

**PENERAPAN METODE *HYBRID VECTOR AUTOREGRESSIVE
EXOGENOUS-CONVOLUTIONAL NEURAL NETWORK (VARX-CNN)*
UNTUK PERAMALAN EKSPOR IMPOR INDONESIA**

(Skripsi)

Oleh

IRMA DESTIANA

1917031028



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

ABSTRACT

APPLICATION OF HYBRID VECTOR AUTOREGRESSIVE EXOGENOUS- CONVOLUTIONAL NEURAL NETWORK (VARX-CNN) METHOD FOR INDONESIAN EXPORT-IMPORT FORECASTING

By

IRMA DESTIANA

Export and import is one An important component in a international trade. Export and import can contribute significantly to economic growth a country. Steps that can be used to continue to stabilize a country's economic growth are to project value in the next few periods so that a country has a business plan and strategy. The science that can be used to make value projections is to use statistics. VARX is a suitable method used in econometric analysis to perform forecasting on economic and financial data. A limitation of VARX is the difficulty in identifying and modeling non-linear components of data that have high fluctuations in value, especially in the context of financial data. . CNN is a model that has three main layers , namely *input layer, hidden layer and output layer*. The three layers are expected to be able to capture nonlinear data patterns in data with high value fluctuations. Therefore, a hybrid VARX - CNN method is proposed which is expected to be able to predict and forecast well. The hybrid VARX-CNN method consists of 2 main models, namely the first model that predicts the prediction results from VARX and the second model that predicts residual data from the VARX prediction. As for this study, the *hybrid* model was able to produce a MAPE value of 0.088 with an accuracy of 99.81%.

Keywords: Hybrid VARX - CNN, CNN, VARX, MAPE, Hybrid Model, Import
Export, Prediction , Forecast

ABSTRAK

PENERAPAN METODE *HYBRID VECTOR AUTOREGRESSIVE EXOGENOUS- CONVOLUTIONAL NEURAL NETWORK (VARX-CNN)* UNTUK PERAMALAN EKSPOR IMPOR INDONESIA

Oleh

IRMA DESTIANA

Ekspor dan impor adalah salah satu komponen yang penting dalam perdagangan internasional suatu negara. Ekspor dan impor dapat berkontribusi secara signifikan terhadap pertumbuhan ekonomi suatu negara. Langkah yang dapat digunakan untuk tetap menstabilkan pertumbuhan ekonomi suatu negara adalah dengan memproyeksikan nilai pada beberapa periode kedepan agar suatu negara mempunyai perencanaan bisnis dan strategi. Ilmu yang dapat digunakan untuk melakukan proyeksi nilai adalah dengan menggunakan statistika. VARX adalah metode yang cocok digunakan dalam analisis ekonometrik untuk melakukan peramalan pada data ekonomi dan keuangan. Keterbatasan VARX yaitu kesulitan dalam mengidentifikasi dan memodelkan komponen non linear pada data yang memiliki fluktuasi nilai yang tinggi, terutama dalam konteks data finansial. CNN merupakan model yang memiliki tiga layer utama, yaitu *input layer*, *hidden layer* dan *output layer*. Ketiga *layer* tersebut diharapkan mampu untuk menangkap pola data nonlinear pada data dengan fluktuasi nilai yang tinggi. Oleh karena itu, diusulkan metode *hybrid VARX - CNN* yang diharapkan mampu melakukan prediksi serta peramalan dengan baik. Metode *hybrid VARX-CNN* terdiri atas 2 model utama yaitu model pertama yang memprediksikan hasil prediksi dari VARX dan model kedua yang memprediksikan data residual dari prediksi VARX. Adapun dari penelitian ini, model *hybrid* mampu menghasilkan nilai MAPE sebesar 0,088 dengan akurasi 99,81%.

