

**ANALISIS PERFORMA MODEL *VECTOR AUTOREGRESSIVE* (VAR),
GATED RECURRENT UNIT (GRU), SERTA *HYBRID* VAR-GRU DALAM
PERAMALAN DATA *MULTIVARIATE TIME SERIES* HARGA SAHAM
DAN NILAI TUKAR RUPIAH**

(Tesis)

Oleh

JUANDA

NPM 2127031005



**PROGRAM STUDI MAGISTER MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
2024**

ABSTRAK

Analisis Performa Model *Vector Autoregressive* (VAR), *Gated Recurrent Unit* (GRU), Serta *Hybrid* (VAR-GRU) Dalam Peramalan Data *Multivariate Time Series* Harga Saham dan Nilai Tukar Rupiah.

Oleh

Juanda

Tantangan dan ketidakpastian dalam memodelkan fenomena data real, terutama dalam analisis multivariate time series yang telah menjadi fokus utama di berbagai bidang. Metode statistik tradisional seperti Vector Autoregressive (VAR) hanya efektif dalam memodelkan hubungan linier antar variabel, namun memiliki keterbatasan dalam menangkap interaksi nonlinier yang kompleks. Sebaliknya model deep learning seperti Gated Recurrent Unit (GRU) unggul dalam menangkap dependensi nonlinier dan pola temporal dalam data, namun interpretabilitas yang rendah dari model deep learning menjadi kendala dalam aplikasinya. Untuk mengatasi ini, pendekatan hybrid yang menggabungkan metode statistik tradisional dan deep learning dapat menawarkan solusi yang lebih baik. Model hybrid memanfaatkan kekuatan pelengkap dari kedua paradigma, memungkinkan peneliti untuk menangkap pola linier dan nonlinier dalam data secara lebih efektif. penelitian ini bertujuan untuk menganalisis performa dan membandingkan hasil peramalan dari model VAR, GRU, dan hybrid VAR-GRU untuk menentukan model yang paling akurat dan efisien. Hasil penerapan model pada data, model VAR dapat menjelaskan pengaruh antar variabel berlaku satu arah, IHSG mempengaruhi secara signifikan terhadap nilai USD dan EUR serta USD mempengaruhi secara signifikan terhadap EUR namun tidak berlaku sebaliknya. Evaluasi kecocokan model keseluruhan model VAR menunjukkan akurasi 97,693 %, model GRU menunjukkan akurasi 98,710 %, dan model hybrid VAR-GRU menunjukkan akurasi 98.978 % yang merupakan akurasi yang paling baik.

Kata kunci : *Traditional statistical; deep learning models; Vector Autoregressive; Gated Recurrent Unit; Hybrid*

ABSTRACT

Performance Analysis of Vector Autoregressive (VAR), Gated Recurrent Unit (GRU), and Hybrid (VAR-GRU) Models in Forecasting Multivariate Time Series Data of Stock Prices and Rupiah Exchange Rates.

By

Juanda

Challenges and uncertainties in modeling real data phenomena, especially in multivariate time series analysis that has become a major focus in various fields. Traditional statistical methods such as Vector Autoregressive (VAR) are only effective in modeling linear relationships between variables, but have limitations in capturing complex nonlinear interactions. In contrast, deep learning models such as Gated Recurrent Unit (GRU) excel in capturing nonlinear dependencies and temporal patterns in data, but the low interpretability of deep learning models is an obstacle in its application. To overcome this, a hybrid approach that combines traditional statistical methods and deep learning can offer a better solution. Hybrid models leverage the complementary strengths of both paradigms, allowing researchers to capture linear and nonlinear patterns in data more effectively. This study aims to analyze the performance and compare the forecasting results of the VAR, GRU, and hybrid VAR-GRU models to determine the most accurate and efficient model. The results of applying the model to the data, the VAR model can explain the influence between variables in one direction, the IHSG significantly affects the value of USD and EUR and the USD significantly affects EUR but does not apply vice versa. The overall model fit evaluation of the VAR model shows an accuracy of 97.693%, the GRU model shows an accuracy of 98.710%, and the hybrid VAR-GRU model shows an accuracy of 98.978% which is the best accuracy.

Keyword : *Traditional statistical; deep learning models; Vector Autoregressive; Gated Recurrent Unit, Hybrid*

**ANALISIS PERFORMA MODEL *VECTOR AUTOREGRESSIVE* (VAR),
GATED RECURRENT UNIT (GRU), SERTA *HYBRID* VAR-GRU DALAM
PERAMALAN DATA *MULTIVARIATE TIME SERIES* HARGA SAHAM
DAN NILAI TUKAR RUPIAH**

Oleh

Juanda

Tesis

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

**Pada
Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung**



**PROGRAM STUDI MAGISTER MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

Judul Tesis : **ANALISIS PERFORMA MODEL *VECTOR AUTOREGRESSIVE (VAR), GATED RECURRENT UNIT (GRU),* SERTA *HYBRID VAR-GRU* DALAM PERAMALAN DATA *MULTIVARIAT TIME SERIES* HARGA SAHAM DAN NILAI TUKAR RUPIAH**

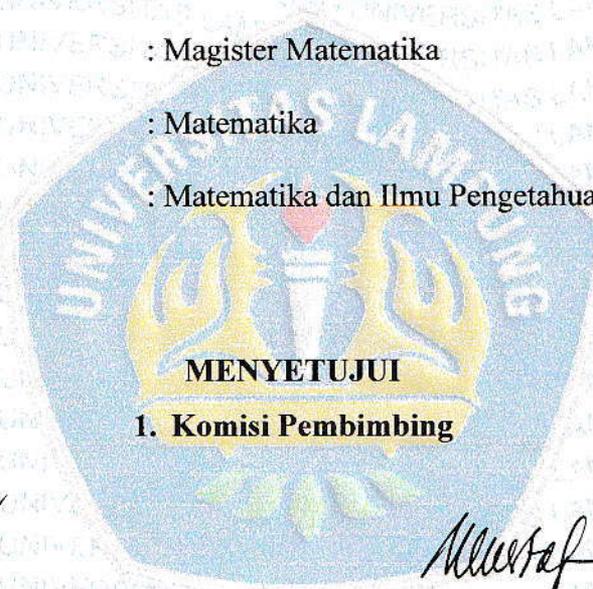
Nama Mahasiswa : **Juanda**

Nomor Pokok Mahasiswa : **2127031005**

Program Studi : Magister Matematika

Jurusan : Matematika

Fakultas : Matematika dan Ilmu Pengetahuan Alam



MENYETUJUI

1. Komisi Pembimbing

Ir. Warsono, M.S., Ph.D.
NIP. 19630216 198703 1 003

Prof. Drs. Mustofa Usman, M.A., Ph.D.
NIP. 19570101 198403 1 020

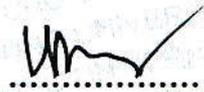
^{g.7}
2. Ketua Program Studi Magister Matematika

Prof. Dr. Asmiati, S.Si., M.Si.
NIP. 19760411 200012 2 001

MENGESAHKAN

1. Tim Penguji

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



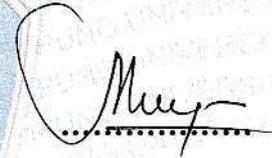
Sekretaris : **Prof. Drs. Mustofa Usman, M.A., Ph.D.**



Penguji Anggota : 1. **Dr. Khoirin Nisa, S.Si., M.Si.**



2. **Dr. Aang Nuryaman, S.Si., M.Si.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

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

NIP. 197110012005011002



3. Direktur Program Pascasarjana

Prof. Dr. Ir. Murhadi, M.Si.

NIP. 196403261989021001



Tanggal Lulus Ujian Tesis : **8 Agustus 2024**

PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : **Juanda**
Nomor Pokok Mahasiswa : **2127031005**
Program Studi : **Magister Matematika**
Jurusan : **Matematika**

Dengan ini menyatakan bahwa tesis saya yang berjudul “**ANALISIS PERFORMA MODEL *VECTOR AUTOREGRESSIVE (VAR)*, *GATED RECURRENT UNIT (GRU)*, SERTA *HYBRID VAR-GRU* DALAM PERAMALAN DATA *MULTIVARIATE TIME SERIES* HARGA SAHAM DAN NILAI TUKAR RUPIAH” adalah hasil pekerjaan saya sendiri. Semua hasil tulisan dalam tesis ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila kemudian hari terbukti bahwa tesis ini merupakan hasil salinan atau telah dibuat orang lain, maka saya bersedia menerima sanksi sesuai ketentuan akademik yang berlaku.**

Bandar Lampung, 08 Agustus 2024
Penulis,



Juanda
NPM. 2127031005

RIWAYAT HIDUP

Penulis dilahirkan di Banding pada tanggal 04 September 1988, sebagai anak ketiga dari pasangan Bapak Rodiyal dan Hernawati serta adik dari Andi Zarkoni dan Hermansyah serta abang dari Rosiyana dan Mia Erdiyanti.

Penulis telah menempuh pendidikan di Sekolah Dasar Negeri Banding pada tahun 1995-2001, Sekolah Menengah Pertama Negeri (SMPN) Sanggi pada tahun 2001-2004, dan Sekolah Menengah Atas Negeri (SMAN) 1 Kotaagung pada tahun 2004-2007.

Pada tahun 2007 penulis terdaftar sebagai Mahasiswa Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung dan lulus sebagai sarjana matematika pada tahun 2011. Pada tahun 2021 penulis berkesempatan untuk melanjutkan pendidikan di program studi Magister Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung, selama menjadi mahasiswa Magister penulis cukup aktif mengikuti seminar internasional dan menulis artikel yang dipublikasi di jurnal nasional terakreditasi.

Pada tahun 2018 penulis menikah dengan Oktavia Ramanda, A.Md dan alhamdulillah dikarunia anak pertama bernama Muhammad Zayn Azka dan anak kedua bernama Ahmad Zydan Abrisam.

KATA MUTIARA

“Maka bersabarlah kamu, sungguh, janji Allah itu benar dan sekali-kali jangan sampai orang-orang yang tidak meyakini (kebenaran ayat-ayat Allah) itu menggelisahkan engkau”

(Qs. Ar-Rum: 60)

“Maka sesungguhnya bersama kesulitan ada kemudahan”

(Qs. Al-Insyirah: 5)

“Allah akan mengangkat derajat orang-orang yang beriman dan orang-orang yang berilmu di antara kamu sekalian”

(Qs. Al-Mujadilah: 11)

PERSEMBAHAN

Dengan mengucap puji dan syukur kehadiran Allah SWT yang telah memberikan petunjuk dan kemudahan untuk menyelesaikan studiku, kupersembahkan karya kecilku ini untuk:

Ayah dan Ibu tercinta yang selalu mendidik, mendoakan, berkorban, dan hal lain yang tak dapatku ungkapkan dengan kata-kata

Istri dan kedua anakku tersayang, yang sudah mendukung selama proses perkuliahan dan penyusunan tesisku

Kedua kakak dan adikku, yang selalu mendoakan kelancaran studiku

Dosen pembimbing dan penguji yang sangat berjasa dan tidak lelah memberikan arahan serta masukan sehingga peulis dapat menyelesaikan tesisku

Sahabat dan teman-temanku, Terimakasih atas kebersamaan, do'a dan semangat yang selalu kalian berikan kepadaku.

Universitas Lampung

SANWACANA

Alhamdulillah Robbil ‘alamin, Puji dan syukur Penulis ucapkan kepada Allah SWT, yang selalu melimpahkan rahmat dan kasih sayang-Nya, sehingga Penulis dapat menyelesaikan tesis ini. Sholawat seraf salam senantiasa tetap tercurah kepada Nabi Muhammad SAW, tuntunan dan tauladan utama bagi seluruh umat manusia.

Tesis dengan judul “Analisis Performa *Model Vector Autoregressive (VAR), Gated Recurrent Unit (GRU), Serta Hybrid (VAR-GRU)* Dalam Peramalan Data *Multivariate Time Series* Harga Saham dan Nilai Tukar Rupiah.” adalah salah satu syarat untuk memperoleh gelar Magister Matematika di Universitas Lampung.

Dalam menyelesaikan tesis ini, banyak pihak yang telah membantu Penulis dalam memberikan bimbingan, dorongan, dan saran-saran. Sehingga dengan segala ketulusan dan kerendahan hati pada kesempatan ini Penulis mengucapkan terimakasih yang sebesar-besarnya kepada:

1. Ir. Warsono, M.S., Ph.D., selaku Dosen Pembimbing 1 yang senantiasa memberikan bimbingan, saran, motivasi, nasehat serta masukan sehingga penulis dapat menyelesaikan perkuliahan dan tesis ini
2. Prof. Drs. Mustofa Usman, M.A., Ph.D., selaku Dosen Pembimbing 2 yang telah memberikan masukan dan saran dalam penyelesaian tesis
3. Dr. Khoirin Nisa, S.Si., M.Si., selaku Dosen Pembahas 1 yang telah memberikan kritik dan saran kepada penulis dalam penyelesaian tesis
4. Dr. Aang Nuryaman, S.Si., M.Si., selaku Dosen Pembahas 2 yang telah memberikan kritik dan saran kepada penulis dalam penyelesaian tesis
5. Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam
6. Prof. Dr. Asmiati, S.Si., M.Si. selaku Ketua Program Studi Magister Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam

7. Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung
8. Dosen, staf dan karyawan Jurusan Matematika FMIPA Universitas Lampung yang telah memberikan ilmu dan bantuan kepada penulis
9. Ayah dan Ibu yang tidak pernah lelah memberikan do'a, dukungan, kasih sayang, dan pengorbanan kepada Penulis
10. Ayah dan Ibu mertua yang selalu menyemangati dan mendukung.
11. Istri dan kedua putraku tersayang, yang sudah mendukung selama proses perkuliahan dan penyusunan tesisku
12. Kedua kakak dan adikku, yang selalu mendoakan kelancaran studiku
13. Teman-teman Magister Matematika Angkatan 2021.
14. Teman-teman guru dan staf Prosus Inten Lampung.

Penulis juga menyadari bahwa dalam penulisan tesis ini masih banyak terdapat kekurangan. Oleh karena itu, Penulis mengharapkan saran dan kritik yang membangun guna penelitian selanjutnya agar lebih baik.

