

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR)*
– *GATED RECURRENT UNIT (GRU)* PADA PERAMALAN DATA BI RATE
DAN INDEKS HARGA SAHAM GABUNGAN (IHSG)**

Oleh

**ADELIA FEBBY AMARA
2017031095**



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

ABSTRAK

IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR)* – *GATED RECURRENT UNIT (GRU)* PADA PERAMALAN DATA *BI RATE* DAN INDEKS HARGA SAHAM GABUNGAN (IHSG)

Oleh

ADELIA FEBBY AMARA

Indeks Harga Saham Gabungan (IHSG) merupakan indeks gabungan dari seluruh jenis saham yang ada atau tercatat di bursa efek. IHSG juga sering dijadikan parameter stabilitas ekonomi. Perekonomian Indonesia juga berkaitan dengan *BI Rate*, yang merupakan suku bunga yang ditetapkan oleh Bank Indonesia, berpengaruh langsung terhadap tingkat inflasi dan pertumbuhan ekonomi. Kedua indikator ini saling terkait, dan kebijakan yang bijak dalam mengelolanya dapat memperkuat fondasi ekonomi. Pemerintah dapat mengambil langkah-langkah terukur, menentukan prioritas kebijakan, dan menciptakan lingkungan ekonomi yang kondusif untuk pertumbuhan jangka panjang dengan adanya peramalan IHSG dan *BI Rate*. Metode statistika klasik yang dapat digunakan untuk meramalkan IHSG dan *BI Rate* yaitu *Vector Autoregressive (VAR)*, namun model VAR memiliki keterbatasan untuk menangkap pola non-linier pada data. Metode *Gated Recurrent Unit (GRU)* yang merupakan salah satu metode *deep learning* dapat menangani keterbatasan metode VAR tersebut. Oleh karena itu, penelitian ini menggunakan metode *hybrid VAR-GRU* untuk melakukan prediksi dan peramalan IHSG dan *BI Rate*. Metode *hybrid VAR-GRU* terdiri atas dua model yaitu model pertama dengan data prediksi model VAR dan model kedua dengan data residual model VAR. Model *hybrid VAR-GRU* terbaik dengan skema *splitting* data, yaitu 90% data *training*-10% data *testing* yang menghasilkan nilai RMSE sebesar 0.3148, MAPE sebesar 0.039%, dan akurasi sebesar 99.96%.

Kata Kunci: *Hybrid VAR-GRU*, Prediksi, Peramalan, IHSG, *BI Rate*

ABSTRACT

IMPLEMENTATION OF THE HYBRID VECTOR AUTOREGRESSIVE (VAR) – GATED RECURRENT UNIT (GRU) METHOD IN FORECASTING BI RATE DATA AND INDEKS HARGA SAHAM GABUNGAN (IHSG)

By

ADELIA FEBBY AMARA

Indeks Harga Saham Gabungan (IHSG) is a combined index of all types of shares existing or listed on the stock exchange. IHSG is also often used as a parameter for economic stability. The Indonesian economy is also related to the BI Rate, which is an interest rate set by Bank Indonesia, which has a direct influence on the level of inflation and economic growth. These two indicators are interrelated, and wise policies in managing them can strengthen the economic foundation. The government can take measurable steps, determine priority policies, and create an economic environment that is conducive to long-term growth with predictions of the IHSG and BI Rate. The classic statistical method that can be used to predict the IHSG and BI Rate is Vector Autoregressive (VAR), however the VAR model has limitations in capturing non-linear patterns in the data. The Gated Recurrent Unit (GRU) method, which is a deep learning method, can overcome the limitations of the VAR method. Therefore, this research uses the hybrid VAR-GRU method to predict and forecast the IHSG and BI Rate. The hybrid VAR-GRU method consists of two models, namely the first model with VAR model prediction data and the second model with residual VAR model data. The best hybrid VAR-GRU model with a data splitting scheme, namely 90% training data-10% testing data which produces an RMSE value of 0.3148, MAPE of 0.039%, and accuracy of 99.96%.

Keyword: Hybrid VAR-GRU, Prediction, Forecasting, IHSG, BI Rate

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE*
(VAR) – *GATED RECURRENT UNIT* (GRU) PADA PERAMALAN DATA
BI RATE DAN INDEKS HARGA SAHAM GABUNGAN (IHSG)**

Oleh

**ADELIA FEBBY AMARA
2017031095**

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



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

Judul Skripsi

: **IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR) – GATED RECURRENT UNIT (GRU)* PADA PERAMALAN DATA BI RATE DAN INDEKS HARGA SAHAM GABUNGAN (IHSG)**

Nama Mahasiswa

: **Adefia Febby Amara**

Nomor Pokok Mahasiswa

: **2017031095**

Jurusan

: **Matematika**

Fakultas

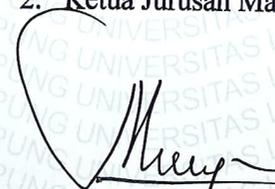
: **Matematika dan Ilmu Pengetahuan Alam**




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

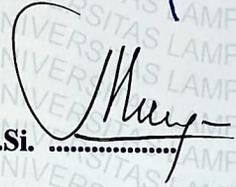
Ketua : Ir. Warsono, M.S., Ph.D



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



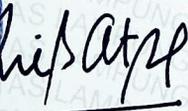
**Penguji
Bukan Pembimbing : Dr. Aang Nuryaman, S.Si., M.Si.**



**2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung**



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



Tanggal Lulus Ujian Skripsi: 8 Juli 2024

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Adelia Febby Amara**
Nomor Pokok Mahasiswa : **2017031095**
Jurusan : **Matematika**
Judul Skripsi : **IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR) – GATED RECURRENT UNIT (GRU)* PADA PERAMALAN DATA BI RATE DAN INDEKS HARGA SAHAM GABUNGAN (IHSG)**

Dengan ini menyatakan bahwa penelitian ini adalah hasil pekerjaan saya sendiri dan 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, 10 Juli 2024

Penulis,



Adelia Febby Amara
NPM. 2017031095

RIWAYAT HIDUP

Penulis bernama lengkap Adelia Febby Amara, lahir di Bandar Lampung, Lampung pada tanggal 8 Februari 2002. Penulis merupakan anak kedua dari 3 bersaudara pasangan Bapak Imron dan Ibu Aida Farhati.

Penulis mengawali pendidikan di Taman Kanak-Kanak (TK) Mutiara Adinda pada tahun 2007-2008 dan menempuh pendidikan dasar di SDN 02 Rawa Laut pada tahun 2008-2014. Kemudian penulis melanjutkan jenjang pendidikannya di SMPN 01 Bandar Lampung pada tahun 2014-2017 dan Sekolah Menengah Atas di SMAN 9 bandar Lampung pada tahun 2017-2020. Setelah itu penulis diterima sebagai mahasiswi Program Studi S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN) pada tahun 2020.

Selama menjadi mahasiswi, penulis aktif di beberapa kegiatan di antaranya: aktif dalam kepengurusan organisasi HIMATIKA FMIPA Unila sebagai anggota Bidang Keilmuan sejak tahun 2020-2021.

Kemudian pada Bulan Januari-Februari 2023 penulis melaksanakan Praktik Kerja Lapangan (PKL) di BPS Provinsi Lampung. Selanjutnya pada bulan Juni-Agustus 2023, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Sindang Garut, Kecamatan Way Lima, Kabupaten Pesawaran, Provinsi Lampung.

KATA INSPIRASI

“Don’t lose hope, nor be sad”

(QS. Ali Imran: 139)

“Maka, sesungguhnya beserta kesulitan ada kemudahan.

Sesungguhnya beserta kesulitan ada kemudahan.”

(QS. Al-Insyirah: 5-6)

*“Jangan terlalu bergantung pada siapapun di dunia ini, karena bayanganmu saja
meninggalkanmu disaat gelap.”*

(Ibnu Taymiyyah)

*”What is destined will reach you, even if it be beneath two mountains. What is not
destined will not reach you even if it be between your two lips.”*

(Imam Al Ghazali)

PERSEMBAHAN

Alhamdulillahirobbil'alamin,

Puji dan Syukur atas kehadiran Allah SWT karena atas rahmat dan hidayahnya sehingga Skripsi ini dapat terselesaikan dengan baik walau dengan berbagai rintangan dilalui saat mengerjakannya.

Dengan penuh ketulusan, saya persembahkan karya sederhana ini untuk:

Kedua Orang Tua Tercinta

Bapak Imron dan Ibu Aida Farhati

Terimakasih kepada Mama dan Papa yang senantiasa selalu mendoakan, memberi motivasi dan dukungan selama ini. Terimakasih telah memberikan pelajaran tentang arti perjalanan hidup sebenarnya sehingga kelak bisa menjadi orang yang bermanfaat bagi orang-orang di sekitar serta Nusa dan Bangsa.

Kakak dan Adik Tersayang

Rio Pratama, S.E., dan Kansya Athifa Mudes

Terimakasih atas semua kasih sayang dan cintanya, serta segala doa dan dukungannya, semoga karya ini dapat bermanfaat dan membuat kalian bangga. Semoga kelak kita menjadi orang sukses dan membanggakan Mama Papa.

Dosen Pembimbing dan Pembahas

Terimakasih atas semua bimbingan, motivasi, arahan, ilmu, serta saran yang berharga selama penyusunan karya ini.

Almamater Tercinta Universitas Lampung

SANWACANA

Puji syukur atas kehadiran Allah Swt. berkat rahmat, nikmat, dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi Metode *Hybrid Vector Autoregressive (VAR) – Gated Recurrent Unit (GRU)* Pada Peramalan Data *BI Rate* dan Indeks Harga Saham Gabungan (IHSG)”.

Terselesainya skripsi ini tidak lepas dari bantuan berbagai pihak, baik langsung maupun tidak. Oleh karena itu, pada kesempatan kali ini penulis mengucapkan terima kasih kepada:

1. Bapak Ir. Warsono, M.S., Ph.D. selaku Pembimbing I yang telah dengan sabar membimbing, memotivasi, dan memberikan arahan sehingga skripsi ini dapat terselesaikan tepat waktu.
2. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku Pembimbing II yang telah memberikan dukungan, arahan, masukan, dan waktunya untuk membimbing dalam proses penyusunan skripsi ini.
3. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Pembahas atas kesediannya untuk menguji dan dengan sabar memberikan masukan, kritik, dan saran.
4. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku dosen pembimbing akademik yang senantiasa memberikan motivasi dan membimbing selama menjalani perkuliahan.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika FMIPA Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.
7. Ibu Prof. Dr. Ir. Lusmeilia Afriani, D.E.A., IPM. selaku Rektor Universitas Lampung.