Kata Kunci: *Hybrid VARX - CNN*, CNN, VARX, MAPE, Model *Hybrid*, Ekspor
Impor, Prediksi, Peramalan

**PENERAPAN METODE *HYBRID VECTOR AUTOREGRESSIVE
EXOGENOUS- CONVOLUTIONAL NEURAL NETWORK (VARX-CNN)*
UNTUK PERAMALAN EKSPOR IMPOR INDONESIA**

Oleh

IRMA DESTIANA

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
2023**

Judul Skripsi : **PENERAPAN METODE *HYBRID VECTOR AUTOREGRESSIVE EXOGENOUS-CONVOLUTIONAL NEURAL NETWORK (VARX-CNN)* UNTUK PERAMALAN EKSPOR IMPOR INDONESIA**

Nama Mahasiswa : **Irma Destiana**

Nomor Pokok Mahasiswa : **1917031028**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**



1. Komisi Pembimbing

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

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

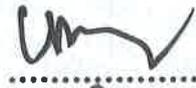
2. Ketua Jurusan Matematika

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

MENGESAHKAN

1. Tim Penguji

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


.....

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


.....

Penguji
Bukan Pembimbing : **Drs. Nusyirwan, M.Si.**


.....

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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

Tanggal Lulus Ujian Skripsi : 31 Juli 2023

PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama Mahasiswa : **Irma Destiana**

Nomor Pokok Mahasiswa : **1917031028**

Jurusan : **Matematika**

Judul Skripsi : **PENERAPAN METODE *HYBRID VECTOR
AUTOREGRESSIVE EXOGENOUS-
CONVOLUTIONAL NEURAL NETWORK*
(VARX-CNN) UNTUK PERAMALAN
EKSPOR IMPOR INDONESIA**

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

Bandar Lampung, 31 Juli 2023
Penulis,



Irma Destiana
NPM. 1917031028

RIWAYAT HIDUP

Penulis bernama lengkap Irma Destiana, dilahirkan di Ujung Karang, 18 Desember 2001. Penulis merupakan anak kelima dari pasangan Bapak Manirin dan Ibu Panirah.

Penulis menyelesaikan pendidikan di SDN 3 Sidodadi pada tahun 2013, SMPN 4 Metro pada tahun 2016, SMAN 4 Metro pada tahun 2019. Penulis diterima di Jurusan Matematika FMIPA Universitas Lampung pada tahun 2019 melalui jalur penerimaan SNMPTN.

Pada tahun 2022 penulis menyelesaikan Praktik Kerja Lapangan (PKL) di BPJS Kesehatan kantor cabang Metro. Penulis juga melakukan pengabdian terhadap masyarakat dengan mengikuti program Kuliah Kerja Nyata (KKN) Universitas Lampung tahun 2023 di Desa Bandar Negeri, Kec. Labuhan Maringgai, Kab. Lampung Timur.

Dalam bidang organisasi penulis sebagai ketua Gugus Fakultas MIPA Kopma Unila dan anggota bidang SPM BEM FMIPA periode 2020-2021. Penulis juga penerima beasiswa Bank Indonesia tahun 2022 dan sebagai peserta lolos pendanaan dalam program Program Mahasiswa Wirausaha 2023 Universitas Lampung. Kemudian penulis melaksanakan penelitian dengan judul “Penerapan Metode *Hybrid Vector Autoregressive Exogenous-Convolutional Neural Network* (VARX-CNN) untuk Peramalan Ekspor Impor Indonesia” sebagai tugas akhir di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

KATA INSPIRASI

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.”

(QS. Al-Baqarah: 286)

“Pendidikan merupakan senjata paling ampuh yang bisa kamu gunakan untuk merubah dunia.”

(Nelson Mandela)

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

(QS. Al Insyirah: 6-7)

“Tidak akan menyerah sebelum mencoba.”

(Irma Destiana)

“Orang lain tidak akan paham dengan *struggle* dan masa sulitnya kita, yang mereka ingin tahu hanya bagian *success stories* nya saja. Jadi berjuanglah untuk diri sendiri meskipun tidak akan ada yang tepuk tangan. Kelak diri kita di masa depan akan sangat bangga dengan apa yang kita perjuangkan hari ini.

