

**PENERAPAN MODEL *HYBRID VECTOR ERROR CORRECTION MODEL*
(VECM) – *BIDIRECTIONAL GATED RECURRENT UNIT* (BIGRU) UNTUK
PERAMALAN HARGA PENUTUPAN SAHAM PT INDOFOOD SUKSES
MAKMUR TBK DAN NILAI TUKAR MATA UANG**

Skripsi

Oleh

**DITA ELYSYIA YULIA PUTRI
NPM. 2117031114**



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

2025

ABSTRACT

***MULTIVARIATE TIME SERIES FORECASTING OF PT. INDOFOOD
SUKSES MAKMUR TBK STOCK CLOSING PRICE AND CURRENCY
EXCHANGE RATE WITH HYBRID METHOD VECTOR ERROR
CORRECTION MODEL (VECM) – BIDIRECTIONAL GATED RECURRENT
UNIT (BIGRU)***

By

Dita Elysia Yulia Putri

The closing price of stocks and the exchange rate of the rupiah against the US dollar show a close relationship and fluctuating characteristics. This relationship encourages the need for forecasting as a basis for decision making. This study builds two hybrid models, namely VECM-E_BiGRU and VECM-EP_BiGRU. The first model utilizes VECM residuals, while the second model uses VECM prediction results as input to BiGRU. VECM captures long-term linear patterns, while BiGRU recognizes bidirectional nonlinear patterns. Model evaluation shows that VECM-EP_BiGRU produces the most accurate prediction with a MAPE of 0.01227%, lower than VECM-E_BiGRU which has a MAPE of 0.773%. The Kolmogorov–Smirnov value results show that the residuals of the VECM-EP_BiGRU model are closest to the actual data distribution. The conclusion shows that VECM-EP_BiGRU is superior in modeling the closing price of PT Indofood Sukses Makmur Tbk shares and the rupiah exchange rate against the US dollar.

Keywords: Stock price, rupiah exchange rate, VECM, BiGRU, hybrid VECM–BiGRU, forecasting, time series.

ABSTRAK

PENERAPAN MODEL *HYBRID VECTOR ERROR CORRECTION MODEL* (VECM) – *BIDIRECTIONAL GATED RECURRENT UNIT* (BiGRU) UNTUK PERAMALAN HARGA PENUTUPAN SAHAM PT INDOFOOD SUKSES MAKMUR TBK DAN NILAI TUKAR MATA UANG

Oleh

Dita Elysyia Yulia Putri

Harga penutupan saham dan kurs rupiah terhadap dolar AS menunjukkan keterkaitan yang erat serta karakteristik yang fluktuatif. Keterkaitan tersebut mendorong perlunya peramalan sebagai dasar pengambilan keputusan. Penelitian ini membangun dua model *hybrid*, yaitu VECM-E_BiGRU dan VECM-EP_BiGRU. Model pertama memanfaatkan residual VECM, sedangkan model kedua menggunakan hasil prediksi VECM sebagai input ke BiGRU. VECM menangkap pola linier jangka panjang, sedangkan BiGRU mengenali pola nonlinier dua arah. Evaluasi model menunjukkan bahwa VECM-EP_BiGRU menghasilkan prediksi paling akurat dengan MAPE sebesar 0,01227%, lebih rendah dibandingkan VECM-E_BiGRU yang memiliki MAPE sebesar 0,0773%. Hasil uji *Kolmogorov-Smirnov* menunjukkan bahwa residual model VECM-EP_BiGRU paling mendekati distribusi data aktual. Kesimpulan menunjukkan bahwa VECM-EP_BiGRU unggul dalam memodelkan harga penutupan saham PT Indofood Sukses Makmur Tbk dan kurs rupiah terhadap dolar AS.

Kata-kata kunci: Harga saham, kurs rupiah, VECM, BiGRU, *hybrid* VECM–BiGRU, peramalan, deret waktu.

**PENERAPAN MODEL *HYBRID VECTOR ERROR CORRECTION MODEL*
(VECM) – *BIDIRECTIONAL GATED RECURRENT UNIT (BIGRU)* UNTUK
PERAMALAN HARGA PENUTUPAN SAHAM PT INDOFOOD SUKSES
MAKMUR TBK DAN NILAI TUKAR MATA UANG**

DITA ELYSYIA YULIA PUTRI

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

: **PENERAPAN MODEL *HYBRID VECTOR ERROR CORRECTION MODEL -BIDIRECTIONAL GATED RECCURENT UNIT (BIGRU)* PADA PERAMALAN HARGA PENUTUPAN SAHAM PT INDOFOOD SUKSES MAKMUR TBK DAN NILAI TUKAR RUPIAH**

Nama Mahasiswa

: **Dita Elyssia Yulia Putri**

Nomor Pokok Mahasiswa : **2117031114**

Program Studi

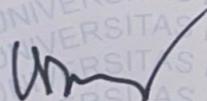
: **Matematika**

Fakultas

: **Matematika dan Ilmu Pengetahuan Alam**

MENYETUJUI

1. Komisi Pembimbing


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


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

2. Ketua 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.

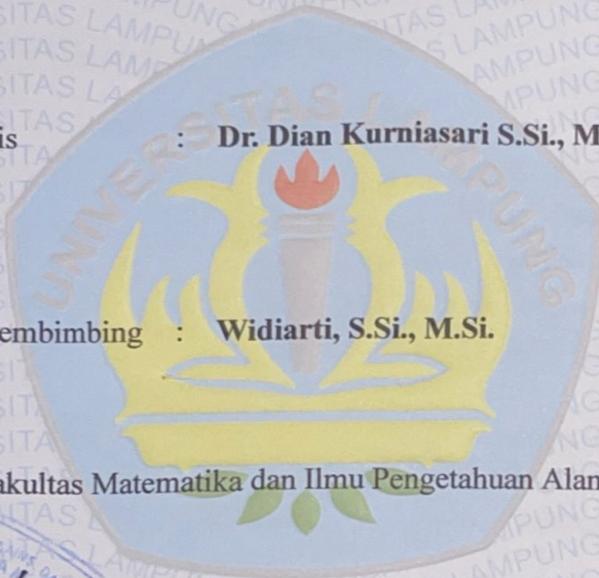
**Penguji
Bukan Pembimbing : Widiarti, S.Si., M.Si.**

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

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

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi: 16 Juni 2025



PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : **Dita Elysyia Yulia Putri**
Nomor Pokok Mahasiswa : **2117031114**
Jurusan : **Matematika**
Judul Skripsi : **Penerapan Model *Hybrid Vector Error Correction Model-Bidirectional Gated Reccurent Unit (BiGRU)* Pada Peramalan Harga Penutupan Saham PT Indofood Sukses Makmur Tbk dan Nilai Tukar Rupiah**

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, 16 Juni 2025

Penulis,



Dita Elysyia Yulia Putri

RIWAYAT HIDUP

Penulis bernama lengkap Dita Elysyia Yulia Putri, lahir di Sidorejo pada tanggal 25 Juli 2003. Penulis merupakan putri dari pasangan Bapak Nurdin dan Ibu Listin Wahyuni. Penulis merupakan anak pertama dari empat bersaudara, memiliki tiga adik bernama Dian Guritno, Nico Alfian, dan Muhammad Rico Dirgantara.

Pendidikan formal penulis dimulai sejak usia dini, yakni pada jenjang taman kanak-kanak di TK Abasiyah pada tahun 2008 hingga 2009. Selanjutnya, penulis melanjutkan pendidikan dasar di SD Negeri 1 Sidorejo yaitu dari tahun 2009 sampai dengan 2015. Penulis kemudian melanjutkan ke jenjang pendidikan menengah pertama di SMP Negeri 1 Bandar Sribhawono dari tahun 2015 hingga 2018. Kemudian, penulis meneruskan pendidikan menengah atas di SMA Negeri 1 Bandar Sribhawono mulai tahun 2018 hingga tahun 2021.

Pada tahun 2021 penulis terdaftar sebagai mahasiswi Program Studi S1 Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Selama menempuh pendidikan, penulis tidak hanya fokus pada kegiatan akademik, tetapi juga aktif berpartisipasi dalam berbagai kegiatan organisasi kemahasiswaan. Salah satu peran yang pernah dijalankan adalah sebagai Asisten Dinas Media dan Informasi (MEDINFO) di Badan Eksekutif Mahasiswa Fakultas MIPA (BEM FMIPA) Universitas Lampung tahun 2023.

Pada awal semester VI, penulis melaksanakan kegiatan Kerja Praktik (KP) di PT TASPEN (PERSERO) Kantor Cabang Bandar Lampung. Kegiatan ini memberikan wawasan nyata mengenai penerapan ilmu yang diperoleh di bangku kuliah ke dalam dunia kerja. Penulis juga mengikuti program Kuliah Kerja Nyata (KKN) yang dilaksanakan di Desa Tanjung Wangi Kec. Waway Karya, Kab. Lampung Timur selama 40 hari sebagai bentuk pengabdian kepada masyarakat.

KATA INSPIRASI

”Kemudian apabila kamu telah membulatkan tekad, maka bertawakallah kepada Allah.”

(QS. Ali-Imran: 159)

”Maka bersabarlah, sesungguhnya janji Allah itu benar. Dan jangan sampai orang-orang yang tidak meyakini (kebenaran itu) melemahkanmu.”

(QS. Ar-Rum: 60)

”Life can be heavy, especially if you try to carry it all at once. Part of growing up and moving into new chapters of your life is about catch and release, you can’t carry all things, decide what is yours to hold and let the rest go.”

(Taylor Swift)

”Let it flow.”

PERSEMBAHAN

Dengan mengucapkan Puji syukur kepada Allah atas nikmat serta hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan rasa syukur dan bahagia, saya persembahkan rasa terimakasih saya kepada:

Kedua Orangtuaku Bapak Nurdin dan Ibu Listin Wahyuni

Terimakasih karena selalu memberikan semangat, pelukan, doa, dan kasih sayang kepada penulis. Skripsi ini adalah persembahan untukmu

Dosen Pembimbing dan Pembahas

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

Sahabat-sahabatku

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

Almamater Tercinta

Universitas Lampung

SANWACANA

Puji dan syukur penulis panjatkan kepada Allah atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi ini yang berjudul "Penerapan Model *Hybrid Vector Error Correction Model-Bidirectional Gated Recurrent Unit* (BiGRU) Pada Peramalan Harga Penutupan Saham PT Indofood Sukses Makmur Tbk dan Nilai Tukar Rupiah" dengan baik dan lancar serta tepat pada waktu yang telah ditentukan.

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

1. Bapak Ir. Warsono, M.S., Ph.D. selaku Pembimbing 1 yang telah banyak meluangkan waktunya untuk memberikan arahan, bimbingan, motivasi, saran serta dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
2. Ibu Dr. Dian Kurniasari S.Si., M.Sc. selaku Pembimbing II yang telah memberikan arahan, bimbingan dan dukungan kepada penulis sehingga dapat menyelesaikan skripsi ini.
3. Ibu Widiarti, S.Si., M.Si. selaku Penguji yang telah bersedia memberikan kritik dan saran serta evaluasi kepada penulis sehingga dapat menjadi lebih baik lagi.
4. Seluruh dosen, staff dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Kepada orangtuaku, bapak Nurdin dan Ibu Listin Wahyuni yang selalu mendukung, mendoakan, memberikan motivasi, menyayangi serta memberikan cinta yang besar kepada penulis sehingga bisa menyelesaikan skripsi ini.
6. Kepada kakek nenekku, kakek Jaelani dan nenek Nafsiyah yang tidak henti memberikan dukungan, doa, serta selalu menyayangi penulis.

7. Teman-teman Vedisya, Rena, Bagas, Anisa, Meiliana, Rahma, Adin, Tasya, Maya, Eva, Nabila, Sherina terimakasih sudah memberikan motivasi, dukungan, masukan serta saran kepada penulis selama proses penyusunan skripsi ini.
8. Teman seperbimbingan Andi, Mey, Nabila, Sherina, Maya, Anggy, Ariz, Lusiana, Fathan, Adin, Dina, Erwin, Yulina, Anastasia yang selalu siap membantu, menemani, memberikan semangat dan kepercayaan kepada penulis.