Bandar Lampung, 08 Agustus 2024
Penulis,

Juanda

DAFTAR ISI

Halaman

HALAMAN JUDUL
DAFTAR ISI
DAFTAR TABEL
DAFTAR GAMBAR

I. PENDAHULUAN

1.1 Latar Belakang Masalah	1
1.2 Tujuan	6
1.3 Manfaat	7

II. TINJAUAN PUSTAKA

2.1 Prediksi dan Peramalan (<i>forecasting</i>)	8
2.2 <i>Time Series</i>	8
2.3 Analisis <i>Time Series</i>	9
2.4 Analisis <i>Multivariate Time Series</i>	10
2.5 Uji Stasioneritas (Uji <i>Augmented Dickey-Fuller</i>)	10
2.6 Uji Kointegrasi (<i>Johansen Trace Statistic Test</i>)	13
2.7 Uji Kausalitas Granger	14
2.8 Pembeda (<i>Differencing</i>)	16
2.9 <i>Vector Autoregressive</i> (VAR)	16
2.9.1 Lag Optimum	17
2.9.2 Estimasi Parameter Model VAR	17
2.9.3 Diagnostik Model	18
2.9.3.1 Uji Autokorelasi (Uji Ljung-Box).	18
2.10 Model <i>Gated Recurrent Unit</i> (GRU)	20
2.10.1 <i>Machine Learning</i>	20
2.10.2 Deep Learning	20
2.10.3 <i>Scaling data</i>	20
2.10.4 <i>Recurrent Neural Network</i> (RNN)	21
2.10.5 <i>Gated Recurrent Unit</i> (GRU)	23

2.10.6 Fungsi Aktivasi	25
2.10.6.1 Fungsi Sigmoid	26
2.10.6.2 Fungsi Tanh (Tangen Hiperbolik)	27
2.11 Model Hybrid (VAR – GRU)	28
2.12 Evaluasi Model	29
2.12.1 Mean Absolute Error (MAE)	29
2.12.2 Root Mean Square Error (RMSE)	29
2.12.3 Mean Absolute Perception Error (MAPE)	30
2.13 Indikator Statistika	30
2.13.1 Konsep Dasar Matriks	30
2.13.2 Distribusi Normal Multivariat	31
2.14 Indikator Non Statistika (Ekonomi)	33
2.14.1 Nilai Tukar Uang	33
2.14.2 Saham	34
 III. METODOLOGI PENELITIAN	
3.1 Waktu dan Tempat Penelitian	35
3.2 Data Penelitian	35
3.3 Metode Penelitian	36
3.1.1 Input Data	38
3.1.2 Model VAR	38
3.1.3 Model GRU	39
3.1.4 Model Hybrid (VAR-GRU)	41

IV. HASIL DAN PEMBAHASAN

4.1	Input Data.....	41
4.1.1	Visualisasi Data	41
4.2.1.1	Statistika Deskriptif Data	43
4.2.1.2	Scaling Data	45
4.2	Pemodelan Var	47
4.2.1	Uji Stasioner Data Level (Uji ADF)	47
4.2.2	Lag Optimum (AIC)	49
4.2.3	Uji Kointegritas (Johansen Test)	50
4.2.4	Uji Kausalitas Geranger.....	51
4.2.5	Estimasi Modek Var	52
4.2.6	Prediksi Model VAR.....	54
4.2.7	Residual Model VAR.....	55
4.2.8	Uji Asumsi Residual.....	55
4.2.8.1	Mean Of Residual.....	55
4.2.8.2	Uji Autokorelasi (Ljung-B0X).....	57
4.2.9	Peramalan Model VAR.....	58
4.3	Pemodelan GRU	59
4.3.1	Hyperparameter Model GRU	59
4.3.2	Membangun Model GRU	60
4.3.3	Prediksi Model GRU	61
4.3.4	Peramalan Model GR.....	61
4.4	Pemodelan Hybrid (VAR-GRU)	62
4.4.1	Scaling Data Residual	62

4.4.2	Hyperparameter Model GRU	63
4.4.3	Membangun Model GRU	64
4.4.4	Prediksi Model GRU (Residual)	65
4.4.5	Peramalan Model GRU (Residual)	65
4.4.6	Prediksi Model Hybrid	66
4.4.7	Peramalan Model Hybrid	66
4.5	Evaluasi model	67

V. SIMPULAN DAN SARAN

5.1	Simpulan	68
5.2	Saran	69

DAFTAR PUSTAKA

LAMPIRAN

DAFTAR TABEL

	Halaman
1. Tabel nilai IHSG, USD, dan EUR	42
2. Karakteristik data nilai harian IHSG, USD, EUR.....	43
3. Normalisasi Nilai IHSG, USD, dan EUR.....	45
4. Uji Stasioner data level	47
5. Data <i>first difference</i>	48
6. Uji Stasioner data <i>first difference</i>	48
7. Nilai Uji Kointegrasi (Uji Johansen Test).....	50
8. Kausalitas Granger dengan <i>Lag = 5</i>	51
9. Estimasi Persamaan Model VAR dengan <i>Lag = 5</i>	52
10. Nilai residual model VAR.....	55
11. Mean of Residu.....	56
12. Uji Ljung-Box.....	57
13. Parameter Model GRU.....	59
14. Parameter pembangun model GRU.....	60
15. Nilai Scaling residual VAR.....	62
16. Parameter Model GRU data residual	63
17. Parameter pembangun model GRU data residual.....	64
18. Evaluasi Model.....	67

DAFTAR GAMBAR

Halaman

1. Pola pergerakan data time series.....	9
2. Contoh pola data stasioner dan tidak stasioner.....	11
3. Skema RNN sederhana.....	21
4. Skema <i>feed forward</i> Model RNN (GRU).....	23
5. fungsi Sigmoid.....	26
6. Grafik fungsi Tanh.....	27
7. <i>Bagan & Flowchart</i> Metode Penelitian.....	37
8. Plot data nilai harian IHSG, USD, EUR.....	42
9. Boxplot data harga harian IHSG, USD, EUR.....	44
10. Normalisasi data.....	46
11. Nilai AIC	49
12. Prediksi Model VAR dalam <i>first difference</i>	54
13. Prediksi Model VAR dalam data level.....	54
14. Visualisasi nilai residual.....	56
15. hasil peramalan model (VAR).....	58
16. Hasil Prediksi (GRU).....	61
17. Plot Hasil Peramalan dan nilai aktual.....	61
18. Prediksi model GRU data residual.....	65
19. Ramalan model GRU data residual.....	65
20. Plot prediksi model <i>Hybrid</i>	66
21. Plot peramalan model <i>Hybrid</i>	66

I. PENDAHULUAN

1.1 Latar Belakang Masalah

Seorang ahli statistik terkenal George E. P. Box dalam bukunya yang berjudul *Empirical model-building and response surface* menuliskan "*All models are wrong, but some are useful*" (Box & Draper, 1986). Frasa ini sering digunakan dalam konteks ilmu statistik dan pemodelan untuk menekankan bahwa model statistik atau matematis yang sering digunakan untuk mewakili realitas tidak pernah sepenuhnya akurat atau sempurna. Namun, meskipun model tersebut tidak sempurna, banyak dari mereka masih dapat memberikan wawasan yang berharga dan berguna untuk memahami fenomena yang kompleks dan membuat kebijakan yang lebih baik.

Dalam konteks lebih dalam *all models are wrong* mengartikan semua model merupakan representasi (gambaran) yang sederhana dari realitas yang mengandung fenomena kompleks, model juga didasarkan pada asumsi tertentu yang mungkin tidak sepenuhnya akurat, sehingga semua model memiliki tingkat kesalahan. Sedangkan *but some are useful* dapat diartikan meskipun model tidak sempurna, model ini memberikan prediksi yang cukup akurat untuk keperluan dasar, model juga dapat membuat peneliti memahami hubungan dan dinamika antar variabel, serta model juga dapat mendukung proses pengambilan keputusan yang memiliki dasar analitis dan informatif.

Sehingga ungkapan ini menggambarkan tantangan dan ketidakpastian yang sering dihadapi dalam memodelkan fenomena dunia nyata, terutama dalam *analysis multivariate time series*. *Analysis multivariate time series* telah menjadi fokus utama dalam berbagai bidang penelitian dan aplikasi praktis, seperti keuangan, ekonomi, meteorologi, ilmu lingkungan, dan perawatan kesehatan, di mana memahami interaksi antara variabel dapat menghasilkan peramalan dan pengambilan keputusan yang lebih baik.

Data *multivariate time series* terdiri dari pengamatan pada dua atau lebih variabel yang direkam dari waktu ke waktu. Jenis data ini menangkap hubungan dinamis antara beberapa variabel yang bergantung pada waktu, memungkinkan analisis tentang bagaimana perubahan dalam satu variabel mempengaruhi variabel lain dari waktu ke waktu. Salah satu tujuan utama dalam analisis *multivariate time series* adalah peramalan. Melakukan peramalan tentang masa depan, memainkan peran penting dalam proses pengambilan keputusan setiap perusahaan yang ingin mempertahankan bisnis yang sukses. Misalnya, peramalan yang akurat sangat penting untuk memprediksi penjualan guna merencanakan inventaris dengan lebih baik atau meramalkan aktivitas ekonomi untuk menginformasikan keputusan pengembangan bisnis.

Dalam upaya untuk memprediksi nilai masa depan beberapa *time series* yang saling terkait, metode statistik tradisional seperti *Vector Autoregressive* (VAR), yang berkembang menjadi *Vector Error Correction Model* (VECM), *Vector Autoregressive Integrated* (VARI) telah banyak digunakan. Model ini menawarkan wawasan yang jelas tentang hubungan antara variabel dan efektif dalam menangkap dependensi linier seperti mampu memodelkan hubungan simultan antara beberapa variabel. Metode statistika tradisional khususnya model VAR sering kali lebih transparan dan lebih mudah ditafsirkan. Interpretabilitas ini memberikan keuntungan dalam memahami mekanisme yang mendasari hubungan antar variabel. Namun, salah satu keterbatasan utama dari metode statistik tradisional dalam hal ini model VAR adalah kemampuannya yang terbatas dalam memodelkan interaksi nonlinier yang kompleks. Dalam banyak kasus, hubungan antara variabel tidak selalu linier dan dapat melibatkan interaksi yang lebih rumit.

Di sisi lain, kesulitan yang dialami model VAR dalam menangkap dependensi dan pola non linier dalam data *time series* dapat dengan mudah dilakukan model *deep learning*. Model *deep learning* yang sering digunakan seperti *Recurrent Neural Network* (RNN), *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). Model *deep learning*, khususnya GRU unggul dalam menangkap dependensi nonlinier, pola temporal, dan interaksi kompleks dalam data. Namun, model GRU juga memiliki kekurangan. Kelemahan model GRU adalah sifatnya

yang seperti "kotak hitam", yang berarti sulit untuk memahami bagaimana model tersebut sampai pada prediksi tertentu. Meskipun model GRU ini sangat kuat dalam memprediksi, kurangnya interpretabilitas dapat menjadi hambatan dalam penerapannya, terutama dalam domain di mana penjelasan dan transparansi sangat penting.

Dalam praktiknya, sering kali sulit untuk menentukan apakah *time series* yang diteliti dihasilkan dari proses dasar linier atau nonlinier. Data *time series* pada dasarnya jarang murni linier atau nonlinier, sering kali mengandung pola linier dan nonlinier. Keadaan ini memberikan motivasi bagi pengembangan model seperti yang dijelaskan oleh Zhang (2003) yang mencatat bahwa hampir secara universal disepakati dalam literatur peramalan bahwa tidak ada satu metode pun yang terbaik dalam setiap keadaan. Hal ini terutama karena masalah *time series* di dunia nyata sering kali rumit, sehingga memungkinkan pola yang berbeda ditangkap secara berbeda oleh model yang berbeda. Oleh karena itu, diperlukan pendekatan terpadu yang menggabungkan interpretabilitas dan kesederhanaan metode statistik klasik dengan kekuatan prediktif dan skalabilitas teknik pembelajaran mendalam, yang disebut model *hybrid*.

Model *hybrid* dapat menjembatani kesenjangan antara pendekatan statistik tradisional dan pembelajaran mendalam. Dengan mengintegrasikan komponen statistik dan *deep learning* secara cerdas, model *hybrid* dapat memanfaatkan keunggulan pelengkap dari kedua paradigma. Misalnya, komponen statistik dapat digunakan untuk menangkap pola linier dan memberikan hubungan antar data, sementara komponen *deep learning* dapat menangkap interaksi nonlinier yang kompleks. Dengan mengintegrasikan keduanya, model *hybrid* dapat menawarkan kerangka kerja yang lebih dapat dipahami untuk prediksi. Model *hybrid* berupaya meningkatkan akurasi peramalan, mengurangi kompleksitas model, dan meningkatkan hubungan antar data dengan mengintegrasikan komponen statistik dan *deep learning* secara cerdas. Integrasi metode statistik tradisional dengan *deep learning* menghadirkan jalan yang menjanjikan untuk memanfaatkan keunggulan pelengkap dari kedua paradigma, yang mengarah pada pengembangan model *hybrid* untuk meramalkan data *multivariate time series*.

Pendekatan *hybrid* ini menunjukkan potensi besar dalam berbagai aplikasi. Dalam bidang ekonomi dan keuangan, misalnya, model *hybrid* dapat digunakan untuk memprediksi harga saham, dan nilai tukar rupiah dengan memanfaatkan pola linier historis dan interaksi nonlinier yang muncul. Nilai tukar uang, harga saham adalah variabel ekonomi penting (GÜLHAN-, 2020) untuk dipelajari, variabel – variabel ekonomi ini yang mendasari pengambilan keputusan (Ramachandran & Tsokos, 2015). Pergerakan nilai tukar Rupiah berdampak pada perdagangan internasional, investasi asing, dan stabilitas harga sedangkan IHSG merupakan barometer kesehatan ekonomi dan sentimen investor.

Berbagai penelitian terdahulu yang sudah mengkombinasikan statistika tradisional dan berbagai model *deep learning* telah banyak dilakukan. Seperti (Wang et al., 2013) mengusulkan model *hybrid* ARIMA- ANN, yang khas dalam mengintegrasikan keunggulan ARIMA dan ANN dalam memodelkan perilaku linier dan nonlinier dalam set data. Model hibrida diuji pada tiga set data aktual, yaitu, data bintang matahari Wolf, data lynx Kanada, dan data harga saham IBM. hasilnya menunjukkan efektivitas model *hybrid* ARIMA- ANN dalam memperoleh peramalan yang lebih akurat dibandingkan dengan model ARIMA dan ANN.

(Jadhav & Ligay, 2016) Dalam penelitiannya menggunakan dan membandingkan kinerja metode statistik autoregressive integrated moving average (ARIMA), metode ekonometrika *vector autoregression* (VAR) dan metode pembelajaran mesin jaringan saraf tiruan ANN (RNN LSTM) dalam meramalkan konsumsi energi. Akhirnya kami merancang dan menguji model hibrida berdasarkan VAR dan ANN untuk menangkap aspek linear dan nonlinear dari deret waktu energi. Kami mengamati bahwa model ANN (RNN LSTM) mengungguli semua model lain dalam hal akurasi ketika akurasi diukur menggunakan mean absolute percentage error (MAPE).selanjutnya (Kulshreshtha & Vijayalakshmi, 2020) Melakukan peramalan Pasar saham, Makalah ini mengusulkan model hybrid (ARIMA-LSTM) dan Pustaka peramalan Prophet oleh Facebook. hybrid (ARIMA-LSTM) dirancang untuk menangkap bagian linier dan non-linier dari deret waktu. Dalam kasus ini, Prophet memiliki Root Mean Square Error (RMSE) yang tinggi,

yaitu 27,59 dan Mean Square Error (MSE) sebesar 761,33, sedangkan hybrid ARIMA-LSTM memberikan MSE sebesar 3,03 dan RMSE sebesar 1,74 beserta kecocokan model sebesar 99%. Sehingga disimpulkan hybrid ARIMA-LSTM berkinerja jauh lebih baik daripada Prophet dan diterima sebagai algoritma akhir untuk implementasi.