Jadi tetap berjuang ya.”

PERSEMBAHAN

Dengan Penuh Rasa Syukur Kepada Allah Subhanahu Wa Ta'ala,
karya ini dipersembahkan kepada:

Bunda, Ibu dan Ayah

Terimakasih untuk segala do'a dan usaha yang selalu diberikan demi kesuksesan putrinya hingga mampu menyelesaikan pendidikan di tingkat Universitas sebagai sarjana

Adikku Tersayang

Terimakasih atas tingkah lucu yang membuat penulis bersemangat dalam menyelesaikan skripsi ini.

Sahabat-sahabatku Terkasih

Terimakasih atas segala dukungan yang telah diberikan sehingga dapat tetap bertahan dalam keadaan suka maupun duka.

Almamaterku Tercinta, Universitas Lampung

SANWACANA

Segala puji bagi Allah SWT atas segala nikmat dan karunia-Nya yang tak terhingga sehingga penulis dapat menyelesaikan skripsi yang berjudul **“Penerapan Metode *Hybrid Vector Autoregressive Exogenous-Convolutional Neural Network (VARX-CNN)* Untuk Peramalan Ekpor Impor Indonesia”** sebagai persyaratan guna mendapatkan gelar sarjana Matematika di Universitas Lampung. Dalam penyusunan skripsi ini banyak pihak yang telah membantu penulis, untuk itu penulis mengucapkan terimakasih kepada :

1. Bapak Ir. Warsono, M.S., Ph.D., selaku Dosen Pembimbing I yang telah memberikan bimbingan, arahan, kritik serta nasihat yang sangat membantu bagi penulis dalam penulisan skripsi.
2. Ibu Dian Kurniasari S.Si., M.Sc., selaku dosen pembimbing II yang senantiasa membimbing dengan sabar, memberi masukan serta saran serta mendukung penulis dalam menyelesaikan skripsi ini.
3. Bapak Drs. Nusyirwan, M.Si., sebagai dosen penguji yang telah memberikan masukan dan koreksi dalam penyelesaian skripsi ini.
4. Bapak Subian Saidi, S.Si., M.Si., sebagai pembimbing akademik yang telah membantu dalam segala proses akademik.
5. Bapak Dr.Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan FMIPA Universitas Lampung.
7. Seluruh dosen, staff, karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

8. Teruntuk Bundaku tercinta, Eka Wiji Lestari yang telah memberikan dukungan, pengorbanan, cinta kasih serta semangat kepada penulis dalam menyelesaikan skripsi ini.
9. Teruntuk keluarga tercinta, terutama Ayah Manirin, Ibu Panirah, Mas Andri dan juga adik Nizam, terimakasih atas do'a, dukungan, cinta kasih, serta perhatian yang telah diberikan demi kesuksesan penulis, semoga dikemudian hari dapat menjadi kebanggan kalian.
10. Sahabat seperjuanganku sejak SMP hingga sekarang, Lutfi, Bela dan Intan yang selalu memberikan semangat dan motivasi kepada penulis.
11. Sahabat kuliah ku, Lulu, Anisa, Rara, Silvia, Dea, Mega dan Melisa, terimakasih atas pengalaman serta dukungan terhadap penulis sejak awal perkuliahan hingga selesai.
12. Muhammad Arif Jarodi, terimakasih atas dukungan, semangat, serta telah menjadi tempat berkeluh kesah, selalu ada dalam suka maupun duka selama proses penyusunan skripsi ini.

Penulis sangat menyadari bahwa dalam penulisan skripsi ini masih banyak terdapat kesalahan dan kekurangan sehingga jauh dari ukuran kesempurnaan. Penulis berharap semoga skripsi ini bermanfaat, khususnya bagi penulis dan bagi pembaca pada umumnya.

