plot Hasil Peramalan Model 2 LSTM untuk <i>splitting</i> 70:30.....	66
18. Plot Hasil Peramalan Model 2 LSTM untuk <i>splitting</i> 80:20.....	67

19. Grafik Hasil Peramalan Model Hybrid VECM-LSTM untuk <i>splitting</i> 70:30 (a) variabel <i>Close</i> dan (b) variabel Kurs rupiah (USD)..	68
20. Grafik Hasil Peramalan Model Hybrid VECM-LSTM untuk <i>splitting</i> 80:20 (a) variabel <i>Close</i> dan (b) variabel Kurs rupiah (USD)	69

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terkait	6
2. Data Harga Penutupan Saham dan Nilai Tukar Rupiah terhadap Dolar	35
3. Hasil Uji ADF pada Data Awal.....	42
4. Hasil Uji ADF pada Tingkat <i>First Difference</i>	43
5. Nilai Kriteria Penentuan <i>Lag</i> Optimum.	44
6. Hasil Uji Kausalitas Granger	45
7. Hasil Uji Kointegrasi Johansen	46
8. Uji Ljung-Box	48
9. Skema <i>Splitting</i> Data.....	51
10. <i>Hyperparameter Tuning</i> Data Prediksi	53
11. Hasil <i>Hyperparameter Tuning</i> model 1 dengan <i>Grid Search</i>	53
12. <i>Hyperparameter Tuning</i> Data Residual	54
13. Hasil <i>Hyperparameter Tuning</i> model 2 dengan <i>Grid Search</i>	55

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Pasar modal Indonesia telah mengalami perkembangan yang signifikan dalam beberapa tahun terakhir (Afifah dan Fauziyyah, 2023). Pertumbuhan investor di pasar modal Indonesia menjadi sebuah fenomena yang mencolok dan menunjukkan eskalasi yang konsisten dalam minat berinvestasi. Statistik Pasar Modal Indonesia tahun 2022 mencatat adanya peningkatan lonjakan yang signifikan sebesar 37,68% dari 7,49 juta investor menjadi lebih dari 10,31 juta orang terdaftar sebagai investor (Indonesia Central Securities Depository, 2023). Perkembangan ini mencerminkan minat yang semakin besar dari masyarakat untuk berinvestasi dalam instrumen pasar modal.

Salah satu instrumen investasi yang mendominasi pasar modal adalah saham (Putri dan Mandayanti, 2021). Harga saham dalam suatu perusahaan mencerminkan kinerja dan ekspektasi pasar terhadap perusahaan di masa mendatang (Wijaya & Siswanti, 2023). Investasi dalam bentuk saham memiliki potensi untuk memberikan investor keuntungan substansial, namun seiring dengan peluang tersebut terdapat juga risiko yang besar. Salah satu aspek utama adalah volatilitas harga saham yang dapat mengundang keraguan di kalangan calon investor karena harga saham dapat berfluktuasi dengan cepat dalam jangka waktu singkat (Agusta dkk., 2021).

Industri farmasi merupakan salah satu sektor penting dalam perekonomian Indonesia dan memiliki peran yang signifikan dalam pasar modal. Sektor ini menjanjikan prospek yang sangat positif dalam jangka waktu yang akan datang

dengan menunjukkan kemampuannya untuk terus berkembang karena menjadi kebutuhan esensial dalam kehidupan masyarakat (Sari dan Yousida, 2022). Salah satu perusahaan farmasi terkemuka di Indonesia adalah PT Kalbe Farma Tbk. Kinerja saham perusahaan farmasi dapat dipengaruhi oleh berbagai faktor, termasuk perkembangan dalam ekonomi makro. Salah satu variabel ekonomi makro yang memiliki dampak signifikan adalah nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD) (Eka dkk., 2022). Fluktuasi nilai tukar Rupiah dapat memengaruhi biaya impor bahan baku farmasi, laba perusahaan, dan kinerja saham perusahaan. Ketidakstabilan harga saham dan kondisi pasar saham mendorong investor yang memiliki niat berinvestasi dalam jangka panjang memilih strategi prospektif dengan tujuan mengurangi potensi kerugian. Sehingga, pentingnya melakukan analisis serta peramalan terhadap data harga saham PT Kalbe Farma Tbk dan nilai tukar Rupiah terhadap Dolar AS tidak dapat diabaikan. Analisis ini memungkinkan para investor dan pengambil kebijakan untuk membuat keputusan yang lebih terinformasi dalam berinvestasi di pasar modal. Namun, harga saham memiliki sifat yang kompleks, berfluktuasi, serta bersifat linier dan non-linier sehingga sulit untuk diprediksi dan diramalkan.

Analisis lebih mendalam pada data *multivariate time series* mengenai harga saham di sektor farmasi dan nilai tukar Rupiah terhadap Dolar Amerika Serikat (USD) seringkali berupa *big data* yang menunjukkan kombinasi pola campuran bersifat linier maupun nonlinier. Sejumlah metode telah dirancang dan dikembangkan dengan tujuan untuk meramalkan pergerakan harga saham di waktu yang akan datang. Secara umum, analisis data *time series* sering difokuskan pada pendekatan *univariate*, yang tidak mempertimbangkan variabel tambahan dalam kumpulan data. Jika dibandingkan dengan hasil analisis *multivariate time series* menunjukkan bahwa perkiraan akan lebih tepat dan akurat dengan interval kepercayaan yang lebih kecil dan ukuran akurasi yang lebih baik, seperti penelitian yang dilakukan oleh Aboagye-Sarfo, dkk. (2015). Namun, pendekatan yang dilakukan tersebut hanya dapat menangani hubungan linier dalam kumpulan data.

Perkembangan teknologi yang bergerak cepat telah mendorong kemajuan dalam pemodelan *machine learning* dan *deep learning*, memungkinkan metode data mining yang canggih dapat digunakan untuk meramalkan pergerakan saham seperti penelitian yang dilakukan oleh Agusta, dkk. (2021) yang melakukan prediksi pergerakan harga saham pada sektor farmasi menggunakan algoritma *Long Short-Term Memory* (LSTM) dengan perolehan nilai RMSE sebesar 27,310. Meskipun begitu, metode statistik klasik masih tetap relevan dan banyak diterapkan dalam era *Artificial Intelligence* (AI) saat ini seperti penelitian yang dilakukan oleh Wikayanti, dkk. (2020) mengenai peramalan kurs dolar Amerika Serikat, inflasi, tingkat suku bunga, dan Indeks Harga Saham Gabungan (IHSG) menggunakan metode *Vector Error Correction Model* (VECM) dengan nilai *Mean Absolute Percentage Error* (MAPE) yang diperoleh sebesar 1,534%. Pendekatan menggunakan metode pembelajaran mesin cenderung hanya membangun hubungan nonlinier. Sehingga dengan mempertimbangkan metode yang dapat menangani tantangan terkait kondisi data *multivariate time series* yang bersifat linier maupun nonlinier serta kemajuan teknologi yang semakin pesat, Indonesia perlu segera mengubah peran dan kontribusinya dalam bidang statistika dan sains data. Transformasi ini harus mengarah pada peran produsen yang mampu menghasilkan analisis statistika dan sains data yang komprehensif, bermutu tinggi, dan bermanfaat untuk kemajuan ilmu pengetahuan dan teknologi dalam masyarakat. Kehadiran di tengah era *Society 5.0* menuntut respon yang cepat dan inovatif. Jika tidak bergerak dengan cepat, persaingan global akan menghasilkan data tanpa makna dan menghambat kemampuan pengambilan keputusan yang informatif.

Salah satu pendekatan perkembangan metode peramalan yang dapat menjadi solusi dalam permasalahan ini adalah metode *hybrid* yang mengintegrasikan prinsip-prinsip statistika dan sains data, sehingga memungkinkan kinerja yang dapat beroperasi dengan keandalan yang berasal dari kedua metode tersebut. Peneliti terdahulu yang telah mengkombinasikan metode statistika dan pembelajaran mesin menggunakan model *hybrid Autoregressive Integrated Moving Average – Long Short-Term Memory* (ARIMA-LSTM) dilakukan oleh

Dave, dkk. (2021) untuk peramalan data ekspor Indonesia dan mendapatkan nilai MAPE sebesar 7,38%. Kemudian penelitian lain terkait *multivariate time series* dengan metode *hybrid Vector Autoregressive – Long Short-Term Memory* (VAR-LSTM) telah dilakukan oleh Bayu Aji dan Surjandari (2020) untuk meramalkan harga transaksi bahan bakar yang menghasilkan nilai *Root Mean Square Error* (RMSE) sebesar 81,52 dan *Mean Absolute Percentage Error* (MAPE) sebesar 1,02% yaitu nilai kesalahan yang sangat kecil, sehingga metode tersebut dapat diterapkan dengan baik dalam kumpulan data. Berdasarkan pemaparan di atas, untuk menciptakan strategi yang dapat meningkatkan kesejahteraan masyarakat dengan pengambilan keputusan investasi yang tepat dan mencapai keberlanjutan ekonomi, maka penulis ingin melakukan analisis dan peramalan harga saham farmasi PT. Kalbe Farma Tbk dan nilai tukar Rupiah sebagai faktor ekonomi makro dengan penelitian yang berjudul “Peramalan *Multivariate Time Series* Harga Penutupan Saham PT Kalbe Farma Tbk Dan Nilai Tukar Rupiah Berbasis Model *Hybrid Vector Error Correction Model – Long Short-Term Memory* (VECM-LSTM)”. Dengan demikian, diharapkan bahwa penelitian ini dapat menghasilkan tingkat kesalahan yang kecil dengan mengintegrasikan keunggulan dan kekuatan bidang statistika serta sains data dalam pengembangan ilmu pengetahuan dan teknologi.

1.2. Rumusan Masalah

Adapun rumusan masalah dari penelitian ini adalah:

1. Apakah terdapat perbedaan signifikan antara hasil peramalan model *Hybrid* VECM-LSTM dengan model VECM untuk harga penutupan saham PT Kalbe Farma Tbk dan nilai tukar rupiah?