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

Bandar Lampung, 16 Juni 2025

Dita Elysyia Yulia Putri

DAFTAR ISI

	Halaman
DAFTAR ISI	ii
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
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
2.1.1. Penelitian Pertama (Putri dkk.,2022)	9
2.1.2. Penelitian Kedua (Valentika dkk., 2022)	9
2.1.3. Penelitian Ketiga (Tanjung dkk., 2024)	10
2.1.4. Penelitian Keempat (Agisya dkk., 2024)	10
2.1.5. Penelitian Kelima (Aji & Surjandari, 2020)	11
2.2. Deret Waktu	12
2.2.1. Analisis Deret Waktu	12
2.2.2. Peramalan Deret Waktu	12
2.3. <i>Vector Autoregressive</i> (VAR)	13
2.4. <i>Vector Error Correction Model</i> (VECM)	13
2.4.1. Uji Kausalitas Granger	14
2.4.2. Penentuan Lag Optimal	14
2.4.3. Uji Kointegrasi	15
2.4.4. Uji Asumsi Residual <i>White Noise</i>	16
2.5. <i>Scaling Data</i>	16
2.6. <i>Machine Learning</i>	17

2.7. Fungsi Aktivasi	18
2.8. <i>Deep Learning</i>	19
2.9. <i>Recurrent Neural Network</i> (RNN)	19
2.10. <i>Gated Recurrent Unit</i> (GRU)	20
2.11. <i>Bidirectional Gated Recurrent Unit</i> (BiGRU)	22
2.12. Model <i>Hybrid</i> VECM-BiGRU	23
2.13. Evaluasi Model	24
2.14. Uji Kesesuaian Model (<i>Goodness Of Fit</i>)	25
III. METODE PENELITIAN	26
3.1. Waktu dan Tempat Penelitian	26
3.2. Data Penelitian	26
3.3. Alat Penelitian	27
3.4. Metode Penelitian	28
IV. HASIL DAN PEMBAHASAN	33
4.1. <i>Input</i> Data	33
4.2. Visualisasi Data	33
4.3. <i>Splitting</i> data	34
4.4. Prediksi dan Peramalan dengan VECM	35
4.4.1. <i>Preprocessing</i> Data	35
4.4.2. Panjang Lag Optimum	35
4.4.3. Uji Kausalitas Granger	36
4.4.4. Uji Kointegrasi	37
4.4.5. Prediksi Model VECM	38
4.4.6. Residual Model VECM	40
4.4.7. Peramalan Model VECM	42
4.5. Prediksi dan Peramalan Model <i>hybrid</i> VECM-E_BiGRU	43
4.5.1. <i>Scaling</i> Data Residual Model VECM	44
4.5.2. <i>Hyperparameter Tuning</i> Model E_BiGRU	44
4.5.3. Membangun Model E_BiGRU	45
4.5.4. Prediksi Model E_BiGRU	46
4.5.5. Prediksi Model <i>Hybrid</i> VECM-E_BiGRU	48
4.5.6. Peramalan Model E_BiGRU	50
4.5.7. Peramalan Model <i>Hybrid</i> VECM-E_BiGRU	51
4.6. Prediksi dan Peramalan Model <i>Hybrid</i> VECM-EP_BiGRU	53
4.6.1. <i>Scaling</i> Data Prediksi Model VECM	53

4.6.2. <i>Hyperparameter Tuning</i> Model P_BiGRU	54
4.6.3. Membangun Model P_BiGRU	54
4.6.4. Prediksi Model P_BiGRU	55
4.6.5. Prediksi Model <i>Hybrid</i> VECM-EP_BiGRU	57
4.6.6. Peramalan Model P_BiGRU	59
4.6.7. Peramalan Model <i>Hybrid</i> VECM-EP_BiGRU	60
4.7. <i>Goodness of Fit</i>	62
V. KESIMPULAN DAN SARAN	64
5.1. Kesimpulan	64

DAFTAR TABEL

Tabel	Halaman
1. Ringkasan Penelitian Sebelumnya	7
2. Tabel Kurs dan <i>Close</i>	26
3. Mengecek Data Hilang	35
4. Nilai Kriteria Penentuan Lag Optimum	35
5. Hasil Analisis Kausalitas Granger	36
6. Hasil Uji Kointegrasi Johansen	37
7. Hasil Prediksi Model VECM	38
8. Hasil Evaluasi Model VECM	39
9. Residual Model VECM	40
10. Hasil Uji Ljung-Box Terhadap Residual Model VECM	41
11. Hasil Peramalan Model VECM	42
12. <i>Hyperparameter Tuning</i> Model E_BiGRU	45
13. Hasil <i>Hyperparameter Tuning</i> Model E_BiGRU	45
14. Hasil Prediksi Model E_BiGRU	46
15. Hasil Prediksi Model E_BiGRU Setelah <i>Unscalling</i>	46
16. Evaluasi Model E_BiGRU	47
17. Hasil Prediksi Model VECM-E_BiGRU	48
18. Evaluasi Model VECM-E_BiGRU	49
19. Hasil Peramalan Model E_BiGRU	50
20. Hasil Peramalan Model VECM-E_BiGRU	52
21. Daftar <i>hyperparameter</i> untuk model P_BiGRU	54
22. Hasil <i>Hyperparameter Tuning</i> Model P_BiGRU	55
23. Hasil Prediksi Model P_BiGRU	55
24. Hasil Prediksi P_BiGRU Setelah <i>Unscalling</i>	56
25. Evaluasi Model P_BiGRU	57
26. Hasil Prediksi <i>Hybrid</i> VECM-EP_BiGRU	57

27. Evaluasi Model <i>Hybrid</i> VECM- EP_BiGRU	59
28. Hasil Peramalan Model P_BiGRU	59
29. Hasil Peramalan Model <i>Hybrid</i> EP_BiGRU	61
30. <i>Goodness of fit Close</i>	62
31. <i>Goodness of fit</i> kurs	63

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur Model GRU (Kostadinov, 2017)	20
2. Arsitektur model BiGRU (Zhang dkk., 2021)	22
3. <i>Flowchart</i> Model <i>Hybrid</i> VECM-E_BiGRU	31
4. <i>Flowchart</i> Model <i>Hybrid</i> VECM-EP_BiGRU	32
5. Data <i>Close</i> PT Indofood Sukses Makmur Tbk dan Kurs Rupiah . . .	33
6. Plot Hasil Prediksi VECM	39
7. Plot Residual Model VECM	41
8. Plot Hasil Peramalan Model VECM	43
9. Plot Hasil Prediksi E_BiGRU	47
10. Hasil Prediksi Model <i>Hybrid</i> VECM-E_BiGRU	49
11. Plot Hasil Peramalan Model E_BiGRU	51
12. Plot Hasil Peramalan <i>Hybrid</i> VECM-E_BiGRU	52
13. Plot Hasil Prediksi dari Model P_BiGRU	56
14. Plot Hasil Prediksi <i>Hybrid</i> VECM- EP_BiGRU	58
15. Plot Hasil Peramalan P_BiGRU	60
16. Plot Hasil Peramalan <i>Hybrid</i> VECM-EP_BiGRU	61

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Perkembangan teknologi saat ini mendorong peran penting analisis data di berbagai bidang, terutama dalam sektor ekonomi dan keuangan. Volume dan kompleksitas data yang terus meningkat menjadikan analisis deret waktu sebagai salah satu pendekatan utama untuk memahami pola dan tren berdasarkan urutan waktu. Melalui pendekatan ini, peneliti dapat mengidentifikasi tren, pola musiman, serta fluktuasi yang memengaruhi pergerakan variabel ekonomi seperti harga saham dan nilai tukar mata uang. Secara umum, model deret waktu digunakan untuk meramalkan nilai masa depan suatu variabel berdasarkan data historis. Salah satu pendekatan dasar dalam analisis deret waktu adalah model *Autoregressive* (AR), yang mengasumsikan bahwa nilai suatu variabel saat ini dipengaruhi oleh nilai-nilai masa lalunya. Seiring meningkatnya kebutuhan untuk menganalisis lebih dari satu variabel secara bersamaan, pendekatan deret waktu berkembang menjadi bentuk yang lebih kompleks, yaitu analisis deret waktu multivariat.

Salah satu model yang populer dalam analisis deret waktu multivariat adalah *Vector Autoregressive* (VAR). Model VAR diperkenalkan oleh Sims (1980) sebagai pengembangan dari model *Autoregressive* (AR) untuk lebih dari satu variabel. Pada model ini, setiap variabel endogen dijelaskan sebagai fungsi linear dari nilai masa lalunya sendiri serta nilai masa lalu dari variabel lain dalam sistem. Model VAR sangat berguna untuk menganalisis hubungan dinamis antara beberapa variabel ekonomi yang saling memengaruhi secara simultan (Gujarati dan Porter, 2003). Salah satu kelebihan dari model ini adalah tidak adanya asumsi mengenai eksogenitas variabel, sehingga seluruh variabel dalam sistem dianggap setara dan saling memengaruhi.

Namun, data ekonomi dan keuangan pada praktiknya sering kali menunjukkan adanya hubungan jangka panjang yang stabil, yang disebut dengan kointegrasi. Apabila terdapat kointegrasi antarvariabel, penggunaan model VAR menjadi tidak sesuai secara metodologis karena dapat menghasilkan estimasi yang bias dan tidak konsisten. Kondisi tersebut dapat diatasi dengan menggunakan model *Vector Error Correction Model* (VECM), yaitu pengembangan dari model VAR yang dirancang untuk menangani data tidak stasioner yang memiliki hubungan kointegrasi.

Model VECM mampu menggambarkan dinamika hubungan jangka pendek antarvariabel sekaligus mempertahankan keseimbangan jangka panjang dalam suatu sistem. Oleh karena itu, VECM menjadi pilihan yang lebih tepat untuk menganalisis data deret waktu yang menunjukkan adanya kointegrasi (Widarjono, 2018). Studi yang dilakukan oleh Valentika dkk. (2022) menunjukkan bahwa VECM memiliki kinerja yang baik dalam meramalkan variabel makroekonomi, seperti ekspor dan impor, dengan nilai *Mean Absolute Percentage Error* (MAPE) di bawah 10%. Hasil analisis dalam penelitian tersebut juga mengungkap adanya hubungan jangka panjang antarvariabel dalam persamaan kointegrasi kedua terhadap perubahan impor, termasuk pengaruh nilai tukar dan ekspor pada periode sebelumnya. Hasil serupa ditunjukkan oleh Putri dkk. (2022) yang menggunakan model VECM untuk meramalkan nilai ekspor dan impor seluruh komoditas di Provinsi Lampung. Penelitian ini menggunakan data bulanan dari Januari 2015 hingga Desember 2021. Melalui serangkaian tahapan seperti uji stasioneritas, uji kointegrasi, dan identifikasi model, VECM(1) ditetapkan sebagai model terbaik. Model tersebut memenuhi uji diagnostik white noise dan normalitas residual, serta menghasilkan nilai MAPE sebesar 17,01%. Hasil ini menunjukkan bahwa model VECM mampu menangani data ekonomi yang memiliki hubungan jangka panjang antarvariabel.

Meskipun VECM unggul dalam menangkap hubungan jangka panjang antarvariabel yang berkointegrasi, model ini memiliki keterbatasan ketika diterapkan pada data deret waktu yang kompleks dan bersifat nonlinier. Model VECM bekerja dengan asumsi adanya hubungan linier antara variabel, sehingga kurang mampu mengakomodasi pola nonlinier yang sering muncul dalam data ekonomi dan keuangan, khususnya pada pergerakan harga saham dan nilai tukar yang dipengaruhi oleh banyak faktor dinamis. Selain itu, performa VECM cenderung menurun ketika menghadapi volatilitas tinggi dan perubahan struktural dalam data, yang dapat menyebabkan hasil peramalan menjadi kurang akurat. Oleh karena itu, dibutuhkan pendekatan tambahan yang lebih fleksibel untuk menangkap pola nonlinier yang

tidak dapat ditangani secara optimal oleh VECM.

Perkembangan model berbasis kecerdasan buatan, khususnya *Recurrent Neural Network* (RNN) dan turunannya menunjukkan kemajuan pesat beberapa tahun terakhir dalam analisis deret waktu. Model RNN memiliki kemampuan untuk memproses data berurutan dan mempertahankan informasi dari waktu sebelumnya, sehingga sangat cocok digunakan dalam pemodelan data deret waktu. Salah satu arsitektur yang populer dan efisien adalah *Gated Recurrent Unit* (GRU). Model GRU merupakan pengembangan dari RNN yang dirancang untuk mengatasi masalah *vanishing gradient* dan mempertahankan informasi penting dalam jangka panjang. Dengan struktur yang lebih sederhana dibandingkan dengan *Long Short-Term Memory* (LSTM), GRU memerlukan waktu komputasi yang lebih singkat namun tetap mampu mengolah data secara efektif (Cho dkk., 2014).