Bandar Lampung, 31 Juli 2023
Penulis,

Irma Destiana

DAFTAR ISI

| | Halaman |
|---|---------|
| DAFTAR TABEL | iv |
| DAFTAR GAMBAR | v |
| I. PENDAHULUAN | 1 |
| 1.1 Latar Belakang dan Masalah | 1 |
| 1.2 Tujuan Penelitian | 5 |
| 1.3 Manfaat Penelitian | 5 |
| II. TINJAUAN PUSTAKA | 6 |
| 2.1 Peramalan | 6 |
| 2.1.1 <i>Time Series</i> (Deret Waktu) | 7 |
| 2.1.1.1 Model <i>Vector Autoregressive</i> (VAR) | 8 |
| 2.1.1.2 Model <i>Vector Autoregressive Exogenous</i> (VARX) | 9 |
| 2.2 Stasioneritas Data | 18 |
| 2.3 <i>Machine Learning</i> (Pembelajaran Mesin) | 20 |
| 2.4 <i>Deep Learning</i> | 21 |
| 2.5 <i>Convolutional Neural Network</i> (CNN) | 22 |
| 2.5.1 Arsitektur <i>Convolutional Neural Network</i> | 22 |
| 2.5.2 Fungsi Aktivasi | 24 |
| 2.6 Normalisasi Data | 27 |
| 2.7 <i>Hybrid VARX-ANN</i> | 28 |
| 2.8 Validasi Model | 30 |
| III. METODOLOGI PENELITIAN | 32 |
| 3.1 Waktu dan Tempat Penelitian | 32 |
| 3.2 Data Penelitian | 32 |
| 3.3 Metode Penelitian | 33 |

| | |
|---|----|
| IV. HASIL DAN PEMBAHASAN | 36 |
| 4.1 Input Data..... | 36 |
| 4.2 Uji Korelasi Pearson | 40 |
| 4.3 Uji Stasioneritas Data | 41 |
| 4.4 Uji Kointegrasi..... | 48 |
| 4.5 Uji Kausalitas Granger..... | 49 |
| 4.6 Penentuan Orde Model VARX | 51 |
| 4.6.1 Penentuan Panjang Lag Optimal | 51 |
| 4.6.2 Pemilihan Model Terbaik VARX..... | 52 |
| 4.6.3 Estimasi Parameter Model VARX | 53 |
| 4.6.4 Uji Signifikansi Parameter Model VARX..... | 55 |
| 4.7 Prediksi dan Peramalan Model VARX | 56 |
| 4.8 Ekstraksi Data Residual | 58 |
| 4.8.1 Uji Asumsi Residual..... | 59 |
| 4.9 Prediksi dengan Model <i>Hybrid</i> VARX-CNN | 60 |
| 4.9.1 Pembagian Data menjadi Data <i>Train</i> dan Data <i>Test</i> | 60 |
| 4.9.2 Normalisasi Data <i>Train</i> dan Data <i>Test</i> | 61 |
| 4.9.3 Membangun Model Prediksi VARX dengan CNN | 62 |
| 4.9.4 Membangun Model Residual VARX dengan CNN..... | 65 |
| 4.9.5 Melakukan Prediksi Model Prediksi VARX dengan CNN | 68 |
| 4.9.6 Melakukan Prediksi Model Residual VARX dengan CNN | 69 |
| 4.9.7 Melakukan Prediksi Model <i>Hybrid</i> | 70 |
| 4.10 Peramalan Model <i>Hybrid</i> | 71 |
| 4.10.1 Hasil Peramalan Model Prediksi VARX dengan CNN | 71 |
| 4.10.2 Hasil Peramalan Model Residual VARX dengan CNN | 72 |
| 4.10.3 Hasil Peramalan Model <i>Hybrid</i> | 73 |
| V. KESIMPULAN DAN SARAN | 75 |
| 5.1 Kesimpulan | 75 |
| 5.2 Saran | 75 |
| DAFTAR PUSTAKA | 77 |
| LAMPIRAN | 81 |