2. Bagaimana kinerja model *Hybrid* VECM-LSTM dalam meramalkan *multivariate time series*, khususnya harga penutupan saham PT Kalbe Farma Tbk dan nilai tukar rupiah?

1.2. Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Melakukan pengembangan dengan menggabungkan analisis statistika dan sains data dalam meramalkan pergerakan harga penutupan saham PT Kalbe Farma Tbk. dan nilai tukar Rupiah terhadap USD yang berkointegrasi.
2. Mengetahui peramalan harga penutupan saham PT Kalbe Farma Tbk. dan nilai tukar Rupiah terhadap USD menggunakan metode *hybrid* VECM-LSTM.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah:

1. Dapat meningkatkan kualitas peramalan harga penutupan saham PT Kalbe Farma Tbk. dan nilai tukar Rupiah, sehingga dapat membantu para pelaku pasar dalam membuat keputusan investasi yang lebih tepat.
2. Dapat memberikan kontribusi pada pengetahuan akademik tentang peramalan pasar keuangan dan penggunaan model *hybrid* VECM-LSTM, serta membuka pintu bagi gagasan, *pilot project*, dan konsep baru dibidang IPTEK.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian terkait dalam penelitian ini digunakan sebagai bahan acuan untuk hasil analisis. Topik penelitian yang menjadi acuan ialah model VECM, model LSTM, model *hybrid* ARIMA-LSTM, dan model *hybrid* VAR-LSTM. Adapun metrik evaluasi yang digunakan adalah RMSE dan MAPE. Secara umum mengenai beberapa penelitian yang digunakan dalam penelitian ini dirangkum dalam Tabel 1 sebagai berikut.

Tabel 1. Penelitian Terkait

No	Penelitian	Data	Metode	Hasil	
				RMSE	MAPE
1	Pengaruh Kurs Dolar Amerika Serikat, Inflasi, dan Tingkat Suku Bunga Terhadap Indeks Harga Saham Gabungan dengan Model <i>Vector Error Correction</i> (Wikayanti dkk., 2020)	Data Indeks Harga Saham Gabungan (IHSG), Kurs Dolar Amerika Serikat, Inflasi, dan Tingkat Suku Bunga Jumlah: 125 observasi Sumber: Yahoo Finance dan Bank Indonesia	<i>Vector Error Correction Model</i> (VECM)	-	1,534%
2.	Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan <i>Algoritma Long Short-Term Memory</i> (Agusta dkk., 2021)	Harga Saham Jumlah: 761 observasi Sumber: Yahoo Finance	Model <i>Long Short-Term Memory</i> (LSTM)	27,310	-

3.	<i>Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM</i> (Dave dkk., 2021)	Data Bulanan Ekspor Indonesia Januari 1998 – Desember 2019 Sumber: <i>Federal Reserve Economic Data</i>	Model Hybrid ARIMA-LSTM	-	7,38%
4.	<i>Hybrid vector autoregression–recurrent neural networks to forecast multivariate time series jet fuel transaction price</i> <i>Air Quality Prediction</i> (Bayu Aji dan Surjandari, 2020)	Data harga transaksi bahan bakar jet Januari 2018 – April 2020 Sumber: Data terbuka, <i>platts's website</i> , <i>pertamina's website</i> , Bank Indonesia <i>website</i> , maskapai penerbangan Indonesia	Model Hybrid VAR-LSTM	81,52	1,02%

Berikut adalah resume dari penelitian pada Tabel 1.

a. Penelitian Pertama (Wikayanti dkk., 2020)

Penelitian ini dilakukan oleh Wikayanti, dkk. (2020) yang menerapkan model VECM untuk analisis pengaruh kurs dolar Amerika Serikat, inflasi dan tingkat suku bunga terhadap indeks harga saham gabungan dan data penelitian diperoleh dari Yahoo Finance dan Bank Indonesia. Data tersebut memiliki total 125 observasi.

Dalam penelitian ini dilakukan pembangunan model VECM dengan beberapa tahapan yaitu menguji kestasioneran data menggunakan uji *Augmented Dickey Fuller*, jika data belum stasioner, maka dilakukan *differencing* pertama, menguji lagi kestasioneran data yang telah di *differencing*, menentukan lag optimal menggunakan AIC, menguji kointegrasi dengan menggunakan *Engle Granger*, melakukan estimasi parameter VECM, menguji Asumsi Klasik, dan melakukan

peramalan. Hasil penelitian dengan menggunakan model VECM diperoleh nilai MAPE sebesar 1,534%.

b. Penelitian Kedua (Agusta dkk., 2021)

Penelitian yang dilakukan Agusta, dkk. (2021) ini adalah penelitian mengenai prediksi pergerakan harga saham pada sektor farmasi dengan menerapkan algoritma LSTM. Data dalam penelitian ini sebanyak 761 observasi yang diperoleh melalui Yahoo Finance.

Dalam prosesnya, tahap pertama yang dilakukan dalam penelitian ini adalah pengumpulan data. Selanjutnya, dilakukan *preprocessing data*. Kemudian, dalam penelitian ini data dibagi menjadi 80% untuk *training* dan 20% untuk *testing*. Selanjutnya dilakukan proses pembangunan, pengujian dan evaluasi model LSTM. Hasil pengujian model dalam penelitian ini diperoleh nilai RMSE sebesar 27,310.

c. Penelitian Ketiga (Dave dkk., 2021)

Penelitian yang dilakukan Dave, dkk. (2021) adalah penelitian mengenai peramalan ekspor Indonesia menggunakan model *hybrid* ARIMA-LSTM. Data dalam penelitian ini dari Januari 1998 – Desember 2019 yang diperoleh melalui *Federal Reserve Economic Data*.

Proses pada penelitian ini meliputi pembangunan model ARIMA, model LSTM, dan model *hybrid*. Selanjutnya, dilakukan perbandingan hasil evaluasi terhadap ketiga model. Hasil dalam penelitian ini menunjukkan bahwa model *hybrid* ARIMA-LSTM memberikan evaluasi model dengan nilai error yang terkecil yaitu MAPE sebesar 7,38%.

d. Penelitian Keempat (Bayu Aji dan Surjandari, 2020)

Penelitian yang dilakukan Bayu Aji dan Surjandari (2020) adalah penelitian mengenai peramalan harga transaksi bahan bakar jet di Bandara CGK Tangerang dengan mengimplementasikan model *hybrid* VAR-LSTM. Data dalam penelitian mulai dari Januari 2017 – April 2020 dan terdiri dari 8 variabel yang diambil melalui 5 sumber berbeda yaitu data terbuka, *platts's website*, *pertamina's website*, Bank Indonesia *website*, dan maskapai penerbangan Indonesia.

Proses awal pada penelitian ini menerapkan metode VAR yang meliputi beberapa tahapan yaitu transformasi data, *assumption checking*, menentukan *lag* optimum. Selanjutnya, membangun model VAR-LSTM menggunakan data prediksi model VAR. Hasil dalam penelitian ini menunjukkan bahwa model *hybrid* VAR-LSTM memberikan nilai evaluasi model yaitu MAPE sebesar 1,02% dan RMSE sebesar 81,52.

2.2 Harga Saham

Harga saham adalah aspek yang sangat krusial dan harus diperhatikan secara serius oleh investor dalam konteks investasi. Harga saham pada dasarnya mencerminkan kinerja suatu perusahaan (*emiten*) di pasar saham. Mekanisme pembentukan harga saham dipengaruhi oleh interaksi antara permintaan (*demand*) dan penawaran (*supply*) atas saham tersebut (Rosyida dkk., 2020). Rahman, dkk. (2023), menyatakan bahwa harga saham pada pasar modal dibagi menjadi tiga kategori utama, yakni harga tertinggi (*high price*), harga terendah (*low price*), dan harga penutupan (*close price*).

Harga tertinggi dan terendah (*high price* dan *low price*) mencerminkan level harga tertinggi dan terendah yang tercapai selama satu hari di bursa saham. Hal ini, menggambarkan variasi harga selama sesi perdagangan dan dapat memberikan wawasan tentang fluktuasi *intraday* yang dapat digunakan oleh para pedagang

jangka pendek. Sementara itu, harga penutupan (*close price*) adalah harga yang sah terjadi pada saat penutupan jam perdagangan bursa saham. Harga saham penutupan mewakili harga terakhir pada akhir hari perdagangan, memiliki relevansi khusus dalam meramalkan data masa depan. Harga saham penutupan yang mencerminkan sentimen pasar pada akhir hari perdagangan, memiliki peran krusial dalam analisis dan peramalan harga saham selanjutnya. Data yang mudah diakses memberikan wawasan mengenai sentimen pasar yang mungkin berpengaruh pada pergerakan harga di masa depan. Selain itu, korelasi antara harga penutupan dengan likuiditas dan volume perdagangan menjadikannya sebagai elemen penting dalam pengambilan keputusan investasi. Kombinasi faktor-faktor ini menjadikan harga saham penutupan sebagai dasar yang berharga dalam analisis dan peramalan dalam dunia investasi.

2.3 Nilai Tukar Mata Uang

Nilai tukar adalah representasi dari nilai satuan suatu mata uang dalam konteks valuta domestik terhadap valuta asing (Suseno, 2014). Penetapan nilai mata uang dipengaruhi oleh tingkat permintaan dan penawaran uang yang ada (Christianingrum, 2022). Fluktuasi dalam permintaan dan penawaran valuta dapat mengakibatkan apresiasi atau depresiasi mata uang, yang pada gilirannya dapat memiliki dampak signifikan pada tingkat inflasi, mempengaruhi peningkatan harga-harga umum secara serentak.

Menurut Mankiw (2007), konsep nilai tukar mata uang dalam suatu wilayah dapat didefinisikan dalam dua dimensi, yaitu nilai tukar nominal dan nilai tukar riil. Nilai tukar nominal merujuk pada angka yang digunakan untuk mengonversi mata uang suatu negara ke mata uang negara lain. Sementara nilai tukar riil mengacu pada nilai yang digunakan untuk mengukur pertukaran barang dan jasa antara dua negara. Dengan kata lain, nilai tukar mata uang menggambarkan seberapa banyak unit valuta satu negara yang dapat ditukarkan dengan valuta negara lain, seperti

halnya nilai tukar Rupiah terhadap USD, Ringgit, Euro, Yen, dan mata uang lainnya.