8. Seluruh Dosen, staf, dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
9. Kedua orang tuaku dan keluarga yang kucintai, Papa, Mama, Masio, dan Adek Kansya, terima kasih atas motivasi, semangat, ajaran, doa, serta kasih dan sayang yang senantiasa diberikan.
10. Diriku sendiri, Adelia Febby Amara yang senantiasa selalu berusaha dan berhasil untuk tidak menyerah di dalam kondisi dan situasi apapun.
11. Sahabatku tersayang sejak SMP, Aya, Dea, Syahda, Shafa, Adela, dan Silvia yang selalu menemani, mendukung, menghibur dan mendoakanku.
12. Yulian, Fegy, Salsa, Callista, Mawar, dan Cindy selaku teman seperbimbingan yang telah bersedia untuk sama-sama berjuang dan saling menyemangati satu sama lain.
13. Chyntia, Naomi, Afra, Monik, Niken, dan Bidari yang senantiasa selalu membantu dan menemani kehidupan perkuliahanku sehingga menjadi lebih berwarna.
14. Teman-teman Jurusan Matematika Angkatan 2020.
15. Semua pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

Bandar Lampung, 10 Juli 2024
Penulis,

Adelia Febby Amara
NPM. 2017031095

DAFTAR ISI

Halaman

DAFTAR TABEL	iv
DAFTAR GAMBAR.....	vi
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian.....	5
1.4 Manfaat Penelitian.....	5
II. TINJAUAN PUSTAKA	5
2.1 Penelitian Terdahulu	5
2.2 Peramalan	8
2.3 Deret waktu	8
2.4 <i>Vector Autoregressive</i> (VAR).....	9
2.4.1 Stasioneritas	10
2.4.2 Panjang <i>Lag</i> Optimum	12
2.4.3 <i>Ordinary Least Square</i> (OLS).....	12
2.4.4 Uji Kointegrasi.....	13
2.4.5 Kausalitas Granger	14
2.4.6 Uji Asumsi Residual <i>White Noise</i>	15
2.5 <i>Machine Learning</i>	16
2.6 Normalisasi dan Denormalisasi Data	16
2.7 Fungsi Aktivasi.....	18
2.8 <i>Deep Learning</i>	20

2.8.1 <i>Recurrent Neural Network (RNN)</i>	20
2.9 <i>Gated Recurrent Unit (GRU)</i>	21
2.10 <i>Hybrid VAR-GRU</i>	24
2.11 Evaluasi Model	25
2.12 Uji T ² Hotelling	26
III. METODOLOGI PENELITIAN	27
3.1 Waktu dan Tempat Penelitian	27
3.2 Data dan Alat Penelitian	28
3.2.1 Data	28
3.2.2 Alat	28
3.3 Alur Kerja Penelitian	29
IV. HASIL DAN PEMBAHASAN	35
4.1 <i>Input Data</i>	35
4.2 Uji Stasioneritas	35
4.3 Uji Kausalitas Granger	36
4.4 Uji Kointegrasi	36
4.5 <i>Splitting Data</i>	37
4.6 Penentuan <i>Lag Optimum</i>	38
4.7 Model VAR	39
4.7.1 Model VAR dengan <i>Splitting Data 80% Data Training dan 20% Data Testing</i>	39
4.7.2 Model VAR dengan <i>Splitting Data 90% Data Training dan 10% Data Testing</i>	40
4.8 Prediksi dan Peramalan Model VAR	41
4.8.1 Prediksi Model VAR	42
4.8.2 Peramalan Model VAR	44
4.9 Residual Model VAR	46
4.9.1 Menghitung Residual	46
4.9.2 Uji Asumsi Residual <i>White Noise</i>	47
4.10 Membangun Model <i>Gated Recurrent Unit (GRU)</i>	48
4.10.1 Membangun Model GRU Pertama dengan Data Prediksi Model VAR ..	49

4.10.2 Membangun Model GRU Kedua dengan Data Residual Model VAR	51
4.11 Prediksi Model GRU	53
4.11.1 Prediksi Model GRU Pertama dengan Data Prediksi Model VAR	54
4.11.2 Prediksi Model GRU Kedua dengan Data Residual Model VAR	56
4.11.3 Prediksi Model <i>Hybrid</i> VAR-GRU	58
4.12 Peramalan dengan Model <i>Hybrid</i> VAR – GRU	60
4.12.1 Peramalan Model GRU Pertama dengan Prediksi Model VAR	60
4.12.2 Peramalan Model GRU Kedua dengan Data Residual Model VAR....	62
4.12.3 Peramalan Model <i>Hybrid</i> VAR-GRU	63
4.13 Perbandingan Data Aktual dan Peramalan	64
V. KESIMPULAN	65
DAFTAR PUSTAKA.....	67

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terkait Peramalan IHSG dan BI Rate dengan Metode <i>Hybrid VAR-GRU</i>	5
2. Data IHSG dan BI Rate periode Januari 2007 – Oktober 2023	28
3. Nilai Uji ADF	35
4. Nilai Uji ADF <i>Differencing 1</i>	35
5. Hasil Uji Kausalitas Granger	36
6. Hasil Uji Kointegrasi dengan <i>Trace Statistic</i>	37
7. Jumlah Data <i>Training</i> dan Data <i>Testing</i>	37
8. Nilai AIC Setiap <i>Lag</i> dengan Skema <i>Splitting 80% Data Training</i> dan 20% Data <i>Testing</i>	38
9. Nilai AIC Setiap <i>Lag</i> dengan Skema <i>Splitting 90% Data Training</i> dan 10% Data <i>Testing</i>	39
10. Hasil Uji Ljung-Box dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	48
11. Hasil Uji Ljung-Box dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	48
12. Parameter Terbaik Model GRU Pertama dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	50
13. Parameter Terbaik Model GRU Pertama dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	51
14. Parameter Terbaik Model GRU Kedua Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	52

15. Parameter Terbaik Model GRU Kedua dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	53
16. Hasil Peramalan IHSG dan BI <i>Rate</i> dengan Metode <i>Hybrid</i> VAR-GRU	66

DAFTAR GAMBAR

Gambar	Halaman
1. Fungsi Aktivasi Sigmoid.....	19
2. Fungsi Aktivasi Tanh.....	20
3. Struktur RNN	21
4. Arsitektur <i>Gated Recurrent Unit</i>	22
5. <i>Flowchart</i> Peramalan Model <i>Hybrid VAR - GRU</i>	30
6. Data IHSG dan <i>BI Rate</i>	35
7. Grafik Data IHSG	34
8. Grafik data <i>BI Rate</i>	34
9. <i>Summary</i> Model VAR(1) dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	40
10. <i>Summary</i> Model VAR(1) dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	41
11. Grafik Prediksi Model VAR dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	42
12. Grafik Prediksi Model VAR dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	43
13. Grafik Peramalan Model VAR dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	44
14. Grafik Peramalan Model VAR dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	45

15. Grafik Data Residual Model VAR dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	46
16. Grafik Data Residual Model VAR dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	47
17. Grafik Prediksi Model GRU Pertama untuk Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	54
18. Grafik Prediksi Model GRU Pertama untuk Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	55
19. Grafik Prediksi Model GRU Kedua dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	56
20. Grafik Prediksi Model GRU Kedua Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	57
21. Grafik Model <i>Hybrid</i> VAR-GRU dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	58
22. Grafik Model <i>Hybrid</i> VAR-GRU dengan Skema 90% Data <i>Training</i> dan 10% Data <i>Testing</i>	59
23. Grafik Peramalan Model GRU Pertama	61
24. Grafik Peramalan Model GRU Kedua	62
25. Grafik Peramalan Model <i>Hybrid</i> VAR-GRU	63

I. PENDAHULUAN

1.1 Latar Belakang

Kondisi perekonomian sebuah negara memegang peranan penting dalam menentukan kesejahteraan masyarakatnya, karena faktor-faktor ekonomi yang stabil dapat menciptakan lingkungan yang kondusif bagi pertumbuhan ekonomi dan peluang kerja. Indonesia, sebagai negara berkembang, terus menghadapi tantangan struktur perekonomian yang masih cenderung agraris, menjadikannya rentan terhadap guncangan yang dapat mempengaruhi kestabilan ekonomi. Kondisi perekonomian suatu negara memiliki keterkaitan yang erat dengan kinerja dua indikator penting, yaitu Indeks Harga Saham Gabungan (IHSG) dan tingkat suku bunga acuan Bank Indonesia (*BI Rate*) (Sampurna, 2016).

IHSG merupakan indeks gabungan dari seluruh jenis saham yang ada atau tercatat di bursa efek. IHSG menjadi indikator utama yang mencerminkan pergerakan harga saham di Bursa Efek Indonesia (BEI). IHSG tidak hanya menjadi tolak ukur perekonomian, tetapi juga sering dijadikan parameter stabilitas ekonomi. Berdasarkan konteks ini, pergerakan IHSG dapat diartikan sebagai cerminan kondisi perekonomian secara umum. Jika IHSG mengalami kenaikan, hal ini sering diartikan sebagai tanda bahwa perekonomian sedang dalam kondisi baik, dan sebaliknya (Oktavia dan Fajar, 2022).

Sementara itu, *BI Rate*, yang merupakan suku bunga yang ditetapkan oleh Bank Indonesia, berpengaruh langsung terhadap tingkat inflasi dan pertumbuhan ekonomi. Kedua indikator ini saling terkait, dan kebijakan yang bijak dalam

mengelolanya dapat memperkuat fondasi ekonomi sebuah negara, memberikan dampak positif pada kesejahteraan masyarakat melalui peningkatan investasi, stabilitas harga, dan pertumbuhan ekonomi yang berkelanjutan. Seiring IHSG, *BI Rate*, atau Suku Bunga Bank Indonesia, menjadi elemen kunci dalam mengelola kebijakan moneter. *BI Rate* ditetapkan dalam Rapat Dewan Gubernur triwulanan dan berlaku selama triwulan berjalan, kecuali ditetapkan berbeda dalam Rapat Dewan Gubernur bulanan di triwulan yang sama. Pendekatan kebijakan moneter ini, seperti yang dijelaskan oleh Sukirno (2006), mencerminkan upaya pemerintah dalam mengatur jumlah uang beredar dengan menaikkan tingkat suku bunga.

Penurunan dalam indeks harga saham suatu negara sering kali disebabkan oleh masalah ekonomi yang sedang dihadapi oleh negara tersebut (Layla dkk., 2021). Ketika awal tahun 2020, Indonesia dihadapkan dengan ancaman wabah penyakit baru yang dikenal sebagai *Corona Virus Disease 2019 (Covid-19)*. Wabah virus Corona memiliki dampak yang signifikan terhadap fluktuasi saham sehingga pada Januari 2020 sampai Juni 2020, nilai IHSG mengalami penurunan yang cukup signifikan. Selain itu, *BI Rate* juga mengalami penurunan berkelanjutan dari awal tahun hingga September 2020 yang menunjukkan bahwa dampak pandemi Covid-19 memengaruhi *BI Rate* (Oktavia dan Fajar, 2022).