(Najamuddin & Fatima, 2022) Melakukan peramalan tentang nilai tukar uang. Untuk mengevaluasi kinerja model, RMSE, MAE, dan MAPE diterapkan. Hasilnya menunjukkan bahwa model *hybrid* BRNN-ARIMA yang diusulkan mengungguli model Bayesian regularized neural network (BRNN), Autoregressive integrated moving average model (ARIMA) dalam meramalkan nilai tukar. Selanjutnya (Safi & Sanusi, 2021) Menunjukkan bahwa akan ideal untuk menggunakan satu model ETS atau ARIMA untuk peramalan deret waktu COVID-19 harian nyata di seluruh dunia untuk periode antara 22 Januari 2020 hingga 19 Juni, dan 20 Juni hingga 2 Januari 2021 daripada model Hibrida rumit yang menggabungkan beberapa model. Makalah ini membahas berbagai pendekatan peramalan dan kriteria untuk memilih teknik peramalan terbaik. Hasil empiris menunjukkan bahwa model ETS dan ARIMA mengungguli model ANN dan Hybrid. Temuan utama menunjukkan bahwa model prakiraan yang dipilih konsisten selama gelombang pertama dan kedua pandemi. Prakiraan ini menggembirakan karena dunia berjuang untuk menahan penyebaran COVID-19. Ini mungkin merupakan hasil dari tindakan pembatasan sosial yang diamanatkan oleh pemerintah di seluruh dunia.

Penelitian terdahulu yang khusus tentang metode *hybrid Vector Autoregressive - Gated Recurrent Unit* (VAR-GRU) juga telah banyak dilakukan. Seperti penelitian dari (Munkhdalai et al., 2020) menunjukkan bahwa kemampuan model *hybrid* VAR-GRU memiliki kinerja prediksi terhadap semua prediktor dasar jauh lebih baik dibandingkan model *hybrid* VAR-RNN dan VAR-LSTM. Selain itu, (Bayu Aji & Surjandari, 2020) Peramalan ini menggunakan metode LSTM, GRU, VAR, VAR-LSTM, VAR-GRU. hasil peramalan VAR-GRU menghasilkan peramalan dengan akurasi sebesar 99,40% lebih baik dibandingkan VAR-LSTM sebesar 98,98%.

Kemudian (Bahra & Pierre, 2021) Hasil simulasi menunjukkan bahwa model mobilitas model *hybrid* VAR-GRU yang diusulkan memiliki kesalahan prediksi paling rendah dibandingkan dengan metode RNN, LSTM, GRU. serta (Sabat et al., 2023) efektivitas model *hybrid* VAR-GRU dibuktikan dengan membandingkan metrik kinerjanya (MAE, MSE, RMSE, dan R2 Score) dengan model dasar lainnya seperti LSTM, VAR, GRU, dan model *hybrid* VAR-LSTM. Terbaru (Di Mauro et al., 2024) meneliti tentang prediksi dari metrik kualitas jaringan. Metode peramalan yang digunakan adalah VAR, CNN, LSTM, GRU, VAR-CNN, VAR-LSTM, VAR-GRU. Kinerja yang dihasilkan menunjukkan keunggulan skema *hybrid* yang diusulkan (VAR-CNN, VAR-LSTM, VAR-GRU) dibandingkan skema murni, dengan pengurangan kesalahan perkiraan yang signifikan.

Berdasarkan beberapa pemaparan diatas, maka penulis ingin melakukan analisis dan peramalan tentang nilai IHSG, dan nilai tukar Rupiah terhadap Dolar Amerika dan Euro Eropa yang berjudul “Analisis performa model VAR, GRU, serta *hybrid* (VAR-GRU) dalam peramalan data *multivariate time series* harga saham dan nilai tukar Rupiah”. Dalam penelitian ini diharapkan dengan mengintegrasikan keunggulan statistika klasik (VAR) dan keunggulan *deep learning* (GRU) mendapatkan nilai akurasi yang baik.

1.2 Tujuan

Berikut ini adalah beberapa tujuan yang menjadi fokus penelitian:

1. Menguji Granger Kausalitas di antara variabel-variabel yang digunakan
2. Menganalisis estimasi model VAR.
3. Menganalisis performa (akurasi) model VAR dalam peramalan data.
4. Menganalisis performa (akurasi) model GRU dalam peramalan data.
5. Menganalisis performa (akurasi) model *hybrid* VAR-GRU dalam peramalan data.
6. Membandingkan hasil peramalan dari ketiga model untuk menentukan model yang paling akurat dan efisien.

1.3 Manfaat

Manfaat dari penelitian ini meliputi:

1. dapat menjadi referensi bagi peneliti yang ingin melakukan penelitian mengenai pemodelan VAR, GRU, dan *hybrid* (VAR-GRU).
2. menambah wawasan keilmuan dan pengetahuan bagi pembaca tentang pemodelan VAR, RNN, dan *hybrid* (VAR-GRU).
3. Penelitian ini dapat berkontribusi pada pengembangan metodologi baru dalam bidang prediksi *multivariate time series*, terutama dalam aplikasi *machine learning* dan model *hybrid*. Ini dapat membuka peluang baru untuk penelitian lanjutan dan inovasi dalam bidang statistik dan data science.
4. Studi ini dapat memberikan wawasan yang lebih dalam mengenai interaksi antara berbagai *variabel* ekonomi dan bagaimana mereka mempengaruhi pergerakan pasar saham dan nilai tukar. Ini dapat membantu dalam mengembangkan teori ekonomi yang lebih komprehensif dan akurat.

II. TINJAUAN PUSTAKA

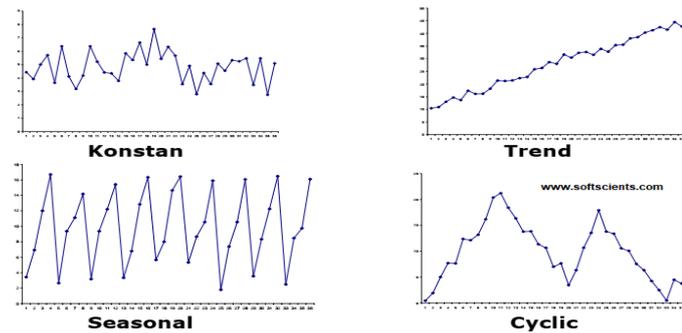
2.1 Prediksi dan Peramalan (*forecasting*)

Prediksi merupakan perkiraan sistematis suatu data variabel ekonomi yang informasinya diambil dari nilai data tersebut di masa lalu, Data ekonomi yang digunakan merupakan angka-angka yang tersusun berurutan berdasarkan deret waktu (*time series*) (Miraswan et al., 2022). Menurut Ella & Arifianto, (2020) Prediksi dapat diartikan teknik untuk memperkirakan nilai pada masa yang akan datang dengan memperhatikan data pada masa kini maupun data masa lalu. Sedangkan Peramalan (*forecasting*) merupakan perkiraan nilai variabel di masa depan yang diluar data pelatihan. Peramalan bertujuan untuk memberikan ekspektasi masa depan berdasarkan model yang telah dibangun. Teknik peramalan ini dibagi menjadi dua kategori yaitu analisis kualitatif dan analisis kuantitatif, analisis kualitatif merupakan peramalan yang berdasarkan data yang tidak dapat direpresentasikan secara tegas menjadi suatu nilai (angka) contohnya peramalan pendapat, sedangkan analisis kuantitatif merupakan peramalan berdasarkan data masa lalu yang dapat direpresentasikan secara tegas menjadi angka dan biasanya disebut data *time series*.

2.2 *Time Series*

Menurut Febrianti et al., (2021), *time-series* atau deret waktu adalah kumpulan pengamatan yang diambil selama periode waktu tertentu, umumnya dengan durasi waktu yang sama (harian, mingguan, bulanan, triwulanan, atau tahunan). Secara umum, deret waktu menunjukkan serangkaian gerakan tipikal tertentu.

Serangkaian gerakan data deret waktu dibagi menjadi stasioner, tren, musiman, siklus, seperti pada Gambar 1.



Gambar 1. Pola pergerakan data time series

berdasarkan Gambar 1 menunjukkan bahwa ada 4 pola pada data *time series*, pola konstan (stasioneritas) deret waktu bersifat konstan sepanjang waktu. Stasioneritas penting dalam analisis deret waktu karena banyak metode dan model yang membutuhkan asumsi ini. Pada pola tren, deret waktu menunjukkan arah pergerakan data umum dalam jangka waktu yang panjang. Tren bisa naik (positif), turun (negatif), atau datar. Pada pola musiman (seasonal) memiliki pola yang berulang dengan periode yang tetap dalam waktu deret. Sedangkan pola siklus, fluktuasi yang terjadi dengan periode yang tidak tetap dalam waktu deret. Siklus biasanya lebih panjang daripada pola musiman dan dapat dikaitkan dengan faktor ekonomi atau sosial yang lebih luas.

2.3 Analisis *Time Series*

Analisis *Time Series* bertujuan untuk memperoleh ukuran yang dapat digunakan untuk membuat keputusan saat ini, untuk memprediksi (meramalkan) periode mendatang, dan untuk memungkinkan perencanaan operasional di masa mendatang (Schkade & Clark, 1983).

Jika nilai suatu variabel tergantung pada nilai variabel tersebut pada periode sebelumnya, kita menulis :

$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-p}) \quad (2.1)$$

dengan X_t adalah nilai variabel yang diinginkan, X_{t-p} adalah nilai variabel p periode sebelum variabel yang diinginkan.

2.4 Analisis *Multivariate Time Series*

Persamaan untuk suatu data *time-series* dapat ditulis :

$$\mathbf{y}_t = \phi_0 + \sum_{j=1}^p \phi_j \mathbf{y}_{t-j} + e_t \quad (2.2)$$

Dengan \mathbf{y}_t adalah vektor dependent berukuran $(k \times 1)$, ϕ_0 merupakan vektor berukuran $(k \times 1)$, ϕ_j koefisien model estimasi berukuran $(k \times k)$, dan \mathbf{y}_{t-1} adalah vektor berukuran $(k \times 1)$, e_t merupakan vektor residu berukuran

Persamaan 2.2 dapat kita jelaskan sebagai berikut :

$$\begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_k \end{bmatrix} = \begin{bmatrix} \phi_{10} & \phi_{11} & \phi_{12} & \cdots & \phi_{1p} \\ \phi_{20} & \phi_{21} & \phi_{22} & \cdots & \phi_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \phi_{k0} & \phi_{k1} & \phi_{k2} & \cdots & \phi_{kp} \end{bmatrix} \begin{bmatrix} \mathbf{1} \\ \mathbf{y}_{t-1} \\ \mathbf{y}_{t-2} \\ \vdots \\ \mathbf{y}_{t-p} \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_k \end{bmatrix} \quad (2.3)$$

Selanjutnya persamaan (2.3) dapat kita tulis kembali menjadi

$$\mathbf{y} = \phi \tilde{\mathbf{y}} + e_t \quad (2.4)$$

Dimana \mathbf{y} adalah vektor variabel dependen $(n \times 1)$, ϕ merupakan matriks koefisien berordo $(n+1) \times p$, $\tilde{\mathbf{y}}$ vektor variabel independen berordo $(p+1) \times 1$, dan e_t adalah vektor galat $(n \times 1)$.

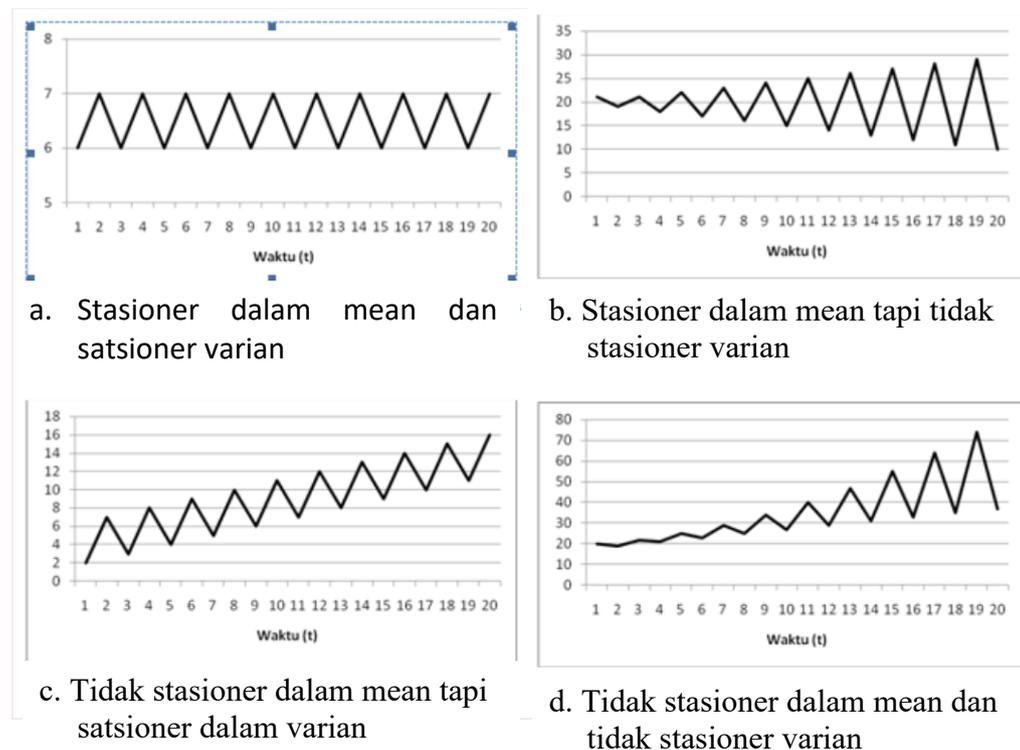
2.5 Uji Stasioneritas (Uji *Augmented Dickey-Fuller*)

Kestasioneran data merupakan asumsi yang penting dalam analisis *time series*. Stasioneritas berarti bahwa data tidak berubah secara signifikan atau bahwa fluktuasi data berada di sekitar nilai rata-rata yang konstan, tidak tergantung pada waktu atau varian.

Sebuah deret waktu dikatakan stasioner jika memenuhi (Gujarati & Porter, 2003):

1. $E(\mathbf{y}_t) = \mu$
2. $Var(\mathbf{y}_t) = E(\mathbf{y}_t - \mu) = \sigma^2$
3. $\gamma_k = E(\mathbf{y}_t - \mu)(\mathbf{y}_{t+k} - \mu)$, dimana γ_k adalah nilai *Covarian* saat *lag* k antara \mathbf{y}_t dan \mathbf{y}_{t+k}

Kestasioneran dapat dilihat dari dua kategori, stasioner dalam mean dan dalam varian.