2.4 Konsep Analisis Deret Waktu

Data deret waktu adalah sekumpulan pengamatan yang dicatat secara berurutan terhadap sebuah variabel dalam interval waktu yang tetap, seperti harian, mingguan, bulanan, kuartalan, tahunan, atau interval lainnya yang sama. Analisis deret waktu adalah pendekatan dalam statistik dan ilmu ekonometri yang digunakan untuk menganalisis data dengan mempertimbangkan faktor waktu sebagai variabel kunci. Data deret waktu memiliki kumpulan pengamatan di berbagai periode waktu, dimana asumsi yang diterima adalah pengamatan dalam satu periode waktu memiliki ketergantungan terhadap pengamatan dalam periode sebelumnya. Oleh karena itu, analisis data deret waktu memungkinkan untuk melakukan peramalan atau prediksi terhadap nilai-nilai di masa depan berdasarkan pola historis yang ada.

Data deret waktu sering kali direpresentasikan oleh variabel X_t , dengan t sebagai indeks waktu yang menunjukkan urutan pengamatan (Hillmer dan Wei, 1991). Analisis deret waktu sangat penting dalam berbagai bidang, seperti ekonomi, keuangan, kesehatan, maupun bidang lainnya. Analisis deret waktu dapat digunakan dalam mengidentifikasi tren, musiman, dan pola siklik dalam data, serta memungkinkan untuk membuat proyeksi dan perencanaan yang lebih baik dalam berbagai konteks. Oleh karena itu, pemilihan metode analisis deret waktu yang tepat sangat penting untuk memahami dan memanfaatkan informasi yang terkandung dalam data deret waktu.

2.5 Konsep Peramalan

Peramalan (*forecasting*) adalah suatu proses yang digunakan untuk memproyeksikan atau memprediksi apa yang akan terjadi di masa depan dengan menggunakan data historis dan informasi yang ada pada saat ini. Konsep peramalan memainkan peran penting dalam berbagai aspek kehidupan, termasuk ekonomi, bisnis, ilmu pengetahuan, dan pengambilan keputusan. Tujuan utama dari peramalan adalah untuk menghasilkan estimasi atau proyeksi mengenai berbagai hal, seperti kuantitas atau kualitas dalam produksi, penjualan, atau peristiwa lainnya yang akan terjadi di masa yang akan datang dengan hasil prediksi yang diperoleh mendekati keadaan yang sebenarnya (Sayuti, 2020). Secara umum, model peramalan memiliki dua komponen yaitu komponen atau nilai yang dapat didefinisikan (*pola*) dan yang tidak dapat didefinisikan (*error*).

2.6 Peramalan *Multivariate Time Series*

Peramalan berbasis *multivariate time series* adalah jenis peramalan yang melibatkan lebih dari satu variabel kriteria yang mengalami perubahan seiring berjalannya waktu (Zahara dan Sugianto, 2021). Peramalan multivariat memungkinkan peneliti untuk mempertimbangkan lebih banyak aspek dalam proses peramalan daripada ditangani dengan model univariat yang hanya menggunakan satu variabel. Menggunakan berbagai variabel kriteria dalam model multivariat mampu memberikan tingkat akurasi peramalan yang lebih baik daripada menggunakan satu variabel dalam model univariat (Aboagye-Sarfo dkk., 2015).

Selain itu, memasukkan berbagai variabel kriteria pada model multivariat juga dapat mendeteksi hubungan kompleks antar variabel, yang mungkin tidak dapat dilihat ketika hanya menggunakan satu variabel dalam model univariat. Hal Ini,

memungkinkan peneliti untuk lebih memahami faktor-faktor yang memengaruhi perubahan variabel kriteria dan menghasilkan peramalan yang lebih kuat dan andal. Dalam 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 *multivariate time series* memungkinkan pengambilan keputusan yang lebih terinformasi dan memperkuat analisis peramalan di berbagai bidang, termasuk keuangan, ekonomi, ilmu sosial, dan lain-lain.

2.7 Stasioneritas

Stasioneritas dalam analisis data deret waktu mengindikasikan bahwa data tersebut tidak mengalami perubahan yang drastis seiring berjalannya waktu. Data deret waktu dianggap stasioner jika fluktuasi nilainya tetap berada dalam rentang tertentu yang memiliki nilai rata-rata yang konstan, tanpa bergantung pada waktu, serta varians yang tetap konstan dari waktu ke waktu. Dengan kata lain, data tersebut menunjukkan perilaku yang stabil dan konvergen di sekitar nilai rata-rata dengan variasi yang minim. Jika data tidak memenuhi asumsi stasioner, maka langkah yang perlu diambil adalah melakukan modifikasi terhadap data tersebut hingga mencapai kondisi data stasioner. Stasioneritas data dapat dikenali secara visual melalui grafik data, namun juga dapat diuji secara formal menggunakan uji stasioneritas. Dengan cara ini, dapat dipastikan bahwa data telah mencapai karakteristik stasioner yang diperlukan untuk analisis deret waktu yang lebih tepat.

Menurut Widarjono (2005), pengujian stasioneritas data dapat dilakukan melalui metode uji akar unit, di mana salah satu pendekatan yang dapat digunakan adalah Uji *Augmented Dickey-Fuller* (ADF). Akar unit mengindikasikan bahwa data cenderung tidak stasioner, sementara ketiadaan akar unit menunjukkan bahwa

data telah mencapai stasioneritas yang diperlukan untuk analisis deret waktu yang lebih akurat. Berdasarkan uji akar unit menggunakan uji ADF pada data, terdapat proses analisis statistika yang dilakukan yakni sebagai berikut:

1. Hipotesis

H_0 : Data tidak stasioner

H_1 : Data stasioner

2. Taraf Signifikansi

$\alpha = 0.05$

3. Daerah Kritis

Jika $p\text{-value} \leq \alpha$ atau $ADF_{hitung} > ADF_{tabel}$, maka tolak H_0

Jika $p\text{-value} > \alpha$ atau $ADF_{hitung} \leq ADF_{tabel}$, maka tidak tolak H_0

4. Statistik Uji ADF diformulasikan dalam Persamaan (2.1) sebagai berikut:

$$ADF_{hitung} = \frac{\delta}{Se(\delta)} \quad (2.1)$$

dimana:

δ : nilai dugaan parameter *autoregressive*

$Se(\delta)$: standar *error* dari δ

5. Keputusan

6. Kesimpulan

Suatu data deret waktu yang tidak stasioner dapat diubah menjadi data stasioner dengan dilakukan *differencing* pada data yang tersedia. *Differencing* didefinisikan sebagai proses menghitung perubahan atau selisih nilai observasi. *Differencing* memiliki bentuk umum yang dapat menghasilkan suatu kejadian atau data baru yang stasioner yang diuraikan dalam Persamaan (2.2) sebagai berikut:

$$w_t = Z_t - Z_{t-1} \quad (2.2)$$

dimana:

w_t : nilai variabel pada waktu ke t setelah *differencing*

Z_t : nilai variabel Z pada waktu ke-t

Z_{t-1} : nilai variabel Z pada waktu ke-(t - 1)

2.8 Kausalitas Granger

Persamaan regresi secara umum cenderung lebih fokus pada hubungan searah. Namun, pada kenyataannya, perilaku variabel ekonomi tidak hanya terbatas pada hubungan searah. Variabel ekonomi maupun variabel lain dapat menunjukkan adanya hubungan timbal balik yang dikenal dengan istilah kausalitas. Untuk mengidentifikasi hubungan sebab-akibat ini, uji kausalitas Granger dapat digunakan sebagai alat analisis (Bambang, 2012).

Uji kausalitas Granger didasarkan pada pengujian F yang bertujuan untuk menentukan apakah terdapat perubahan dalam satu variabel yang disebabkan oleh perubahan dalam variabel lainnya. Konsep ini menyatakan bahwa suatu variabel X dapat disebut sebagai *granger cause* variabel Y jika nilai-nilai sebelumnya dari variabel X dapat memberikan indikasi terhadap variabel Y pada waktu saat ini. Untuk melakukan uji kausalitas Granger, langkah-langkah berikut dapat diikuti:

1. Hipotesis:

H_0 : variabel X tidak menyebabkan variabel Y. Dengan kata lain, tidak ada hubungan sebab-akibat antara X dan Y.

H_1 : variabel X memiliki pengaruh pada variabel Y, sehingga ada hubungan sebab akibat antara X dan Y.

2. Kriteria pengujian

Jika p-value $< \alpha$, maka tolak H_0 , atau F-hitung $>$ F-tabel (α), tolak H_0 berarti terdapat pengaruh yang signifikan secara statistik.

Jika p-value $> \alpha$, maka tidak tolak H_0 , berarti tidak terdapat pengaruh yang signifikan secara statistik.

3. Statistik Uji kausalitas Granger diilustrasikan dalam Persamaan (2.3) sebagai berikut:

$$F = \left(\frac{n - k}{q} \right) \left(\frac{SSE_{terbatas} - SSE_{penuh}}{SSE_{penuh}} \right) \quad (2.3)$$

dengan:

$SSE_{terbatas}$: *Sum of Square* dipenuhi dari regresi yang dilakukan terhadap Y tanpa melibatkan *lag* variabel X yang diuraikan dalam Persamaan (2.4) seperti berikut:

$$Y_t = \sum \alpha_t Y_{t-i} + \varepsilon_t \quad (2.4)$$

SSE_{penuh} : *Sum of Square* dipenuhi dari regresi yang dilakukan terhadap Y dengan melibatkan *lag* variabel X yang ditulis dalam Persamaan (2.5) seperti berikut:

$$Y_t = \sum \alpha_t Y_{t-i} + \sum \beta_t Y_{t-i} + \varepsilon_t \quad (2.5)$$

dengan:

n : banyaknya pengamatan

k : banyaknya parameter model penuh

q : banyaknya parameter model terbatas

(Bambang, 2012).