IHSG dan *BI Rate* memiliki dampak yang cukup signifikan dalam pertumbuhan ekonomi di Indonesia. Oleh karena itu, pentingnya peran pemerintah dalam perencanaan, pengambilan kebijakan, dan evaluasi kebijakan ekonomi di Indonesia sangat besar, terutama karena dampak signifikan dari Indeks Harga Saham Gabungan (IHSG) dan Suku Bunga Bank Indonesia (*BI Rate*) terhadap pertumbuhan ekonomi. IHSG mencerminkan kesehatan pasar modal, sedangkan *BI Rate* mengendalikan suku bunga dan kebijakan moneter. Melalui peramalan IHSG, pemerintah dapat merencanakan kebijakan yang responsif terhadap perubahan pasar, sedangkan peramalan *BI Rate* membantu mengelola suku bunga dengan lebih tepat. Instrumen ini memungkinkan pemerintah untuk mengambil langkah-langkah terukur, menentukan prioritas kebijakan, dan menciptakan lingkungan ekonomi yang kondusif untuk pertumbuhan jangka panjang. Keberhasilan dalam menyusun

strategi yang responsif terhadap dinamika pasar dan kebijakan moneter akan membawa dampak positif bagi pertumbuhan ekonomi, kestabilan keuangan, dan kesejahteraan masyarakat.

Salah satu metode statistika klasik yang dapat dilakukan untuk meramalkan data *deret waktu* IHSB dan BI Rate adalah metode *Vector Autoregressive* (VAR). VAR merupakan pemodelan persamaan simultan yang memiliki beberapa variabel endogen secara bersamaan yang dalam penelitian ini IHSB dan BI Rate selaku variabel endogen. Metode VAR ini cocok untuk meramalkan variabel yang saling terkait seperti hubungan antara IHSB dan BI Rate, namun metode VAR sendiri memiliki kekurangan yakni tidak selalu efektif untuk menangkap pola non-linier atau kompleks dalam data. Selain metode statistika klasik, terdapat pula perkembangan metode peramalan data *deret waktu* yaitu dengan *deep learning*. *Deep learning* merupakan cabang ilmu dari *machine learning* yang menggunakan jaringan saraf tiruan sebagai dasar pengolahannya (Ilahiyah dan Nilogiri, 2018).

Salah satu metode dari *deep learning* yaitu *Recurrent Neural Network* (RNN). RNN mempunyai kemampuan untuk melihat korelasi tersembunyi yang terjadi dalam data pada aplikasi pengenalan suara, pemrosesan bahasa alami, dan prediksi deret waktu (Tian dkk., 2018). *Gated Recurrent Unit* (GRU) adalah algoritma variasi dari LSTM yang mana merupakan salah satu jenis *machine learning* berbasis pendekatan dari arsitektur RNN. Metode GRU mampu menangkap pola temporal yang kompleks termasuk pola non-linier dan dapat menyesuaikan diri dengan perubahan dalam data sepanjang waktu. Data IHSB dan BI Rate sendiri termasuk data yang kompleks karena terdapat pola non-linier. Pendekatan dengan metode *hybrid* VAR – GRU akan cocok digunakan pada penelitian ini karena memanfaatkan kelebihan kedua metode, yaitu kemampuan VAR untuk menangani hubungan linier dan GRU untuk menangkap pola temporal yang kompleks.

Penelitian terkait peramalan dengan metode VAR pernah dilakukan oleh Hardani, dkk. pada tahun 2017 yaitu meramalkan data Laju inflasi, SBI, dan IHSB. Pada

penelitian tersebut menghasilkan peramalan untuk 6 periode kedepan dan memiliki nilai akurasi MAPE sebesar 47.11% yang termasuk dalam kategori cukup. Kemudian untuk penelitian terkait peramalan dengan metode GRU sudah pernah dilakukan oleh Yulisa dkk. (2023) yaitu meramalkan data nilai ekspor migas Indonesia. Pada penelitian tersebut diperoleh nilai MAPE sebesar 13.3% dan akurasi sebesar 86.7% yang berarti termasuk kategori baik.

Penelitian dengan metode *hybrid* VAR – GRU pernah dilakukan oleh Munkhdalai dkk., pada tahun 2020 dengan judul “*VAR-GRU: A Hybrid Model for Multivariate Financial Deret waktu Prediction*”. Penelitian tersebut menggunakan data pasar keuangan namun pada penelitian tersebut tidak dituliskan apa parameter terbaik maupun nilai akurasinya. Selain itu, penelitian dengan model *hybrid* VAR-GRU juga pernah dilakukan oleh Aji dkk. pada tahun 2020 dalam meramalkan harga transaksi bahan bakar jet dengan skema 80% data *training* dan 20% data *testing*. Penelitian tersebut memiliki nilai evaluasi model yaitu RMSE sebesar 62.53 dan MAPE 0.60%, serta akurasi sebesar 99.40%.

Berdasarkan pemaparan latar belakang di atas, penulis tertarik untuk melakukan penelitian terkait implementasi model *hybrid* VAR – GRU dalam meramalkan data IHSG dan BI Rate serta melihat parameter terbaik model GRU pada model *hybrid* VAR – GRU dalam meramalkan data IHSG dan BI Rate.

1.2 Rumusan Masalah

Rumusan masalah dari penelitian ini adalah sebagai berikut:

1. Apa saja parameter terbaik model GRU pada model *hybrid* VAR – GRU dalam meramalkan data IHSG dan BI Rate?
2. Bagaimana performa dari model *hybrid* VAR – GRU terhadap data IHSG dan BI Rate?
3. Bagaimana hasil peramalan data IHSG dan BI Rate dengan model *hybrid* VAR – GRU?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui parameter terbaik model GRU pada model *hybrid* VAR – GRU dalam meramalkan data IHSG dan *BI Rate*.
2. Mengetahui performa dari model *hybrid* VAR – GRU terhadap data IHSG dan *BI Rate*.
3. Mengetahui hasil peramalan data IHSG dan *BI Rate* dari model *hybrid* VAR – GRU.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah sebagai berikut:

1. Menambah wawasan dan pengetahuan terkait peramalan dengan model VAR dan model *hybrid* VAR – GRU.
2. Menjadi referensi bagi peneliti selanjutnya terkait peramalan menggunakan model *hybrid* VAR – GRU dengan jenis data berbeda.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Tabel 1. Penelitian Terkait Peramalan IHSG dan BI *Rate* dengan Model *Hybrid* VAR-GRU

No	Penelitian	Data	Metode	MAPE	Akurasi
1	Peramalan Laju Inflasi, Suku Bunga Indonesia dan Indeks Harga Saham Gabungan menggunakan Metode <i>Vector Autoregressive</i> (VAR)	Laju Inflasi, SBI, IHSG	VAR	47.11%	52.89%
2	Peramalan Nilai Ekspor Migas di Indonesia dengan Model <i>Long Short Term Memory</i> (LSTM) dan <i>Gated Recurrent Unit</i> (GRU)	Nilai Ekspor Migas	LSTM dan GRU	LSTM: 12.8% GRU: 13.3%	LSTM: 87.2% GRU: 86.7%
3	<i>VAR-GRU: A Hybrid Model for Multivariate Financial Time Series Prediction</i>	Data Pasar Keuangan	<i>Hybrid</i> VAR-GRU	0.576%	99.42%
4	<i>Hybrid Vector Autoregression–Recurrent Neural Networks to Forecast Multivariate Time Series Jet Fuel Transaction Price</i>	Harga Transaksi Bahan Bakar Jet	<i>Hybrid</i> VAR-GRU	0.60%	99.40%

Penelitian terkait implementasi metode *Vector Autoregressive* (VAR) pada peramalan data IHSG dan BI Rate pernah dilakukan oleh Hardani dkk. (2017) yaitu meramalkan data Laju inflasi, SBI, dan IHSG dengan menggunakan metode *Vector Autoregressive* (VAR). Penelitian tersebut menghasilkan peramalan untuk 6 periode kedepan dan memiliki nilai akurasi MAPE sebesar 47.11% yang termasuk dalam kategori cukup.

Penelitian tentang peramalan dengan metode GRU sudah pernah dilakukan oleh Yulisa dkk (2023) yaitu meramalkan data nilai ekspor migas Indonesia. Penelitian tersebut menggunakan *splitting* data *training* 60% dan data *testing* 40%, jumlah *neuron* 20 dan *epochs* 100. Penelitian tersebut menghasilkan nilai MAPE sebesar 13.3 % yang termasuk kategori baik.

Penelitian dengan metode *hybrid* VAR – GRU pernah dilakukan oleh Munkhdalai dkk. pada tahun 2020 dengan judul “*VAR-GRU: A Hybrid Model for Multivariate Financial Deret waktu Prediction*”. Penelitian tersebut menggunakan data pasar keuangan namun pada penelitian tersebut tidak dituliskan apa parameter terbaiknya. Penelitian ini juga melakukan perbandingan beberapa metode yaitu VAR dengan RNN, VAR dengan LSTM dan VAR dengan GRU, namun hasil metode terbaiknya yaitu prediksi dengan menggunakan metode VAR-GRU Penelitian tersebut memperoleh nilai MAPE sebesar 0.576%, MAE sebesar 104.6 dan RMSE sebesar 144.9.

Selain itu, penelitian dengan metode *hybrid* VAR-GRU juga pernah dilakukan oleh Aji dkk. pada tahun 2020 dalam meramalkan harga transaksi bahan bakar jet dengan skema 80% data *training* dan 20% data *testing*. Penelitian tersebut memiliki nilai evaluasi model yaitu RMSE sebesar 62.53 dan MAPE 0.60%, serta akurasi sebesar 99.40%.

2.2 Peramalan

Peramalan adalah suatu kegiatan memperkirakan apa yang akan terjadi pada masa yang akan datang (Makridakis dkk., 1997). Peramalan merupakan suatu proses dalam memperkirakan sesuatu yang mungkin terjadi di masa depan berdasarkan informasi pada masa lalu dan masa sekarang. Metode peramalan dikategorikan menjadi dua kategori, yaitu metode peramalan kualitatif dan metode kuantitatif. Metode peramalan kualitatif didasarkan pada data kualitatif masa lalu berdasarkan pengetahuan dan pengalaman dari penulis, sedangkan metode peramalan kuantitatif didasarkan pada data kuantitatif pada informasi masa lalu dalam bentuk data yang numerik seperti model deret waktu dan model kausal (Makridakis dkk., 1997)

Heizer dan Render (1996) menyatakan bahwa, jangka waktu peramalan terbagi menjadi tiga kategori, yaitu:

1. Peramalan jangka pendek, yaitu peramalan untuk jangka waktu kurang dari tiga bulan.
2. Peramalan jangka menengah, yaitu peramalan untuk jangka waktu antara tiga bulan sampai tiga tahun.
3. Peramalan jangka panjang, yaitu peramalan untuk jangka waktu lebih dari tiga tahun

2.3 Deret waktu

Deret waktu merupakan serangkaian data pengamatan yang berasal dari satu sumber tetap dan terjadi berdasarkan indeks waktu t secara beruntun dengan interval waktu yang tetap (Cryer dan Chan, 1986). Setiap pengamatan dapat dinyatakan sebagai variabel random Z_t dengan notasi $Z_{t1}, Z_{t2}, \dots, Z_{tn}$. Tujuan deret waktu adalah menemukan pola dalam data deret waktu dan mengekstrapolasikan pola tersebut ke masa depan (Wei, 2006). Secara garis besar pemodelan data deret

waktu terbagi atas dua klasifikasi yaitu univariat dan multivariat. Pada model univariat peramalan data suatu variabel hanya didasarkan pada nilai variabel tersebut pada masa lampau, sedangkan model multivariat peramalan data dilakukan dengan menggunakan beberapa variabel secara simultan yang memiliki hubungan atau saling berkorelasi untuk mendapatkan keakuratan peramalan. Data deret waktu adalah sekumpulan pengamatan kuantitatif yang disusun dari satu objek yang terdiri dari beberapa waktu periode, seperti harian, bulanan, triwulanan, dan tahunan.