Namun, GRU hanya memproses data dalam satu arah, yaitu dari masa lalu ke masa kini. Pendekatan satu arah ini menjadi kurang optimal pada situasi tertentu, khususnya ketika informasi dari masa depan diperlukan untuk memberikan konteks terhadap data masa lalu. Permasalahan tersebut diatasi dengan menggunakan varian *Bidirectional Gated Recurrent Unit* (BiGRU), yang mampu membaca urutan data dalam dua arah, baik maju maupun mundur. Struktur dua arah ini memungkinkan BiGRU memahami konteks secara lebih menyeluruh serta mengenali pola yang lebih kompleks dan asimetris dalam data deret waktu. Hal ini menyebabkan BiGRU sangat potensial untuk meningkatkan akurasi peramalan, terutama dalam konteks data ekonomi dan keuangan yang sangat dinamis. Penelitian yang dilakukan oleh Agisya dkk. (2024) menunjukkan efektivitas BiGRU dalam peramalan data keuangan. Penelitian tersebut menerapkan BiGRU untuk meramalkan rasio *Non-Performing Loans* (NPL) pada sektor usaha pertambangan dan penggalian, dengan menggunakan data sekunder yang mencakup informasi kredit serta rasio NPL. Model BiGRU menghasilkan tingkat kesalahan MAPE sebesar 7,01% pada pembagian data pelatihan 70% dan penggunaan time steps sebanyak 3, yang menunjukkan kemampuannya menangkap hubungan temporal serta pola kompleks dalam data NPL.

Temuan serupa muncul dalam penelitian Tanjung dkk. (2024) yang menerapkan algoritma BiGRU untuk memprediksi Indeks Harga Konsumen (IHK) di Indonesia. Penelitian ini menggunakan data bulanan dari Januari 2006 hingga Desember 2022 dan mengembangkan berbagai arsitektur BiGRU dengan kombinasi jumlah

neuron dan lapisan. Arsitektur terbaik terdiri atas dua lapisan BiGRU dengan masing-masing 256 dan 400 unit neuron, serta satu lapisan dense. Model tersebut menghasilkan nilai MAPE sebesar 0,24% yang mencerminkan kemampuan BiGRU dalam menangkap pola kompleks dan nonlinier pada data ekonomi jangka panjang. Kedua temuan tersebut mengkonfirmasi bahwa BiGRU dapat digunakan secara efektif dalam menangani data deret waktu dengan karakteristik nonlinier yang kuat. Walaupun BiGRU membutuhkan waktu pelatihan yang lebih lama serta pengaturan parameter yang optimal untuk mencapai performa maksimal (Goodfellow dkk., 2016).

Keterbatasan ini menunjukkan bahwa tidak ada satu model peramalan yang secara universal terbaik untuk semua jenis data atau situasi (Makridakis dkk.,1998). Kompleksitas pola data di dunia nyata sering kali sulit ditangani dengan pendekatan tunggal, sehingga pendekatan *hybrid* menjadi solusi yang lebih efektif. Penelitian oleh Aji dan Surjandari (2020) membandingkan model VAR, LSTM, GRU, serta model *hybrid* VAR–LSTM dan VAR–GRU dalam meramalkan harga transaksi bahan bakar jet di Bandara Soekarno-Hatta. Hasilnya menunjukkan bahwa model *hybrid* memberikan performa terbaik, dengan VAR–GRU menghasilkan MAPE serendah 0,60%, jauh lebih akurat dibandingkan model individu seperti LSTM dan GRU. Temuan ini menegaskan bahwa pendekatan *hybrid* yang menggabungkan model statistik dan *deep learning* mampu meningkatkan akurasi peramalan data deret waktu multivariat secara signifikan.

Penerapan model *hybrid* banyak digunakan untuk memprediksi variabel ekonomi yang saling berhubungan, seperti nilai tukar dan harga saham. Pasar modal yang mencakup pergerakan harga saham berperan penting dalam perekonomian modern, khususnya sebagai sumber pendanaan jangka panjang bagi perusahaan, peningkatan efisiensi manajemen, dan inovasi melalui investasi di sektor-sektor utama (Chirkova, 2024). Saham sebagai instrumen utama pasar modal, mencerminkan kepemilikan investor dalam perusahaan serta memberikan keuntungan melalui *capital gain* dan *dividen*. Selain itu, saham juga berfungsi sebagai indikator ekonomi yang mencerminkan kondisi perekonomian suatu negara.

Bursa Efek Indonesia (BEI) memiliki peran strategis dalam mendukung pertumbuhan ekonomi nasional di Indonesia. Salah satu perusahaan yang menarik perhatian investor adalah PT Indofood Sukses Makmur Tbk, yang bergerak di sektor pangan dan agribisnis (Setiawan, 2019). Harga saham PT Indofood Sukses Makmur

Tbk dipengaruhi oleh faktor internal, seperti kinerja perusahaan, serta faktor eksternal, seperti nilai tukar USD terhadap rupiah. Ketergantungan perusahaan pada bahan baku impor menjadikan nilai tukar sebagai variabel eksternal yang penting. Pelemahan Rupiah akan meningkatkan biaya impor, sementara penguatan Rupiah dapat mengurangi beban tersebut.

Penelitian yang menggunakan model *hybrid* VECM–BiGRU masih terbatas, khususnya terkait peramalan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar. Oleh karena itu, peneliti tertarik untuk melakukan peramalan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar dengan model *hybrid* VECM–BiGRU. Penelitian ini diharapkan dapat memperluas penggunaan model *hybrid* dalam peramalan data deret waktu yang kompleks. Secara praktis, hasil penelitian ini diharapkan dapat membantu investor dan perusahaan dalam pengambilan keputusan strategis terkait investasi dan manajemen risiko.

1.2 Rumusan Masalah

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Pengembangan model *hybrid* VECM–E_BiGRU dan *hybrid* VECM–EP_BiGRU diperlukan sebagai pendekatan alternatif dalam peramalan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah.
2. Analisis hasil peramalan diperlukan untuk mengetahui efektivitas model VECM, *hybrid* VECM–E_BiGRU dan *hybrid* VECM–EP_BiGRU dalam memprediksi harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah.
3. Perbandingan kinerja antar model VECM, *hybrid* VECM–E_BiGRU dan *hybrid* VECM–EP_BiGRU untuk menentukan model dengan tingkat akurasi terbaik dalam meramalkan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah.

1.3 Tujuan Penelitian

Adapun tujuan penelitian ini adalah sebagai berikut:

1. Membangun model VECM, *hybrid* VECM–E_BiGRU, dan *hybrid* VECM–EP_BiGRU untuk meramalkan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah.

2. Mengetahui hasil peramalan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah menggunakan model VECM, *hybrid* VECM–E_BiGRU, dan *hybrid* VECM–EP_BiGRU.
3. Membandingkan kinerja model VECM, *hybrid* VECM–E_BiGRU, dan *hybrid* VECM–EP_BiGRU dalam meramalkan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Dapat meningkatkan pemahaman tentang peramalan dengan menggunakan model *hybrid* VECM-BiGRU.
2. Dapat memberikan evaluasi untuk harga saham yang lebih akurat sehingga mendukung investor dalam pengambilan keputusan investasi yang lebih optimal.
3. Dapat menjadi sumber dan referensi bagi peneliti selanjutnya dengan menggunakan model *hybrid* VECM-BiGRU.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian ini menggunakan studi terkait sebagai referensi untuk memperdalam pemahaman terhadap topik yang diteliti. Ringkasan dari penelitian-penelitian tersebut dapat dilihat pada Tabel 1 sebagai berikut:

Tabel 1. Ringkasan Penelitian Sebelumnya

Penelitian	Data	Metode	Hasil
Penerapan Model <i>Vector Error Correction Model</i> (VECM) pada Peramalan Data Nilai Ekspor dan Nilai Impor Seluruh Komoditas di Provinsi Lampung Tahun 2022 (Putri, M., Widiarti, A., Nuryaman, A., & Warsono, 2022)	Data nilai ekspor dan impor di Provinsi Lampung	VECM	MAPE: 17.01%
Peramalan Kurs, Inflasi, Impor, dan Ekspor dengan VECM (Valentika, N., Nursyirwan, V. I., & Ilmadi, 2022)	Data kurs, inflasi, impor, dan ekspor	VECM	MAPE Ekspor: 6.23% MAPE Impor: 0.85%

Penelitian	Data	Metode	Hasil
<i>Implementation of the Bidirectional Gated Recurrent Unit Algorithm on Consumer Price Index Data in Indonesia</i> (Tanjung, A. A. C., Saputro, D. R. S., & Kurdhi, N. A., 2024)	Data Indeks Harga Konsumen (Consumer Price Index/CPI) Indonesia	BiGRU	MSE: 0.24 Epoch 200
Peramalan Rasio <i>Non Performing Loans</i> Sektor Usaha Pertambahan dan Penggalian Menggunakan Metode <i>Bidirectional Gated Recurrent Unit</i> (BiGRU) (Agisya, M. N., Andriyana, Y., & Handoko, B., 2024)	Data sekunder mengenai kredit dan rasio <i>Non-Performing Loans</i> (NPL) berdasarkan sektor usaha	BiGRU	Training 70%, time steps 3 MAPE: 7.01%
<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 di Bandara CGK, Tangerang, Indonesia, Januari 2017 – April 2020	VAR, LSTM, GRU, VAR-LSTM, VAR-GRU	RMSE VAR: 62,53 GRU: 794,27 VAR-GRU: 62,53 VAR-LSTM: 81,52 MAPE VAR: 2,52% GRU: 10,97% VAR-GRU: 0,60% VAR-LSTM: 1,02%

2.1.1 Penelitian Pertama (Putri dkk.,2022)

Putri dkk. (2022) melakukan penelitian dengan menggunakan model *Vector Error Correction Model* (VECM) untuk meramalan nilai ekspor dan nilai impor seluruh komoditas di Provinsi Lampung. Data yang digunakan adalah nilai ekspor dan nilai impor dari periode Januari 2015 hingga Desember 2021. Penelitian ini diawali dengan mengumpulkan data, kemudian dilakukan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF). Hasil uji menunjukkan bahwa data tidak stasioner, sehingga dilakukan *differencing* untuk menjadikannya stasioner.

Selanjutnya, peneliti melakukan uji kointegrasi Johansen untuk mengetahui adanya hubungan jangka panjang antar variabel. Hasil uji menunjukkan bahwa data memiliki hubungan kointegrasi, sehingga digunakan model VECM. Setelah itu, dilakukan identifikasi model untuk menentukan lag optimum dan melakukan estimasi parameter model. Model yang diperoleh adalah VECM(1).

Peneliti kemudian menguji model ini melalui *diagnostic checking*, yang mencakup pemeriksaan asumsi white noise dan normalitas residual, dan keduanya terpenuhi. Berdasarkan model VECM(1), peneliti melakukan peramalan untuk periode Januari hingga Desember 2022. Hasil peramalan menunjukkan bahwa model menghasilkan nilai MAPE sebesar 17,01%, yang mencerminkan tingkat akurasi peramalan yang baik.

2.1.2 Penelitian Kedua (Valentika dkk., 2022)

Valentika dkk. (2022) melakukan penelitian dengan menggunakan model VECM untuk memodelkan dan meramalkan nilai tukar, inflasi, impor, dan ekspor di Indonesia. Penelitian ini menggunakan data bulanan dari periode Januari 2009 hingga Desember 2019. Tahapan penelitian mencakup pengumpulan data dari Bank Indonesia dan Badan Pusat Statistik, pengujian stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF), identifikasi lag optimal berdasarkan *Schwarz Information Criterion* (SC), serta uji kointegrasi Johansen untuk memastikan adanya hubungan jangka panjang antar variabel.

Peneliti menerapkan model VECM dengan lag 2 pada data yang memiliki dua hubungan kointegrasi. Hasil uji diagnostik menunjukkan bahwa model tersebut akurat dalam meramalkan nilai ekspor dan impor, dengan nilai MAPE kurang dari

10%. Berdasarkan hasil penelitian, terdapat hubungan jangka panjang antara nilai tukar, inflasi, impor, dan ekspor pada periode sebelumnya terhadap perubahan masing-masing variabel. Hasil peramalan menunjukkan bahwa nilai MAPE untuk ekspor sebesar 6,23% dan untuk impor sebesar 0,85%, yang mencerminkan tingkat akurasi peramalan yang sangat baik.

2.1.3 Penelitian Ketiga (Tanjung dkk., 2024)

Tanjung dkk. (2024) menggunakan algoritma *Bidirectional Gated Recurrent Unit* (BiGRU) untuk meramalkan data Indeks Harga Konsumen (IHK) di Indonesia. Penelitian ini menggunakan data bulanan IHK dari Januari 2006 hingga Desember 2022 dengan total sebanyak 204 data. Data tersebut dibagi menjadi dua bagian, yaitu 80% data latih (163 data) dan 20% data uji (41 data). Sebelum proses pemodelan dilakukan, peneliti menerapkan model *sliding window* dengan ukuran jendela 10 guna mengurangi tingkat kesalahan dalam peramalan.