2.9 Panjang *Lag* Optimum

Penentuan panjang *lag* yang optimal menjadi krusial dalam upaya untuk menangkap pengaruh variabel satu terhadap variabel lainnya dalam sistem VAR (*Vector Autoregression*). Panjang *lag*, yang sering disimbolkan sebagai "order p ," dapat disesuaikan dengan berbagai kriteria informasi yang tersedia. Panjang *lag* yang terbaik untuk model VAR dapat diidentifikasi dengan melihat nilai minimum dari masing-masing kriteria informasi yang umumnya digunakan dalam analisis ini. Beberapa kriteria informasi yang sering digunakan adalah sebagai berikut:

1. *Akaike Information Criterion* (AIC)

Akaike Information Criteria (AIC) adalah salah satu kriteria untuk memilih model terbaik dengan mempertimbangkan jumlah parameter dalam model

tersebut (Pertiwi dkk., 2022). Model dengan kinerja terbaik ditentukan berdasarkan nilai AIC yang paling rendah dengan Persamaan (2.6) sebagai berikut:

$$AIC = \ln \frac{1}{T} \sum_t^T \left(\check{\epsilon}_t^{(p)} \right)^2 + m \frac{2}{T} \quad (2.6)$$

dimana $\check{\epsilon}_t^{(p)}$ merujuk pada residual yang diestimasi dari model VAR(p), m menyatakan jumlah variabel tak bebas, T adalah jumlah observasi yang tersedia, dan p merupakan panjang *lag* dari model VAR (Kirchgässner dan Wolters, 2007).

2. Bayesian Information Criterion (BIC)

Bayesian Information Criterion adalah suatu kriteria informasi yang didasarkan pada asumsi distribusi data bersifat eksponensial (Kasali dan Adeyemi, 2022). Persamaan (2.7) dan (2.8) merupakan rumus dari kriteria informasi BIC.

$$BIC = n \cdot \ln(\widehat{\sigma}_e^2) + k \cdot \ln(n) \quad (2.7)$$

$$\widehat{\sigma}_e^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_i)^2 \quad (2.8)$$

dimana:

x : data yang diamati

n : jumlah pengamatan

k : jumlah parameter bebas yang perlu di estimasi

$\widehat{\sigma}_e^2$: varians kesalahan

2.10 Kointegrasi Johansen

Sebelum melakukan pemodelan VECM harus dilakukan uji kointegrasi. Konsep kointegrasi pada dasarnya untuk melihat keseimbangan jangka panjang di antara

variabel-variabel yang diobservasi. Persamaan yang mengandung penyesuaian jangka panjang dan jangka pendek terhadap perubahan y_t dapat didefinisikan dalam Persamaan (2.9) sebagai berikut:

$$\Delta y_t = \Pi y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta y_{t-1} + \varepsilon_t \quad (2.9)$$

dimana:

y_t : Variabel endogen pada waktu ke- t

p : Panjang *lag*

ε : Residual

Kointegrasi merupakan kombinasi linier dari variabel-variabel yang *non-stasioner*, dimana semua variabel tersebut harus terintegrasi pada orde atau derajat yang sama. Apabila tidak ada hubungan kointegrasi maka analisis dilakukan dengan metode VAR *difference* dan apabila memiliki hubungan kointegrasi maka analisis VECM dapat dilakukan.

Pengujian adanya kointegrasi dapat dilakukan dengan menggunakan Uji Johansen. Uji Johansen menggunakan analisis *trace statistic* dan atau statistik uji nilai eigen maksimum dan nilai kritis pada tingkat kepercayaan $\alpha = 5\%$ dengan langkah - langkah sebagai berikut:

1. Hipotesis

H_0 : tidak terdapat r persamaan kointegrasi

H_1 : terdapat r persamaan kointegrasi

2. Statistik Uji

Statistik uji *trace* ditransformasikan dalam Persamaan (2.10) sebagai berikut:

$$LR_{tr}(r|k) = -T \sum_{i=r+1}^k \log(1 - \lambda_i) \quad (2.10)$$

Statistik uji nilai eigen maksimum ditulis dalam Persamaan (2.11) sebagai berikut:

$$LR_{max}(r|r+1) = -T \log(1 - \lambda_{r+1}) = LR_{tr}(r|k) - LR_{tr}(r+1|k) \quad (2.11)$$

Untuk $r = 0, 1, \dots, k-1$

dimana:

λ_i : nilai eigen *value* terbesar ke-1 dari matriks $\prod(\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n)$

T : Jumlah observasi yang teramati

k : banyaknya variabel dependen

3. Kriteria:

H_0 ditolak jika uji *trace* dan atau uji nilai eigen maksimum $> \alpha = 5\%$ atau *p-value* $< \alpha = 5\%$ (Kirchgässner dan Wolters, 2007).

2.11 Vector Autoregressive (VAR)

Secara umum, dalam sistem dinamis, hubungan antara variabel-variabel seringkali tidak dapat dijelaskan hanya dengan satu model persamaan statis. Sebaliknya, diperlukan beberapa persamaan yang bersifat dinamis dan saling memengaruhi satu sama lain untuk menjelaskan hubungan tersebut. Penggunaan metode VAR adalah pilihan yang tepat ketika melakukan analisis data pada data runtun waktu yang melibatkan lebih dari satu variabel. Metode VAR adalah kerangka kerja berbasis sistem persamaan yang menyatakan bahwa setiap variabel adalah hasil dari kombinasi linier dari konstanta serta *lag* variabel-variabel lain dalam sistem tersebut (Enders, 1995). Model VAR dapat dijelaskan melalui Persamaan (2.12) sebagai berikut:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_P Y_{t-P} + \varepsilon_t \quad (2.12)$$

dimana:

- Y_t : elemen vektor observasi pada waktu t yang memiliki dimensi $n \times 1$
- Φ_i : matriks parameter vector autoregressive ordo ke- p berukuran $n \times n$
- p : panjang *lag* optimal
- Y_{t-p} : vektor pengamatan pada waktu ke- $t - p$
- ε_t : vektor dampak dari guncangan (*shock*) terhadap setiap variable dengan dimensi $n \times 1$.

Apabila data yang digunakan menunjukkan sifat stasioner pada tingkat *differencing* yang sama dan memiliki hubungan kointegrasi, maka model di atas dapat dikombinasikan dengan *Error Correction Model* (ECM) untuk membentuk model VECM.

2.12 Vector Error Correction Model (VECM)

Model VECM merupakan varian dari model VAR yang dikembangkan khusus untuk data non-stasioner yang menunjukkan adanya hubungan kointegrasi (Enders, 1995). Keberadaan model VECM memiliki nilai yang signifikan karena mampu memberikan estimasi efek jangka pendek serta efek jangka panjang dalam data runtun waktu. Bentuk umum dari VECM (p), dimana p merupakan jumlah *lag* dari variabel endogen dengan rank kointegrasi $r \leq k$, dapat dinyatakan dalam Persamaan (2.13) sebagai berikut:

$$\Delta Y_t = \Pi Y_{t-1} + \Gamma_1 \Delta Y_{t-1} + \dots + \Gamma_i \Delta Y_{t-i} + \varepsilon_t \quad (2.13)$$

dimana:

- ΔY_t : vektor pembeda pertama variabel endogen
- Y_{t-p} : vektor pengamatan pada waktu ke- $t - p$
- Π : matiks koefisien dari kointegrasi ($\Pi = \alpha\beta'$; α = vektor *adjustment* (parameter jangka pendek) dan β = vector kointegrasi (parameter jangka panjang))

- Γ_i : koefisien matriks variable endogen ke- i
 ε : vektor residual

2.13 Uji Asumsi Residual

Uji asumsi residual adalah proses penting dalam statistika, terutama dalam analisis deret waktu yang digunakan untuk menguji kelayakan pada model. Asumsi residual ini merujuk pada nilai residual (*error*) yang dihasilkan oleh model statistik harus menunjukkan sifat *white noise*. Namun, menurut Armstrong (2007), pemeriksaan asumsi-asumsi dapat dianggap sebagai aspek sekunder dalam peramalan, sebab yang paling esensial adalah kemampuan model dalam menghasilkan peramalan yang akurat.

Faradilla dan Suharsono (2023), menyatakan bahwa uji asumsi *white noise* dalam uji residual digunakan untuk mengevaluasi apakah residual yang dihasilkan adalah independen dan memiliki karakteristik yang identik. Menurut Wei (2006), pengujian asumsi residual *white noise* dapat dilakukan menggunakan metode Ljung-Box 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 Signifikansi
 - $\alpha = 0.05$
- c) Daerah Kritis
 - Jika $p\text{-value} \leq \alpha$, maka tolak H_0
 - Jika $p\text{-value} > \alpha$, maka tidak tolak H_0
- d) Statistik Uji Ljung Box dituliskan dalam Persamaan (2.14) sebagai berikut:

$$Q_{hitung} = n(n + 2) \sum_{i=1}^m \frac{\rho_i^2}{(n - i)} \quad (2.14)$$

dimana:

n : banyaknya data pengamatan

ρ_i : autokorelasi *lag* ke i

m : jumlah *lag*

- e) Keputusan
- f) Kesimpulan

2.14 *Machine learning*

Machine Learning (ML) adalah bagian dari AI yang berfokus pada kemampuan sistem untuk belajar dari data (Cholissodin dkk., 2019). *Machine learning* memiliki ciri khas yaitu adanya proses pelatihan, sehingga dalam ML data latih (*training*) dibutuhkan untuk proses pelatihan. Untuk mencapai hasil optimal saat pengujian, metode ML bergantung pada penggunaan data yang valid sebagai materi pembelajaran selama proses pelatihan sebelum diterapkan pada pengujian (Cholissodin dkk., 2019).