2.4 *Vector Autoregressive (VAR)*

Model VAR pertama kali ditemukan oleh Sims (1980). Model tersebut dibangun sebagai suatu solusi yang mana hubungan antarvariabel ekonomi dapat tetap diestimasi tanpa perlu menitikberatkan masalah eksogenitas. Dalam pendekatan ini semua variabel dianggap sebagai endogen dan estimasi dapat dilakukan secara serentak atau sekuensial (Alawiyah dkk., 2019).

Menurut Wei (2006), model VAR dengan ordo p dengan n buah peubah tak bebas pada waktu ke- t dapat dimodelkan pada persamaan (2.1) sebagai berikut:

$$\dot{Y}_t = \phi_0 + \phi_1 \dot{Y}_{t-1} + \phi_2 \dot{Y}_{t-2} + \dots + \phi_p \dot{Y}_{t-p} + a_t \quad (2.1)$$

dengan:

\dot{Y}_t = vektor peubah tak bebas ($Z_{1,t}, Z_{2,t}, \dots, Z_{m,t}$) berukuran $m \times 1$

ϕ_0 = vektor intersep berukuran $m \times 1$

ϕ_t = matriks parameter berukuran $m \times m$ untuk setiap $i = 1, 2, \dots, p$

a_t = vektor sisaan ($a_{1,t}, a_{2,t}, \dots, a_{m,t}$)

Menggunakan metode VAR memiliki beberapa kelebihan yakni tidak perlu membedakan variabel endogen dan eksogen, metode pendugaan sederhana karena menggunakan metode *Ordinary Least Square (OLS)*, dan hasil pendugaan lebih baik dibandingkan dengan metode simultan yang lebih kompleks (Gujarati dan Porter, 2009).

2.4.1 Stasioneritas

Proses deret waktu harus berada dalam keadaan stasioner yaitu suatu keadaan dari proses deret waktu tidak berubah sepanjang waktu (Cryer dan Chan, 1986). Data deret waktu dikatakan stasioner jika nilai tengah (rata-rata) dan ragamnya stabil dari periode ke periode, serta kovarian antara dua data deret waktu hanya tergantung dari lag antara dua kurun waktu tersebut (Makridakis dkk., 1997). Stasioner data dapat dilihat secara visual melalui plot data. Selain menggunakan plot, stasioner data dapat dilihat dengan melakukan uji stasioner.

Pengujian stasioneritas data yang dapat digunakan salah satunya yaitu *Augmented Dickey-Fuller* (ADF). Tahapan uji ADF sebagai berikut:

1. Hipotesis

$H_0: \phi = 0$ (artinya terdapat *unit root* atau deret waktu tidak stasioner)

$H_1: \phi < 0$ (artinya tidak terdapat *unit root* atau deret waktu stasioner)

2. Taraf signifikansi

$\alpha = 5\% = 0,05$

3. Daerah kritis

- Jika $ADF_{hitung} > ADF_{tabel}$ atau $P - value < \alpha$ maka tolak H_0
- Jika $ADF_{hitung} < ADF_{tabel}$ atau $P - value > \alpha$ maka tolak H_0

4. Statistik uji diformulasikan dengan persamaan (2.2):

$$ADF_{hitung} = \frac{\hat{\phi} - 1}{SE(\hat{\phi})} \quad (2.2)$$

dengan:

$\hat{\phi}$ = nilai dugaan parameter *Autoregressive* (AR) dengan orde p

SE = *standard error*

5. Keputusan dan kesimpulan

Jika data deret waktu tidak stasioner maka dilakukan proses *differencing* (Wei, 2006) dan kemudian dilakukan pengujian stasioneritas kembali. Proses *differencing* notasi yang sering digunakan, yaitu operator langkah mundur

(*backward shift*) yang dilambangkan dengan B . Bentuk dari persamaan *backward shift* diformulasikan dalam persamaan (2.3) berikut:

$$By_t = y_{t-1} \quad (2.3)$$

Notasi B pada y_t berfungsi untuk menggeser data sebanyak 1 periode ke belakang.

Penggunaan *backward shift* pada persamaan untuk *differencing* pertama ($d=1$) diuraikan dalam persamaan (2.4) yaitu sebagai berikut:

$$y'_t = \Delta y_t = y_t - y_{t-1} = y_t - By_t = (1 - B)y_t \quad (2.4)$$

dengan $t = 2, 3, \dots, n$

Adapun persamaan untuk orde *difference* = 2 diuraikan dalam persamaan (2.5).

$$\begin{aligned} y''_t = \Delta^2 y_t &= y'_t - y'_{t-1} = y_t - By_t \\ &= (1 - 2B - B^2)y_t = (1 - B)^2 y_t \end{aligned} \quad (2.5)$$

dengan $t = 3, 4, \dots, n$

Maka dari itu bentuk umum untuk *differencing* sebanyak d kali diilustrasikan pada persamaan (2.6) berikut:

$$(1 - B)^d y_t \quad (2.6)$$

(Suhendra dkk., 2023)

Langkah pertama pembentukan model VAR adalah uji stasioneritas data. Jika data stasioner pada tingkat level maka akan didapat model VAR biasa (*unrestricted VAR*). Sebaliknya jika data tidak stasioner pada level namun stasioner pada proses diferensi data, maka harus di uji apakah data memiliki hubungan jangka panjang atau tidak dengan uji kointegrasi. Jika data stasioner pada proses diferensi namun variabel tidak terkointegrasi maka disebut model VAR dengan data diferensi atau *VAR in difference*. Terdapat penelitian yang melakukan peramalan model VAR dengan data diferensi yaitu penelitian oleh Hardani dkk. (2017) yang meramalkan data Laju inflasi, SBI, dan IHSG. Kemudian ada penelitian oleh Amry dkk. (2018) yang meramalkan produksi kelapa sawit PTPN XIII.

2.4.2 Panjang *Lag* Optimum

Penentuan panjang *lag* (p) optimum penting dalam upaya melihat pengaruh variabel satu terhadap variabel lain pada model VAR. Dalam menentukan panjang *lag* yang akan digunakan didasarkan pada masing-masing kriteria yaitu *Akaike Information Criterion* (AIC) dengan persamaan yang dituliskan dalam persamaan (2.7) sebagai berikut (Lütkepohl, 2005):

$$AIC(p) = \ln \left| \sum \hat{u}\hat{u}(p) \right| + (k + pk^2) \frac{2}{T} \quad (2.7)$$

dengan:

$|\sum \hat{u}\hat{u}(p)|$ = determinan matriks varians kovarians dari model VAR(p)

k = banyaknya variabel

T = banyaknya pengamatan

p = panjang *lag* model VAR

Lag yang akan dipilih dalam penelitian ini adalah model dengan nilai AIC yang paling kecil. Dalam tahapan ini pula dilakukan uji stabilitas model VAR. penentuan *lag* optimum dan uji stabilitas model VAR dilakukan terlebih dahulu sebelum melalui tahap uji kointegrasi (Sembiring, 2016).

2.4.3 *Ordinary Least Square* (OLS)

Estimasi parameter model VAR dapat dicari dengan membentuk model VAR sebagai persamaan (2.8) berikut (Zhao dan Chen, 2015).

$$y = X\beta + e \quad (2.8)$$

dengan:

$$y = \begin{bmatrix} Y_{1t} \\ Y_{2t} \\ \vdots \\ Y_{kt} \end{bmatrix}; \beta = \begin{bmatrix} \alpha_i \\ \beta_{11} \\ \vdots \\ \beta_{1p} \\ \gamma_{21} \\ \vdots \\ \gamma_{2p} \\ \lambda_{k1} \\ \vdots \\ \lambda_{kp} \end{bmatrix}^T ;$$

$$X = \begin{bmatrix} 1 & Y_{1,1-p} & \cdots & Y_{1,1-p} & Y_{2,1-p} & \cdots & Y_{2,1-p} & \cdots & Y_{k,1-p} & \cdots & Y_{k,1-p} \\ 1 & Y_{1,2-p} & \cdots & Y_{1,2-p} & Y_{2,2-p} & \cdots & Y_{2,2-p} & \cdots & Y_{k,2-p} & \cdots & Y_{k,2-p} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & Y_{1,n-1} & \cdots & Y_{1,n-1} & Y_{2,n-1} & \cdots & Y_{2,n-1} & \cdots & Y_{k,n-1} & \cdots & Y_{k,n-1} \end{bmatrix}$$

Estimasi parameter model VAR dapat menggunakan metode *Ordinary Least Square* (OLS) sehingga diperoleh nilai parameter dalam persamaan (2.9) berikut:

$$\hat{\beta} = (X^T X)^{-1} X^T y \quad (2.9)$$

2.4.4 Uji Kointegrasi

Uji kointegrasi dilakukan untuk mengidentifikasi keterkaitan dan hubungan jangka panjang data deret waktu. Salah satu metode dari uji kointegrasi adalah metode Johansen. Uji kointegrasi dapat dijadikan dasar penentuan persamaan yang digunakan memiliki keseimbangan jangka panjang atau tidak, apabila persamaan terbukti terkointegrasi melalui uji johansen ini, maka persamaan estimasi tersebut memiliki keseimbangan jangka panjang (Gujarati dan Porter, 2009). Menurut Lütkepohl (2005), uji kointegrasi Johansen dapat dilakukan dengan menggunakan statistik uji yaitu *trace statistic* dengan hipotesis sebagai berikut:

H_0 : banyaknya vektor kointegrasi (r) = 0

H_1 : banyaknya vektor kointegrasi (r) > 0

Statistik uji *trace* yang digunakan pada uji kointegrasi diformulasikan dalam persamaan (2.10) berikut:

$$Tr(r) = -T \sum_{i=r+1}^k \ln(1 - \hat{\lambda}_i) \quad (2.10)$$

dengan:

- $\hat{\lambda}_i$ = pendugaan nilai eigen
 T = banyaknya pengamatan
 k = banyaknya peubah endogen

Uji ini dimulai dari $r = 0$ dan dilakukan sampai pertama kalinya hipotesis nol tidak dapat ditolak. *Rank kointegrasi* diperoleh dari nilai r . Hipotesis nol ditolak untuk nilai yang lebih besar dari uji statistiknya, atau *p-value* lebih kecil dari nilai signifikansi α .