DAFTAR TABEL

| Tabel | Halaman |
|--|---------|
| 1. Data Ekspor, Impor, Kurs, Inflasi, Dan BI Rate | 33 |
| 2. Uji Kointegrasi Johansen Berdasarkan <i>Trace Statistic</i> | 48 |
| 3. Uji Kointegrasi Johansen Berdasarkan <i>Max-Eigen Statistic</i> | 48 |
| 4. <i>Output</i> Uji Kausalitas Granger Ekspor | 49 |
| 5. <i>Output</i> Uji Kausalitas <i>Granger</i> Impor | 50 |
| 6. <i>Output</i> Uji Kausalitas Granger Kurs | 50 |
| 7. <i>Output</i> Uji Kausalitas <i>Granger</i> Inflasi | 50 |
| 8. <i>Output</i> Uji Kausalitas Granger BI Rate | 51 |
| 9. Nilai <i>Lag</i> Optimal | 52 |
| 10. Orde Model VARX..... | 53 |
| 11. Estimasi Parameter Model VARX (4,0) | 55 |
| 12. Ringkasan Uji Signifikansi Parameter | 55 |
| 13. Prediksi dari Model VARX | 56 |
| 14. Residual dari Model VARX..... | 58 |
| 15. Hasil Uji Portmanteau | 59 |
| 16. Hasil Uji Jarque-Bera Residual..... | 60 |
| 17. <i>Splitting</i> data | 61 |

DAFTAR GAMBAR

| Gambar | Halaman |
|---|---------|
| 1. Arsitektur <i>Convolutional Neural Network</i> | 22 |
| 2. Fungsi Aktivasi Sigmoid..... | 25 |
| 3. Fungsi Aktivasi Tanh..... | 26 |
| 4. Fungsi Aktivasi ReLU..... | 27 |
| 5. Diagram Alir Metode Penelitian..... | 35 |
| 6. Proses <i>Input Data</i> | 36 |
| 7. Data Ekspor, Impor, Kurs, Inflasi, dan BI Rate..... | 37 |
| 8. Plot Data Ekspor Indonesia..... | 37 |
| 9. Plot Data Impor Indonesia..... | 38 |
| 10. Plot Data Kurs Indonesia..... | 38 |
| 11. Plot Data Inflasi Indonesia..... | 39 |
| 12. Plot Data BI Rate..... | 39 |
| 13. Plot dan Nilai Korelasi Pearson..... | 40 |
| 14. Nilai <i>P-Value</i> Uji ADF Data Ekspor..... | 41 |
| 15. Nilai <i>P-Value</i> Uji ADF Data Ekspor Setelah <i>Differencing</i> Pertama..... | 42 |
| 16. Nilai <i>P-Value</i> Uji ADF Data Ekspor Setelah <i>Differencing</i> Kedua..... | 42 |
| 17. Plot Data Ekspor Setelah <i>Differencing</i> Kedua..... | 42 |
| 18. Nilai <i>P-Value</i> Uji ADF Data Impor..... | 43 |
| 19. Nilai <i>P-Value</i> Uji ADF Data Impor Setelah <i>Differencing</i> Pertama..... | 43 |
| 20. Nilai <i>P-Value</i> Uji ADF Data Impor Setelah <i>Differencing</i> Kedua..... | 43 |
| 21. Plot Data Impor Setelah <i>Differencing</i> Kedua..... | 44 |
| 22. Nilai <i>P-Value</i> Uji ADF Data Kurs..... | 44 |
| 23. Nilai <i>P-Value</i> Uji ADF Data Kurs Setelah <i>Differencing</i> Pertama..... | 45 |
| 24. Plot Data Kurs Setelah <i>Differencing</i> Pertama..... | 45 |
| 25. Nilai <i>P-Value</i> Uji ADF Data Inflasi..... | 46 |