Berdasarkan teknik pembelajaran, ML diklasifikasikan menjadi tiga yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning* (Sidik dan Ansawarman, 2022). *Supervised learning* adalah salah satu pendekatan ML menggunakan kumpulan data yang telah dilengkapi dengan label (*labeled data*) untuk melatih mesin. Hal ini memungkinkan mesin untuk mengidentifikasi label *input* menggunakan fitur yang ada, sehingga mesin dapat melakukan prediksi dan klasifikasi. *Unsupervised learning* merupakan suatu jenis algoritma ML yang dimanfaatkan untuk menganalisis kumpulan data yang terdiri dari *input* data tanpa *respons* yang telah diberi label sebelumnya. Sedangkan, *reinforcement learning* adalah jenis algoritma ML yang memungkinkan agen perangkat lunak (*software agent*) untuk belajar dan beroperasi secara otomatis dengan tujuan menentukan perilaku ideal yang dapat mengoptimalkan kinerja algoritma. Beberapa contoh tugas yang termasuk dalam *reinforcement learning* meliputi

pengambilan keputusan secara *real-time*, navigasi robot, pembelajaran tugas-tugas kompleks, pengembangan keterampilan, dan kecerdasan buatan dalam permainan (*game AI*) (Sidik dan Ansawarman, 2022).

2.15 Deep Learning

Menurut Lien Minh, dkk. (2018), *deep learning* merupakan salah satu subdisiplin dalam domain ML. *Deep learning* memiliki kemampuan untuk mengenali hubungan yang bersifat nonlinier, tersembunyi dan mengekstrak fitur-fitur yang signifikan dari data yang kompleks serta *noisy*, tanpa perlu bergantung pada pengetahuan manusia atau asumsi-asumsi ekonomi. Tujuan dari *deep learning* adalah menciptakan representasi data yang hierarkis melalui berbagai lapisan pemrosesan data. Beberapa algoritma yang termasuk dalam domain *Deep Learning* mencakup *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), dan *Long Short Term Memory* (LSTM). Salah satu algoritma *deep learning* yang cocok untuk memproses data *time series* adalah LSTM.

2.16 Normalisasi dan Denormalisasi Data

Normalisasi data adalah suatu tahap penting yang melibatkan transformasi data ke dalam bentuk yang sesuai untuk analisis data mining. Normalisasi data meningkatkan kemampuan model untuk mencapai konvergensi yang lebih baik selama proses pelatihan.

Menurut Munkhdalai, dkk. (2019), terdapat beberapa teknik normalisasi yang sering digunakan yaitu skala logaritmik, normalisasi *min-max*, dan normalisasi *z-score*. Ketika menggunakan jaringan saraf tiruan sebagai model prediksi, teknik skala logaritmik kurang cocok karena normalisasi dapat membuat setiap nilai menjadi lebih stabil untuk mengatasi masalah gradien yang menghilang atau

melonjak. Di sisi lain, teknik *z-score* bermanfaat ketika nilai minimum dan maksimum dari data deret waktu tidak diketahui.

Dengan demikian, skala logaritmik biasanya tidak digunakan dalam konteks jaringan saraf tiruan karena efeknya yang tidak diinginkan pada perilaku gradien. Sementara itu, teknik *min-max* dan *z-score* memiliki aplikasi yang lebih luas, dengan *min-max* sesuai untuk data dengan rentang yang terbatas antara 0 hingga 1, dan *z-score* sesuai ketika informasi tentang rentang data tidak lengkap. Namun, perlu diperhatikan bahwa *z-score* lebih sesuai untuk data deret waktu yang bersifat stasioner, dimana data bersifat stasioner tidak selalu mungkin dalam semua situasi.

1. Normalisasi *Min-max*

Metode normalisasi *min-max* adalah teknik yang digunakan dengan mengubah nilai data masukan asli menjadi nilai dalam rentang 0 hingga 1. Metode normalisasi *min-max* dapat dijelaskan melalui Persamaan (2.15) berikut ini.

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (2.15)$$

dimana:

- 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

Sebelum menghitung tingkat akurasi hasil prediksi, perlu dilakukan denormalisasi terhadap keluaran dari suatu model. Denormalisasi adalah tahap yang melibatkan pengembalian nilai-nilai hasil peramalan ke bentuk data asli sebelum proses normalisasi dilakukan. Proses denormalisasi dapat dijelaskan menggunakan Persamaan (2.16) berikut ini (Dewi dkk., 2018).

$$x = x_{min} + (x'(x_{max} - x_{min})) \quad (2.16)$$

dimana:

- x' : Nilai hasil normalisasi
- x : Nilai hasil denormalisasi
- x_{max} : Nilai maksimal variabel x
- x_{min} : Nilai minimal variabel x

2. Normalisasi z -score

Metode normalisasi z -score didasarkan pada rata-rata dan standar deviasi. Metode ini dapat bekerja dengan baik pada kasus yang tidak diketahui nilai minimum dan maksimum sebenarnya dari data input atau memiliki *outlier* yang berpengaruh besar terhadap rentang data. Normalisasi z -score dapat mengurangi efek *outlier* dan menghasilkan data yang lebih terdistribusi dengan baik untuk analisis lebih lanjut. Metode normalisasi z -score dapat dijelaskan melalui Persamaan (2.17) berikut ini (Ambarwari dkk., 2020).

$$x' = \frac{x - \text{mean } x}{std} \quad (2.17)$$

dimana:

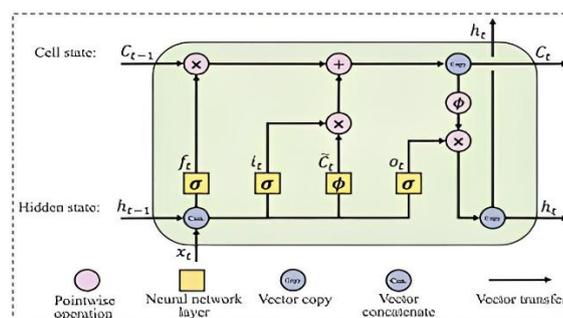
- x' : Nilai hasil normalisasi z -score
- x : Nilai pada variabel x yang dinormalisasi
- $\text{mean } x$: Nilai rata-rata pada variabel x
- std : Standar deviasi

Proses denormalisasi dari metode normalisasi z -score dapat dijelaskan menggunakan Persamaan (2.18) berikut ini.

$$x = \text{mean } x + (x'.std) \quad (2.18)$$

2.17 Long Short Term Memory

Long Short Term Memory (LSTM) sering disebut sebagai jenis jaringan saraf yang memiliki fleksibilitas dalam beradaptasi, sehingga bentuknya dapat disesuaikan dengan kebutuhan aplikasi tertentu (Sanjaya dan Heksaputra, 2020). Model LSTM merupakan pengembangan dari model *Recurrent Neural Network* (RNN) yang diperkenalkan sebagai solusi untuk mengatasi masalah Gradien yang menghilang (Hochreiter dan Schmidhuber, 1997). Kondisi dari permasalahan *Vanishing Gradient* dapat menyebabkan pembelajaran model menjadi terlalu lambat atau berhenti sama sekali (Yadav dkk., 2020). Model LSTM dapat mengatasi masalah gradien yang menghilang dengan memperkenalkan sel memori (*Memory Cell*) untuk menyimpan nilai-nilai selama interval waktu tertentu, serta dengan memperkenalkan tiga pintu (*gate*), yaitu Pintu Masukan (*Input Gate*), Pintu Keluar (*Output Gate*), dan Pintu Lupakan (*Forget Gate*) untuk mengendalikan aliran informasi yang masuk dan keluar dari sel memori. Hal ini memungkinkan LSTM untuk dapat lebih baik dalam menangkap ketergantungan jangka panjang (*Long-Term Dependencies*) (Minaee dkk., 2020). Arsitektur LSTM diilustrasikan pada Gambar 1 berikut:



Gambar 1. Arsitektur LSTM

(Sumber: Luo dkk., 2021)

Menurut Luo, dkk. (2021), model LSTM memiliki kemampuan untuk mengontrol aliran informasi ke dalam dan keluar dari sel memori (*cell state*) dengan teliti menggunakan struktur lapisan pintu (*gate*). Terdapat empat lapisan utama (tiga

lapisan gerbang dan satu lapisan *tanh*) yang berperan dalam mengatur aliran informasi dalam LSTM.

1. *Forget Gate*

Gerbang awal dikenal sebagai *forget gate* yang bertujuan untuk menentukan informasi mana dari langkah-langkah sebelumnya yang perlu dihapus. Gerbang ini memanfaatkan fungsi aktivasi *sigmoid*, sehingga hasil dari operasi *forget gate* yang disimbolkan sebagai f_t menghasilkan nilai di antara 0 atau 1 (Le dkk., 2019). Nilai ini menunjukkan sejauh mana informasi sebelumnya akan dihapus dari sel memori. Jika nilainya adalah 1, maka semua data akan tetap disimpan, sementara jika nilainya adalah 0, maka semua data akan dihapus. Berikut disajikan Persamaan (2.19) dari *forget gate*.

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (2.19)$$

dimana:

f_t : *Forget gate*

σ : Fungsi *sigmoid*

W_f : Nilai bobot 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*

2. *Input Gate*

Input Gate merupakan gerbang yang menentukan dan menyimpan informasi dari *input* baru (X_t) ke dalam keadaan sel (*cell state*) serta memperbarui keadaan sel tersebut. Langkah ini terdiri dari dua bagian, yaitu lapisan *sigmoid* dan lapisan *tanh*. Pertama, lapisan *sigmoid* menentukan apakah informasi baru harus diperbarui atau diabaikan (0 atau 1), dan kedua, fungsi *tanh* memberikan bobot pada nilai-nilai yang lolos, menentukan tingkat pentingnya (-1 hingga 1) (Le dkk., 2019). Berikut disajikan Persamaan (2.20), dan (2.21) dari *input gate*.

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (2.20)$$

$$\check{c}_t = \varphi(W_c \cdot [h_{t-1}, X_t] + b_c) \quad (2.21)$$

dimana:

- i_t : *Input gate*
- \check{c}_t : Nilai baru yang ditambahkan ke *cell state*
- σ : Fungsi *sigmoid*
- φ : Fungsi *tangen hiperbolik*
- W_i : Nilai bobot untuk *input gate*
- W_c : Nilai bobot 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*

Kemudian, *cell state* yang lama diperbarui menjadi *cell state* yang baru dengan mengalikan *cell state* yang lama dengan nilai dari *forget gate* (f_t) untuk menghapus informasi yang telah ditentukan oleh *forget gate*. Selanjutnya, nilai tersebut akan ditambahkan dengan $i_t * \check{c}_t$ yang merupakan nilai baru untuk memperbarui *cell state*. Berikut disajikan Persamaan (2.22) merupakan persamaan *cell state* yang telah dihasilkan.

$$C_t = f_t * C_{t-1} + i_t * \check{c}_t \quad (2.22)$$

dimana:

- C_t : *Cell state*
- f_t : *Forget gate*
- C_{t-1} : *Cell state* sebelum orde ke-t
- i_t : *Input gate*
- \check{c}_t : Nilai baru yang dapat ditambahkan ke *cell state*.