2.4.5 Kausalitas Granger

Uji Kausalitas Granger digunakan untuk menentukan apakah dua variabel memiliki hubungan sebab-akibat. Uji ini menentukan apakah perubahan dalam satu variabel adalah hasil dari perubahan variabel lain. Uji kausalitas yang sering dipakai pada penelitian yaitu uji kausalitas *Granger*. Untuk melakukan pengujian terhadap hipotesis digunakan uji F dengan tahapan sebagai berikut:

Hipotesis:

H_0 : antar variabel tidak memiliki hubungan sebab akibat.

H_1 : antar variabel memiliki hubungan sebab akibat.

Statistik uji yang digunakan dalam uji kausalitas *Granger* diuraikan dalam persamaan (2.11), yaitu (Gujarati dan Porter, 2009):

$$F = \frac{(RSS_R - RSS_{UR})/p}{RSS_{UR}/(n - b)} \quad (2.11)$$

dengan:

RSS_R = jumlah kuadrat residual dari regresi bersyarat (*restricted*)

RSS_{UR} = jumlah kuadrat residual dari regresi tanpa syarat (*unrestricted*)

p = banyak *lag*

- n = banyak data pengamatan
 b = banyak parameter yang diestimasi pada model

Ketika kriteria uji yaitu jika nilai F hitung $> F_{(p,n-b)}$ Tabel pada taraf signifikansi 5% atau nilai prob $< \alpha$ (5%) maka hipotesis nol ditolak, sehingga dapat disimpulkan variabel satu memengaruhi variabel lain.

2.4.6 Uji Asumsi Residual *White Noise*

Uji asumsi residual dilakukan untuk mendapatkan kelayakan pada model. Uji asumsi residual *white noise* menunjukkan bahwa tidak ada korelasi dari residual dalam model, atau dengan kata lain residual dari model tersebut saling bebas (Rosyidah dkk., 2017). Uji asumsi residual *white noise* dapat dilakukan dengan menggunakan uji Ljung-Box berikut (Wei, 2006):

1. Hipotesis
 - H_0 : tidak ada korelasi pada data residual
 - H_1 : ada korelasi pada data residual
2. Taraf signifikansi
 - $\alpha = 5\% = 0,05$
3. Daerah kritis
 - Jika $Q_{hitung} > X_{tabel}^2$ atau $p - value < \alpha$ maka tolak H_0
 - Jika $Q_{hitung} < X_{tabel}^2$ atau $p - value > \alpha$ maka tolak H_0
4. Statistik uji asumsi residual *white noise* diuraikan dalam persamaan (2.12) sebagai berikut (Gujarati dan Porter, 2009):

$$Q_{hitung} = n(n + 2) \sum_{i=1}^m \frac{\rho_i^2}{(n - i)} \quad (2.12)$$

dengan:

- n = banyak data pengamatan
 ρ_i = autokorelasi lag ke- i
 m = jumlah lag
5. Keputusan
 6. Kesimpulan

2.5 Machine Learning

Machine Learning merupakan bagian dari *Artificial Intelligence (AI)* yang berbentuk system atau algoritma yang memiliki kemampuan mengolah banyak data serta mempelajari polanya untuk kemudian membuat prediksi di masa depan yang berbasis matematika dan statistika komputasi (Wahyono, 2018). *Machine Learning* memiliki tujuan untuk mengatasi permasalahan secara otomatis dengan mempelajari data, dari data, *machine learning* mendapatkan wawasan dan hal baru untuk membentuk sebuah sistem yang baik.

Menurut Wahyono (2018), secara garis besar, *machine learning* terbagi menjadi 2 yaitu:

1. *Supervised Learning*
pembelajaran terarah (*Supervised Learning*) merupakan suatu teknik yang mana proses pembelajarannya dibawah pengawasan. Biasanya pembelajaran ini menggunakan data yang sudah ada dan memiliki label. Contoh dari *supervised learning* yaitu algoritma *neural network*.
2. Pembelajaran tidak terarah (*Unsupervised Learning*) merupakan algoritma *machine learning* yang mana proses pembelajarannya tanpa pengawasan dan tidak memiliki target output. Tujuannya yaitu mengelompokkan unit yang mempunyai kemiripan di area tertentu. Contohnya yaitu algoritma klusterisasi yang salah satunya k-means.

2.6 Normalisasi dan Denormalisasi Data

Ambarwari dkk. (2020) menyatakan bahwa *scalling data* atau normalisasi data merupakan teknik mengubah nilai numerik yang ada dalam dataset menjadi skala umum, tanpa mendistorsi perbedaan pada rentang nilai. *Scalling data* bermanfaat untuk memperkecil ukuran data tanpa mengubah data aktual. Teknik untuk melakukan *scalling data* adalah sebagai berikut:

1. *Min-max scaler*

Untuk meminimalkan error, perlu dilakukan normalisasi data dengan mengubah data aktual menjadi nilai dengan *range* interval 0 sampai 1. Rumus untuk normalisasi *min-max* diformulasikan dalam persamaan (2.13) sebagai berikut (Aldi dkk., 2018):

$$x' = \frac{(x - \min_x)}{(\max_x - \min_x)} \quad (2.13)$$

dengan:

x' = data hasil normalisasi

x = data aktual

\min_x = nilai minimum data x

\max_x = nilai maksimum data x

2. *Standard scaler*

Menurut Ambarwari dkk. (2020), teknik *standard scaler* didasari pada nilai *mean* dan standar deviasinya. Teknik ini mengubah skala distribusi nilai, sehingga nilai *mean* sama dengan 0 dan standar deviasinya sama dengan 1. Teknik ini dipakai Ketika terdapat asumsi data berdistribusi normal. Rumus *standard scaler* dituliskan dalam persamaan (2.14) sebagai berikut:

$$x' = \frac{x - \text{mean}_x}{\text{std}_x} \quad (2.14)$$

dengan:

x' = data hasil normalisasi

x = data aktual

mean_x = rata-rata data x

std_x = standar deviasi data x

Setelah mendapat hasil prediksi maupun peramalan yang masih berbentuk data normalisasi, perlu dilakukan denormalisasi untuk mengembalikan skala data menjadi seperti data asli. Denormalisasi dilakukan sebelum menghitung tingkat akurasi hasil prediksi. Menurut Dewi dkk. (2018), proses denormalisasi dijelaskan dengan menggunakan persamaan (2.15) berikut:

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

dimana:

x = Nilai hasil denormalisasi

x' = Nilai hasil normalisasi

x_{max} = Nilai maksimum dari variabel x

x_{min} = Nilai minimum dari variabel x

2.7 Fungsi Aktivasi

Menurut Julpan dkk. (2015), fungsi aktivasi merupakan fungsi yang digunakan dalam jaringan saraf untuk mengaktifkan saraf (*neuron*). Fungsi aktivasi yang sering digunakan diantaranya sebagai berikut:

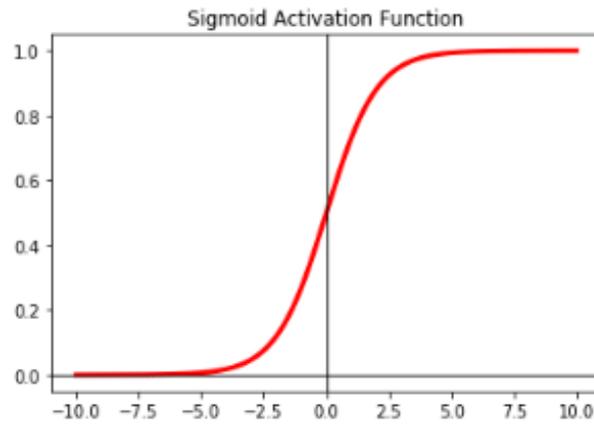
1. Fungsi aktivasi sigmoid, yaitu fungsi *non-linear* yang menampilkan nilai di *range* 0 sampai 1. Persamaan (2.16) merupakan persamaan dari fungsi sigmoid sebagai berikut (Feng dan Lu, 2019):

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.16)$$

Fungsi *sigmoid* didapatkan dari turunan berikut:

$$\begin{aligned} f(x) &= \frac{u(x)}{v(x)} \\ f'(x) &= \frac{u'(x)v(x) - u(x)v'(x)}{[v(x)]^2} \\ \frac{d}{dx}\sigma(x) &= \frac{d}{dx} \frac{1}{(1 + e^{-x})^2} \\ &= \frac{e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 - 1 + e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 + e^{-x}}{(1 + e^{-x})^2} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{(1 + e^{-x})} - \frac{1}{(1 + e^{-x})^2} \end{aligned}$$

$$\begin{aligned}
 &= \frac{1}{(1 + e^{-x})} \left(1 - \frac{1}{(1 + e^{-x})} \right) \\
 &= \sigma(x)(1 - \sigma(x))
 \end{aligned} \tag{2.17}$$



Gambar 1. Fungsi Aktivasi Sigmoid

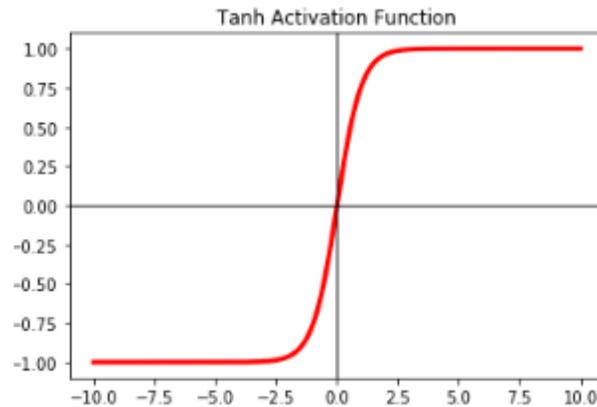
(Sumber: Feng dan Lu, 2019)

2. Fungsi aktivasi tangen hiperbolik (*tanh*) yaitu fungsi alternatif dari lapisan *sigmoid*. *Input* di fungsi aktivasi tanh ini merupakan bilangan asli serta untuk *output* nya berada di *range* -1 sampai 1 yang ditunjukkan dengan persamaan (2.18) berikut (Feng dan Lu, 2019):

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} \tag{2.18}$$

Fungsi tanh didapatkan dengan aturan turunan berikut:

$$\begin{aligned}
 f(x) &= \frac{u(x)}{v(x)} \\
 \frac{d}{dx} \tanh(x) &= \frac{d}{dx} \frac{\sinh(x)}{\cosh(x)} \\
 &= \frac{\cosh^2(x) - \sinh^2(x)}{\cosh^2(x)} \\
 &= \frac{\cosh^2(x)}{\cosh^2(x)} - \frac{\sinh^2(x)}{\cosh^2(x)} \\
 &= 1 - \tanh^2(x)
 \end{aligned} \tag{2.19}$$



Gambar 2. Fungsi Aktivasi Tanh

(Sumber: Feng dan Lu, 2019)

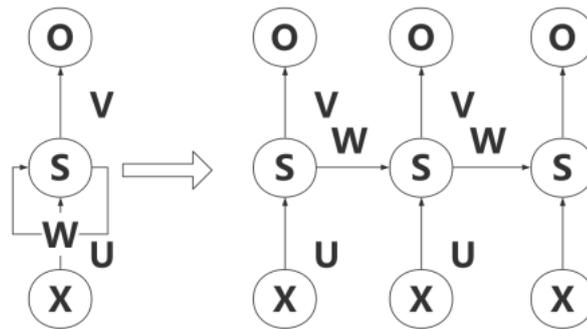
2.8 Deep Learning

Deep learning merupakan cabang ilmu dari *machine learning* yang menggunakan jaringan saraf tiruan sebagai dasar pengolahannya (Ilahiyah dan Nilogiri, 2018). Menurut Openg dkk. (2022) *deep learning* memiliki tujuan untuk merepresentasi data secara bertingkat dengan memakai sejumlah *lapisan* pengolahan data. Algoritma yang termasuk dalam *deep learning* diantaranya yaitu *Convolutional Neural Network* (CNN), dan *Recurrent Neural Network* (RNN). Algoritma yang biasa digunakan untuk mengolah data deret waktu adalah RNN.