Gambar 2. Contoh pola data stasioner dan tidak stasioner
(Juanda & Junaidi, 2012)

Gambar 2.a merupakan data stasioner dalam mean sekaligus dalam varians, ini terlihat dimana nilai mean dan varians selalu tetap sepanjang waktu. Pada Gambar 2.b data stasioner dalam mean tapi tidak stasioner dalam varians, ini terlihat dari mean selalu tetap sepanjang waktu namun nilai varians naik (tidak tetap) sepanjang waktu. Pada Gambar 2.c data stasioner dalam varians namun tidak dalam mean, ini terlihat dengan nilai varians tetap sepanjang waktu namun nilai mean naik (tidak tetap) sepanjang waktu. Pada Gambar 2.d data time series tidak stasioner baik dalam mean dan variannya, ini terlihat dari baik mean dan variannya tidak tetap sepanjang waktu.

Jika data tidak stasioner dalam mean, kita dapat melakukan perbedaan (*differencing*) sampai memperoleh data stasioner dalam mean. Jika data tidak stasioner dalam varians, maka akan dilakukan transformasi Box-cox pada data asli

yang bertujuan untuk menstabilkan data sehingga memiliki nilai varians yang konstan setiap waktu.

Uji stasioneritas dapat dideteksi secara formal menggunakan uji *Automatic Direction Finder* (ADF). Uji ini melihat apakah terdapat unit root di dalam model atau tidak. Unit root dapat pula dipandang sebagai uji stasioneritas. Hal ini karena pada prinsipnya uji tersebut dimaksudkan untuk menguji apakah koefisien tertentu dalam model autoregresi yang ditaksir mempunyai nilai 1 atau tidak.

Statistik uji pada uji stasioneritas dapat dihitung dengan menggunakan ADF hitung.

1. Hipotesis:

$H_0: \phi = 1$ (terdapat *unit root* atau data tidak stasioner)

$H_1: \phi < 1$ (tidak terdapat *unit root* atau data stasioner)

2. Model ADF

$$\Delta y_t = \alpha + \phi y_{t-1} + \sum_{i=1}^p \delta_i \Delta y_{t-1} + \varepsilon_t$$

Dimana :

1. Δy_t adalah perubahan (selisih) data *time series*
2. α adalah intercept.
3. ϕ adalah koefisien penguji keberadaan akar unit
4. δ_i adalah koefisien dari lag perubahan deret waktu untuk mengatasi autokorelasi pada data residual.

3. Taraf Signifikansi

$$\alpha = 0,05$$

4. Kritis

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

Jika $p - value > \alpha$ atau $ADF_{hitung} \leq ADF_{tabel}$, maka tidak cukup bukti untuk menolak H_0 .

5. Statistik uji:

$$\hat{\sigma}_e^2 = \sum_{t=1}^n \frac{(Y_t - \hat{\phi}Y_{t-1})^2}{n-1}$$

$$SE(\hat{\phi}) = \left[\hat{\sigma}_e^2 \left(\sum_{t=1}^n Y_{t-1}^2 \right) \right]^{\frac{1}{2}}$$

$t = 1, 2, 3, \dots, n$ dan $Y_0 = 0$

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

6. Pengambilan Keputusan

7. Kesimpulan

2.6 Uji Kointegrasi (*Johansen Trace Statistic Test*)

Kointegrasi digunakan untuk mengetahui hubungan keseimbangan dalam jangka Panjang (Roman & Kartiko, 2020). Jika tidak terdapat hubungan kointegrasi, model VAR dapat diaplikasikan. Tetapi, bila terdapat hubungan kointegrasi antar seri, model *Vector Error Correction* (VECM) yang dipergunakan. Uji kointegrasi menurut Johansen umumnya hanya untuk variabel yang terintegrasi pada orde satu dan orde nol, yaitu $I(1)$ dan $I(1)$ Untuk suatu model VAR (p).

Secara umum dapat dinyatakan sebagai berikut:

$$\Delta X_t = \Pi X_{t-1} + \sum_{i=1}^{p-1} \Pi_i \Delta X_{t-1} + e_t$$

Persamaan diatas dikatakan jangka panjang dan jangka pendek terhadap perubahan X_t . Rank matriks Π ditandai dengan r , menentukan berapa banyak kombinasi linear X_t yang bersifat stasioner. Jika $0 < r < n$, maka terdapat r vektor kointegrasi atau r kombinasi linear yang stasioner dari X_t .

Menguji jumlah hubungan kointegrasi dengan *Trace* test, yaitu uji untuk mengukur jumlah vektor kointegrasi dalam data time series dengan menggunakan pengujian rank matriks kointegrasi dinyatakan (Kholis et al., 2016):

1. Hipotesis:

H_0 : tidak terdapat r persamaan kointegrasi

H_1 : terdapat r persamaan kointegrasi

2. Taraf Signifikansi

$$\alpha = 0,05$$

3. Kritis

Jika $p - value \leq \alpha$ maka tolak H_0 .

Jika $p - value > \alpha$ maka tidak cukup bukti untuk menolak H_0 .

4. Statistik uji:

Statistik uji *trace* ditransformasikan sebagai berikut :

$$\lambda_{trace}(r|k) = -T \sum_{i=r+1}^k \ln(1 - \hat{\lambda}_i)$$

Dengan statistik uji nilai eigen maksimum ditulis sebagai berikut :

$$\lambda_{max}(r|k) = -T \log(1 - \hat{\lambda}_{r+1}) = \lambda_{trace}(r|k) - \lambda_{trace}(r + 1|k)$$

Dimana:

T : Jumlah waktu pengamatan.

$\hat{\lambda}_i$: estimasi eigenvalue yang dihasilkan dari estimasi matriks Π .

r : pangkat yang menjelaskan jumlah vektor kointegrasi.

5. Pengambilan keputusan

6. kesimpulan

2.7 Uji Kausalitas Granger

Uji kausalitas adalah pengujian untuk menentukan hubungan sebab akibat antara variabel dalam sistem *Vector Autoregressive* (VAR). Uji kausalitas pada permodelan VAR bertujuan untuk melihat pengaruh antar peubah baik jangka panjang maupun jangka pendek. Adanya hubungan antar peubah tidak membuktikan adanya kausalitas atau pengaruh sehingga untuk mengetahui apakah terdapat pengaruh satu arah maupun dua arah perlu dilakukan uji kausalitas. Jika

sebuah kejadian x terjadi sebelum y , maka terdapat kemungkinan bahwa x mempengaruhi y namun tidak mungkin sebaliknya, inilah ide dalam penerapan Uji kausalitas Granger (Gujarati, 2003).

Untuk melakukan pengujian terhadap hipotesis digunakan uji F dengan tahapan hipotesis sebagai berikut:

Diberikan model VAR seperti pada persamaan 2.9

Hipotesis:

$$H_0: (\Phi_1, \Phi_2, \dots, \Phi_p) = 0$$

(variabel x_t tidak berpengaruh terhadap variabel y_t) atau sebaliknya.

$$H_1 : \text{ada } (\Phi_1, \Phi_2, \dots, \Phi_p) \neq 0$$

(variabel x_t tidak berpengaruh terhadap variabel y_t) atau sebaliknya

1. Taraf Signifikansi

$$\alpha = 0,05$$

2. Kritis

Jika $p - value \leq \alpha$ maka tolak H_0 .

Jika $p - value > \alpha$ maka tidak cukup bukti untuk menolak H_0 .

3. Statistik Uji :

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

dengan

RSS_R : *Residual sum of square* dari regresi lag yang diuji (*restricted*)

RSS_{UR} : *Residual sum of square* dari regresi keseluruhan (*unrestricted*)

p : banyak parameter model regresi yang diuji.

n : banyak data pengamatan.

b : banyak parameter yang diestimasi pada model (seluruh)

4. Pengambilan keputusan

5. Kesimpulan

2.8 Pembedaan (*Differencing*)

Model VAR digunakan jika data stasioner. Jika data tidak stasioner pada levelnya tetapi stasioner pada *differencing* (selisih) pertama dan variabel tidak ada kointegrasi, maka digunakan *Vektor Autoregressive in Difference* (Usman et al., 2022). Jadi, proses differencing dilakukan apabila data *time-series* tidak stasioner pada level. Sehingga data *time-series* level akan diganti dengan data *time-series* selisih dari data level.

Differencing tahap pertama dapat ditulis sebagai berikut :

$$\Delta y_t = y_t - y_{t-1} \quad (2.5)$$

Dengan

Δy_t : nilai differencing tahap pertama pada waktu ke t.

y_t : nilai data level pada waktu ke t.

y_{t-1} : nilai data level pada waktu ke t-1.

2.9 *Vector Autoregressive* (VAR)

Persamaan model VAR dengan ordo *lag p* atau VAR(p) dapat ditulis (Wozniak, 2016):

$$\mathbf{y}_t = \Phi \tilde{\mathbf{y}}_t + \boldsymbol{\varepsilon}_t \quad (2.6)$$

Dengan \mathbf{y}_t adalah vektor ($k \times 1$) variabel saat ini, Φ adalah matriks $k \times (p+1)$ dari parameter model, $\tilde{\mathbf{y}}_t$ adalah vektor ($k \cdot (p+1) \times 1$), dan $\boldsymbol{\varepsilon}_t$ adalah vektor galat ($k \times 1$), vektor galat atau suku kesalahan pada waktu t, bekerja mengingat pengamatan masa lalu pada vektor \mathbf{y}^* hingga waktu t-1, berdistribusi normal dengan himpunan rata-rata ke vektor nol dan dengan matriks kovarians Σ , dilambangkan dengan

$$\boldsymbol{\varepsilon}_t \sim N(\mathbf{0}, \Sigma) \quad (2.7)$$

Persamaan (2.6) dapat dijabarkan menjadi :

$$\begin{bmatrix} y_{1t} & y_{2t} & \vdots & y_{kt} \end{bmatrix} = \begin{bmatrix} \Phi_0 & \Phi_1 & \Phi_2 & \cdots & \Phi_p \end{bmatrix} \begin{bmatrix} 1 & \tilde{y}_{(t-1)} & \tilde{y}_{(t-2)} & \vdots & \tilde{y}_{(t-p)} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} & \varepsilon_{2t} & \vdots & \varepsilon_{kt} \end{bmatrix} \quad (2.8)$$

Sehingga persamaan (2.8) dapat ditulis:

$$\mathbf{y}_t = \Phi_0 + \Phi_1 \mathbf{Y}_{t-1} + \Phi_2 \mathbf{Y}_{t-2} + \cdots + \Phi_p \mathbf{Y}_{t-p} + \varepsilon_t \quad (2.9)$$

Sedemikian sehingga persamaan (2.9) dapat dijelaskan sebagai berikut :

$$\begin{aligned} & \begin{bmatrix} y_{t,1} & y_{t,2} & \vdots & y_{t,k} \end{bmatrix} \\ & = \begin{bmatrix} \Phi_{0,1} & \Phi_{0,2} & \vdots & \Phi_{0,k} \end{bmatrix} \\ & + \begin{bmatrix} \Phi_{11,1} & \Phi_{21,1} & \vdots & \Phi_{k1,1} & \Phi_{12,1} & \Phi_{22,1} & \vdots & \Phi_{k2,1} & \cdots & \cdots \\ \vdots & \cdots & \Phi_{1k,1} & \Phi_{2k,1} & \vdots & \Phi_{kk,1} \end{bmatrix} \begin{bmatrix} y_{(t-1),1} & y_{(t-1),2} & \vdots & y_{(t-1),k} \end{bmatrix} \\ & + \begin{bmatrix} \Phi_{11,2} & \Phi_{21,2} & \vdots & \Phi_{k1,2} & \Phi_{12,2} & \Phi_{22,2} & \vdots & \Phi_{k2,2} & \cdots & \cdots \\ \vdots & \cdots & \Phi_{1k,2} & \Phi_{2k,2} & \vdots & \Phi_{kk,2} \end{bmatrix} \begin{bmatrix} y_{(t-2),1} & y_{(t-2),2} & \vdots & y_{(t-2),k} \end{bmatrix} + \cdots \\ & + \begin{bmatrix} \Phi_{11,p} & \Phi_{21,p} & \vdots & \Phi_{k1,p} & \Phi_{12,p} & \Phi_{22,p} & \vdots & \Phi_{k2,p} & \cdots & \cdots \\ \vdots & \cdots & \Phi_{1k,p} & \Phi_{2k,p} & \vdots & \Phi_{kk,p} \end{bmatrix} \begin{bmatrix} y_{(t-p),1} & y_{(t-p),2} & \vdots & y_{(t-p),k} \end{bmatrix} \\ & + \begin{bmatrix} \varepsilon_{t,1} & \varepsilon_{t,2} & \vdots & \varepsilon_{t,k} \end{bmatrix} \end{aligned}$$

2.9.1 Lag Optimum

Pemeriksaan lag digunakan untuk menentukan panjang lag optimal yang akan digunakan dalam analisis selanjutnya dan akan menemukan estimasi parameter untuk model VAR. Dalam model VAR, panjang lag menunjukkan derajat bebas. Model terbaik adalah model yang memiliki nilai *Akaike Information Criterion* (AIC) terkecil. Kriteria tersebut dirumuskan sebagai berikut:

$$AIC(l) = \ln|\hat{\Sigma}_{\varepsilon,p}| + \frac{2}{T}pn^2, \quad (2.10)$$

Dimana T adalah ukuran sampel, $\hat{\Sigma}_{\varepsilon,p}$ adalah penduga *maksimum likelihood* bagi Σ_{ε} .

2.9.2 Estimasi Parameter Model VAR

Estimasi parameter adalah suatu proses dengan menggunakan sampel untuk memperkirakan parameter yang tidak diketahui suatu populasi (Warsono et al., 2019). Metode *Ordinary Least Squares* (OLS) adalah pendekatan statistik yang digunakan untuk meminimalkan jumlah kuadrat selisih antara nilai-nilai yang diamati (y) dan nilai-nilai yang diprediksi oleh model (\hat{y}) dalam analisis regresi. OLS banyak digunakan dalam konteks regresi linier, baik regresi linier sederhana maupun regresi linier berganda.

Pendekatan OLS dapat diperluas untuk multivariat time series, dan salah satu model yang umum digunakan dalam konteks ini adalah VAR. Estimasi VAR dengan menggunakan metode OLS melibatkan pencarian koefisien autoregresif untuk setiap variabel waktu-seri dalam sistem. Sistem VAR memodelkan setiap variabel sebagai fungsi linier dari nilai-nilai waktu-seri sebelumnya, dan OLS digunakan untuk mendapatkan estimasi koefisien-koefisien ini.