| | |
|---|----|
| 26. Nilai <i>P-Value</i> Uji ADF Data Inflasi Setelah <i>Differencing</i> Pertama..... | 46 |
| 27. Plot Data Inflasi Setelah <i>Differencing</i> Pertama | 46 |
| 28. Nilai <i>P-Value</i> Uji ADF Data BI Rate..... | 47 |
| 29. Nilai <i>P-Value</i> Uji ADF Data BI Rate Setelah <i>Differencing</i> Pertama | 47 |
| 30. Plot Data BI Rate Setelah <i>Differencing</i> Pertama | 48 |
| 31. Plot Data Aktual dan Prediksi Ekspor | 57 |
| 32. Plot Data Aktual dan Prediksi Impor | 57 |
| 33. Plot Data Residual Ekspor dan Impor..... | 58 |
| 34. <i>Hyperparameter Tuning</i> Model Prediksi VARX dengan CNN untuk Skema 70% <i>Training</i> dan 30% <i>Testing</i> | 62 |
| 35. <i>Hyperparameter Tuning</i> Model Prediksi VARX dengan CNN untuk Skema 80% <i>Training</i> dan 20% <i>Testing</i> | 63 |
| 36. <i>Input</i> Nilai Parameter untuk Skema 70% <i>Training</i> dan 30% <i>Testing</i> | 64 |
| 37. <i>Input</i> Nilai Parameter untuk Skema 80% <i>Training</i> dan 20% <i>Testing</i> | 65 |
| 38. <i>Hyperparameter Tuning</i> Model Residual VARX dengan CNN untuk Skema 70% <i>Training</i> dan 30% <i>Testing</i> | 66 |
| 39. <i>Hyperparameter Tuning</i> Model Residual VARX dengan CNN untuk Skema 80% <i>Training</i> dan 20% <i>Testing</i> | 66 |
| 40. <i>Input</i> Nilai Parameter untuk Skema 70% <i>Training</i> dan 30% <i>Testing</i> | 67 |
| 41. <i>Input</i> Nilai Parameter untuk Skema 80% <i>Training</i> dan 20% <i>Testing</i> | 67 |
| 42. Plot Prediksi Model Prediksial VARX dengan CNN..... | 68 |
| 43. Plot Prediksi Model Residual VARX dengan CNN | 69 |
| 44. Plot Prediksi Model <i>Hybrid</i> | 70 |
| 45. Plot Peramalan Model Prediksi VARX dengan CNN | 71 |
| 46. Plot Peramalan Model Residual VARX dengan CNN..... | 73 |
| 47. Plot Peramalan Model <i>Hybrid</i> | 74 |

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Perekonomian di Indonesia yang naik turun dapat mempengaruhi kondisi maupun kemajuan kehidupan masyarakat. Saat ini pemerintah berusaha untuk meningkatkan pertumbuhannya melalui kebijakan-kebijakan yang ditentukan. Indonesia termasuk yang menganut sistem ekonomi terbuka dalam perekonomiannya. Perekonomian terbuka merupakan perekonomian yang melibatkan diri dalam perdagangan internasional (ekspor dan impor) barang dan jasa serta modal dengan negara-negara lain. Dalam perekonomian terbuka, arus perdagangan internasional adalah aktivitas yang dilakukan suatu negara untuk menopang perekonomiannya. Perdagangan internasional yang meliputi ekspor dan impor selalu terjadi antar negara di dunia sebagai upaya dalam memenuhi ketersediaan barang dan jasa penduduknya. Ekspor adalah penjualan barang ke luar negeri dengan menggunakan sistem pembayaran, kualitas, kuantitas dan syarat penjualan lainnya yang telah disetujui oleh pihak eksportir dan importir. Sedangkan, impor adalah kegiatan memasukkan barang ke dalam daerah pabean berdasarkan Undang-undang Republik Indonesia Nomor 17 Tahun 2006 tentang kepabeanan.