Peneliti membangun 20 arsitektur BiGRU dengan berbagai kombinasi jumlah neuron dan lapisan. Arsitektur terbaik terdiri atas dua lapisan BiGRU dengan masing-masing 256 dan 400 unit neuron, satu lapisan dense, fungsi aktivasi ReLU, algoritma optimisasi Adam, dan jumlah epoch sebanyak 200. Model terbaik tersebut menghasilkan nilai MAPE sebesar 0,24%, yang menunjukkan tingkat akurasi peramalan yang sangat baik. Peneliti melakukan peramalan untuk data IHK periode Juni hingga Desember 2023, dan hasilnya menunjukkan adanya kenaikan nilai IHK yang mengindikasikan potensi inflasi atau pertumbuhan ekonomi selama periode tersebut.

2.1.4 Penelitian Keempat (Agisya dkk., 2024)

Agisya dkk. (2024) menggunakan model *Bidirectional Gated Recurrent Unit* (BiGRU) untuk meramalkan rasio *Non-Performing Loans* (NPL) pada sektor usaha pertambangan dan penggalian. Penelitian ini menggunakan data bulanan dari Maret 2012 hingga November 2023. Peneliti memulai proses analisis dengan melakukan normalisasi data menggunakan *Min-Max Scaler*, kemudian membagi data menjadi 70% data latih dan 30% data uji. Pemodelan dilakukan melalui proses *tuning hyperparameter* dengan pendekatan *trial and error*, yang menghasilkan konfigurasi optimal berupa *time steps* sebanyak 3, 3 *hidden layers*, 32 *units*, *learning rate*

sebesar 0,0005, dan *batch size* sebesar 2. Evaluasi model menghasilkan nilai MAPE sebesar 7,01%, yang menunjukkan bahwa model memiliki performa peramalan yang sangat baik.

Hasil peramalan untuk 6 bulan ke depan, yaitu periode Desember 2023 hingga Mei 2024, menunjukkan adanya penurunan rasio NPL hingga mencapai 0,832% pada Mei 2024. Penurunan tersebut mengindikasikan bahwa sektor pertambangan dan penggalian tidak mengalami risiko kredit macet yang signifikan selama periode tersebut, karena rasio NPL berada jauh di bawah ambang batas sebesar 5%.

2.1.5 Penelitian Kelima (Aji & Surjandari, 2020)

Aji & Surjandari (2020) melakukan penelitian yang bertujuan untuk meramalkan harga transaksi bahan bakar jet di Bandara Soekarno-Hatta (CGK), Tangerang, Indonesia, dengan menggunakan beberapa model peramalan, yaitu *Vector Autoregression* (VAR), *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), serta model *hybrid* VAR–LSTM dan VAR–GRU. Data yang digunakan merupakan data bulanan dari Januari 2017 hingga April 2020. Evaluasi performa masing-masing model dilakukan dengan dua indikator, yaitu *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

Hasil penelitian menunjukkan bahwa model VAR menghasilkan RMSE sebesar 62,53 dan MAPE sebesar 2,52%. Sementara itu, model berbasis *deep learning* seperti LSTM dan GRU memberikan hasil yang kurang optimal, dengan RMSE masing-masing sebesar 989,95 dan 794,27, serta MAPE sebesar 13,07% dan 10,97%. Namun, penerapan model *hybrid* mampu meningkatkan akurasi secara signifikan. Model VAR–LSTM menunjukkan RMSE sebesar 81,52 dan MAPE sebesar 1,02%, sedangkan model VAR–GRU memberikan hasil terbaik dengan RMSE sebesar 62,53 dan MAPE terendah, yaitu 0,60%. Temuan ini mengindikasikan bahwa kombinasi model VAR dan GRU mampu mengintegrasikan keunggulan pendekatan statistik dan *deep learning* secara efektif dalam meramalkan data deret waktu multivariat. Ikan data deret waktu multivariat.

2.2 Deret Waktu

2.2.1 Analisis Deret Waktu

Analisis deret waktu merupakan cara untuk menganalisis ketergantungan pada data deret waktu. Deret waktu adalah kumpulan data yang diobservasi pada interval waktu yang teratur dan memiliki peran penting dalam analisis statistik serta peramalan. Beberapa komponen utama yang perlu diperhatikan dalam analisis deret waktu adalah tren, musiman, siklus, dan fluktuasi acak (Hyndman & Athanasopoulos, 2018).

1. Tren merujuk pada pola jangka panjang yang tampak dalam data dan dapat menunjukkan pertumbuhan, penurunan, atau stabilitas selama periode waktu tertentu.
2. Musiman mengacu pada pola yang berulang dalam interval waktu tetap, seperti bulanan atau tahunan.
3. Siklus menggambarkan fluktuasi yang berlangsung dalam jangka waktu lebih panjang tanpa periode tetap, yang sering kali terkait dengan kondisi ekonomi.
4. Fluktuasi acak merupakan variasi yang tidak dapat diprediksi dalam data dan disebabkan oleh faktor eksternal yang tidak terkontrol. Komponen ini mencerminkan ketidakpastian dalam deret waktu yang tidak dapat dijelaskan oleh pola atau tren tertentu.

2.2.2 Peramalan Deret Waktu

Peramalan merupakan proses sistematis yang digunakan untuk memprediksi kejadian atau kondisi di masa depan berdasarkan pola data historis. Bidang ekonomi dan manajemen bisnis memanfaatkan peramalan untuk mendukung pengambilan keputusan strategis terkait pengelolaan sumber daya, keuangan, dan operasi organisasi (Makridakis dkk., 1993). Hyndman & Athanasopoulos (2018) menyatakan bahwa peramalan adalah proses memprediksi masa depan berdasarkan data masa lalu dan saat ini, dengan memanfaatkan model statistik untuk mengidentifikasi tren dan pola. Teknik peramalan membantu organisasi dalam mengurangi ketidakpastian dan meningkatkan akurasi perencanaan masa depan.

Montgomery dkk. (2015) menjelaskan bahwa metode peramalan umumnya terbagi menjadi dua jenis, yaitu metode kualitatif dan metode kuantitatif:

1. Metode peramalan kualitatif memanfaatkan data kualitatif dari masa lalu, seperti penilaian ahli atau intuisi. Penyusunan hasil peramalan ini sangat bergantung pada pengalaman dan penilaian individu, sehingga bersifat subjektif.
2. Metode peramalan kuantitatif menggunakan data kuantitatif dari masa lalu, seperti data statistik atau angka historis. Proses peramalan ini dipengaruhi oleh metode matematis atau statistik yang digunakan, sehingga menghasilkan output yang lebih objektif dan terukur.

2.3 *Vector Autoregressive (VAR)*

Model *Vector Autoregressive (VAR)* adalah teknik yang digunakan dalam analisis deret waktu *multivariate*, di mana setiap variabel dalam model dipengaruhi oleh nilai-nilai masa lalu dari semua variabel lainnya. Model ini sangat berguna dalam analisis hubungan dinamis antar variabel dan memungkinkan untuk diidentifikasi interaksi kompleks dalam data (Sims, 1980. Menurut Wei (2006), secara matematis model VAR (p) dapat dinyatakan dalam Persamaan (2.1) sebagai berikut:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.1)$$

dengan:

Y_t = vektor berukuran $n \times 1$ berisi n variabel endogen pada waktu t dan $t - i$,
 $i = 1, 2, \dots, p$

α = vektor konstanta berukuran $n \times 1$

ϕ_i = matriks parameter variabel endogen berukuran $n \times n$

ε_t = vektor galat berukuran $n \times 1$

$\varepsilon_t \sim N_p(0, \Sigma)$

2.4 *Vector Error Correction Model (VECM)*

Model *Vector Error Correction Model (VECM)* adalah pengembangan dari model *Vector Autoregressive (VAR)*. Model VAR sendiri adalah model yang memprediksi nilai berdasarkan data aktual dari periode sebelumnya. Model VECM diterapkan ketika data dalam penelitian tidak stasioner dan terdapat hubungan kointegrasi di antara variabel-variabel tersebut (Usman dkk., 2017). Secara umum, model VAR (p)

dapat dinyatakan dalam Persamaan (2.1).

Model VAR beralih menjadi model VECM ketika terdapat hubungan kointegrasi yang bersifat linier. Proses perubahan ini dilakukan melalui penghilangan Y_{t-1} dari kedua sisi persamaan dalam model VAR. Setelah dilakukan perubahan tersebut, bentuk umum dari model VECM dituliskan pada Persamaan (2.2) sebagai berikut (Lütkepohl, 2005):

$$\Delta Y_t = \Pi Y_{t-1} + \Gamma_1 \Delta Y_{t-1} + \dots + \Gamma_i \Delta Y_{t-i} + \alpha_t \quad (2.2)$$

dengan:

$$i = 1, 2, \dots, p - 1$$

ΔY_t = vektor pembeda pertama variabel endogen

Π = matriks kointegrasi berukuran $m \times m$, $\Pi = \alpha\beta'$

m = jumlah variabel endogen

Γ_i = matriks koefisien parameter berukuran $m \times m$

2.4.1 Uji Kausalitas Granger

Uji kausalitas Granger menilai apakah satu deret waktu dapat memprediksi yang lain, menunjukkan pengaruh arah antara variabel, yang biasa digunakan dalam mendiagnosis gangguan proses (Wang dkk., 2024). Menurut Gujarati (2003), jika terdapat dua peubah X dan Y maka terdapat beberapa kemungkinan yang terjadi, antara lain :

1. X menyebabkan Y, apabila lag dari X secara signifikan dapat memprediksi Y, sedangkan lag dari Y tidak signifikan terhadap X.
2. Y menyebabkan X, apabila lag dari Y secara signifikan dapat memprediksi X, sedangkan lag dari X tidak signifikan terhadap Y.
3. X menyebabkan Y dan Y menyebabkan X, apabila lag dari X signifikan terhadap Y dan lag dari Y juga signifikan terhadap X, yang menunjukkan adanya hubungan dua arah (*bi-directional causality*).
4. X dan Y tidak memiliki hubungan, apabila lag dari X tidak berpengaruh terhadap Y dan lag dari Y juga tidak berpengaruh terhadap X.

2.4.2 Penentuan Lag Optimal

Penentuan lag optimal adalah langkah penting dalam model VECM untuk menentukan jumlah lag yang tepat agar model dapat menangkap pola hubungan antar variabel secara akurat. Menurut Sornette & Zhou (2004), penentuan lag

optimal bertujuan untuk mengidentifikasi struktur *lag-lead* antara dua deret waktu dengan meminimalkan ketidakcocokan total melalui metode non-parametrik, meningkatkan ketahanan terhadap *noise*, dan memberikan prediksi akurat dari nilai masa depan berdasarkan data historis.

Salah satu metode yang sering digunakan dalam menentukan lag optimal adalah *Bayesian Information Criterion* (BIC). Kriteria informasi BIC dimanfaatkan untuk menentukan lag yang paling optimal dengan mempertimbangkan keseimbangan antara ketepatan model dan tingkat kompleksitasnya. BIC memberikan penalti terhadap model yang memiliki terlalu banyak parameter, sehingga cenderung memilih model yang lebih sederhana namun tetap mempertahankan kemampuan prediksinya. Dengan demikian, BIC membantu mengungkap struktur model yang paling tepat (Samad & Nasir, 2018). Rumus BIC diuraikan dalam Persamaan (2.3) sebagai berikut (Wei, 2006):

$$BIC(p) = \ln |\Sigma(p)| + \frac{\ln n \cdot m^2 h}{n} \quad (2.3)$$

dengan:

$\Sigma(p)$ = determinan matriks kovarian residual

n = banyaknya pengamatan

m = jumlah variabel

h = jumlah lag

2.4.3 Uji Kointegrasi

Uji kointegrasi adalah metode statistik yang digunakan untuk menentukan apakah satu set variabel deret waktu non-stasioner berbagi hubungan kesetimbangan jangka panjang. Uji ini bisa digunakan pada efisiensi semiparametrik untuk menguji peringkat kointegrasi dalam model autoregresif vektor (Zhou, 2023).