Dari persamaan 2.6 kita dapat menuliskan estimasi parameter dengan metode OLS dapat ditulis :

$$\hat{y}_t = \hat{\Phi}_0 + \sum_{i=1}^p \hat{\Phi}_i \cdot y_{(t-i)}$$

Dimana \hat{y}_t adalah vektor variabel ke t , $\hat{\Phi}_0$ merupakan vektor konstanta, $\hat{\Phi}_i$ vektor koefisien variabel $y_{(t-i)}$, $y_{(t-i)}$ adalah vektor lag pada $(t - i)$.

akan diperoleh penyederhanaan persamaan kedalam bentuk notasi matrik yaitu

$$Y = \tilde{Y}\Phi + \varepsilon$$

Dimana $\tilde{Y} = (\tilde{y}'_1, \tilde{y}'_2, \dots, \tilde{y}'_T)'$, $\Phi = (c, \Phi_1, \Phi_2, \dots, \Phi_p)'$ dan $\varepsilon = (\varepsilon'_1, \dots, \varepsilon'_T)'$

Dengan nilai estimasi koefisien VAR dengan metode OLS :

$$\hat{\Phi} = (\tilde{Y}'\tilde{Y})^{-1}\tilde{Y}'Y$$

2.9.3 Diagnostik Model

Pada analisis time series VAR, ada beberapa asumsi yang harus terpenuhi, asumsi tersebut antara lain uji normalitas, uji autokorelasi, uji heteroskedastisitas, uji multikolinieritas, dan uji stabilitas.

2.9.3.1 Uji Autokorelasi (Uji Ljung-Box)

Autokorelasi merupakan suatu keadaan dimana galat berkorelasi berdasarkan urutan waktu. Salah satu uji korelasi yang sering digunakan adalah uji Ljung-Box. Uji Ljung-Box digunakan untuk memastikan ada atau tidaknya korelasi antar galat sekarang dengan galat sebelumnya.

Uji autokorelasi Model VAR 2.9 dapat dilakukan dengan proses seperti berikut:

$$\hat{\varepsilon}_t = y_t - \hat{y}_t$$

Dengan $t = (p+1, p+2, \dots, T)$

Dimana :

1. $\hat{\varepsilon}_t$ adalah nilai residual pada saat t.
2. y_t adalah nilai aktual pada saat t.
3. \hat{y}_t adalah nilai estimasi pada saat t.

1. Hipotesis:

H_0 : tidak terdapat autokorelasi

H_1 : terdapat korelasi

2. Taraf Signifikansi

$$\alpha = 0,05$$

3. Kritis

Jika $p - value \leq \alpha$ maka tolak H_0 .

Jika $p - value > \alpha$ maka tidak cukup bukti untuk menolak H_0 .

4. Statistik uji:

$$\hat{\rho}_i = \frac{\sum_{t=p+1}^T \hat{\varepsilon}_t \hat{\varepsilon}_{t-p}}{\sum_{t=p+1}^T (\hat{\varepsilon}_t)^2}$$

$$L = T(T+2) \sum_{i=1}^p \frac{\hat{\rho}_i}{n-i}$$

Dimana :

1. T merupakan jumlah observasi
2. p merupakan jumlah lag yang diuji.
3. $\hat{\rho}_i$ merupakan koefisien autokorelasi pada lag ke-i
5. Pengambilan Keputusan
6. Kesimpulan

2.10 Model *Gated Recurrent Unit* (GRU)

Model GRU adalah varian dari *Recurrent Neural Network* (RNN) yang merupakan jenis arsitektur deep learning, dimana *deep learning* adalah sub-bidang dari *machine learning* yang menggunakan jaringan syaraf tiruan dengan banyak lapisan.

2.10.1 *Machine Learning*

Machine Learning adalah suatu pendekatan dalam bidang kecerdasan buatan yang memungkinkan sistem untuk belajar dari data dan pengalaman tanpa di-program secara eksplisit. Ide dasar dibalik Machine Learning adalah memberikan komputer kemampuan untuk secara otomatis belajar dan meningkat dari pengalaman tanpa harus di-program secara khusus untuk setiap tugas.

2.10.2 *Deep Learning*

Deep Learning adalah subbidang dari Machine Learning yang menggunakan neural networks yang sangat kompleks, disebut *deep neural networks* (DNNs), untuk memodelkan dan mengekstraksi representasi tingkat tinggi dari data. Deep Learning dikenal karena kemampuannya dalam menangani tugas-tugas yang sangat kompleks dan data yang besar dengan cara yang lebih efektif daripada metode tradisional.

2.10.3 *Scaling data*

Scaling data merupakan bagian dari preprocessing data yang bertujuan untuk mengubah data awal dengan nilai dan jangkauan besar menjadi data yang lebih efisien dengan nilai dan jangkauan yang kecil. Pada penelitian ini menggunakan scaling Dengan metode *min-max normalization* yang digunakan untuk menyusutkan nilai data ke dalam rentang [0,1] namun memiliki bentuk *time-series* yang mirip seperti data aslinya.

min-max normalization dapat ditulis dengan rumus sebagai berikut:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

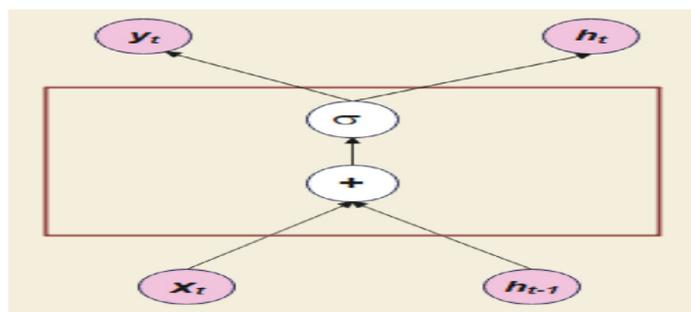
Dimana :

- X_{norm} merupakan nilai variabel dalam bentuk data normal.
- X_{max} adalah nilai terbesar data
- X_{min} adalah data minimal.
- X adalah data awal

2.10.4 Recurrent Neural Network (RNN)

RNN dirancang untuk menangani data sekuensial (berurutan), di mana informasi bergantung pada konteks sebelumnya. RNN adalah jenis khusus dari ANN yang merupakan bagian dari *deep learning*, *deep learning* merupakan salah satu jenis *machine learning*.

Menurut (Amalou et al., 2022) Ini adalah kelas model pembelajaran mesin yang diawasi, yang mengambil data urutan sebagai input, mereka berbeda dari arsitektur model Pembelajaran Mesin lainnya dengan koneksi berulang, yang berarti bahwa keluaran sel saat ini juga terkait dengan keluaran sel sebelumnya, lebih khususnya jaringan akan mengingat informasi dari keluaran sebelumnya, sehingga dapat ditambahkan dalam perhitungan hasil saat ini seperti yang ditunjukkan pada Gambar 3.



Gambar 3. Skema RNN sederhana

Proses *feedforward* RNN sederhana memiliki beberapa tahap yaitu:

1. Input.

Variabel input pada RNN (GRU) terbagi menjadi 2 yaitu variabel X_t dimana mewakili nilai variabel pada waktu ke t dan h_{t-1} nilai memori data sebelumnya.

$$\mathbf{X}_t = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_k \end{bmatrix} \quad \text{dan} \quad \mathbf{h}_{t-1} = \begin{bmatrix} h_1 \\ h_2 \\ \vdots \\ h_k \end{bmatrix} \quad \text{dengan} \quad \mathbf{h}_0 = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

2. *Hidden layer* (h_t)

$$h_t = \sigma(WX_t + Uh_{t-1} + b_h)$$

Dengan σ merupakan fungsi sigmoid, h_t merupakan keadaan tersembunyi pada waktu t , W adalah matriks bobot dari input X_t pada waktu t , U adalah matriks bobot dari keadaan tersembunyi pada waktu sebelumnya ($t-1$), h_{t-1} adalah vektor keadaan sebelumnya, dan b_h adalah vektor bias.

3. Output (y_t)

Pada prediksi *time series* fungsi output berkaitan dengan nilai tersembunyi sebelumnya. fungsi yang digunakan adalah fungsi identitas, dimana nilai dari output sama dengan nilai dari keadaan t saat ini.

$$y_t = h_t$$

4. Fungsi *loss* (kehilangan)

$$L = (y - \hat{y})^2$$

fungsi *loss* berguna untuk melihat seberapa baik nilai estimasi dengan nilai target atau sebenarnya.

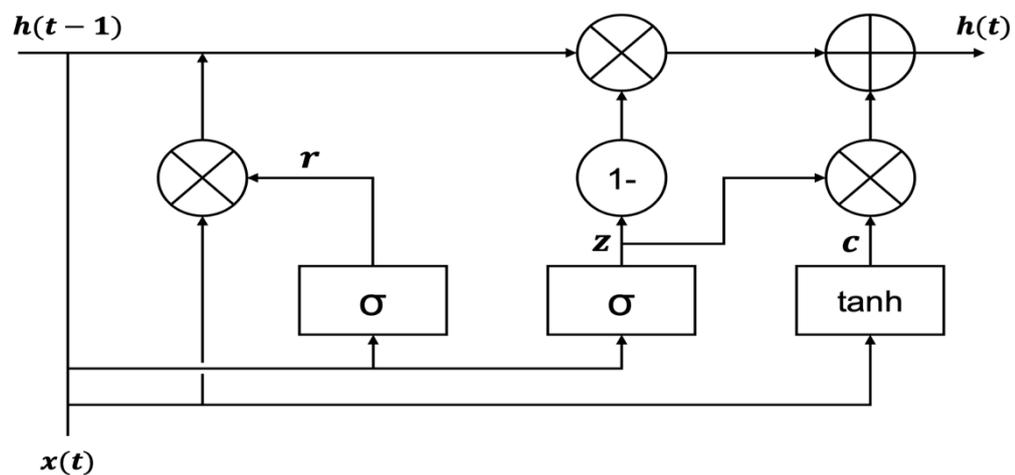
Meskipun RNN sederhana dapat lebih efektif dalam menangani urutan, mereka juga memiliki beberapa tantangan, seperti kesulitan dalam mempertahankan informasi

jangka panjang (masalah vanishing gradient) yang telah memicu perkembangan arsitektur jaringan yang lebih canggih seperti GRU

2.10.5 Gated Recurrent Unit (GRU)

Prinsip GRU diperkenalkan oleh (Cho et al., 2014) pada tahun 2014 untuk mengatasi masalah gradien hilang yang dihadapi oleh jaringan berulang konvensional dan mengusulkan arsitektur dengan parameter yang lebih sedikit untuk dilatih dibandingkan dengan LSTM. Untuk mengurangi jumlah parameter, sel-sel GRU mengintegrasikan dua gerbang "masuk" dan "lupakan" dalam satu gerbang "perbarui". Gerbang pembaruan dan gerbang reset masing-masing menentukan jumlah informasi yang akan disimpan dan jumlah informasi yang akan dilupakan.

Proses feedforward GRU dapat dijelaskan pada gambar 4.



Gambar 4. Skema *feed forward* Model RNN (GRU)
(Sumber: Jung et al., 2021)

Proses *feedforward* GRU dapat dijelaskan pada gambar 4 (Amalou et al., 2022):

1. Input.

Variabel input pada RNN (GRU) terbagi menjadi 2 yaitu Variabel X_t dimana mewakili nilai variabel pada waktu ke t dan h_{t-1} nilai memori data data sebelumnya.

$$X_t = [x_1 \ x_2 \ : \ x_k] \text{ dan } h_{t-1} = [h_1 \ h_2 \ : \ h_k] \text{ dengan } h_0 = [0 \ 0 \ : \ 0]$$

2. Hidden Layer.

Dalam hidden layer dengan p titik dibagi menjadi 2 tahapan yaitu *update gate* (pembaharuan) dan *reset gate* (pembaharuan memori).

○ *update gate* (z_t)

pintu ini memiliki peran kunci dalam menentukan seberapa banyak informasi baru yang harus dimasukkan ke dalam memori pada saat ini (h_t). Pada saat nilai z_t mendekati 1, nilai dari h_{t-1} akan dipertahankan. Namun, pada saat nilai z_t mendekati 0, h_{t-1} akan diabaikan dan nilai h_t lebih dipengaruhi informasi baru dari variabel X_t . selain itu z_t berperan dalam mengatasi vanishing pada RNN sederhana yang membuat model kurang efektif untuk data time-series yang Panjang. Nilai z_t dapat dijelaskan dengan persamaan :

$$z_t = \sigma(W_z h_{t-1} + U_z X_t)$$

○ *reset gate* (r_t)

sama halnya dengan z_t , r_t juga berperan seberapa banyak informasi baru yang harus dimasukkan ke dalam memori pada saat ini (h_t).

$$r_t = \sigma(W_r h_{t-1} + U_r X_t)$$

3. *Candidate Memory Vector* (C_t)

\tilde{h}_t merupakan vektor yang mungkin yang mencerminkan informasi baru yang dapat dimasukkan ke dalam *hidden layer* h_t . C_t dihasilkan dari menggabungkan informasi input x_t , h_{t-1} , dan mempertimbangkan nilai r_t .

$$C_t = \tanh(W_C(h_{t-1} \otimes r_t) + U_C \cdot X_t)$$

4. *Memory Update* (h_t)

Proses pembaharuan h_t melibatkan interaksi antara data hidden sebelumnya (h_{t-1}), *Candidate Memory Vector* (C_t), dan *update gate* (z_t).

$$h_t = ((1 - z_t) \otimes h_{t-1}) + z_t \otimes C_t$$

5. *Output* (y_t)

Pada data time-series nilai *Output* (y_t) dapat dihitung dari nilai h_t . Pada prediksi time-series, fungsi output yang sering digunakan adalah identitas, dimana nilai hari y_t akan sama dengan nilai h_t .

$$y_t = \text{identitas}(h_t) = h_t$$

6. **Fungsi loss (kehilangan)**

$$L = (y - \hat{y})^2$$

fungsi loss berguna untuk melihat seberapa baik nilai estimasi dengan nilai target atau sebenarnya.

2.10.6 Fungsi Aktivasi

Fungsi aktivasi adalah fungsi matematik yang berguna untuk memperoleh nilai *output* berdasarkan nilai *input*, jadi informasi dari input diproses di fungsi aktivasi ini. fungsi ini meniru neuron pada otak dikarenakan bergantung pada kekuatan sinyal input. Fungsi aktivasi harus memiliki sifat yang penting seperti kontinu, terdeferensiasi, dan monoton (Fausett & Elwasif, 1994). Beberapa fungsi aktivasi antara lain fungsi sigmoid, fungsi Tanh.