2.8.1 Recurrent Neural Network (RNN)

Recurrent Neural Network merupakan sejenis *Artificial Neural Network* atau jaringan saraf tiruan yang mempunyai kemampuan untuk melihat korelasi tersembunyi yang terjadi dalam data pada aplikasi pengenalan suara, pemrosesan bahasa alami, dan prediksi deret waktu (Tian dkk., 2018). Model RNN memiliki karakteristik yang unik, yaitu arsitekturnya memiliki minimal satu *feedbackloop*, sehingga dapat menyimpan data dalam struktur jaringannya dan kinerja dari model RNN ini dalam melakukan prediksi bergantung pada bobot dan arsitekturnya (Walid, 2019). Model RNN terdiri atas unit *input*, unit *output*, dan unit tersembunyi.

Ciri dari model RNN saat melakukan prediksi yaitu tidak hanya memakai *input* satu waktu saja tetapi membutuhkan masukan dan *input* sebelumnya. Sehingga antar *input* saling berhubungan dan dapat memberi informasi ke lapisan tersembunyi. Model RNN memiliki memori yang berisikan hasil rekaman informasi yang dihasilkan sebelumnya. (Sen dkk., 2020).

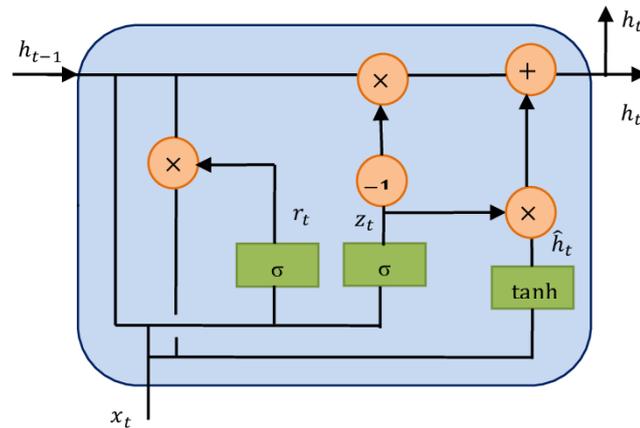


Gambar 3. Struktur RNN

(Sumber: Tian, dkk., 2018)

2.9 Gated Recurrent Unit (GRU)

Gated Recurrent Unit adalah algoritma variasi dari LSTM yang mana merupakan salah satu jenis *machine learning* berbasis pendekatan dari arsitektur RNN. Model GRU pertama kali diperkenalkan pada tahun 2014 oleh tiga orang professor Bernama Chung, Kyung, dan Yoshua. Proses sel GRU dilakukan mirip dengan proses sel LSTM yang membedakannya yaitu sel GRU hanya menggunakan satu sel tersembunyi yang menggabungkan gerbang *forget* dan gerbang *input* menjadi satu gerbang pembaruan.



Gambar 4. Arsitektur *Gated Recurrent Unit*

(Sumber: Dridi dan Ouni, 2020)

Menurut Chung dkk. (2014), komponen yang mengatur alur informasi di dalam GRU disebut dengan gerbang, dan di GRU terdapat 2 gerbang yaitu gerbang *reset* dan gerbang *update* sebagai berikut:

1. Gerbang *reset* digunakan sebagai penentu cara bagaimana menggabungkan informasi *input* baru dan informasi masa lalu dengan menggunakan persamaan (2.20) berikut:

$$r_t = \sigma(W_r * [h_{t-1}, x_t] + b_r) \quad (2.20)$$

dengan:

- r_t = gerbang *reset*
- σ = fungsi sigmoid
- W_r = nilai bobot untuk gerbang *reset*
- h_{t-1} = nilai *output* sebelum orde ke-t
- x_t = nilai *input* pada orde ke-t
- b_r = nilai bias pada gerbang *reset*

2. Gerbang *update* digunakan sebagai penentu seberapa banyak informasi masa lalu yang disimpan dengan persamaan (2.21) berikut:

$$z_t = \sigma(W_z * [h_{t-1}, x_t] + b_z) \quad (2.21)$$

dengan:

- z_t = gerbang *update*
- σ = fungsi sigmoid
- W_z = nilai bobot untuk gerbang *update*
- h_{t-1} = nilai *output* sebelum orde ke-t
- x_t = nilai *input* pada orde ke-t
- b_z = nilai bias pada gerbang *update*

Untuk menentukan kandidat *state* tersembunyi pada *time step* saat ini (t) serta informasi masa lalu ($t-1$) menggunakan fungsi aktivasi *tanh* dengan persamaan (2.22) berikut:

$$\tilde{h}_t = \tanh(W * x_t + (r_t * h_{t-1}) * W + b_h) \quad (2.22)$$

dengan:

- \tilde{h}_t = kandidat *state* tersembunyi
- tanh* = fungsi *tangen* hiperbolik
- W = nilai parameter *bobot*
- x_t = nilai *input* pada orde ke-t
- r_t = gerbang *reset*
- h_{t-1} = nilai *output* sebelum orde ke-t
- b_h = nilai bias pada *state* tersembunyi

Proses perhitungan *output* terakhir menggunakan persamaan (2.23) berikut:

$$h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1} \quad (2.23)$$

dengan:

- h_t = *output*
- h_{t-1} = *state* tersembunyi sebelum orde ke-t
- z_t = *output* pada gerbang *update*
- \tilde{h}_t = kandidat *state* tersembunyi

2.10 Hybrid VAR-GRU

Metode *hybrid* adalah pengembangan dalam metode peramalan deret waktu dengan penggabungan dua metode atau lebih, salah satunya penggabungan metode VAR dan GRU. Menurut Zhang (2003), secara umum kombinasi dari model deret waktu yang memiliki struktur linier dan non-linier dapat ditulis dalam persamaan (2.24) sebagai berikut:

$$y_t = L_t + N_t + \alpha_t \quad (2.24)$$

dengan:

- y_t = data aktual ke- t
- L_t = komponen linier ke- t
- N_t = komponen nonlinier ke- t
- t = indeks waktu
- α_t = kesalahan

Metode *hybrid* VAR – GRU melibatkan dua tahap penting. Tahap pertama adalah penerapan metode VAR untuk memodelkan komponen linier data, kemudian tahapan kedua menggunakan metode GRU untuk memodelkan komponen non-linier. Setelah kedua tahap tersebut selesai, model-model ini digabungkan, mencakup aspek linier dan non-linier pada data. Proses ini melibatkan tiga tahap utama:

1. Model VAR dibangun menggunakan data aktual.
2. Model GRU dibangun dengan data hasil prediksi model VAR sebagai model GRU pertama dan data residual model VAR sebagai model GRU kedua.
3. Menggabungkan hasil kedua model GRU untuk melakukan prediksi dan peramalan.

Persamaan (2.25) untuk peramalan *hybrid* metode VAR – GRU dapat ditulis sebagai berikut:

$$y'_t = L'_t + N'_t \quad (2.25)$$

dengan:

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

- L'_t = nilai prediksi komponen linier dari GRU ke t
 N'_t = nilai prediksi komponen residual dari GRU ke t
 t = indeks waktu

2.11 Evaluasi Model

Menurut Makridakis dkk. (1997), Ketepatan atau akurasi menunjukkan seberapa jauh model peramalan tersebut mampu mereproduksi data yang telah diketahui. Ukuran ketepatan model sebagian besar menggunakan faktor kesalahan galat yang didapat dari selisih antara data aktual dan hasil peramalan. Menurut Makridakis dkk. (1997), untuk melihat akurasi model digunakan ukuran sebagai berikut:

1. *Root Mean Square Error* (RMSE)

Root Mean Square Error merupakan akar kuadrat dari MSE atau selisih antara data aktual dan data hasil peramalan serta membagi hasil penjumlahan tersebut dengan banyaknya waktu peramalan. Rumus RMSE dapat ditulis dengan persamaan (2.26) berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2.26)$$

dimana:

Y_i = data aktual pada periode t

\hat{Y}_i = data hasil peramalan pada periode t

n = jumlah periode peramalan yang terlibat

2. *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error adalah rata-rata diferensiasi absolut antara data aktual dan data hasil peramalan, yang dinyatakan sebagai persentase data aktual (Pertiwi dkk., 2021). Persamaan MAPE dirumuskan dalam persamaan (2.27) sebagai berikut (Yao dkk., 2023):

$$MAPE = 100\% \times \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{Y}_i - Y_i}{Y_i} \right| \quad (2.27)$$

dimana:

Y_i = data aktual pada periode t

\hat{Y}_i = data hasil peramalan pada periode t

n = jumlah periode peramalan yang terlibat

Nilai evaluasi yang dihasilkan oleh MAPE memiliki kriteria sebagai berikut (Andres dan Erlin, 2022).

- a. $MAPE < 10\%$: kemampuan peramalan sangat baik.
- b. $10\% \leq MAPE < 20\%$: kemampuan peramalan baik.
- c. $20\% \leq MAPE < 50\%$: kemampuan peramalan cukup.
- d. $MAPE \geq 50\%$: kemampuan peramalan buruk.

2.12 Uji T^2 Hotelling

Statistik T^2 Hotelling merupakan generalisasi dari *T-statistic student* yang digunakan dalam pengujian hipotesis multivariat. Uji ini mengukur “jarak” dari target yang dalam penelitian ini yaitu data prediksi dan data aktual menggunakan matriks kovarians.