Salah satu pendekatan yang umum digunakan dalam uji kointegrasi adalah Johansen Test. Uji ini diterapkan pada model VECM untuk mengidentifikasi jumlah vektor kointegrasi antara variabel-variabel yang dianalisis. Rumus dari Johansen Test dapat dinyatakan pada Persamaan (2.4) sebagai berikut (Johansen, 1988):

$$JLR = -T \sum_{i=r+1}^n \ln(1 - \lambda_i) \quad (2.4)$$

dengan:

T = jumlah observasi

r = jumlah vektor kointegrasi

λ_i = nilai eigen yang diestimasi dari model

2.4.4 Uji Asumsi Residual *White Noise*

Uji residual *white noise* merupakan langkah penting untuk memastikan residual model bersifat acak (*white noise*), yaitu tidak memiliki pola sistematis. Sehingga menunjukkan bahwa model telah menangkap semua informasi yang relevan dari data. *White noise* memiliki tiga karakteristik utama: rata-rata residual bernilai nol, variansi residual konstan, dan tidak adanya autokorelasi antar residual (Lütkepohl, 2005). Salah satu cara untuk menguji asumsi ini adalah melalui uji Ljung-Box sebagai berikut (Ljung & Box, 1978):

1. Hipotesis

- H_0 : residual memenuhi asumsi *white noise*
- H_1 : residual tidak memenuhi asumsi *white noise*

2. Taraf signifikansi

$$\alpha = 5\%$$

3. Statistik uji

Pengujian asumsi residual *white noise* dilakukan dengan menggunakan statistik Ljung-Box, yang dinyatakan dalam Persamaan (2.5) sebagai berikut:

$$Q = n(n + 2) \sum_{i=1}^m \frac{\rho_i^2}{(n - i)} \quad (2.5)$$

dengan:

n = banyaknya data pengamatan

p_i = dugaan ACF residual pada periode lag ke- i m = jumlah lag i

4. Kriteria Uji

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

5. Keputusan

6. Kesimpulan

2.5 *Scaling Data*

Scaling data membantu meningkatkan kinerja model pembelajaran mesin dengan menyediakan representasi yang konsisten dari berbagai skala atribut. Langkah

pra-pemrosesan ini meningkatkan kemampuan algoritma untuk mempelajari pola, menghasilkan peningkatan akurasi, terutama untuk data yang tidak terlihat (Moghniuddin, 2024). Salah satu teknik umum yang sering digunakan dalam scaling data, yaitu *Min-Max Scaler*. *Min-Max Scaler* adalah teknik yang mengubah nilai data ke dalam rentang [0, 1] dengan Persamaan (2.6) sebagai berikut (Han dkk., 2012):

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.6)$$

dengan:

X = nilai asli

X_{min} = nilai minimum dari fitur

X_{max} = nilai maksimum dari fitur

2.6 Machine Learning

Machine learning merupakan cabang ilmu data yang membuat prediksi dengan menggunakan model statistik. Metode ini belajar dari data masa lalu dan secara otomatis menyesuaikan model untuk meningkatkan akurasi peramalan, terutama dalam memprediksi tren pasar saham (Abbahaddou dkk., 2022). Tujuan *machine learning* adalah mengembangkan program komputer yang mampu mengakses data, belajar dari data tersebut, mengidentifikasi pola, dan membuat keputusan secara otomatis tanpa campur tangan manusia. Dengan demikian, *machine learning* dapat membantu analisis data dan meningkatkan hasil bisnis. Keberhasilan metode ini sangat bergantung pada kualitas dan kuantitas data yang digunakan selama proses pelatihan. Selain itu, dalam *machine learning* terdapat dua metode utama yang sering digunakan, yaitu *Supervised Learning* dan *Unsupervised Learning*.

1. Supervised learning

Metode ini melatih model menggunakan dataset yang sudah dilabeli, di mana *input* (fitur) dan *output* (label) sudah diketahui. Tujuan *supervised learning* adalah memprediksi output berdasarkan input yang diberikan. Contoh *supervised learning* meliputi klasifikasi email sebagai spam atau tidak spam, pengenalan wajah, dan prediksi harga rumah berdasarkan fitur seperti ukuran dan lokasi. Metode ini melibatkan pelatihan model dengan dataset berlabel untuk membuat prediksi pada data baru (Khan & Al-Habsi, 2020).

2. Unsupervised Learning

Berbeda dengan *supervised learning*, *unsupervised learning* diterapkan pada dataset yang tidak dilabeli. Metode ini memungkinkan model untuk mencoba menemukan pola atau struktur pada data tanpa adanya informasi output yang

jelas. Contoh *unsupervised learning* meliputi pengelompokan data (*clustering*) seperti K-means, pengurangan dimensi seperti *Principal Component Analysis* (PCA), serta analisis asosiasi untuk menemukan pola pada data tanpa label atau target output yang jelas (McNicholas & Tait, 2019).

2.7 Fungsi Aktivasi

Fungsi aktivasi memainkan peran penting dalam jaringan saraf dan model machine learning lainnya karena berfungsi untuk memperkenalkan non-linearitas ke dalam model. Tanpa fungsi aktivasi, model yang dibangun hanya mampu mempelajari hubungan linier antara input dan output, sehingga sangat membatasi kemampuannya dalam menangkap pola kompleks pada data. Peran fungsi aktivasi terletak pada kemampuannya membantu jaringan saraf membuat keputusan yang lebih baik serta menyesuaikan diri terhadap berbagai jenis data secara efektif (Goodfellow dkk., 2016). Dua fungsi aktivasi yang umum digunakan adalah sebagai berikut:

1. Fungsi sigmoid (fungsi *logistic*)

Fungsi aktivasi sigmoid merupakan salah satu fungsi yang sering digunakan pada jaringan saraf karena mampu memetakan nilai input ke dalam rentang (0, 1). Menurut Goodfellow dkk. (2016), fungsi sigmoid sangat sesuai untuk diterapkan pada lapisan output dalam model klasifikasi biner, karena mampu menghasilkan output yang dapat diinterpretasikan sebagai probabilitas. Rumus dari fungsi sigmoid dituliskan dalam Persamaan (2.7) sebagai berikut (Kurniawan dkk., 2024):

$$f(y) = \frac{1}{1 + e^{-y}} \quad (2.7)$$

dengan:

y = data

e = bilangan Euler

2. Fungsi *tangen hiperbolik* (fungsi *tanh*)

Fungsi aktivasi *tanh* memetakan bilangan real ke interval [-1, 1], menghasilkan output yang dinormalisasi yang tahan terhadap outlier. Ini halus dan nonlinier, memfasilitasi pembelajaran hubungan kompleks dalam jaringan saraf yang dalam (Mastromichalakis, 2023). Rumus fungsi *tanh* dituliskan dalam Persamaan (2.8) sebagai berikut (Kurniawan dkk., 2024):

$$\tanh(y) = \frac{e^y - e^{-y}}{e^y + e^{-y}} \quad (2.8)$$

dengan:

y = data

e = bilangan Euler

2.8 Deep Learning

Deep learning adalah subbidang dari pembelajaran mesin dan kecerdasan buatan, yang berfokus pada pengembangan model yang mengatasi masalah dunia nyata menggunakan kumpulan data besar. Keberhasilan *deep learning* didorong oleh kemajuan dalam komputasi, khususnya penggunaan GPU yang memungkinkan pelatihan model yang lebih besar dan lebih kompleks (Goodfellow dkk., 2016). Salah satu arsitektur penting dalam deep learning adalah *Recurrent Neural Network* (RNN), yang dirancang untuk menangani data sekuensial. Ini menggunakan koneksi umpan balik, memungkinkannya untuk mempertahankan memori input sebelumnya.

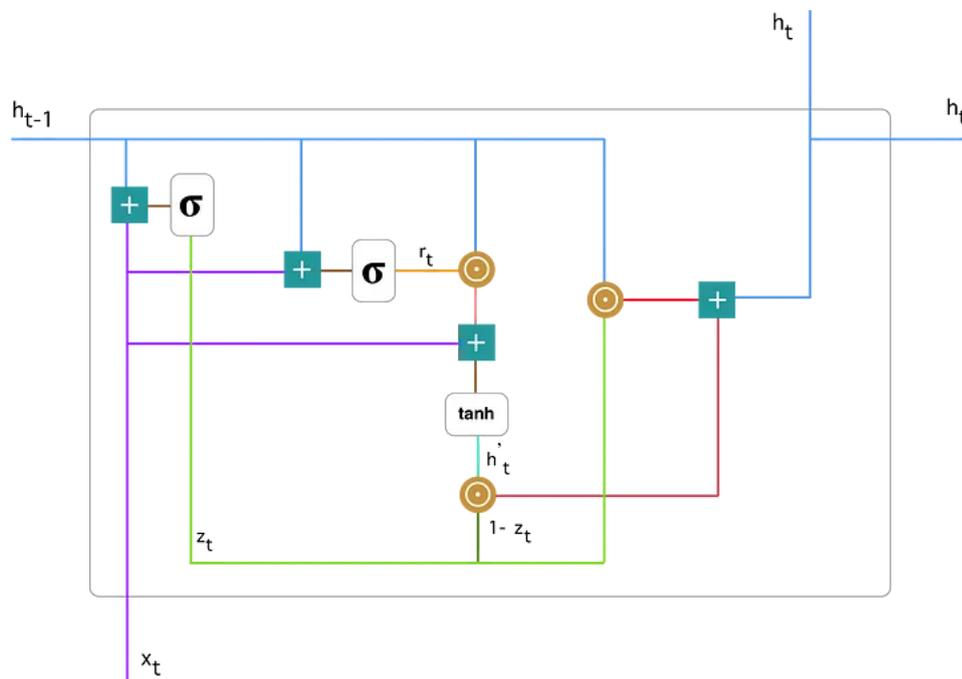
2.9 Recurrent Neural Network (RNN)

Model RNN adalah jenis arsitektur jaringan saraf yang dirancang untuk memproses data sekuensial dengan mengandalkan umpan balik dari output sebelumnya ke input, yang memungkinkan model untuk mempertimbangkan konteks temporal dari data. Model RNN memiliki kemampuan untuk menyimpan informasi dari langkah sebelumnya melalui memori internal, sehingga dapat mengingat dan memanfaatkan informasi tersebut dalam proses pengambilan keputusan untuk input berikutnya (Gulli & Pal, 2019). Model RNN sangat efektif dalam berbagai aplikasi, seperti pemrosesan bahasa alami dan analisis deret waktu, karena kemampuannya untuk menangkap hubungan jangka panjang dalam urutan data.

Model RNN menghadapi tantangan dalam proses pelatihan, terutama saat menangani dependensi jangka panjang akibat masalah gradien yang lenyap atau meledak. Arsitektur GRU kemudian dikembangkan sebagai solusi yang efektif dalam menangani permasalahan tersebut, sekaligus menawarkan efisiensi melalui jumlah parameter yang lebih sedikit dibandingkan LSTM. Kemampuan ini menjadikan GRU sebagai alternatif yang sering digunakan dalam berbagai aplikasi yang memerlukan pemahaman konteks mendalam terhadap urutan data.

2.10 Gated Recurrent Unit (GRU)

Model GRU merupakan arsitektur jaringan saraf berulang yang berhasil diterapkan pada data deret waktu. Masalah dalam pelatihan dapat diatasi oleh GRU dengan mengontrol informasi dari masa lalu melalui dua gerbang, yaitu gerbang pembaruan dan gerbang reset (Kanai dkk., 2017). Struktur arsitektur model GRU ditunjukkan pada gambar berikut:



Gambar 1. Arsitektur Model GRU (Kostadinov, 2017)

Menurut Gao & Glowcka (2016), GRU menggunakan dua gerbang yaitu gerbang pembaruan dan gerbang *reset*.