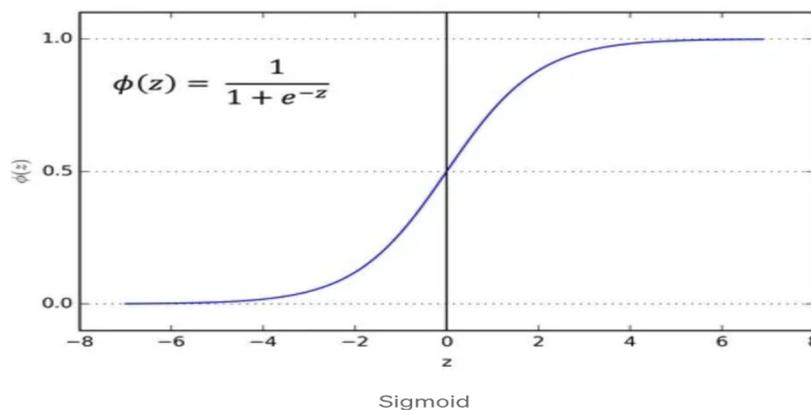
2.10.6.1 Fungsi Sigmoid

Fungsi sigmoid (fungsi logistik) merupakan fungsi yang mengambil rentang angka 0 dan 1. Persamaan sigmoid dapat ditulis :

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

Dengan menggunakan aturan diferensiasi parsial

$$\begin{aligned} f(x) = \frac{u(x)}{v(x)} &\rightarrow f'(x) = \frac{u'(x)v(x) - v'(x)u(x)}{v^2(x)} \\ \frac{d}{dx} S(x) &= \frac{d}{dx} \left(\frac{1}{1 + e^{-x}} \right) \\ &= \frac{0 - (-1)e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1}{(1 + e^{-x})} \left(1 - \frac{1}{(1 + e^{-x})} \right) \\ &= S(x)[1 - s(x)] \end{aligned}$$



Gambar 5 fungsi Sigmoid.

(Sumber: (Sharma, 2020))

2.10.6.2 Fungsi Tanh (Tangen Hiperbolik)

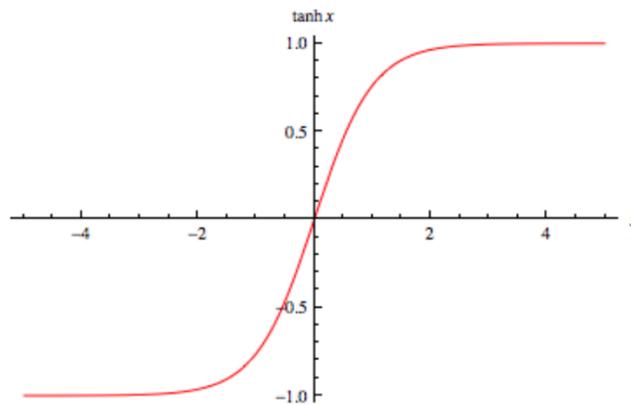
Fungsi TanH menghasilkan nilai antara -1 sampai 1. Dikarenakan rentang nilai yang lebih luas dibandingkan fungsi sigmoid, fungsi TanH efektif digunakan untuk pemodelan non linier yang kompleks. Persamaan fungsi Tanh dapat ditulis:

$$\begin{aligned} \operatorname{Tanh}(x) &= \frac{e^x - e^{-x}}{e^x + e^{-x}} \\ \operatorname{Tanh}(x) &= \frac{\sinh(x)}{\cosh(x)} \end{aligned}$$

Dengan menggunakan aturan diferensiasi parsial

$$f(x) = \frac{u(x)}{v(x)} \rightarrow f'(x) = \frac{u'(x)v(x) - v'(x)u(x)}{v^2(x)}$$

$$\begin{aligned} \frac{d}{dx} \operatorname{Tanh}(x) &= \frac{d}{dx} \left(\frac{\sinh(x)}{\cosh(x)} \right) \\ &= \frac{\cosh^2(x) - \sinh^2(x)}{\cosh^2(x)} \\ &= \frac{\cosh^2(x) - \sinh^2(x)}{\cosh^2(x)} \\ &= 1 - \operatorname{Tanh}^2(x) \end{aligned}$$



Gambar 6 Grafik fungsi Tanh.

(Sumber: (Sharma, 2020))

2.11 Model Hybrid (VAR – GRU)

Model *hybrid* menyesuaikan beberapa spesifikasi model individual untuk memudahkan pembuatan prakiraan. Model *hybrid* terdiri dari kombinasi dua model: Model VAR, dan model RNN. Misalkan \hat{L}_t penduga dari Y_t pada model VAR dengan e_t adalah kesalahan peramalan yang merupakan selisih antara penduga model VAR dengan variabel nyata, nilai e_t dapat ditulis

$$Y_t = \hat{L}_t + e_t \quad (2.18)$$

Maka nilai dari e_t adalah

$$e_t = Y_t - \hat{L}_t$$

kesalahan terdiri dari hubungan non linier dengan kesalahan sebelumnya. Hubungan non linier dapat dimodelkan dari sisa masa lalu sebagai berikut:

$$e_t = f(e_{t-1}, e_{t-2}, e_{t-3}, \dots, e_{t-n}) + \varepsilon_t$$

Kemudian, dengan menggunakan model RNN untuk \hat{N}_t sebagai penduga e_t , kita dapat menghitung perkiraan persamaan 2.18 sebagai berikut:

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t$$

Model *hybrid* mengeksplorasi fitur unik dan kekuatan model VAR serta model RNN dalam menentukan pola yang berbeda. Dengan demikian, mungkin menguntungkan untuk memodelkan pola linier dan non linier secara terpisah dengan menggunakan model yang berbeda dan kemudian menggabungkan prakiraan untuk meningkatkan kinerja pemodelan dan prakiraan secara keseluruhan (Zhang, 2003).

2.12 Evaluasi Model

Banyak ukuran akurasi peramalan telah dikembangkan, model peramalan terbaik yang dipilih akan dibandingkan menggunakan tiga kriteria pengukuran akurasi peramalan yang berbeda: *mean absolute error* (MAE), *root mean squared error* (RMSE), dan *mean absolute perception error* (MAPE). Kriteria evaluasi ukuran akurasi peramalan ini adalah semakin kecil nilai yang diperoleh maka semakin baik kemampuan peramalan model (McKenzie, 2011).

Terkadang keakuratan peramalan disebut dengan galat peramalan (out-of – sampel). Galat peramalan dapat ditulis:

$$e_t(1) = y_t - \hat{y}_t$$

Dimana $\hat{y}_t(t - 1)$ adalah peramalan dari y_t yang dibuat untuk 1 periode.

Misalkan n observasi yang mana peramalan akan dibuat dan n galat peramalan $e_t(1)$, dengan $t = 1, 2, \dots, n$

2.12.1 Mean Absolute Error (MAE)

Misalkan $y_1, y_2, y_3, \dots, y_n$ menunjukkan kumpulan data, MAE dapat di didefinisikan sebagai:

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t(1)|$$

2.12.2 Root Mean Square Error (RMSE)

RMSE telah menjadi populer, terutama karena relevansi teoritisnya dalam pemodelan statistik (Hyndman et al., 2002). Namun, ukuran ini lebih sensitif terhadap outlier dibandingkan MAE, yang menyebabkan beberapa penulis seperti (Armstrong, 2001) tidak merekomendasikannya. RMSE didefinisikan sebagai:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n [e_t(1)]^2}$$

2.12.3 Mean Absolute Perception Error (MAPE)

MAPE menyajikan kesalahan perkiraan dalam bentuk persentase dan karenanya bersifat invarian skala dan bebas unit (Lyhagen et al., 2015). MAPE adalah rata-rata sederhana dari persentase kesalahan absolut. Disarankan untuk menggunakan MAPE ketika membandingkan keakuratan metode yang sama atau berbeda pada data deret waktu yang berbeda dengan skala yang berbeda, kecuali data tersebut mengandung angka nol atau nilai kecil (Hyndman & Koehler, 2006).

MAPE didefinisikan sebagai:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t(1)}{y_t} \right| 100$$

2.13 Indikator Statistika

2.13.1 Konsep Dasar Matriks

Definisi 2.1.1 Invers dan Trace

Sebuah matriks $A_{m \times m}$ merupakan $A_{m \times m}$, jika terdapat sebuah matriks unik $C_{m \times m}$ sedemikian sehingga $AC = CA = I_m$. Pada kasus ini, C merupakan invers dari matriks A dan dapat dituliskan dengan $C = A^{-1}$ (Tsay, 2013).

Trace dari matriks $A_{m \times m}$ merupakan jumlah dari semua elemen diagonal matriks $A_{m \times m}$, jadi nilai trace suatu matriks dapat ditulis sebagai berikut:

$$tr(A) = \sum_{i=1}^m a_{ii}$$

Dari persamaan diatas nilai Trace suatu matriks memiliki beberapa sifat yaitu (Tsay, 2013):

1. $tr(A + B) = tr(A) + tr(B)$
2. $tr(A) = tr(A')$

$$3. \quad \text{tr}(AC) = \text{tr}(CA)$$

Definisi 2.1.3 Akar Ciri dan Vektor Ciri (Vektor eigen)

Diberikan dua matriks, matriks $A_{m \times m}$ dan $I_{m \times m}$. Selanjutnya skalar $\lambda_1, \lambda_2, \dots, \lambda_m$ disebut akar ciri dari suatu matrik jika memenuhi persamaan ciri (fungsi dari λ) $|\mathbf{A} - \lambda \mathbf{I}| = 0$. Misalkan $A_{m \times m}$ dan λ adalah akar ciri dari matriks \mathbf{A} . jika $x_{k \times 1}$ merupakan vektor tak nol, sedemikian sehingga $\mathbf{A}x = \lambda x$ maka x disebut sebagai vektor eigen (vektor ciri) dari matriks \mathbf{A} yang bersesuaian dengan akar ciri λ (Johnson & Wichern, 2007).

Definisi 2.1.4 Matriks Ortogonal

Suatu matriks persegi \mathbf{A} dikatakan ortogonal jika setiap barisnya mempertimbangkan sebagai vektor-vektor tegak lurus satu sama lain dan mempunyai panjang unit, yaitu $\mathbf{A}\mathbf{A}' = \mathbf{I}$. Sebuah matriks \mathbf{A} ortogonal jika dan hanya jika $\mathbf{A}^{-1} = \mathbf{A}'$. Untuk sebuah matriks orthogonal $\mathbf{A}\mathbf{A}' = \mathbf{A}'\mathbf{A} = \mathbf{I}$, sehingga setiap kolomnya juga tegak lurus satu sama lain dan mempunyai panjang unit (Johnson & Wichern, 2007).

2.13.2 Distribusi Normal Multivariat

Definisi 2.2.1 Peubah Acak

Menurut (Evans & Rosenthal, 2009), peubah acak X adalah suatu fungsi dari ruang sampel S ke himpunan bilangan real R . Secara intuitif, peubah acak menetapkan nilai numerik untuk setiap kemungkinan hasil dalam ruang sampel. Peubah acak biasanya disimbolkan dengan huruf kapital X , dan untuk nilai dari peubah acak tersebut disimbolkan dengan huruf kecil x . Jika suatu ruang sampel S mengandung sejumlah kemungkinan tak terhingga yang sama dengan jumlah titik pada ruas garis, maka ruang sampel tersebut dinamakan ruang sampel kontinu (Walpole et al., 2011).

Definisi 2.2.2 Fungsi Kepekatan Peluang (FKP)

Fungsi $f(x)$ merupakan fungsi kepekatan peluang untuk peubah acak kontinu X , didefinisikan atas himpunan bilangan real, jika (Walpole et al., 2011):

1. $f(x) \geq 0$, untuk setiap $x \in R$,

2. $\int_{-\infty}^{\infty} f(x) dx = 1$,

3. $P(a < X < b) = \int_a^b f(x) dx$.

Definisi 2.2.3 Nilai Harapan, Varians, Kovarian, dan Korelasi

Misalkan X adalah peubah acak dengan distribusi peluang $f(x)$. Nilai harapan dari peubah acak X untuk kasus kontinu adalah sebagai berikut (Walpole et al., 2011):

$$\mu = E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx$$

Misalkan X adalah peubah acak dengan distribusi peluang $f(x)$ dan nilai harapan μ . Varians dari peubah acak X untuk kasus kontinu adalah sebagai berikut (Walpole et al., 2011):

$$Var(X) = \sigma^2 = E[(X - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 \cdot f(x) dx$$

Kovarian dari suatu peubah acak X dan Y dapat di tulis sebagai berikut (Walpole et al., 2011):

$$\begin{aligned} Cov(X, Y) &= \sigma_{XY} = E[(X - \mu_X)(Y - \mu_Y)] \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_X)(y - \mu_Y) f(x, y) dx dy \end{aligned}$$

Dengan

$$f(x, y) = P(X = x, Y = y)$$

Dimana persamaan diatas memenuhi :

1. $f(x, y) > 0$, untuk setiap (x, y)

2. $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$

Koefisien korelasi antara dua variabel acak X dan Y digunakan untuk mengukur kekuatan ketergantungan linier antara kedua variabel. koefisien korelasi dapat di tulis sebagai berikut (Tsay, 2013) :

$$\rho_{x,y} = \frac{Cov(X,Y)}{\sqrt{Var(X).Var(Y)}}, -1 < \rho_{x,y} < 1$$

Dengan

1. $\rho_{x,y} = 0$: Tidak ada Korelasi
2. $0 < (\rho_{x,y})^2 < 0,25$: Korelasi Sangat Lemah
3. $0,25 < (\rho_{x,y})^2 < 0,5$: Korelasi Sedang
4. $0,5 < (\rho_{x,y})^2 < 0,75$: Korelasi Kuat
5. $0,75 < (\rho_{x,y})^2 < 1$: Korelasi Sangat kuat
6. $\rho_{x,y} = 1$: sempurna

Definisi 2.2.4 Normal Multivariate

Misal $y = (y_1, y_2, \dots, y_n)$ adalah vektor berdimensi n dari suatu peubah acak, maka y disebut memiliki (nonsingular) distribusi multivariate normal jika fungsi kepekatan peluangnya adalah

$$f(y) = (2\pi)^{-\frac{n}{2}} |\Sigma|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (y - \mu)' \Sigma^{-1} (y - u) \right]. \quad (2.7)$$

$$-\infty < y_j < \infty \text{ dan } j = 1, 2, \dots, n$$

Dimana $\Sigma = \sigma_{jk}$ adalah definit positif ($\Sigma > 0$). Dengan $E(y) = \theta$ dan $Var(y) = \Sigma$, maka dapat dinotasikan dengan $y \sim N_n(\theta, \Sigma)$ **atau** $y \sim N_n$ (Tsay, 2013).

2.14 Indikator Non Statistika (Ekonomi)

2.14.1 Nilai Tukar Uang

Nilai tukar (kurs) mata uang didefinisikan sebagai harga dari mata uang asing dalam mata uang domestik. Nilai tukar menjadi topik menarik untuk di bahas, ini karena pengaruhnya terhadap perekonomian suatu negara relatif signifikan. Indonesia menganut sistem nilai tukar mengambang bebas. Sistem pergerakan nilai tukar tergantung pada mekanisme permintaan dan penawaran mata uang di pasar valas.