3. *Output Gate*

Gerbang terakhir dalam LSTM adalah *output gate*, yang bertanggung jawab untuk menghasilkan keluaran akhir berdasarkan *cell state* yang telah diperbarui. Hasil dari *cell state* dimasukkan ke dalam lapisan *tanh* dan selanjutnya dikalikan dengan *sigmoid gate* agar keluaran sesuai dengan keputusan sebelumnya. Berikut disajikan Persamaan (2.23) dari *output gate*.

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) * \varphi(C_t) \quad (2.23)$$

dimana:

o_t : *Cell state*

σ : Fungsi *sigmoid*

W_o : Nilai bobot untuk *output gate*

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

x_t : Nilai *input* pada orde ke-t

b_o : Nilai bias pada *output gate*

C_t : *Cell state*

φ : Fungsi *tangen hiperbolik*

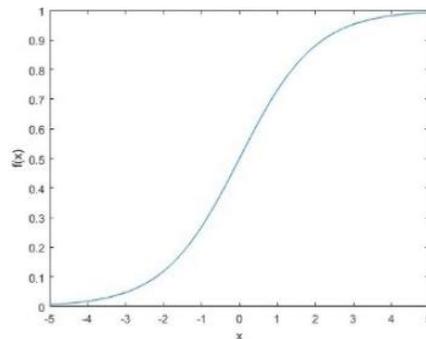
2.18 Fungsi Aktivasi

Menurut Julpan, dkk. (2015), fungsi aktivasi adalah sebuah komponen penting yang digunakan dalam jaringan saraf dan berfungsi untuk mengatur pengaktifan atau non-aktifkan *neuron*. Fungsi ini memiliki peran krusial dalam memungkinkan jaringan saraf untuk memproses data secara non-linier, sehingga mampu menangani masalah yang kompleks dan merepresentasikan hubungan yang rumit dalam data. Pada penelitian sebelumnya, fungsi aktivasi yang terkenal seperti fungsi *sigmoid* dan *tanh* telah digunakan dalam berbagai jaringan *deep learning* (Saha dkk., 2019).

1. Fungsi Aktivasi *Sigmoid*

Fungsi *sigmoid* yang diilustrasikan pada Gambar 2 merupakan fungsi nonlinier dengan nilai berkisar antara 0 hingga 1. Berikut disajikan Persamaan (2.24) dari fungsi aktivasi *sigmoid* (Feng dan Lu, 2019).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.24)$$



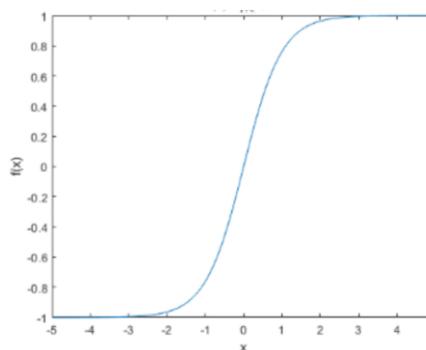
Gambar 2. Fungsi Aktivasi *Sigmoid*

(Sumber: Feng dan Lu, 2019)

2. Fungsi Aktivasi *Tanh*

Fungsi *tanh* atau disebut juga fungsi tangen hiperbolik yang diilustrasikan pada Gambar 3 merupakan fungsi nonlinier dengan keluaran yang berpusat pada nol dan mengontraksi angka riil ke rentang nilai berkisar antara -1 hingga 1. Berikut disajikan Persamaan (2.25) dari fungsi aktivasi *tanh* (Feng dan Lu, 2019).

$$f(x) = \frac{\sinh x_i}{\cosh x_i} = \frac{e^{x_i} - e^{-x_i}}{e^{x_i} + e^{-x_i}} \quad (2.25)$$



Gambar 3. Fungsi Aktivasi *Tanh*

(Sumber:Feng dan Lu, 2019)

2.19 Hybrid VECM – LSTM

Metode *Hybrid* adalah pendekatan peramalan yang menggabungkan dua atau lebih metode untuk meningkatkan kinerja peramalan. Metode *Hybrid* telah terbukti lebih efektif dibandingkan dengan metode statistik atau *Deep Learning* tunggal dalam tugas peramalan dalam mengestimasi ketidakpastian yang terkait dengan prediksi tersebut, terutama dalam membentuk interval prediksi (Mathonsi dan van Zyl, 2022). Peramalan dengan metode *hybrid* yang lebih akurat diperoleh dengan memanfaatkan kelebihan dan menghindari kekurangan dari pendekatan statistik klasik dan pembelajaran mesin.

Model VECM sebagai pendekatan statistika klasik yang mempertimbangkan adanya kointegrasi dalam data dan model LSTM sebagai pendekatan pembelajaran mesin telah mencapai keberhasilan dalam domain linier dan nonliniernya masing-masing. Penerapan model VECM dalam permasalahan nonlinier yang kompleks mungkin tidak memadai. Sedangkan LSTM, dapat diterapkan dengan baik pada data berpola nonlinier. Namun, diperlukan sejumlah besar data untuk memahami pola nonlinier, dan LSTM sendiri tidak cukup untuk mengatasi pola linier dan nonlinier secara bersamaan. Dengan demikian, berdasarkan pertimbangan tersebut diperlukan penggunaan model *hybrid*. Diasumsikan bahwa dalam model gabungan deret waktu terdapat dua elemen dasar, yakni elemen linier dan elemen nonlinier yang dapat dinyatakan dalam Persamaan (2.26) sebagai berikut (Zhang, 2003).

$$y_t = L_t + N_t + a_t \quad (2.26)$$

dimana:

y_t : data pengamatan deret waktu pada waktu ke-t

L_t : Komponen linier ke-t

N_t : Komponen nonlinier ke t

t : indeks waktu

a_t : *error*

Metode *hybrid* VECM-LSTM melibatkan dua tahap penting. Tahap pertama adalah penerapan metode VECM untuk memodelkan komponen linier data, sedangkan tahap kedua menggunakan metode LSTM untuk memodelkan komponen nonlinier. Setelah kedua tahap tersebut selesai, model-model ini digabungkan, mencakup aspek linier dan nonlinier dari data. Proses pemodelan ini melibatkan tiga tahap utama:

1. Model VECM dibangun menggunakan data aktual.
2. Dua model LSTM dibangun untuk data hasil prediksi dan residual yang diperoleh melalui model VECM.
3. Menggabungkan hasil dari kedua model LSTM untuk melakukan prediksi dan peramalan.

Proses peramalan dilakukan dengan menerapkan persamaan peramalan *Hybrid* VECM-LSTM yang dituliskan dalam Persamaan (2.27) sebagai berikut:

$$Y'_t = L'_t + N'_t \quad (2.27)$$

dimana:

- Y'_t : hasil peramalan dari model *hybrid* ke t
- L_t : hasil peramalan dari komponen linier ke t
- N_t : hasil peramalan dari komponen nonlinier ke t
- t : indeks waktu

2.20 Evaluasi Model

Evaluasi terhadap model digunakan untuk menentukan ketepatan model dengan melihat seberapa besar atau kecil kesalahan yang dihasilkan dalam proses prediksi (Ferdinandus dkk., 2023). Pada penelitian ini dipilih metrik evaluasi model yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

1. *Root Mean Square Error* (RMSE)

Evaluasi model RMSE mengukur besarnya kesalahan rata-rata antara nilai yang diprediksi dan nilai sebenarnya. Dengan demikian, RMSE adalah rata-rata jarak vertikal antara nilai aktual dan nilai hasil prediksi yang ada pada garis *fitting*. Secara sederhana, evaluasi model RMSE merupakan akar kuadrat dari *Mean Square Error* (MSE) diuraikan dalam Persamaan (2.28) sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (2.28)$$

dimana:

n : banyaknya data yang diamati

Y_t : nilai data actual pada periode ke-t

\hat{Y}_t : nilai data hasil peramalan pada periode ke-t

2. *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error merupakan salah satu metrik evaluasi model yang paling umum digunakan. Metrik evaluasi ini digunakan untuk mengukur persentase kesalahan antara hasil prediksi dan nilai aktual. Secara sederhana, MAPE adalah hasil dari rata-rata kesalahan absolut selama periode tertentu yang kemudian dikalikan dengan 100% untuk mendapatkan hasil dalam bentuk persentase (Pertiwi et al., 2022). Berikut disajikan Persamaan (2.29) yang dipakai dalam menghitung MAPE (Yao dkk., 2023).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| 100\% \quad (2.29)$$

dimana:

Y_t : data aktual pada periode ke-t

\hat{Y}_t : data peramalan pada period ke-t

n : banyaknya data yang di amat

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Waktu dan tempat penelitian ini yaitu sebagai berikut:

a. Tempat Penelitian

Penelitian ini dilakukan secara studi pustaka di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Lokasi bertempat di Jalan Prof. Dr. Soemantri Brojonegoro No. 1, Gedong Meneng, Bandar Lampung.

b. Waktu Penelitian

Penelitian ini dilakukan dimulai pada Semester Ganjil tahun akademik 2023/2024, tepatnya pada bulan Agustus 2023. Penelitian ini dibagi menjadi tiga tahap, tahap pertama dimulai dari studi literatur pengumpulan jurnal ataupun buku yang berkaitan dengan topik penelitian yang akan digunakan sebagai referensi dalam penyusunan proposal penelitian hingga akhir. Selanjutnya, yaitu pengumpulan data yang akan digunakan sebagai bahan untuk dilakukan penelitian dan penyusunan draf proposal penelitian. Tahap ke-2 merupakan tahap pengerjaan program mulai dari *preprocessing* data, membangun model VECM, *splitting* data, membangun model *hybrid* VECM-LSTM, dan evaluasi kinerja model. Tahap terakhir pada penelitian ini yaitu penyusunan hasil pengujian dan analisis dalam bentuk draf laporan yang akan disampaikan pada seminar hasil serta sidang komprehensif.