Pertumbuhan ekspor dalam negeri juga tidak lepas dari pengaruh nilai tukar (kurs) dan suku bunga. Nilai tukar mata uang suatu negara terhadap negara asing lainnya atau perbandingan nilai tukar mata uang antar negara saat melakukan proses transaksi inilah yang disebut dengan kurs (Sulaiman, 2019). Dalam sistem

kurs, depresiasi atau apresiasi nilai mata uang akan mengakibatkan perubahan keatas ekspor maupun impor. Jika kurs mengalami depresiasi yaitu nilai mata uang asing bertambah tinggi kursnya (harganya), maka akan menyebabkan ekspor meningkat dan impor cenderung menurun. Kurs memiliki keterkaitan dengan ekspor dikarenakan jika nilai tukar tidak stabil maka eksportir akan sulit untuk menentukan harga barang dan berdampak pula terhadap harga penawaran maupun permintaan perdagangan. Sedangkan suku Bunga adalah jumlah yang dibayarkan atas peminjaman uang untuk jangka waktu tertentu dan biasanya dinyatakan dalam persentase (Moorcy, dkk., 2021). Suku bunga mempengaruhi kegiatan ekspor dari sisi produksi, yakni tingkat bunga kredit yang semakin tinggi maka akan menyebabkan pengusaha atau eksportir akan mengurangi jumlah pinjaman, sehingga dapat berdampak pada jumlah penawaran yang mampu diciptakan eksportir

Salah satu kebijakan moneter untuk mempengaruhi perekonomian adalah dengan menaikkan atau menurunkan suku bunga acuan Bank Indonesia atau disebut BI rate. Kenaikan dan penurunan BI rate akan mempengaruhi inflasi. Inflasi dapat diartikan sebagai kenaikan harga barang dan jasa secara umum dan terus menerus dalam waktu tertentu. Inflasi menjadi salah satu masalah utama dalam perekonomian, inflasi yang tidak stabil akan menimbulkan ketidakpastian keputusan para pelaku ekonomi sehingga menurunkan pertumbuhan ekonomi. Hubungan inflasi dengan ekspor adalah ketika terjadi inflasi, harga-harga barang di dalam negeri naik sehingga menaikkan biaya produksi dari produk yang akan di ekspor ke luar negeri. Tingkat inflasi yang tinggi mungkin akan memiliki sejumlah dampak buruk sebelum krisis, termasuk penurunan ekspor dan peningkatan impor.

Peningkatan maupun penurunan nilai ekspor dan impor dapat di perkirakan menggunakan teknik statistika peramalan analisis runtun waktu. Salah satu faktor kunci dalam pengambilan keputusan adalah peramalan karena, peramalan bertujuan untuk memperkirakan nilai dari sebuah data di masa depan. Data dengan beberapa variabel juga dapat dianalisis, selain data dengan satu variabel.

Analisis runtun waktu dengan satu variabel disebut analisis runtun waktu univariat sedangkan analisis runtun waktu dengan banyak variabel disebut analisis runtun waktu multivariat. Data impor dan ekspor merupakan data runtun waktu sehingga dapat dimodelkan dengan model runtun waktu. Model runtun waktu yang dapat digunakan untuk memodelkan lebih dari satu variabel amatan (multivariat) adalah model vector autoregressive (VAR). Pada model VAR diasumsikan semua variabel dalam model adalah endogen (Amry, dkk., 2018) dan semua variabel dianggap sebagai variabel endogen yang saling berkaitan (Rosyidah, dkk., 2017). Pada penelitian ini variabel yang digunakan adalah variabel endogen dan variabel eksogen. Variabel endogen adalah variabel yang nilainya dipengaruhi oleh variabel lain dalam model sedangkan variabel eksogen adalah variabel yang nilainya tidak dipengaruhi oleh variabel lain dalam model. Untuk mengetahui ekspor dan impor sebagai variabel endogen serta kurs, inflasi dan BI rate sebagai variabel eksogen pada masa yang akan datang maka digunakan analisis runtun waktu multivariate yaitu *Vector Autoregressive Exogenous* (VARX). Model *vektor autoregressive* dengan variabel eksogen (VARX) adalah salah satu analisis statistik yang sering digunakan dalam banyak penelitian yang melibatkan data deret waktu (Warsono, dkk., 2019). Berdasarkan pendapat Ferry, dkk. (2018), VARX adalah pengembangan dari VAR dimana dalam model VARX terdapat penambahan variabel eksogen. Model VARX digunakan jika masing-masing variabel memiliki hubungan dua arah dan deret waktu yang digunakan sudah stasioner dan tidak saling berkointegrasi.