Kelebihan sistem nilai tukar mengambang bebas adalah tidak membutuhkan cadangan devisa yang besar. Namun, memiliki kelemahan yaitu nilai tukar mudah berfluktuasi, sehingga mudahnya nilai tukar mengalami depresiasi dan apresiasi mata uang (Fadilah et al., 2022). Depresiasi mata uang terjadi jika harga dari valuta asing meningkat sehingga mata uang domestik relatif murah, sebaliknya apresiasi mata uang terjadi jika harga dari valuta asing mengalami penurunan sehingga terjadi peningkatan relatif nilai mata uang domestik (Firdaus et al., 2018)

2.14.2 Saham

Saham dapat diartikan sebagai tanda penyertaan modal seseorang atau pihak (badan usaha) pada suatu perusahaan atau Perseroan Terbatas. Dengan menyertakan modal tersebut, maka pihak tersebut memiliki klaim (hak) atas pendapatan perusahaan, aset perusahaan, dan berhak hadir dalam Rapat Umum Pemegang Saham (RUPS) (OJK, 2023). Di pasar sekunder (bursa) atau dalam aktivitas perdagangan saham sehari-hari, harga-harga saham mengalami fluktuasi baik berupa kenaikan maupun penurunan yang dapat dilihat secara *Online* dimana dan kapan saja dapat dipantau (Sapitri & Anhar, 2020). Pembentukan harga saham terjadi karena adanya permintaan dan penawaran atas saham tersebut. Permintaan dan penawaran atas suatu dipengaruhi banyak faktor, baik yang sifatnya spesifik berhubungan saham tersebut (kinerja perusahaan) maupun faktor yang sifatnya makro atau eksternal, seperti perkembangan tingkat suku bunga, inflasi, nilai tukar, dan faktor-faktor non ekonomi seperti kondisi sosial dan politik.

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada semester genap tahun ajaran 2023/2024. Penelitian ini dibagi menjadi tiga tahap, tahap pertama melakukan studi literatur dengan mengumpulkan jurnal dan buku yang berkaitan dengan topik penelitian, literatur ini akan digunakan sebagai referensi dalam menyusun proposal penelitian. Kemudian tahap kedua melakukan pemrograman menggunakan program python untuk menganalisa data mulai dari penginputan, prediksi dan peramalan menggunakan metode VAR, model GRU, dan Hybrid, serta mengevaluasi kinerja model yang digunakan. Selanjutnya tahap ketiga menyusun hasil analisis dalam bentuk draf laporan yang akan disampaikan pada seminar hasil serta sidang komprehensif tesis.

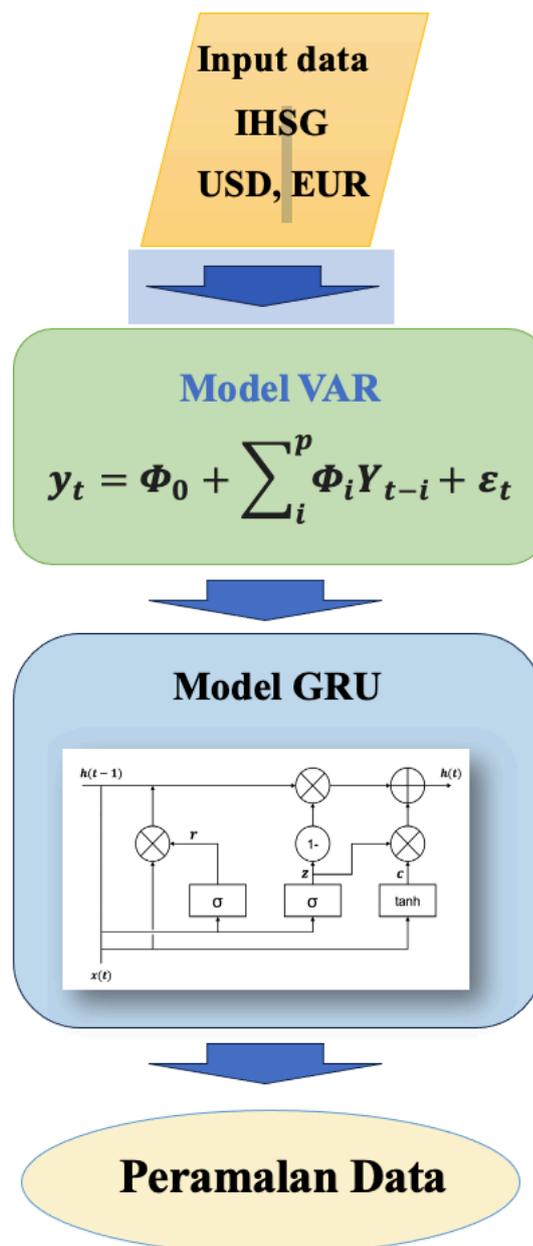
Penelitian ini dilakukan di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Universitas Lampung. Universitas Lampung berlokasi di Jl. Prof. Dr. Soemantri Brojonegoro No. 1, Gedong meneng, Kec. Rajabasa, Bandar Lampung.

3.2 Data Penelitian

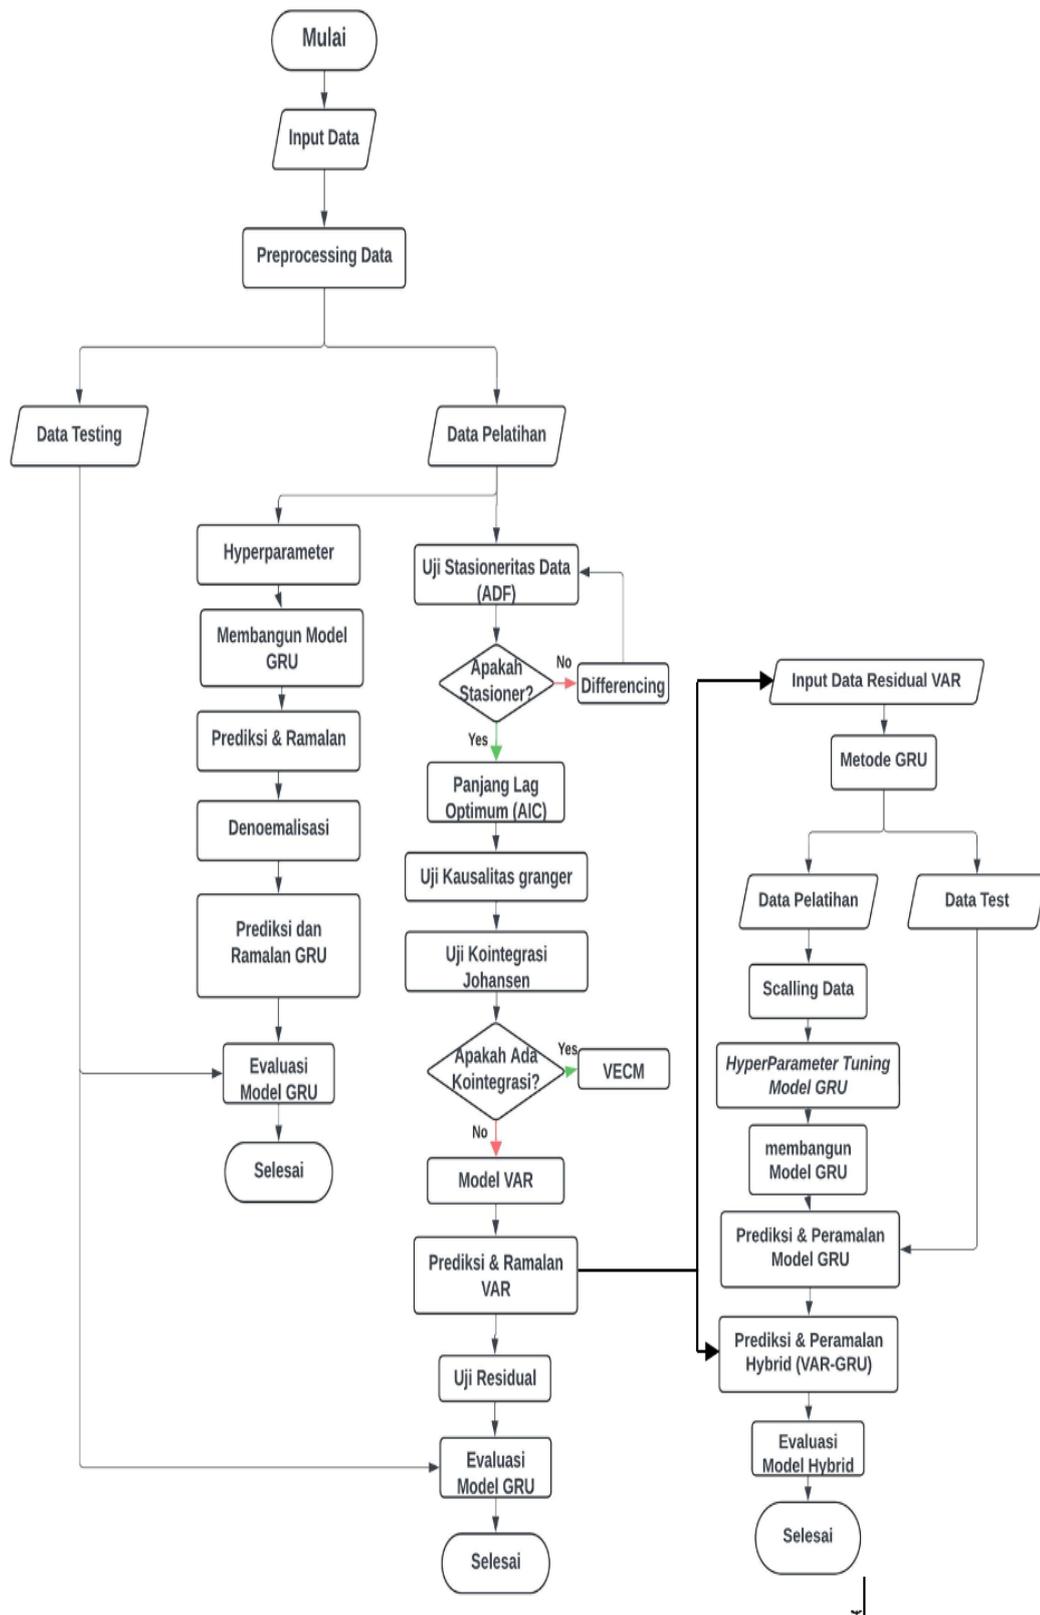
Data yang digunakan dalam penelitian ini menggunakan data sekunder yang diperoleh dari dua sumber. Data pertama dari situs resmi Bank Indonesia (<https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/Default.aspx>) untuk data harian nilai tukar USD-IDR dan nilai tukar EUR-IDR, serta data kedua dari situs resmi Bursa Efek Indonesia (<https://www.idx.co.id/id>). Data diambil dalam selang selama 5 tahun yaitu pada periode 1 November 2018 sampai dengan 31 Oktober 2023 dengan jumlah masing masing variabel sebanyak 1122. data sebanyak 1009 sampel awal digunakan untuk pemodelan dan 123 out-sampel yang akan digunakan untuk memeriksa keakuratan model VAR, GRU, dan Hybrid (VAR-GRU).

3.3 Metode Penelitian

Penelitian diawali dengan mempelajari studi literatur dari jurnal dan buku untuk mendapati informasi pendukung penelitian, kemudian dari informasi ini akan dilakukan simulasi untuk menjelaskan teori yang didapat. Adapun alur dari penelitian ini dibagi menjadi 3 simulasi sesuai dengan banyaknya model yang digunakan.



Gambar 7a. Bagan Metode Penelitian



Gambar 7b. Flowchart Metode Penelitian

Berdasarkan Gambar 7a dan Gambar 7b, menunjukkan metode penelitian yang digunakan, penjelasan rinci dapat dijelaskan sebagai berikut :

3.3.1 Input Data

Berdasarkan *Flowchart* penelitian pada Gambar 7, berikut penjelasan tahap tahap yang dilakukan.

1. Input Data

Data yang digunakan pada penelitian ini berupa harga penutupan saham IHSG, serta nilai tukar mata uang Rupiah dengan Dolar dan Euro di tanggal yang sama.

2. *Scaling* Data

Scaling Data input menggunakan normalisasi *min-max*.

3. Data pelatihan dan data testing

Data dibagi menjadi data pelatihan untuk melatih pemodelan VAR dan data testing untuk melihat akurasi peramalan.

3.3.2 Model VAR

Alur penelitian dengan Model VAR dapat dipresentasikan dalam bentuk *Flowchart* pada Gambar 7.

1. Uji stasioner data

Uji stasioner dalam rata-rata menggunakan uji ADF, jika tidak stasioner akan dilakukan *differencing* data, kemudian melakukan uji ADF sampai didapat data yang stasioner.

2. Panjang lag optimum

Menentukan panjang lag yang terbaik menggunakan uji AIC (nilai minimum)

3. Uji Kointegrasi

Uji ini dilakukan untuk melihat ada tidaknya hubungan jangka panjang antar variabel, jika ada kointegrasi maka akan digunakan model VECM.

4. Membangun model VAR

Model VAR akan dibangun berdasarkan nilai lag optimum.

5. Uji kelayakan model

melakukan uji kelayakan model dengan menggunakan beberapa uji diagnostik.

6. **Prediksi Model VAR**
menentukan nilai prediksi dari hasil model VAR yang sudah dibangun.
7. **Peramalan Model VAR**
Menentukan nilai peramalan dari model VAR.
8. **akurasi model**
Melakukan pengecekan performa model dengan menggunakan metrik yang sesuai, seperti *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE) untuk melihat keakuratan peramalan model dengan nilai data testing

3.3.3 Model GRU

Berdasarkan *Flowchart* penelitian pada Gambar 7, berikut penjelasan tahap tahap yang dilakukan.

1. *Hyperparameter* model GRU
Menentukan jumlah unit pada lapisan tersembunyi, banyak lapisan tersembunyi, learning rate, jumlah sampel, fungsi aktivasi.
2. Membangun model GRU
Membangun model GRU dengan fungsi aktivasi fungsi sigmoid dan fungsi tanh.
3. **Prediksi & Peramalan Model GRU**
menentukan nilai prediksi dari hasil model VAR yang sudah dibangun, dan Menentukan nilai peramalan dari model VAR.
4. **Evaluasi Model GRU**
Melakukan pengecekan performa model dengan menggunakan metrik yang sesuai, seperti MAE, MSE, RMSE untuk melihat keakuratan peramalan model dengan nilai data testing.

3.3.4 Model *Hybrid* VAR-GRU

Alur penelitian dengan Model *Hybrid* VAR-GRU dapat dipresentasikan dalam bentuk *Flowchart* pada Gambar 7.

1. Tahap awal mendapatkan residu Pemodelan VAR.
Nilai residu didapat dari selisih nilai aktual dan prediksi dari data pelatihan dan

data testing.

2. Input residu untuk pemodelan GRU
residu hasil pemodelan VAR akan digunakan sebagai nilai input untuk pemodelan GRU.
3. *Hyperparameter* model GRU
Menentukan jumlah unit pada lapisan tersembunyi, banyak lapisan tersembunyi, learning rate, jumlah sampel, fungsi aktivasi.
4. Membangun model GRU
Membangun model GRU dengan fungsi aktivasi fungsi sigmoid dan fungsi tanh.
5. Prediksi & Peramalan Model GRU
menentukan nilai prediksi dari hasil model GRU yang sudah dibangun, Menentukan nilai peramalan dari model GRU.
6. Menentukan nilai prediksi dan peramalan *hybrid*
Nilai prediksi dan nilai peramalan *hybrid* didapat dengan menjumlahkan nilai prediksi dan peramalan VAR dan nilai prediksi dan peramalan GRU pada residual.
7. Menentukan akurasi model
Melakukan pengecekan performa model dengan menggunakan metrik yang sesuai, seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE) untuk melihat keakuratan peramalan model dengan nilai data testing.