Bentuk umum uji T^2 Hotelling untuk dua variabel dituliskan pada persamaan (2.28) sebagai berikut (Mardia, dkk., 2024):

$$T^2 = (\bar{x}_1 - \bar{x}_2)^T S_p^{-1} (\bar{x}_1 - \bar{x}_2) \quad (2.28)$$

dengan:

T^2 : Statistik uji T^2 Hotelling

\bar{x}_1 : vektor rata-rata variabel pertama

\bar{x}_2 : vektor rata-rata variabel kedua

S_p : Matriks kovarians gabungan

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Waktu dan tempat penelitian ini sebagai berikut:

a. Tempat Penelitian

Penelitian ini dilakukan secara studi pustaka yang bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

b. Waktu Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2023/2024 tepatnya mulai Bulan September 2023. Penelitian ini terbagi menjadi tiga tahapan, tahap pertama yaitu melakukan studi literatur dengan mengumpulkan dan membaca jurnal dan buku yang berkaitan dengan penelitian ini serta menentukan tema penelitian, lalu mengumpulkan data yang akan dipakai untuk penelitian ini, kemudian menyusun Bab I sampai III proposal. Kemudian untuk tahap kedua yaitu mulai menjalankan program komputer penelitian mulai dari pemodelan dan peramalan metode VAR, sampai pemodelan dan peramalan metode GRU dan melakukan *hybrid* metode VAR-GRU serta evaluasi model. Tahap ketiga penelitian ini yaitu penyusunan hasil dan pembahasan penelitian dalam Bab IV sampai V proposal yang akan dipaparkan dalam seminar hasil dan sidang komprehensif.

3.2 Data dan Alat Penelitian

3.2.1 Data

Data yang digunakan pada penelitian ini adalah data bulanan Indeks Harga Saham Gabungan (IHSG) dan Suku Bunga Bank Indonesia atau *BI Rate* sejak Januari 2007 sampai Oktober 2023 yang dapat diakses di *website* Badan Pusat Statistik Republik Indonesia (BPS RI): (<https://www.bps.go.id/id/statistics-table/2/Mzc5IzI=/bi-rate.html>). Data yang digunakan dalam penelitian ini disajikan dalam Tabel 2 sebagai berikut:

Tabel 2. Data IHSG dan *BI Rate* periode Januari 2007 – Oktober 2023

Periode	IHSG (Ribu Rupiah)	BI Rate (%)
Januari 2007	1.75726	9.5
Februari 2007	1.74097	9.25
Maret 2007	1.83092	9
April 2007	1.99917	9
Mei 2007	2.08432	8.75
Juni 2007	2.13928	8.5
.	.	.
.	.	.
.	.	.
Juli 2023	6.93136	5.75
Agustus 2023	6.95326	5.75
September 2023	6.93989	5.75
Oktober 2023	6.75221	6

3.2.2 Alat

Alat atau perangkat yang digunakan dalam penelitian ini adalah laptop dengan merek HP tipe 14s-dq2xxx dengan tipe sistem 64-bit *operating system*, *x64-based processor*.

Spesifikasi *hardware* perangkat tersebut adalah sebagai berikut:

- *Processor* : 11th Gen Intel(R) Core(TM) i3-1115G4 @ 3.00GHz 2.90 GHz
- *Memori* : SSD 512 GB

- RAM : 4 GB

Spesifikasi *software* yang digunakan dalam penelitian ini adalah sebagai berikut:

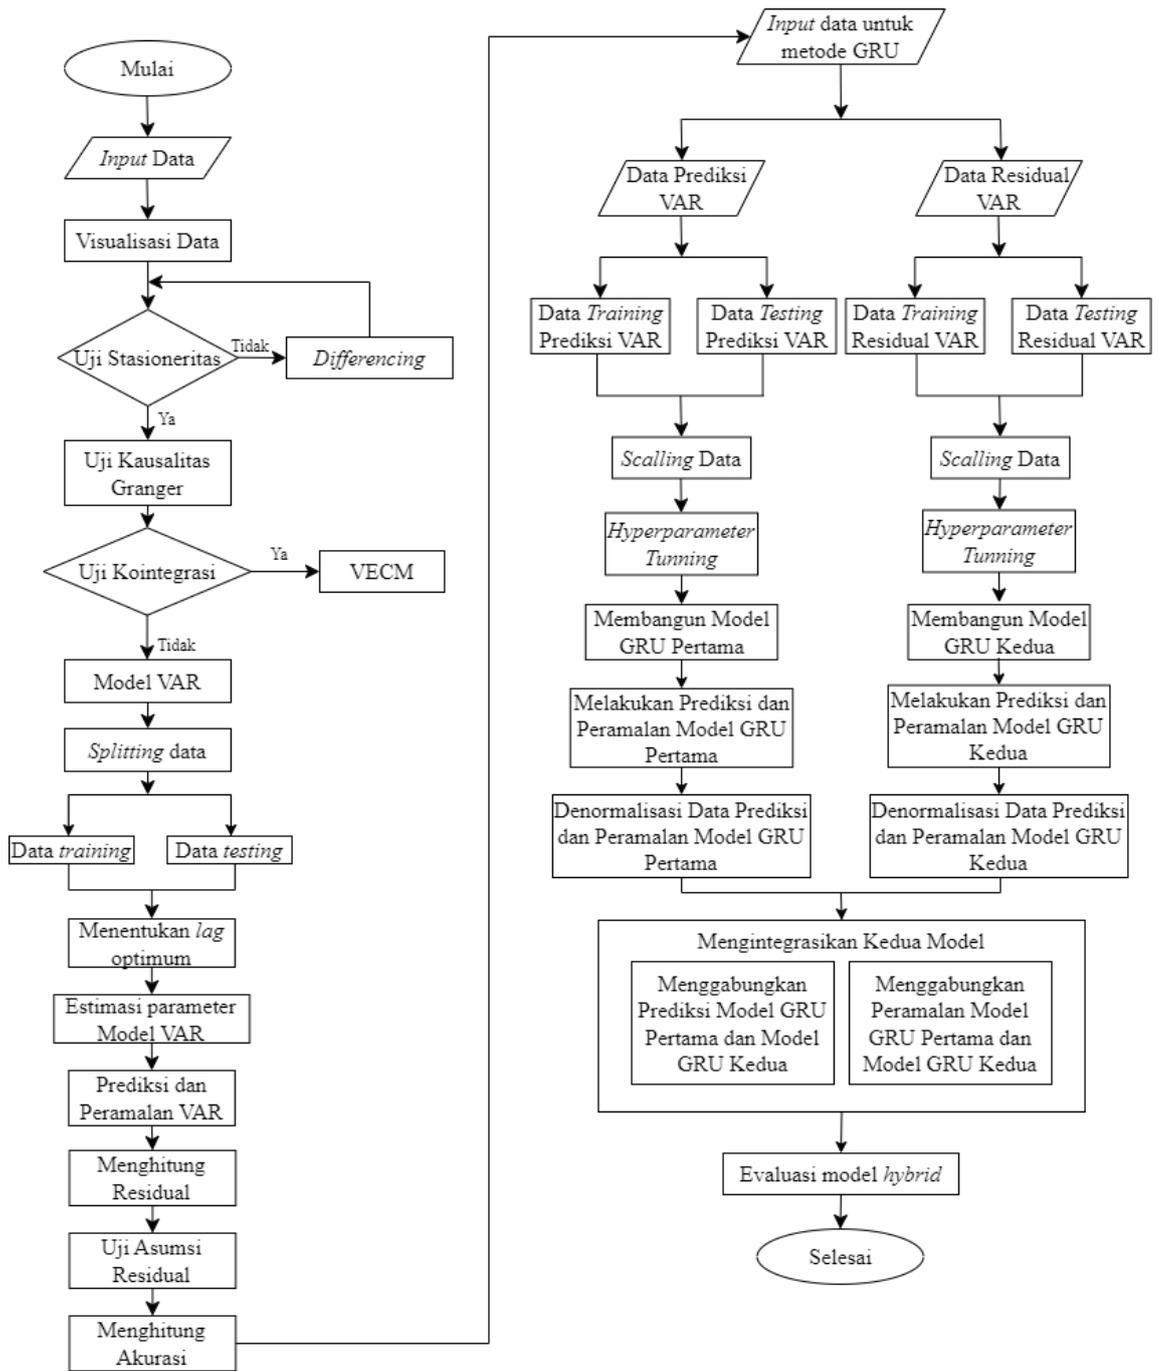
- Sistem operasi Windows 11 64-bit
- Jupyter notebook 6.4.8 (Python 3.9.12)

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

- *Pandas* 1.4.2
- *NumPy* 1.22.4
- *Statsmodels* 0.14.0
- *Matplotlib* 3.5.1
- *Tensorflow* 2.12.0
- *Scikit-learn* 1.0.2

3.3 Alur Kerja Penelitian

Penelitian ini merupakan peramalan data *BI Rate* dan *IHSG* menggunakan metode *hybrid* antara metode VAR dan metode GRU dengan bantuan *software* python. Adapun alur penelitian ini ditampilkan dalam *flowchart* pada Gambar 5 sebagai berikut:



Gambar 5. Flowchart Peramalan Metode Hybrid VAR - GRU

Adapun penjelasan dari setiap tahap yang ada di *flowchart* adalah sebagai berikut:

1. Input data penelitian ke *software* python.
2. Melakukan visualisasi data penelitian dengan *package matplotlib* untuk melihat fluktuasi data.
3. Melakukan uji stasioneritas untuk memeriksa kestasioneran data penelitian, jika belum stasioner maka dilakukan *differencing*.
4. Memeriksa kembali kestasioneran data *differencing* pertama, jika sudah stasioner maka dilanjutkan ke tahapan berikutnya.
5. Melakukan uji kausalitas dengan uji kausalitas *Granger* untuk melihat hubungan sebab-akibat pada data.
6. Melakukan uji kointegrasi dengan menggunakan uji kointegrasi Johansen pada data, jika terdapat kointegrasi maka menjadi model VECM. jika tidak terdapat kointegrasi maka bisa dilanjutkan ke model VAR.
7. Melakukan *splitting* data dengan dua skema, yaitu 80% data *training* dan 20% data *testing* serta 90% data *training* dan 10% data *testing*.
8. Melakukan penentuan *lag* optimum untuk model dengan melihat nilai AIC terkecil pada masing-masing skema
9. Membangun model VAR dengan *lag* optimum yang diperoleh sebelumnya dan dengan menggunakan metode estimasi parameter *Ordinary Least Square* (OLS) kemudian melakukan prediksi dan peramalan data penelitian dengan menggunakan model VAR.
10. Menghitung residual data penelitian dengan mengurangi data aktual dengan data prediksi yang dihasilkan dengan metode VAR.
11. Melakukan uji asumsi residual berupa uji asumsi residual *white noise* dengan uji *Ljung-box*.
12. Melakukan evaluasi dan menghitung akurasi model VAR dengan melihat nilai MAPE dan RMSE.