1. Gerbang pembaruan berfungsi untuk menentukan seberapa banyak aktivasi sebelumnya yang perlu dipertahankan. Persamaan untuk gerbang pembaruan dijabarkan pada Persamaan (2.9) sebagai berikut (Gao & Glowcka, 2016):

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_f) \quad (2.9)$$

dengan:

z_t = gerbang *update* dalam timestep t

σ = fungsi *sigmoid*

W_z = nilai bobot untuk gerbang *update*

$h_{(t-1)}$ = nilai t dalam *timestep* $(t - 1)$

x_t = nilai *input* dalam *timestep* t

b_f = nilai bias gerbang *update*

2. Gerbang reset berfungsi untuk memutuskan seberapa banyak informasi masa lalu yang perlu dilupakan. Struktur ini membantu mengelola aliran informasi secara efektif. Persamaan untuk gerbang reset dituliskan pada Persamaan (2.10) sebagai berikut (Gao & Glowcka, 2016):

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2.10)$$

dengan:

r_t = gerbang *update* dalam *timestep* t

σ = fungsi *sigmoid*

W_r = nilai bobot untuk gerbang *update*

$h_{(t-1)}$ = nilai *output* dalam *timestep* $(t - 1)$

x_t = nilai *input* dalam *timestep* t

b_r = nilai bias gerbang *update*

Selanjutnya, menentukan kandidat state tersembunyi pada langkah waktu saat ini (t) berdasarkan informasi yang relevan dari langkah waktu sebelumnya ($t - 1$) dilakukan menggunakan fungsi aktivasi *tanh* sesuai dengan Persamaan (2.11) sebagai berikut (Gao & Glowcka, 2016):

$$\hat{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \quad (2.11)$$

dengan:

\hat{h}_t = kandidat state tersembunyi

\tanh = fungsi *tanh*

W = nilai bobot

r_t = gerbang *reset*

σ = fungsi *sigmoid*

x_t = nilai *input* dalam *timestep* t

b_h = nilai bias gerbang *update*

Proses penghitungan output akhir dilakukan menggunakan Persamaan (2.12) yang dijelaskan sebagai berikut (Gao & Glowcka, 2016):

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \hat{h}_t \quad (2.12)$$

dengan:

$h_t = output$

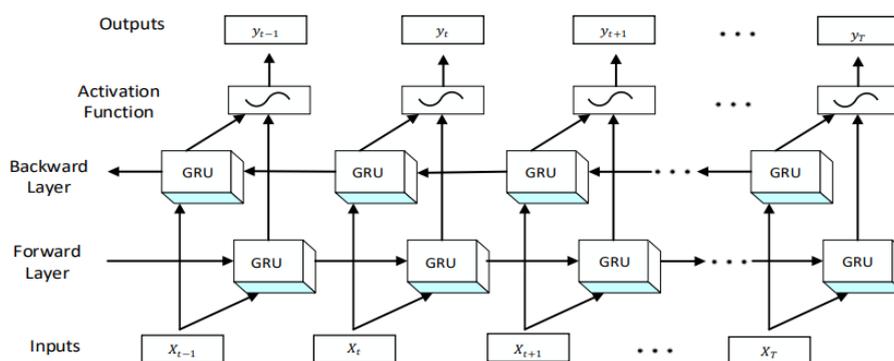
$z_t = output$ pada gerbang pembaruan

$h_{(t-1)}$ = state tersembunyi dalam timestep $(t - 1)$

$\hat{h}_t = output$ pada gerbang *reset*

2.11 Bidirectional Gated Recurrent Unit (BiGRU)

Model BiGRU merupakan varian dari RNN yang memproses data sekuensial dengan mengenali pola dalam arah maju dan mundur, meningkatkan kemampuannya untuk menangkap hubungan kompleks dalam data deret waktu, seperti harga saham (Liu dkk., 2023). Arsitektur ini terdiri atas dua lapisan GRU yang beroperasi secara paralel, di mana satu lapisan memproses urutan dalam arah maju, sementara lapisan lainnya memproses dalam arah mundur. Pendekatan tersebut memungkinkan jaringan untuk menangkap pola dan hubungan berdasarkan konteks masa lalu maupun masa depan, sehingga meningkatkan pemahaman terhadap data berurutan. Integrasi informasi dari kedua arah memungkinkan model BiGRU mengatasi keterbatasan model satu arah. Model ini sangat efektif untuk berbagai aplikasi, seperti pemrosesan bahasa alami, analisis sentimen, dan peramalan data deret waktu, terutama pada kasus yang memerlukan identifikasi hubungan dua arah. Struktur model BiGRU ditampilkan pada Gambar 2 sebagai berikut:



Gambar 2. Arsitektur model BiGRU (Zhang dkk., 2021)

2.12 Model *Hybrid* VECM-BiGRU

Model *hybrid* dalam analisis data merupakan pendekatan yang menggabungkan dua atau lebih teknik atau model untuk memanfaatkan keunggulan masing-masing dalam meningkatkan kinerja dan akurasi analisis. Salah satu contoh model *hybrid* adalah kombinasi VECM dan BiGRU, yang membentuk model VECM-BiGRU. Beberapa alasan mendasari pengembangan metode *hybrid* tersebut (Zhang, 2021).

1. Beberapa kasus peramalan sulit memastikan apakah deret waktu yang dianalisis memiliki pola linier atau nonlinier. Oleh karena itu, digunakan lebih dari satu model yang kemudian dibandingkan untuk memperoleh hasil dengan tingkat akurasi tertinggi. Penggabungan berbagai model diperlukan agar permasalahan dalam pemilihan model dapat diminimalkan.
2. Masalah deret waktu yang sepenuhnya linier atau nonlinier jarang ditemukan, karena pola data cenderung mengandung elemen dari keduanya. Situasi seperti ini membuat model tunggal dianggap kurang efektif karena tidak mampu menangkap pola gabungan secara menyeluruh.
3. Tidak ada satu model peramalan yang dapat dianggap terbaik untuk semua kondisi, sebab kompleksitas pola data pada situasi nyata sering kali tidak dapat ditangani secara optimal dengan hanya menggunakan satu pendekatan.

Oleh karena itu, kemampuan mengenali pola berbeda dalam data dapat ditingkatkan dengan mengombinasikan berbagai model, sehingga akurasi peramalan menjadi lebih baik. Beberapa penelitian empiris menunjukkan bahwa kombinasi model menghasilkan peramalan yang lebih akurat dibandingkan model tunggal. Secara umum, kombinasi model deret waktu diasumsikan terdiri atas dua komponen utama, yaitu komponen linier dan nonlinier, yang diuraikan dalam Persamaan (2.13) sebagai berikut (Zhang, 2021):

$$Y_t = L_t + NL_t + a_t \quad (2.13)$$

dengan:

Y_t = data actual pada periode t

L_t = komponen linear pada periode t

NL_t = komponen nonlinear pada periode t

a_t = kesalahan

t = indeks waktu

Model *hybrid* VECM–BiGRU terdiri dari dua tahap utama. Tahap pertama menggunakan model VECM untuk menangkap dan memodelkan komponen linier dalam data. Tahap kedua memanfaatkan model BiGRU untuk mengidentifikasi

dan memodelkan komponen nonlinier. Sehingga persamaan model *hybrid* VECM-BiGRU dapat ditulis dalam Persamaan (2.14) sebagai berikut (Zhang, 2003):

$$Y'_t = L'_t + NL'_t \quad (2.14)$$

dengan:

Y'_t = nilai peramalan dari model *hybrid* pada periode t

L'_t = nilai peramalan dari komponen linear pada periode t

NL'_t = nilai peramalan dari komponen nonlinier pada periode t

t = indeks waktu

2.13 Evaluasi Model

Evaluasi model merupakan proses dalam analisis data dan *machine learning* yang bertujuan menilai kinerja model dalam memprediksi atau menjelaskan variabel yang diamati. Proses ini mencakup pengukuran tingkat akurasi prediksi model berdasarkan data yang telah digunakan untuk pelatihan. Melalui evaluasi model, peneliti dapat menilai kesesuaian model untuk diterapkan dalam situasi nyata atau menentukan perlunya penyesuaian lebih lanjut. Proses evaluasi umumnya dilakukan dengan membagi dataset menjadi dua bagian, yaitu data pelatihan untuk membangun model dan data pengujian untuk menilai performanya. Salah satu pendekatan yang sering digunakan dalam evaluasi adalah penggunaan metrik kesalahan, seperti *Mean Absolute Percentage Error* (MAPE) atau *Root Mean Squared Error* (RMSE).

1. Nilai MAPE merupakan metrik yang digunakan untuk mengukur rata-rata kesalahan absolut dalam bentuk persentase. Penggunaan MAPE memberikan gambaran mengenai sejauh mana nilai prediksi menyimpang dari nilai aktual dalam bentuk persentase, sehingga lebih mudah dipahami. Persamaan yang digunakan untuk menghitung MAPE ditampilkan pada Persamaan (2.15) sebagai berikut (Kusdarwati & Handoyo, 2018):

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left(\frac{|A_i - F_i|}{A_i} \right) \times 100\% \quad (2.15)$$

dengan :

A_i = nilai data aktual

F_i = nilai hasil prediksi

n = banyaknya data

i = indeks waktu, $i = 1, 2, \dots$

2. Nilai RMSE merupakan akar kuadrat dari rata-rata kuadrat selisih antara nilai

aktual dan nilai prediksi. Penggunaan RMSE memberikan ukuran kesalahan dalam satuan yang sama dengan data asli, sehingga memudahkan interpretasi dalam konteks nilai sebenarnya. Persamaan yang digunakan untuk menghitung MAPE ditampilkan pada Persamaan (2.16) sebagai berikut (Kusdarwati & Handoyo, 2018):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \quad (2.16)$$

dengan :

A_t = nilai data aktual

F_t = nilai hasil prediksi

n = banyaknya data

t = indeks waktu, $t = 1, 2, \dots$

2.14 Uji Kesesuaian Model (*Goodness Of Fit*)

Goodness of fit merupakan metode statistik yang digunakan untuk menguji kesesuaian antara distribusi data empiris dengan distribusi teoritis yang diasumsikan. Salah satu metode yang sering digunakan adalah uji *Kolmogorov-Smirnov* (KS). Menurut Gibbons dan Chakraborti (2011), uji K-S mengukur jarak maksimum antara fungsi distribusi kumulatif empiris dan fungsi distribusi kumulatif teoritis yang dibandingkan. Tujuannya adalah untuk menilai apakah sampel berasal dari distribusi tertentu, seperti distribusi normal. Penggunaan *goodness of fit* berbasis uji KS menjadi penting karena memberikan dasar statistik dalam memverifikasi asumsi distribusi sebelum dilakukan pemodelan lebih lanjut. Persamaan dasar dari statistik KS dirumuskan pada Persamaan (2.17) sebagai berikut (Gibbons & Chakraborti, 2011):

$$KS = \sup_x |F_n(x) - F(x)| \quad (2.17)$$

dengan :

KS = statistik uji Kolmogorov-Smirnov

$F_n(x)$ = fungsi distribusi kumulatif empiris dari sampel

$F(x)$ = fungsi distribusi kumulatif teoritis

BAB III

METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2024/2025, bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data harian harga penutupan saham PT. Indofood Sukses Makmur Tbk yang diperoleh dari <https://finance.yahoo.com/quote/INDF.JK/history/> dan kurs mata uang Rupiah dari Bank Indonesia di <https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/Default.aspx>. Data mencakup periode 1 Januari 2019 hingga 30 September 2024 dengan total 1.394 data, seperti yang ditampilkan pada Tabel 2 sebagai berikut:

Tabel 2. Tabel Kurs dan *Close*

Tanggal	Kurs	Close
01/01/2019	14.465	7.450
02/01/2019	14.474	7.275
03/01/2019	14.350	7.475
04/01/2019	14.105	7.425
⋮	⋮	⋮
25/09/2024	15.092	7.175

3.3 Alat Penelitian

Penelitian ini dilakukan dengan menggunakan alat dalam mendukung dan menunjang pelaksanaan penelitian sebagai berikut.

1. Perangkat Keras

Penelitian ini, menggunakan satu unit laptop sebagai perangkat keras dengan spesifikasi sebagai berikut:

- *Processor* : Intel(R) Celeron(R) N5100 @ 1.10GHz 1.11 GHz
- *RAM* : 4,00 GB

2. Perangkat Lunak

- *Google Collaboratory (Phyton 3.10.12)*
- *Sistem Operasi Windows 10 Pro 64-bit*

3. Library yang digunakan:

- *NumPy (1.26.4)*

Digunakan untuk operasi matematika dan manipulasi array. Dalam konteks ini, digunakan untuk representasi dan manipulasi data deret waktu.

- *Pandas (2.2.2)*

Digunakan untuk membaca, mengelola, dan memanipulasi data. Pada penelitian ini digunakan untuk membaca data deret waktu dari file CSV atau database serta mengorganisirnya dalam bentuk dataframe.

- *Matplotlib (3.10.0)*

Digunakan untuk memvisualisasikan data deret waktu, hasil prediksi, atau kinerja model dalam bentuk grafik dan plot.

- *Seaborn (0.13.2)*

Library visualisasi statistik yang meningkatkan estetika grafik. Biasa digunakan bersama *Matplotlib*.

- *Scikit-Learn (1.6.0)*

Digunakan untuk membagi data menjadi pelatihan dan pengujian serta mengevaluasi kinerja model BiGRU.

- *Statsmodels (0.14.4)*

Digunakan untuk membangun dan mengevaluasi model statistik seperti VECM.

3.4 Metode Penelitian

Tahapan yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. *Input Data*

Analisis dimulai dengan *input data*. Harga penutupan saham sebagai endogen (Y_1) dan nilai tukar mata uang sebagai endogen (Y_2) digunakan dalam data multivariat ini.

2. *Visualisasi Data*

Visualisasi data digunakan untuk mengidentifikasi pola dan perubahan dalam data.