V. KESIMPULAN

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan penelitian, diperoleh kesimpulan sebagai berikut:

1. Granger kausalitas pada variabel pengamatan hanya berlaku satu arah yaitu IHSB berpengaruh terhadap USD tetapi USD tidak berpengaruh terhadap IHSB, IHSB berpengaruh terhadap EUR tetapi EUR tidak berpengaruh terhadap IHSB, dan USD berpengaruh terhadap EUR tetapi EUR tidak berpengaruh terhadap USD.
2. Nilai estimasi pemodelan VAR. sebagai berikut :

$$\begin{aligned}\Delta IHSB_t = & 0,767 - 0,008 * \Delta IHSB_{t-1} + 0,003 * \Delta USD_{t-1} + 0,015 \\ & * \Delta EUR_{t-1} - 0,013 * \Delta IHSB_{t-2} - 0,016 * \Delta USD_{t-2} + 0,02 \\ & * \Delta EUR_{t-2} + 0,122 * \Delta IHSB_{t-3} + 0,006 * \Delta USD_{t-3} + 0,005 \\ & * \Delta EUR_{t-3} + 0,037 * \Delta IHSB_{t-4} + 0,034 * \Delta USD_{t-4} - 0,019 \\ & * \Delta EUR_{t-4} + 0,056 * \Delta IHSB_{t-5} + 0,013 * \Delta USD_{t-5} - 0,015 \\ & * \Delta EUR_{t-5}\end{aligned}$$

$$\begin{aligned}\Delta USD_t = & 1,308 - 0,375 * \Delta IHSB_{t-1} - 0,326 * \Delta USD_{t-1} + 0,008 * \Delta EUR_{t-1} \\ & - 0,142 * \Delta IHSB_{t-2} - 0,188 * \Delta USD_{t-2} + 0,026 * \Delta EUR_{t-2} \\ & - 0,280 * \Delta IHSB_{t-3} - 0,029 * \Delta USD_{t-3} + 0,028 * \Delta EUR_{t-3} \\ & + 0,007 * \Delta IHSB_{t-4} - 0,040 * \Delta USD_{t-4} - 0,047 * \Delta EUR_{t-4} \\ & - 0,171 * \Delta IHSB_{t-5} - 0,015 * \Delta USD_{t-5} - 0,052 * \Delta EUR_{t-5}\end{aligned}$$

$$\begin{aligned}\Delta EUR_t = & -0,648 - 0,292 * \Delta IHSB_{t-1} + 0,245 * \Delta USD_{t-1} - 0,461 \\ & * \Delta EUR_{t-1} - 0,013 * \Delta IHSB_{t-2} + 0,213 * \Delta USD_{t-2} - 0,289 \\ & * \Delta EUR_{t-2} - 0,091 * \Delta IHSB_{t-3} + 0,296 * \Delta USD_{t-3} - 0,183 \\ & * \Delta EUR_{t-3} + 0,060 * \Delta IHSB_{t-4} + 0,230 * \Delta USD_{t-4} - 0,072 \\ & * \Delta EUR_{t-4} - 0,119 * \Delta IHSB_{t-5} + 0,168 * \Delta USD_{t-5} - 0,022 \\ & * \Delta EUR_{t-5}\end{aligned}$$

3. Pada model VAR diperoleh nilai MAE, RMSE, MAPE, dan Akurasi sebesar 326, (438,140), (2,307 %), dan (97,693 %).
4. Pada model GRU diperoleh nilai MAE, RMSE, MAPE, dan Akurasi sebesar (148,487), (181,588), (1,290 %), (98,710 %)

5. Pada metode Hybrid diperoleh nilai MAE, RMSE, MAPE, dan Akurasi sebesar (118,774), (150,257), (1,022 %), (98.978 %)
6. Dibandingkan metode VAR dan metode GRU, akurasi prediksi metode *Hybrid* VAR-GRU memiliki tingkat akurasi yang lebih baik untuk memprediksi harga saham IHSG, nilai tukar USD – IDR, dan nilai tukar EUR-IDR. sehingga dapat diadopsi untuk memprediksi variabel harga IHSG, nilai tukar USD-IDR, dan nilai tukar EUR-IDR.

5.2 Saran

Berdasarkan hasil dari pembahasan dan kesimpulan, peneliti menyarankan:

1. Bagi peneliti selanjutnya, Pengujian ketiga model prediksi dapat dilakukan pada variabel sektor perekonomian yang lain, untuk lebih memvalidasi hasil penelitian secara general.
2. Selain model *hybrid* VAR-GRU, penelitian lebih lanjut dapat lebih mengeksplorasi kombinasi metode lain yang lebih kompleks untuk mendapatkan akurasi yang lebih baik.
3. Sektor ekonomi saling mempengaruhi satu sama lain, usahakan data yang digunakan memiliki kualitas yang baik dan dalam selang waktu yang tidak dipengaruhi diluar variabel yang digunakan.

REFERENSI

- Amalou, I., Mouhni, N., & Abdali, A. (2022). Multivariate time series prediction by RNN architectures for energy consumption forecasting. *Energy Reports*, 8(May), 1084–1091. <https://doi.org/10.1016/j.egy.2022.07.139>
- Armstrong, J. S. (2001). Combining forecasts. *Principles of Forecasting*, 30.
- Bahra, N., & Pierre, S. (2021). A Hybrid User Mobility Prediction Approach for Handover Management in Mobile Networks. *Telecom*, 2(2), 199–212. <https://doi.org/10.3390/telecom2020013>
- Bayu Aji, A., & Surjandari, I. (2020). Hybrid vector autoregression-recurrent neural networks to forecast multivariate time series jet fuel transaction price. *IOP Conference Series: Materials Science and Engineering*, 909(1). <https://doi.org/10.1088/1757-899X/909/1/012079>
- Box, G. E. P., & Draper, N. R. (1986). *Empirical model - building and response surfaces*. John Wiley and Sons.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1724–1734. <https://doi.org/10.3115/v1/d14-1179>
- Di Mauro, M., Galatro, G., Postiglione, F., Song, W., & Liotta, A. (2024). Hybrid learning strategies for multivariate time series forecasting of network quality metrics. *Computer Networks*, 243(August 2023), 110286. <https://doi.org/10.1016/j.comnet.2024.110286>
- Ella, A. P., & Arifianto, D. (2020). Penerapan Fuzzy Time Series Dalam Peramalan Harga Minyak Serai Pada Cv Agam Jaya Atsiri. *Jurnal Teknik Elektro Dan Komputasi (ELKOM)*, 1–8. <http://repository.unmuhjember.ac.id/8580/11/j. JURNAL.pdf>

- Evans, M. J., & Rosenthal, J. S. (2009). Probability and Statistics: The Science of Uncertainty. In *W. H. Freeman, New York*. <https://doi.org/10.2307/2987918>
- Fadilah, T. N., Hakim, D. B., & Rindayati, W. (2022). The effect of asymmetric rupiah exchange rate on export value of Indonesian agricultural sector. *Jurnal Ekonomi Pertanian Dan Agribisnis (JEPA)*, 6, 154–165.
- Fausett, L. V, & Elwasif, W. (1994). Predicting performance from test scores using backpropagation and counterpropagation. *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)*, 5, 3398–3402 vol.5. <https://doi.org/10.1109/ICNN.1994.374782>
- Febrianti, D. R., Tiro, M. A., & Sudarmin, S. (2021). Metode Vector Autoregressive (VAR) dalam Menganalisis Pengaruh Kurs Mata Uang Terhadap Ekspor Dan Impor Di Indonesia. *Variansi: Journal of Statistics and Its Application on Teaching and Research*, 3(1), 23. <https://doi.org/10.35580/variasiunm14645>
- Firdaus, M., Holis, A., Amaliah, S., Fazri, M., & Sangadji, M. (2018). Dampak Pergerakan Nilai Tukar Rupiah terhadap Aktivitas Ekspor dan Impor Nasional. *Laporan Akhir Dampak Pergerakan Nilai Tukar Rupiah Terhadap Aktivitas Ekspor Dan Impor Nasional, Fakultas Ekonomi Dan Manajemen Institut Pertanian Bogor Dan Indonesia Dan Indonesia EXIM Bank: Bogor*, 98.
- Gujarati, D. N., & Porter, D. C. (2003). Basic Econometrics, McGraw-Hill. *New York*.
- GÜLHAN-, Ü. (2020). Covid-19 Pandemisine BIST 100 Reaksiyonu: Ekonometrik Bir Analiz. *Journal of Turkish Studies, Volume 15*(Volume 15 Issue 4), 497–509. <https://doi.org/10.7827/turkishstudies.44122>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., & Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18(3), 439–454. [https://doi.org/https://doi.org/10.1016/S0169-2070\(01\)00110-8](https://doi.org/https://doi.org/10.1016/S0169-2070(01)00110-8)

- Jadhav, V., & Ligay, V. (2016). *Forecasting Energy Consumption using Machine Learning*. January 2016.
<https://www.researchgate.net/publication/319990487>
- Johnson, R. A., & Wichern, D. W. (2007). *Applied multivariate statistical analysis sixth edition*. Pearson.
- Juanda, B., & Junaidi, J. (2012). *Ekometrika Deret Waktu*.
- Jung, S., Moon, J., Park, S., & Hwang, E. (2021). An attention-based multilayer gru model for multistep-ahead short-term load forecasting. *Sensors*, *21*(5), 1–20. <https://doi.org/10.3390/s21051639>
- Kholis, M., Astuti, D., & Febrianti, R. (2016). Hubungan antara pendapatan nasional dan investasi di Indonesia (Suatu Kajian Ekonomi Makro Dengan Model VAR). *Jurnal Organisasi Dan Manajemen*, *12*(1), 65–78.
<https://doi.org/10.33830/jom.v12i1.48.2016>
- Kulshreshtha, S., & Vijayalakshmi, A. (2020). An ARIMA-LSTM hybrid model for stock market prediction using live data. *Journal of Engineering Science and Technology Review*, *13*(4), 117–123.
<https://doi.org/10.25103/jestr.134.11>
- Lyhagen, J., Ekberg, S., & Eidestedt, R. (2015). Beating the VAR: Improving Swedish GDP Forecasts Using Error and Intercept Corrections. *Journal of Forecasting*, *34*(5), 354–363. <https://doi.org/https://doi.org/10.1002/for.2329>
- McKenzie, J. (2011). Mean absolute percentage error and bias in economic forecasting. *Economics Letters*, *113*(3), 259–262.
<https://doi.org/https://doi.org/10.1016/j.econlet.2011.08.010>
- Miraswan, K. J., Puspita, W. A., & Utami, A. S. (2022). Prediction of the Number of New Cases of Covid-19 in Indonesia Using Fuzzy Time Series Model Chen. *Sriwijaya Journal of Informatics and Applications*, *3*(1), 20–29.
<https://doi.org/10.36706/sjia.v3i1.35>
- Munkhdalai, L. , Li, M., & Theera-umpon, N. (2020). *VAR-GRU : A Hybrid Model for Multivariate*. *6*, 322–332.
- Najamuddin, M., & Fatima, S. (2022). Hybrid BRNN-ARIMA Model for Financial Time Series Forecasting. *Sukkur IBA Journal of Computing and Mathematical Sciences*, *6*(1), 62–71.

<https://doi.org/10.30537/sjcms.v6i1.1027>

OJK. (2023). *Saham*. <https://sikapiuangmu.ojk.go.id/FrontEnd/CMS/Article/285>

Ramachandran, K. M., & Tsokos, C. P. (2015). Chapter 1 - Descriptive Statistics. In K. M. Ramachandran & C. P. Tsokos (Eds.), *Mathematical Statistics with Applications in R (Second Edition)* (Second Edi, pp. 1–52). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-417113-8.00001-1>

Roman, F. F., & Kartiko. (2020). Penerapan Kausalitas Granger dan Kointegrasi Johansen Trace Statistic Test untuk Indeks Pembangunan Manusia terhadap Pertumbuhan Ekonomi, Inflasi dan Kemiskinan di Nusa Tenggara Timur. *Jurnal Statistika Industri Dan Komputasi*, 05(2), 73–83.

Sabat, N. K., Pati, U. C., Nayak, R., & Das, S. K. (2023). A Deep Learning-Based Vector Autoregressive-Gated Recurrent Unit Hybrid Model for Long-Term Forecasting of Weather Parameters for Smart Farms. *Artificial Intelligence Tools and Technologies for Smart Farming and Agriculture Practices*, 159–183. <https://doi.org/10.4018/978-1-6684-8516-3.ch009>

Safi, S. K., & Sanusi, O. I. (2021). A hybrid of artificial fneural network, exponential smoothing, and ARIMA models for COVID-19 time series forecasting. *Model Assisted Statistics and Applications*, 16(1), 25–35. <https://doi.org/10.3233/MAS-210512>

Sapitri, N. R., & Anhar, M. (2020). The Influence Of Online Trading Facilities, Minimal Investment Capital And Risk Perception On Millennial Generation Investment Interest The Influence Of Online Trading Facilities, Minimal Investment Capital And Risk Perception On Millennial Generation Inves. *Indonesian College of Economics*, 1–19.

Schkade, L. L., & Clark, C. T. (1983). Statistical Analysis for Administrative Decisions. In *USA : Ohio South-Western Publihing CO*. South - western P Co.

Sharma, S. (2020). Understanding Activation Functions in Neural Network. *International Journal of Engineering Applied Sciences and Technology*, 4(12), 310–316.

Tsay, R. S. (2013). *Multivariate time series analysis: with R and financial*

applications. John Wiley & Sons.

- Usman, M., Loves, L., Russel, E., Ansori, M., Warsono, W., Widiarti, W., & Wamiliana, W. (2022). Analysis of Some Energy and Economics Variables by Using VECMX Model in Indonesia. *International Journal of Energy Economics and Policy*, 12(2), 91–102. <https://doi.org/10.32479/ijeep.11897>
- Walpole, R. E., Myers, R. H., Myers, S. L., & Ye, K. (2011). *Probability and Statistics for Engineers and Scientists*, 9th. Pearson.
- Wang, L., Zou, H., Su, J., Li, L., & Chaudhry, S. (2013). An ARIMA-ANN Hybrid Model for Time Series Forecasting. *Systems Research and Behavioral Science*, 30(3), 244–259. <https://doi.org/10.1002/sres.2179>
- Warsono, Gustavia, E., Kurniasari, D., Amanto, & Antonio, Y. (2019). On the Comparison of the Methods of Parameter Estimation for Pareto Distribution. *Journal of Physics: Conference Series*, 1338(1). <https://doi.org/10.1088/1742-6596/1338/1/012042>
- Wozniak, T. (2016). *Bayesian Vector Autoregressions*.
- Zhang, P. G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)