3.2 Data dan Alat Penelitian

Data dan alat yang digunakan dalam penelitian ini yaitu sebagai berikut:

a. Data Penelitian

Data yang digunakan pada penelitian ini merupakan data sekunder yang diperoleh dari dua sumber utama. Data pertama adalah data harian harga penutupan saham PT Kalbe Farma Tbk. yang diperoleh melalui situs Yahoo Finance (<https://finance.yahoo.com>). Data kedua adalah data nilai tukar mata uang Rupiah terhadap Dolar yang diperoleh melalui situs resmi Bank Indonesia (<http://www.bi.go.id>). Data yang digunakan mencakup rentang waktu dari 4 Januari 2010 hingga 7 Agustus 2023, dengan jumlah data sebanyak 2918 observasi.

Tabel 2. Data Harga Penutupan Saham dan Nilai Tukar Rupiah terhadap Dolar

<i>Date</i>	<i>Close Price</i>	Kurs Rupiah (USD)
2010-01-04	264	9075
2010-01-06	270	9210
2010-01-07	270	9094
...
2023-08-03	1885	15171
2023-08-04	1875	15198
2023-08-07	1850	15168

b. Alat Penelitian

Adapun alat yang digunakan dalam penelitian ini yaitu sebagai berikut:

1. Perangkat keras (*Hardware*)

Perangkat keras yang digunakan pada penelitian ini yaitu:

- Processor Intel(R) Core(TM) i3-3217U CPU @ 1.80GHz ~ 1.70 GHz
- Installed RAM 4,00 GB

2. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan pada penelitian ini yaitu sebagai berikut:

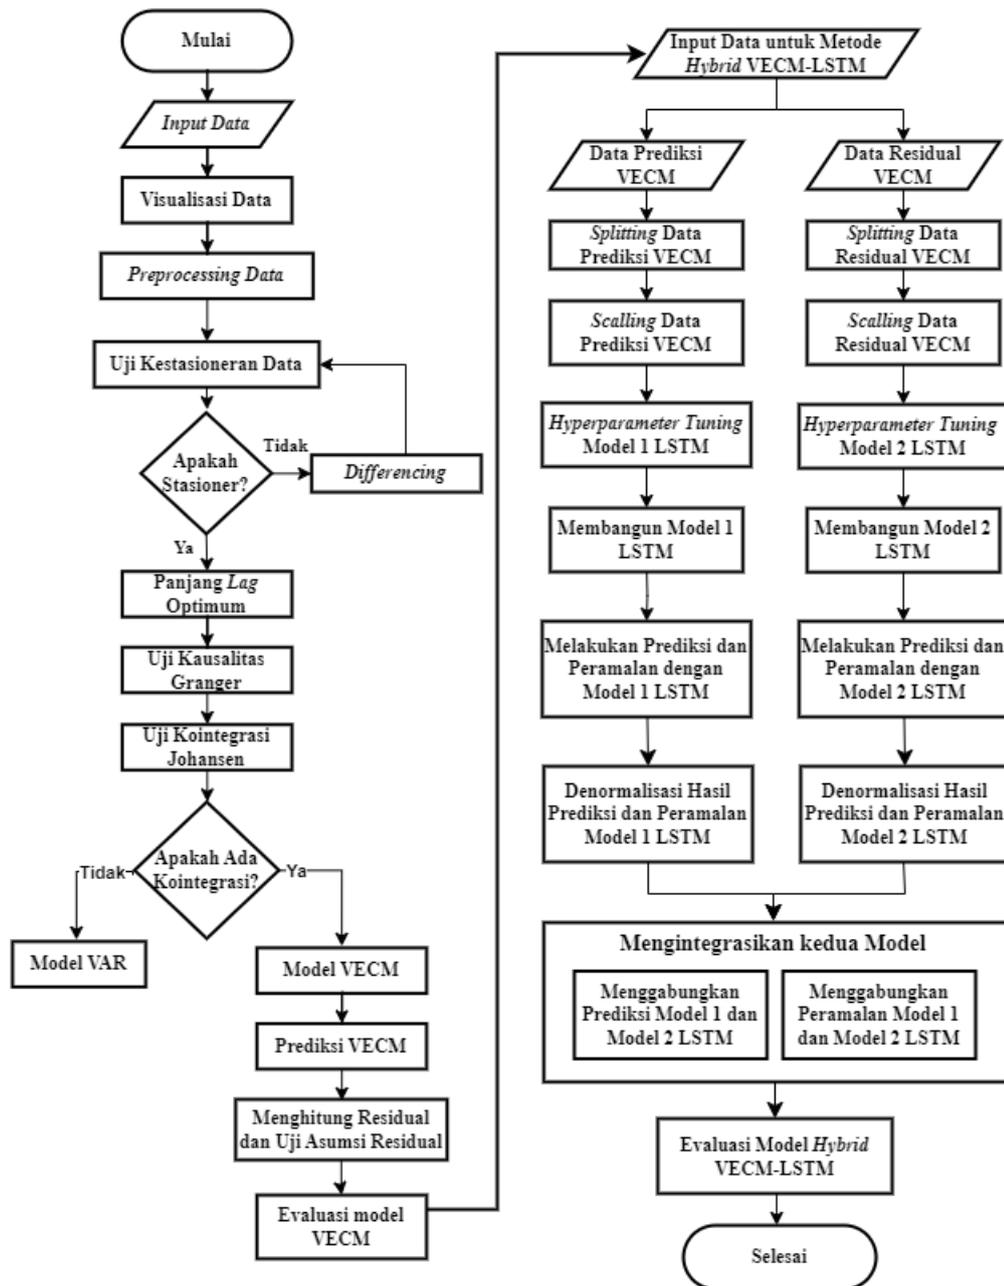
- Sistem Operasi Windows 10 Pro 64-bit
- *Google Colaboratory*

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

- *Tensorflow* 2.12.0
- *Scikit-learn* 1.2.2
- *NumPy* 1.23.5
- *Pandas* 1.5.3
- *Matplotlib* 3.7.1
- *Statsmodels* 0.14.0

3.3 Metode Penelitian

Penelitian ini dilakukan dengan langkah awal studi literatur dari jurnal-jurnal, buku, dan artikel yang penulis peroleh melalui internet maupun media lain. 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. Adapun alur pada penelitian ini yang dipresentasikan dalam bentuk *flowchart* pada Gambar 4 sebagai berikut.



Gambar 4. Flowchart Metode Hybrid VECM-LSTM

Berdasarkan *flowchart* penelitian pada Gambar 4, berikut penjelasan setiap tahap yang dilakukan.

1. Input Data

Data yang digunakan pada penelitian ini merupakan data harga penutupan saham PT Kalbe Farma Tbk dan nilai tukar mata uang Rupiah terhadap Dolar

yang telah dilakukan *merging* kumpulan data sehingga memiliki tanggal yang sama.

2. Melakukan Visualisasi Data

Visualisasi data digunakan untuk melihat dan mengidentifikasi tren, pola, dan potensi keterkaitan antara variabel harga penutupan saham PT Kalbe Farma Tbk dan nilai tukar mata uang Rupiah terhadap Dolar.

3. Melakukan *Preprocessing* Data

Preprocessing data dilakukan untuk melihat ada atau tidak *missing value* dalam kumpulan data.

4. Melakukan Uji Stasioneritas Data

Uji stasioneritas data pada rata-rata menggunakan uji akar unit yaitu *Dickey Fuller test*. Jika data tidak stasioner maka akan dilakukan *differencing* data. Namun, jika data telah stasioner maka langkah selanjutnya dilakukan.

5. Menentukan Panjang *Lag* Optimum

Menentukan panjang *lag* yang terbaik dilakukan dengan melihat nilai minimum dari masing-masing kriteria informasi.

6. Melakukan Uji Kausalitas Granger

Uji kausalitas granger digunakan untuk mengetahui hubungan sebab akibat antar kedua variabel yaitu harga penutupan saham PT Kalbe Farma Tbk dan nilai tukar mata uang Rupiah terhadap Dolar.

7. Melakukan Uji Kointegrasi Johansen

Uji kointegrasi Johansen dilakukan untuk mengetahui hubungan jangka panjang antar kedua variabel. Jika tidak memenuhi asumsi uji kointegrasi maka model yang dapat digunakan adalah model VAR. Namun jika memenuhi asumsi uji kointegrasi maka model yang digunakan adalah model VECM dan langkah selanjutnya dapat dilakukan.

8. Membangun Model VECM

Tahap selanjutnya yaitu membangun model VECM menggunakan nilai *lag* optimum dan nilai *rank* yang telah di peroleh pada tahap sebelumnya.

9. Melakukan Prediksi dengan Model VECM
Proses prediksi menggunakan model VECM melibatkan kumpulan data yang terdiri dari dua variabel yaitu harga penutupan saham PT Kalbe Farma Tbk dan nilai tukar mata uang Rupiah terhadap Dolar.
10. Menghitung Residual dan Uji Asumsi Residual
Tahap selanjutnya, menghitung nilai residual dengan mengurangi nilai pada data aktual dengan nilai hasil prediksi. Kemudian uji asumsi residual yang digunakan adalah uji Ljung-Box untuk asumsi *white noise*.
11. Melakukan evaluasi model VECM
Evaluasi model VECM dilakukan dengan metrik evaluasi yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).
12. Input Data Prediksi dan Residual model VECM
Input kedua kumpulan data digunakan untuk proses pembangunan model *hybrid* VECM-LSTM.
13. Melakukan *Splitting* Data
Splitting untuk kedua data dilakukan dengan 2 skema. Skema pertama dengan *splitting* 70% data *training*, 30% data *testing*. Skema kedua sebesar 80% data *training* dan 20% data *testing*.
14. Melakukan *Scalling* Data
Scalling data pada data prediksi dari model VECM menggunakan normalisasi *min-max* dan data residual dari model VECM menggunakan normalisasi *z-score*.
15. Melakukan *Hyperparameter Tuning*
Pada tahap ini, terdapat 2 *hyperparameter tuning* yang dilakukan menggunakan *Grid Search*. *Hyperparameter tuning* model 1 LSTM melibatkan data prediksi VECM dan *hyperparameter* model 2 LSTM melibatkan data residual VECM.
16. Membangun model 1 LSTM dan model 2 LSTM
Model 1 LSTM dan model 2 LSTM dibangun menggunakan parameter terbaik yang diperoleh melalui *hyperparameter tuning*.