3. *Splitting Data*

Data kemudian dibagi menjadi data *training* (untuk melatih model) sebesar 80% dan data *testing* (untuk mengevaluasi model) sebesar 20%. Pembagian ini penting untuk memastikan bahwa model tidak *overfitting* dan dapat digeneralisasikan pada data baru.

4. *Preprocessing Data*

Pada tahap ini, data diproses untuk memastikan tidak ada nilai yang hilang (*missing values*) atau duplikasi data yang dapat mengganggu hasil analisis. Data yang sudah dibersihkan kemudian siap untuk dianalisis pada tahap selanjutnya.

5. Uji Kausalitas Granger

Uji kausalitas Granger dilakukan untuk menentukan apakah suatu variabel memiliki pengaruh terhadap variabel lainnya. Uji ini penting dalam memahami hubungan sebab-akibat antar variabel yang akan memengaruhi pembentukan model.

6. Uji Kointegrasi

Jika hasil uji kausalitas menunjukkan adanya hubungan jangka panjang antar variabel, maka perlu dilakukan uji kointegrasi. Apabila variabel-variabel memiliki kointegrasi, hal ini mengindikasikan adanya hubungan keseimbangan jangka panjang di antara variabel, sehingga model VECM dapat digunakan. Sebaliknya, jika tidak ditemukan kointegrasi, maka model VAR yang digunakan.

7. Model VECM

Model VECM digunakan untuk menangkap hubungan antar variabel waktu dan memprediksi variabel berdasarkan lag dari variabel lainnya. Model VECM sangat berguna dalam peramalan data ekonomi dan finansial.

8. Menentukan Panjang Lag Optimum

Pemilihan lag optimal sangat penting untuk meningkatkan akurasi model VECM. Lag yang tepat dipilih berdasarkan kriteria informasi dengan nilai *Bayesian*

Information Criterion (BIC) terkecil. Lag optimum memastikan bahwa model menangkap hubungan jangka waktu yang paling relevan.

9. Estimasi Parameter Model VECM

Setelah menentukan lag, parameter model VECM diestimasi menggunakan data *training*. Estimasi ini bertujuan untuk menghasilkan model terbaik yang dapat digunakan untuk prediksi.

10. Prediksi dan Peramalan VECM

Model VECM kemudian digunakan untuk melakukan prediksi pada variabel yang dianalisis. Hasil prediksi ini nantinya akan menjadi input bagi model BiGRU.

11. Menghitung Residual dan Uji Asumsi Residual *White Noise*

Residual dari model VECM dihitung, yang merepresentasikan kesalahan prediksi model. Uji asumsi *white noise* dilakukan pada residual untuk memastikan bahwa tidak ada pola yang tersisa dalam residual, yang menunjukkan bahwa model sudah *fit* dengan baik.

12. Evaluasi Model VECM

Evaluasi kinerja model VECM dilakukan menggunakan metrik seperti *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Squared Error* (RMSE). Evaluasi ini bertujuan untuk melihat seberapa baik model dalam memprediksi variabel.

13. *Input Data* untuk Metode BiGRU

Setelah prediksi dan residual dari model VECM diperoleh, data ini digunakan sebagai input untuk dua model BiGRU. Prediksi VECM digunakan sebagai input untuk model P_BiGRU, sementara residual VECM digunakan sebagai input untuk model E_BiGRU.

14. *Scaling Data*

Data residual maupun data prediksi VECM distandarisasi menggunakan *Min-Max Scaler*. Data dinormalisasi agar setiap fitur memiliki rentang nilai yang seragam, seperti antara 0 dan 1. Langkah ini penting untuk meningkatkan kinerja dan kestabilan model GRU selama tahap pelatihan.

15. *Hyperparameter Tuning*

Proses tuning dilakukan untuk menentukan parameter terbaik bagi P_BiGRU dan E_BiGRU. Parameter seperti jumlah unit di *hidden layer*, *learning rate*, dan *batch size* ditentukan menggunakan teknik *grid search*.

16. Membangun Model P_BiGRU dan E_BiGRU

Kedua model ini dibangun menggunakan parameter terbaik yang telah diperoleh melalui proses tuning sebelumnya.

17. Melakukan Prediksi dan Peramalan pada P_BiGRU dan E_BiGRU

Proses prediksi dan peramalan dilakukan menggunakan model P_BiGRU dan E_BiGRU, yang dibangun berdasarkan data prediksi serta residual dari model VECM.

18. *Unscaling Data*

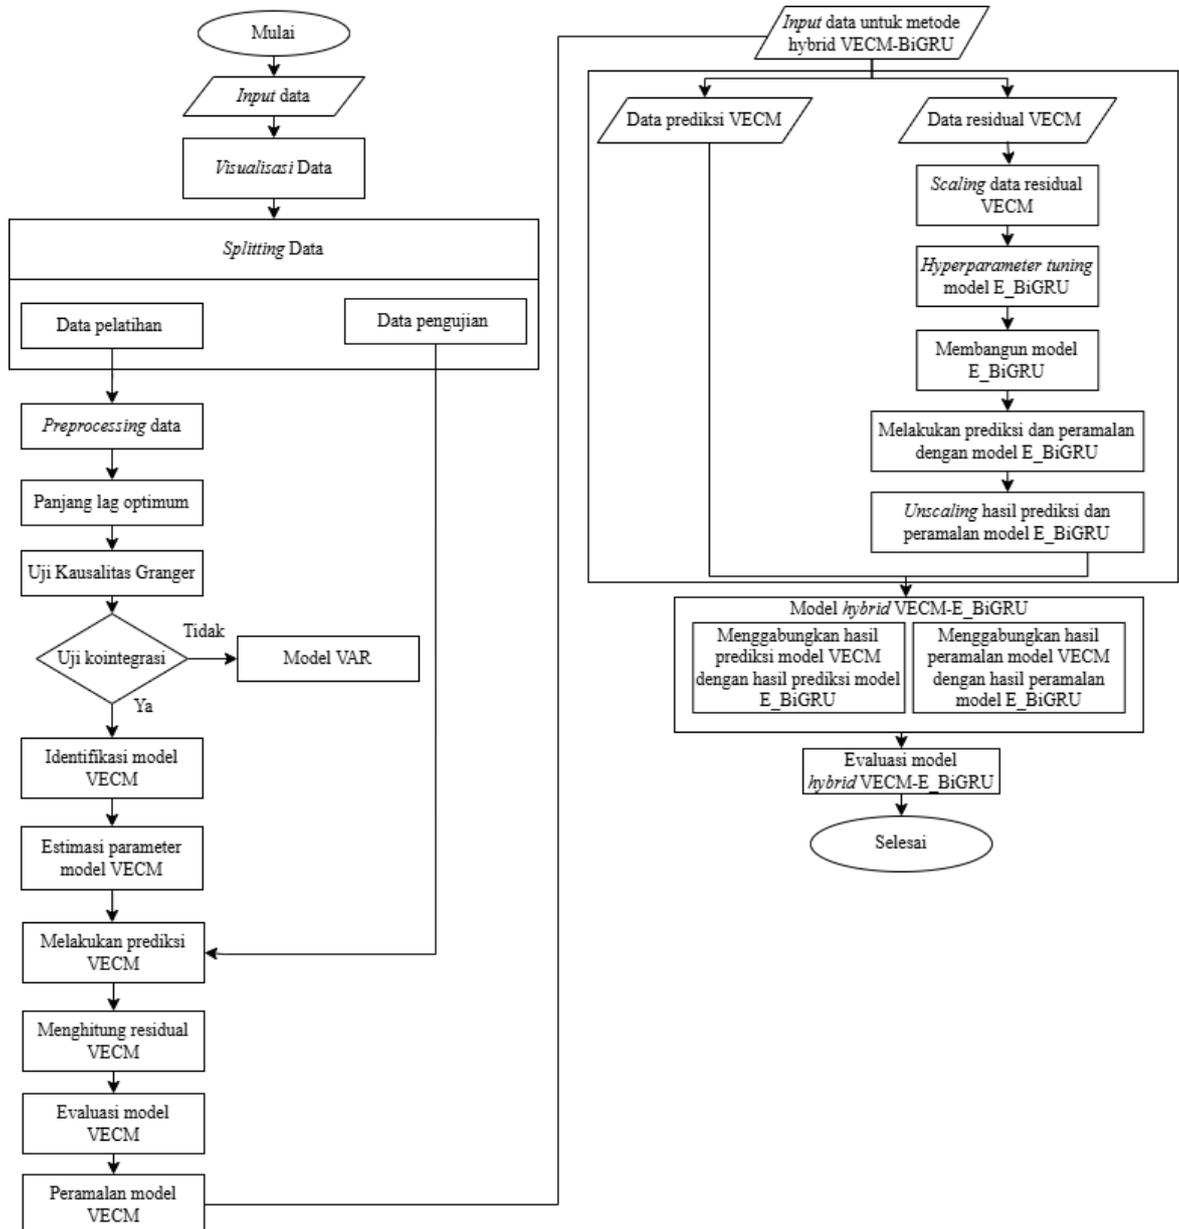
Setelah proses prediksi selesai, data hasil prediksi dan peramalan dari model P_BiGRU dan model E_BiGRU diubah kembali ke skala aslinya melalui proses *unscaling*, agar hasil tersebut dapat diinterpretasikan sesuai dengan skala awal data.

19. Mengintegrasikan Hasil Prediksi dan Peramalan (Model *Hybrid*)

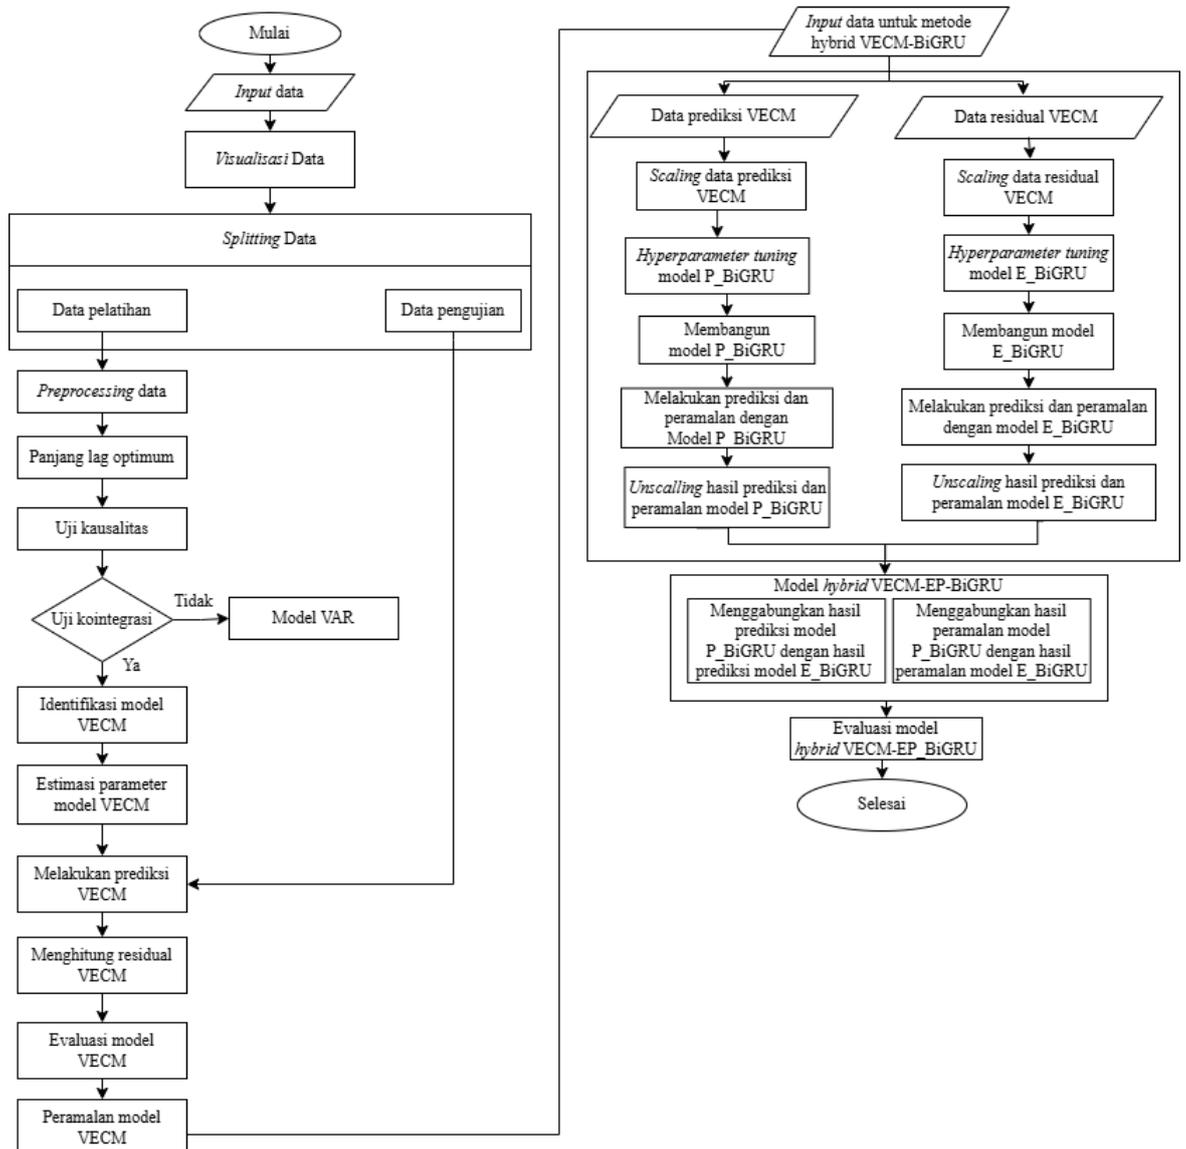
Data hasil prediksi dan peramalan dari model P_BiGRU dan E_BiGRU digabungkan melalui proses penjumlahan untuk membentuk model *hybrid* VECM-EP_BiGRU. Selain itu, data hasil prediksi dan peramalan dari model VECM dan E_BiGRU juga digabungkan melalui proses penjumlahan untuk membentuk model *hybrid* VECM-E_BiGRU.