13. Selanjutnya yaitu *input* data untuk metode GRU dengan data prediksi dan data residual dengan masing-masing skema yang dihasilkan oleh metode VAR sebelumnya.
14. *Input* data prediksi dan residual model VAR yang sudah di-*splitting* menjadi data *training* dan data *testing* sebelumnya untuk membangun 2 model utama GRU. Model GRU pertama dengan data prediksi model VAR dan Model GRU kedua dengan data residual model VAR.
15. Melakukan normalisasi data dengan menggunakan *Min-Max scaler*.
16. Melakukan *hyperparameter tuning* dengan *Grid-Search*. Proses *hyperparameter tuning* ada 2, yaitu *hyperparameter tuning* model GRU pertama dengan data prediksi model VAR dan *hyperparameter tuning* model GRU kedua dengan data residual model VAR.
17. Membangun dua model GRU dengan parameter terbaik hasil *hyperparameter tuning*.
18. Melakukan prediksi dan peramalan dari kedua model GRU (data prediksi dan residual model VAR).
19. Melakukan denormalisasi data prediksi dan peramalan model GRU pertama dengan data prediksi model VAR dan model GRU kedua dengan data residual model VAR.
20. Mengintegrasikan hasil prediksi dari model GRU pertama dan model GRU kedua yang disebut sebagai model prediksi *hybrid*.
21. Menggabungkan hasil peramalan dari model GRU pertama dan model GRU kedua sebagai model peramalan *hybrid*.
22. Melakukan evaluasi model *hybrid* dengan melihat nilai RMSE, MAPE dan akurasinya.
23. Membuat kesimpulan.

V. KESIMPULAN

Berdasarkan hasil dan pembahasan terkait peramalan data IHSG dan BI *Rate* dengan menggunakan metode *hybrid* VAR-GRU yang sudah diperoleh, dapat ditarik kesimpulan sebagai berikut:

1. Model *hybrid* VAR-GRU dibangun dengan menggunakan kombinasi Model GRU pertama dan Model GRU kedua. Masing-masing parameter kedua model berupa GRU *unit*, *Dense unit*, *batch size*, dan *time steps* terbaik diperoleh melalui proses *hyperparameter tuning*, yaitu model GRU pertama dengan skema *splitting* 80% data *training* dan 20% data *testing*, yaitu 64, 32, 64, dan 6. Sedangkan untuk skema 90% data *training* dan 10% data *testing*, yaitu 32, 64, 32, dan 6. Kemudian model GRU kedua dengan skema *splitting* 80% data *training* dan 20% data *testing*, yaitu 64, 32, 64, dan 6 dan untuk skema 90% data *training* dan 10% data *testing*, yaitu 32, 32, 64, dan 6.
2. Model *hybrid* VAR-GRU merupakan metode terbaik untuk melakukan prediksi dan peramalan data deret waktu multivariat, yaitu data IHSG dan BI *Rate* dibandingkan hanya dengan menggunakan model VAR saja. Hal ini dapat dilihat dari nilai akurasi pada metode *hybrid* VAR-GRU yang lebih besar. Model *hybrid* VAR-GRU dengan skema 90% data *training* dan 10% data *testing* memiliki nilai MAPE yang lebih kecil dan akurasi yang lebih besar, yaitu 0.039% dengan akurasi 99.96%.
3. Hasil peramalan IHSG dan BI *Rate* selama 6 bulan ke depan menggunakan model *hybrid* VAR-GRU dengan *splitting* data 90% data *training* dan 10% data *testing* ditampilkan pada Tabel 16 berikut:

Tabel 17. Hasil Peramalan IHSG dan BI Rate dengan Metode *Hybrid VAR-GRU*

Periode	IHSG (Rupiah)	BI Rate (%)
November 2023	7133,24	5.52
Desember 2023	6738,21	5.62
Januari 2024	6975,20	5.58
Februari 2024	7203,89	5.49
Maret 2024	7120,61	5.53
April 2024	7111,77	5.54

DAFTAR PUSTAKA

- 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). <https://doi.org/10.1088/1757-899X/909/1/012079>
- Alawiyah, T., Haryadi, ;, Vyn, Y., Prodi, A., Pembangunan, E., Ekonomi, F., & Bisnis, D. (2019). Pengaruh inflasi dan jumlah uang beredar terhadap nilai tukar rupiah dengan pendekatan model struktural VAR. *Journal Perdagangan Industri dan Moneter*. **7**(1): 51–60.
- Aldi, M. W. P., Jondri, J., & Aditsaia, A. (2018). Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin. *E-Proceeding of Engineering*. **5**(2): 3548–3555.
- Ambarwari, A., Adrian, Q. J., & Herdiyeni, Y. (2020). Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning untuk Identifikasi Tanaman. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*. **1**(3): 117–122.
- Amry, F., Kusnandar, D., & Debatara, N. N. (2018). Model vector autoregressive (VAR) dalam meramal produksi kelapa sawit PTPN XIII. *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, **7**(2):77-84.
- Andres, & Erlin. (2022). Peramalan Jumlah Penjualan Tepung Pada UD. Citra Pekanbaru Menggunakan Fuzzy Time Series. *Jurnal Mahasiswa Aplikasi Teknologi Komputer dan Informasi*. **4**(3): 128–134.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *Proceedings of 2014 Neural Information Processing System NIPS*. 1-9.
- Cryer, J. D., & Chan, K.-S. (1986). *Springer Texts in Statistics Time Series Analysis With Applications in R Second Edition*. Springer, Iowa.
- 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.

- Feng, J., & Lu, S. (2019). Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics: Conference Series*. **1237**(2): 1–6.
- Gujarati, D. N., & Porter, D. C. (2009). *Basic Econometrics*. 5th Edition. McGraw-Hill Irwin, New York.
- Hardani, P. R., Hoyyi, A., & Sudarno. (2017). Peramalan Laju Inflasi, Suku Bunga Indonesia Dan Indeks Harga Saham Gabungan Menggunakan Metode Vector Autoregressive (VAR). *Jurnal Gaussian*. **6**(1): 101–110.
- Heizer, J., & Render, B. (1996). *Operation Management*. Prentice Hall, New Jersey.
- Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *Jurnal Sistem Dan Teknologi Informasi Indonesia (JUSTINDO)*. **3**(2): 49–56.
- Julpan, Nababan, E. B., & Zarlis, M. (2015). Analisis Fungsi Aktivasi Sigmoid Biner Dan Sigmoid Bipolar Dalam Algoritma Backpropagation Pada Prediksi Kemampuan Siswa. *Jurnal Teknovasi*. **2**(1): 103–116.
- Layla, N. N., Kurniati, E., & Suhaedi, D. (2021). Peramalan Indeks Harga Saham dengan Autoregressive Moving Average Generalized Autoregressive Conditional Heteroscedasticity (ARMA-GARCH). *Jurnal Riset Matematika*. **1**(1): 7–12.
- Lütkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. Springer, Berlin.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1997). *Forecasting: Methods and Applications*. 3rd Edition. John Wiley and Sons, New York.
- Mardia, K. V., Kent, J. T., & Taylor, C. C. (2024). *Multivariate Analysis*. 2nd Edition. John Wiley & Sons, New Jersey.
- Munkhdalai, L., Li, M., Theera-Umpon, N., Auephanwiriyaikul, S., & Ryu, K. H. (2020). VAR-GRU: A Hybrid Model for Multivariate Financial Time Series Prediction. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, **12034 LNAI**, 322–332. https://doi.org/10.1007/978-3-030-42058-1_27
- Oktavia, A., & Fajar, M. Y. (2022). Peramalan Laju Inflasi, BI Rate dan Indeks Harga Saham Gabungan. *Jurnal Riset Matematika*. **2**(1): 16–22.
- Openg, J. B. J. R., Hiswati, M. E., & Hamzah, H. (2022). Klasifikasi Unggas Ordo Anseriformes Berdasarkan Citra Menggunakan Metode Deep Learning

- Dengan Algoritma Convolutional Neural Network (CNN). *Prosiding Seminar Nasional Teknik Elektro, Informatika & Sistem Informasi (SINTaKS)*. **1**(1): 26–31.
- Pertiwi, A., Dewi, L. F., Toharudin, T., & Ruchjana, B. N. (2021). Penerapan Model Vector Autoregressive Integrated Moving Average (VARIMA) untuk Prakiraan Indeks Harga Saham Gabungan dan Kurs Rupiah Terhadap USD. *Pattimura Proceeding: Conference of Science and Technology*. **1**: 431–442.
- Rosyidah, H., Rahmawati, R., & Prahutama, A. (2017). Pemodelan Vector Autoregressive X (VARX) Untuk Meramalkan Jumlah Uang Beredar Di Indonesia. *Jurnal Gaussian*. **6**(3): 333–343.
- Savitri, C., Faddila, S.P., Irmawartini, Iswari, H.R., Anam, C., Syah, S., Mulyani, S.R., Sihombing, P.R., Kismawadi, E.R., Pujiyanto, A., Mulyati, A., Astuti, Y., Adinugroho, W.C., Imanuddin, R., Kristia, Nuraini, A., Siregar, M.T. (2021). *Statistik Multivariat dalam Riset*. Widina Bhakti Persada, Bandung.
- Sampurna, D. S. (2016). Analisis Pengaruh Faktor-Faktor Ekonomi Makro Terhadap IHSG Di Bursa Efek Indonesia (BEI). *Jurnal Stei Ekonomi*. **25**(01): 54–73.
- Sembiring, M. (2016). Analisis Vector Autoregresion (VAR) Terhadap Interrelationship Antara IPM Dan Pertumbuhan Ekonomi Di Sumatera Utara. *Jurnal Ekonomikawan*. **16**(2): 77–83.
- Sen, S., Sugiarto, D., & Rochman, A. (2020). Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) dalam Peramalan Harga Beras. *Ultimatics: Jurnal Teknik Informatika*. **11**(1): 35–41.
- Suhendra, C. D., Marlina, L. F., & Sarungallo, A. (2023). Prediksi Mahasiswa Baru Universitas Papua Menggunakan Autoregressive Integrated Moving Average. *Jurnal Informatika*. **10**(2): 157–162.
- Sukirno, S. (2006). *Pengantar Ekonomi (Mikro Dan Makro)*. Edisi ke-1. Rajagrafindo Persada., Jakarta.
- Tian, C., Ma, J., Zhang, C., & Zhan, P. (2018). A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network. *Energies Journal*. **11**(12): 1–13.
- Wahyono, T. (2018). *Fundamental of Python for Machine Learning: Dasar-Dasar Pemrograman Python untuk Machine Learning dan Kecerdasan Buatan*. Gava Media, Yogyakarta.
- Walid. (2019). Peramalan penjualan harga saham PT Bank Rakyat Indonesia (Persero) Tbk (BBRI) dengan Menggunakan Recurrent Neural Network (RNN). *Prosiding Seminar Nasional Matematika (PRISMA)*. **2**: 139–147.

- Wei, W. W. S. (2006). *Time Series Analysis : Univariate and Multivariate Methods*. 2nd Edition. Person Education, New York.
- Yao, E., Zhang, L., Li, X., & Yun, X. (2023). Traffic Forecasting of Back Servers Based on ARIMA-LSTM-CF Hybrid Model. *International Journal of Computational Intelligence Systems*. **16**(1): 1–13.
- Yulisa, P. N., Al Haris, M., & Arum, P. R. (2023). Peramalan Nilai Ekspor Migas di Indonesia dengan Model Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU). *J Statistika*. **16**(1): 328–341.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. **50**(6): 159–175.
- Zhao, X. hua, & Chen, X. (2015). Auto Regressive and Ensemble Empirical Mode Decomposition Hybrid Model for Annual Runoff Forecasting. *Water Resources Management*. **29**(8): 2913–2926.