17. Melakukan Prediksi dan Peramalan

Terdapat 2 proses prediksi dan peramalan yang dilakukan. Pertama, akan dilakukan prediksi dan peramalan dengan model 1 LSTM menggunakan data prediksi VECM. Kedua, akan dilakukan prediksi dan peramalan dengan model 2 LSTM menggunakan data residual VECM.

18. Melakukan Denormalisasi

Tahap selanjutnya adalah melakukan denormalisasi data hasil prediksi dan peramalan kedalam bentuk data asli sebelum normalisasi dilakukan.

19. Menggabungkan Hasil Prediksi Model 1 dan Model 2 LSTM

Proses selanjutnya adalah menggabungkan hasil prediksi kedua model LSTM dengan proses operasi penjumlahan.

20. Menggabungkan Hasil Peramalan Model 1 dan 2 LSTM

Proses selanjutnya adalah menggabungkan hasil peramalan kedua model LSTM dengan proses operasi penjumlahan.

21. Melakukan Evaluasi Model *hybrid* VECM-LSTM

Evaluasi model *hybrid* VECM-LSTM dilakukan dengan metrik evaluasi yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

DAFTAR PUSTAKA

- Aboagye-Sarfo, P., 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(1), 62–73.
- Afifah, S. N., & Fauziyyah, N. (2023). Dampak Resesi 2023 terhadap Harga Saham di Indonesia. *MIZANIA: Jurnal Ekonomi Dan Akuntansi*, 3(1), 292–299.
- Agusta, A., Ernawati, I., & Muliawati, A. (2021). Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory. *Informatik : Jurnal Ilmu Komputer*, 17(2), 164 - 173.
- Ambarwari, A., Jafar Adrian, Q., & 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.
- Armstrong, J. S. (2007). Significance tests harm progress in forecasting. *International Journal of Forecasting*, 23(2), 321–327.
- Bambang, J. (2012). *Ekonometrika deret waktu : teori dan aplikasi*. IPB Pres, Bogor.
- Bayu Aji, A., & Surjandari, I. (2020). Hybrid vector autoregression-recurrent neural networks to forecast multivariate time series jet fuel transaction price. *IOP Conference Series: Materials Science and Engineering*, 909(1), <https://doi.org/10.1088/1757-899X/909/1/012079>.
- Cholissodin, I., Sutrisno, Soebroto, A. A., Hasanah, U., & Febiola, Y. I. (2019). *AI , MACHINE LEARNING & DEEP LEARNING (Teori & Implementasi)*. Fakultas Ilmu Komputer. Universitas Brawijaya, Malang.
- Christianingrum, R. (2022). Pengaruh Variabel Ekonomi Makro Terhadap Nilai Tukar Rupiah. *Jurnal Budget : Isu dan Masalah Keuangan Negara*, 4(1), 43–63.
- Dave, E., Leonardo, A., Jeanice, M., & Hanafiah, N. (2021). Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM. *Procedia Computer Science*, 179(2020), 480–487.

- Dewi, K., Adikara, P. P., & Adinugroho, S. (2018). Prediksi Indeks Harga Konsumen (IHK) Kelompok Perumahan, Air, Listrik, Gas dan Bahan Bakar Menggunakan Metode Support Vector Regression. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(10), 3856–3862.
- Eka, I., Pramesti, P., Fakultas Ekonomi, N., Bisnis, D., & Nurdianingsih, P. P. (2022). Pengaruh Inflasi, Nilai Tukar Kurs, Suku Bunga Sbi Terhadap Harga Saham. *Jurnal Management Risiko Dan Keuangan*, 1(3), 179–187.
- Enders, W. (1995). *Applied econometric time series*. Low State University, New York.
- Faradilla, S., & Suharsono, A. (2023). Peramalan Penjualan Produk Baja dan Besi di PT MSU dengan Pendekatan Metode ARIMA dan Single Moving Average. *Jurnal Sains dan Seni ITS*, 12(1), 2337-3520.
- Feng, J., & Lu, S. (2019). Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics: Conference Series*, 1237(2), doi:10.1088/1742-6596/1237/2/022030.
- Ferdinandus, Y. R. M., Kusriani, K., & Hidayat, T. (2023). Gold Price Prediction Using the ARIMA and LSTM Models. *Sinkron*, 8(3), 1255–1264.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
- Indonesia Central Securities Depository. (2023). *Statistik Pasar Modal Indonesia*. Publikasi PT Kustodian Sentral Efek Indonesia, Jakarta.
- Julpan, Nababan, E. B., & Zarlis, M. (2015). Bipolar Dalam Algoritma Backpropagation Pada Prediksi Kemampuan Siswa. *Jurnal Teknovasi*, 2(1), 103–116.
- Kasali, J., & Adeyemi, A. A. (2022). Model-Data Fit using Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), and The Sample-Size-Adjusted BIC. *Square: Journal of Mathematics and Mathematics Education*, 4(1), 43–51.
- Kirchgässner, G., & Wolters, J. (2007). *Introduction to modern time series analysis*. Springer Berlin Heidelberg, New York.
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) neural network for flood forecasting. *Water*, 11(7), 1-19.
- Lien Minh, D., Sadeghi-Niaraki, A., Huy, H. D., Min, K., & Moon, H. (2018). Deep learning approach for short-term stock trends prediction based on two-stream gated recurrent unit network. *IEEE Access*, 55392–55404.
- Luo, X., Zhang, D., & Zhu, X. (2021). Deep learning based forecasting of

photovoltaic power generation by incorporating domain knowledge. *Energy*, 225, <https://doi.org/10.1016/j.energy.2021.120240>.

Mankiw, N.G. 2007. *Makroekonomi*. Ed. Ke-6. Erlangga, Jakarta.

Mathonsi, T., & van Zyl, T. L. (2022). A Statistics and Deep Learning Hybrid Method for Multivariate Time Series Forecasting and Mortality Modeling. *Forecasting*, 4(1), 1–25.

Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2020). *Deep Learning Based Text Classification: A Comprehensive Review*. 1(1), 1–43.

Munkhdalai, L., Munkhdalai, T., Park, K. H., Lee, H. G., Li, M., & Ryu, K. H. (2019). Mixture of Activation Functions with Extended Min-Max Normalization for Forex Market Prediction. *IEEE Access*, 7, 183680–183691.

Pertiwi, A., Dewi, L. F., Toharudin, T., & Ruchjana, B. N. (2022). 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*, 2(1), 431–442.

Putri, V. A., & Mandayanti, E. (2021). Perspektif Perkembangan dan Tantangan Pasar Modal di Indonesia. *Jurnal Pendidikan Tambusai*, 5(3), 10904–10908.

Rahman, A. A., Permatasari, N., Yudhanto, W., & Sijabat, Y. P. (2023). Pengaruh Likuiditas dan Solvabilitas Terhadap Harga Saham pada Perusahaan Sektor Transportasi dan Logistik Periode 2019-2021. *GEMILANG: Jurnal Manajemen dan Akuntansi*, 3(1), 182–196.

Rosyida, H., Firmansyah, A., & Wicaksono, S. B. (2020). Volatilitas Harga Saham: Leverage, Ukuran Perusahaan, Pertumbuhan Aset. *JAS (Jurnal Akuntansi Syariah)*, 4(2), 196–208.

Saha, S., Nagaraj, N., Mathur, A., Yedida, R., & H R, S. (2019). Evolution of novel activation functions in neural network training for astronomy data: habitability classification of exoplanets. *European Physical Journal: Special Topics*, 229(16), 2629–2738.

Sanjaya, F. I., & Heksaputra, D. (2020). Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 7(2), 163–174.

Sari, N. N. P., & Yousida, I. (2022). Pengaruh Likuiditas Dan Profitabilitas Dan Ukuran Perusahaan Terhadap Harga Saham Pada Perusahaan Farmasi Yang Terdaftar Di Bursa Efek Indonesia. *Jurnal Ilmiah Ekonomi Bisnis*, 8(2), 209–220.

- Sayuti. (2020). Aplikasi Perhitungan Metode Peramalan. *Jurnal TEKNOVASI*, 1(1), 35–43.
- Sidik, A. D., & Ansawarman, A. (2022). Prediksi Jumlah Kendaraan Bermotor Menggunakan Machine Learning. *Formosa Journal of Multidisciplinary Research*, 1(3), 559–568.
- Suseno, I. S. (2014). *Sistem dan Kebijakan Nilai Tukar: Seri Kebanksentralan No. 12*. Pusat Pendidikan dan Studi Kebanksentralan BI, Jakarta.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods*. Addison Wesley, New York.
- Widarjono, A. (2005). *Ekonometrika : Teori dan Aplikasi Untuk Ekonomi dan Bisnis*. Ekonisia, Yogyakarta.
- Wijaya, P. S., & Siswanti, T. (2023). Pengaruh Return on Equity (Roe) Dan Earning Per Share (Eps) Terhadap Harga Saham Pada Perusahaan Sub Sektor Industri Dasar Dan Kimia Yang Terdaftar Di Bei Tahun 2018-2020. *JIMA Jurnal Ilmiah Mahasiswa Akuntansi*, 3(2), 149–162.
- Wikayanti, N. L. P. D., Aini, Q., & Fitriyani, N. (2020). Pengaruh Kurs Dolar Amerika Serikat, Inflasi, dan Tingkat Suku Bunga Terhadap Indeks Harga Saham Gabungan Dengan Vector Error Correction. *Eigen Mathematics Journal*, 03(01), 64–72.
- Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167(2019), 2091–2100.
- 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(65), 1-13, <https://doi.org/10.1007/s44196-023-00232-7>.
- 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.
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.