20. Evaluasi Model *Hybrid*

Setelah hasil prediksi dari model VECM-EP_BiGRU dan VECM-E_BiGRU diperoleh, dilakukan evaluasi terhadap kinerja kedua model *hybrid* tersebut. Evaluasi dilakukan dengan menggunakan dua metrik, yaitu MAPE dan RMSE, yang juga digunakan pada evaluasi model VECM sebelumnya. MAPE digunakan untuk mengukur persentase kesalahan rata-rata antara nilai aktual dan nilai prediksi, sedangkan RMSE digunakan untuk mengukur besar rata-rata kesalahan dalam satuan yang sama dengan data aslinya. Melalui evaluasi ini, dapat diketahui tingkat akurasi dan efektivitas model *hybrid* dalam melakukan prediksi terhadap data harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah.



Gambar 3. Flowchart Model Hybrid VECM-E_BiGRU



Gambar 4. Flowchart Model Hybrid VECM-EP_BiGRU

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Hasil dan pembahasan tentang penerapan metode *hybrid* VECM-BiGRU untuk peramalan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah menghasilkan kesimpulan berikut:

1. Pembangunan model *hybrid* VECM-BiGRU dilakukan melalui dua pendekatan. Pendekatan pertama menghasilkan peramalan dengan menjumlahkan hasil prediksi dari model P-BiGRU dan E-BiGRU. Pendekatan kedua menghasilkan peramalan dengan menjumlahkan hasil prediksi dari model VECM dan E-BiGRU. Seluruh pendekatan tersebut memanfaatkan kombinasi parameter terbaik yang telah diperoleh melalui proses pengaturan hyperparameter. Rincian kombinasi parameter ditampilkan sebagai berikut:
 - (a) Model VECM-E_BiGRU dibangun dengan menggabungkan kombinasi parameter terbaik yang diperoleh: 64 BiGRU *unit*, 32 *unit dense*, 64 ukuran *batch*, dan 0.1 *dropout*.
 - (b) Model VECM-EP_BiGRU dibangun dengan menggabungkan kombinasi parameter terbaik yang diperoleh: 32 BiGRU *unit*, 128 *unit dense*, dan 32 ukuran *batch*.
2. Peneliti telah melakukan peramalan harga penutupan saham PT Indofood Sukses Makmur Tbk dan nilai tukar rupiah untuk 30 periode ke depan menggunakan model *hybrid* VECM-BiGRU dengan dua pendekatan berbeda. Hasil peramalan model *hybrid* VECM-EP_BiGRU menunjukkan perbedaan yang signifikan dibandingkan dengan model VECM dan model *hybrid* VECM-E_BiGRU. Meskipun model VECM mampu memberikan hasil prediksi yang cukup baik, peramalan yang dihasilkannya cenderung kurang

adaptif karena hanya mengikuti pola linier yang konstan. Hal serupa juga terlihat pada hasil peramalan model *hybrid* VECM-E_BiGRU yang menunjukkan pola pergerakan hampir sama dengan model VECM individu. Sebaliknya, model *hybrid* VECM-EP_BiGRU mampu menangkap pola dan tren pergerakan harga saham serta nilai tukar dengan lebih dinamis dan fleksibel, serta tetap menghasilkan evaluasi yang optimal.

3. Hasil *goodness of fit* menggunakan nilai statistik *Kolmogorov-Smirnov* menunjukkan bahwa model *hybrid* VECM-EP_BiGRU memiliki nilai statistik KS terkecil dibandingkan model VECM maupun model *hybrid* VECM-E_BiGRU, baik pada variabel harga *close* saham PT Indofood Sukses Makmur Tbk dan kurs. Nilai tersebut mengindikasikan bahwa model *hybrid* VECM-EP_BiGRU memiliki kemampuan paling baik dalam menyesuaikan distribusi hasil peramalan terhadap distribusi data aktual. Dengan demikian, model *hybrid* VECM-EP_BiGRU dapat disimpulkan sebagai model dengan kinerja peramalan terbaik dibandingkan dua model lainnya.

DAFTAR PUSTAKA

- Abbahaddou, K., Chiadmi, M., & Aboulaich, R. 2022. An Enhanced Adaptive System Based on Machine Learning for Predicting The Evolution of Islamic Stock Prices. *WSEAS Transactions on Business and Economics*, **19**: 1661–1668.
- Agisya, M. N., Andriyana, Y., & Handoko, B. 2024. Peramalan rasio non-performing loans sektor usaha pertambangan dan penggalian menggunakan metode bidirectional gated recurrent unit (BiGRU). *Prosiding Seminar Nasional Statistika Aktuaria III*. Universitas Padjadjaran. **3**(1): 284–300.
- 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).
- Chirkova, O. A. 2024. Forecasting the implementation of strategic development programs of the municipality. *Economic and Political Bulletin*, **15**(1), 45–58.
- Cho, K., van Merriënboer, B., Bahdanau, D., & Bengio, Y. 2014. On The Properties Of Neural Machine Translation: Encoder-Decoder Approaches. *arXiv preprint arXiv: 1409.1259*.
- Gao, Y., & Glowacka, D. 2016. Deep gate recurrent neural network. In R. J. Durrant K.-E. Kim (Eds.), *Proceedings of the Workshop and Conference on Machine Learning Research*, **63**: pp. 350–365.
- Gibbons, J. D., & Chakraborti, S. 2011. *Nonparametric statistical inference* (5th Ed.). CRC Press.
- Goodfellow, I., Bengio, Y., Courville, A. 2016. *Deep learning*. MIT Press.
- Gujarati, D. N., & Porter, D. C. 2003. *Basic Econometrics* (4th ed.). New York: McGraw-Hill.
- Gujarati, D. N. 2009. *Basic Econometrics* (4th Ed.). Gary Burke.
- Gulli, A., & Pal, S. 2019. *Deep Learning with Keras*. Packt Publishing.
- Han, J., Kamber, M., & Pei, J. 2012. *Data Mining: Concepts and Techniques* (3rd Ed.). Morgan Kaufmann.
- Hyndman, R. J., & Athanasopoulos, G. 2018. *Forecasting: Principles and Practice* (2nd Ed.). Otexts.

- Johansen, S. 1988. Statistical analysis of cointegration vectors. *Journal of Economic Dynamics and Control*, **12**(2–3), 231–254.
- Kanai, S., Fujiwara, Y., & Iwamura, S. 2017. Preventing Gradient Explosions in Gated Recurrent Units. In *31st Conference on Neural Information Processing Systems (NIPS 2017)*, Long Beach, CA, USA.
- Khan, A. I., & Al-Habsi, S. 2020. Machine learning in computer vision. *Procedia Computer Science*, **167**: 1444–1451.
- Kimura, K., & Waki, H. 2016. Minimization of Akaike's information criterion in linear regression analysis via mixed integer nonlinear program. *Optimization and Control*.
- Kostadinov, S. 2017. Understanding GRU Networks. Medium. Retrieved From <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>. Accessed November 12, 2024.
- Kurniawan, K., Caesaro, B., & Sucipto. 2024. Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM Dalam Prediksi Ketinggian Air Sungai. *Jurnal Edukasi dan Penelitian Informatika*. **10**(1): 134-143.
- Kusdarwati, H., & Handoyo, S. 2018. System for Prediction of Non-Stationary Time Series Based on The Wavelet Radial Basis Function Neural Network Model. *International Journal of Electrical and Computer Engineering (IJECE)*, **8**(4): 2327–2337.
- Liu, Y., Ren, S., & Wang, Y. 2023. Improved BIGRU Model and Its Application in Stock Price Forecasting. *Electronics*, **12**(12), 2718.
- Ljung, G. M., & Box, G. E. 1978. On a Measure of Lack of Fit in Time Series Models. *Biometrika*. **65**(2): 297-303.
- Lütkepohl, H. 2005. *New Introduction to Multiple Time Series Analysis*. Springer.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. 1998. *Forecasting Methods And Applications* (3rd Ed.). Wiley.
- Mastromichalakis, S. 2023. Parametric Leaky Tanh: A New Hybrid Activation Function For Deep Learning. *arXiv preprint arXiv:2310.07720*.
- McNicholas, P. D. & Tait, P. A. 2019. *Unsupervised Learning*. CRC Press.
- Moghniuddin, M. 2024. Effect of Using Numerical Data Scaling on Supervised Machine Learning Performance. *Al-Magalla Al-Libiyya Al-Al[∞] Amiyya*, **67**: 1–21.
- Montgomery, D. C., Jennings, L. C., & Kulahci, M. 2015. *Introduction to time series analysis and forecasting* (2nd Ed.). John Wiley and Sons.

- Putri, M., Widiarti, & Nuryaman, A. 2023. Penerapan Model Vector Error Correction Model (VECM) pada Peramalan Data Nilai Ekspor dan Nilai Impor Seluruh Komoditas di Provinsi Lampung Tahun 2022. *Jurnal Siger Matematika*, **4**(2): 67–74.
- Setiawan, B. 2019. Analisis Kinerja Perusahaan di Sektor Pangan. *Jurnal Ekonomi dan Bisnis*, **7**(2): 122–131.
- Sims, C. A. 1980. Macroeconomics and Reality. *Econometrica*, **48**(1): 1–48.
- Sornette, D., & Zhou, W.-X. 2004. Non-Parametric Determination of Real-Time Lag Structure between Two Time Series: The "Optimal Thermal Causal Path" Method. *Journal of Macroeconomics*, **28**(1), 195–224.
- Stock, J. H., & Watson, M. W. 2001. Vector Autoregressions. *The Journal of Economic Perspectives*, **15**(4): 101–115.
- Tanjung, A. A. C., & Saputro, D. R. S., Kurdhi, N. A. 2024. Implementation of the Bidirectional Gated Recurrent Unit Algorithm on Consumer Price Index Data in Indonesia. *BAREKENG: Journal of Mathematics and Its Applications*, **18**(1), 95–104.
- Usman, M., Fatin, D. F., & Barusman, M. Y. S., Elfaki, F. A. M. 2017. Application of Vector Error Correction Model (VECM) and Impulse Response Function for Analysis Data Index of Farmers' Terms of Trade. *Indian Journal of Science and Technology*, **10**(19): 1–14.
- Valentika, N., Nursyirwan, V. I., & Imdadi. 2022. Peramalan Kurs, Inflasi, Impor, Dan Ekspor dengan VECM. *Accounting Information System*, **5**(1): 119–130.
- Wang, X., Zhang, Y., & Li, J. 2024. Granger causality test in Time Series Analysis: Assessing The Predictive Power and Directional Relationships between Variables. *Journal of Time Series Analysis*, **45**(3): 234–250.
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. Pearson.
- Widarjono, A. (2018). *Ekonometrika: Teori dan aplikasi untuk ekonomi dan bisnis* (Edisi ke-4). Yogyakarta: UPP STIM YKPN.
- Zhang, Z., Dong, Z., Lin, H., He, Z., Wang, M., He, Y., & Gao, M. 2021. An Improved Bidirectional Gated Recurrent Unit Method for Accurate State-of-Charge Estimation. *IEEE access*. **9**: 11252-11263
- Zhou, B. 2023. Semiparametrically Optimal Cointegration Test. *Social Science Research Network*.