Seiring berjalannya waktu banyak permasalahan yang timbul pada bidang ekonomi yang sulit terpecahkan dikarenakan data yang akan dianalisis memiliki pola data tertentu dan sulit didefinisikan. Salah satu metode pemodelan yang bisa digunakan untuk menangkap pola-pola non linier adalah metode *Convolutional Neural Network* (CNN). *Convolutional Neural Network* adalah salah satu pengembangan dari algoritma *Artificial Neural Network* (ANN). *Convolutional Neural Network* merupakan salah satu jenis dari bidang *Deep Learning* (DL), yang termasuk dalam sub bidang dari *Machine Learning* (ML) yang menerapkan konsep dasar algoritma ANN dengan lapisan yang lebih banyak (Halimi, dkk.,

2018). Keunggulan CNN pada data ekonomi yaitu dapat mengekstrak fitur-fitur penting pada rentang waktu tertentu, seperti kenaikan harga, fluktuasi nilai tukar, dan lain sebagainya. Metode VARX memberikan hasil peramalan yang lebih baik, tetapi keakuratan peramalan masih memberikan hasil yang kurang baik. Salah satu cara untuk meningkatkan keakuratan metode VARX ini yaitu dengan menggunakan model hybrid. Model hybrid merupakan metode yang mengkombinasikan VARX sebagai komponen linear dan CNN sebagai komponen non-linear, sehingga diharapkan mampu menghasilkan hasil peramalan yang lebih akurat.

Penelitian terdahulu menggunakan metode VARX telah dilakukan oleh Warsono, dkk. (2019) yang membahas tentang pemodelan dan peramalan data energi dengan studi kasus PTBA dan HRUM energi dan ditemukan bahwa VARX (3,0) adalah model terbaik untuk menilai hubungan antara variabel yang dipertimbangkan dalam penelitian ini. Kemudian penelitian metode VARX oleh Vinie, dkk. (2019), yaitu memprediksikan hasil produksi karet PTPN XIII Provinsi Kalimantan Barat dengan hasil prediksi menggunakan model VARX (1,1) dan nilai MAPE masing-masing sebesar 14,73% dan 16,06%. Selanjutnya yaitu penelitian yang dilakukan oleh Muschilati & Irsalinda (2020), dengan judul “*Forecasting Tourist Visit Using the Vector Autoregressive Exogenous Method (VARX)*” dan mendapatkan model VARX (1,0) dengan nilai MAPE masing-masing yaitu 8.6580%, 8.1308%, 11.1852%, 6.5978%, dan 7.2862%.

Penelitian mengenai CNN dilakukan oleh Halimi, dkk. (2019) untuk memprediksi harga emas menghasilkan bahwa model terbaik adalah model 1 dengan pengujian dense 5 dengan hasil RMSE 690,40. Peramalan mengenai model *hybrid* sudah pernah dilakukan salah satunya oleh Barzagar, dkk (2016) menggunakan metode *hybrid Convolutional Neural Network – Long Short Term Memory* (CNN-LSTM) untuk memprediksikan variabel kualitas air jangka pendek, dengan hasil model hybrid CNN-LSTM lebih baik dari model LSTM, CNN, *Support Vector Regression* (SVR) dan *Decision Tree* (DT). Penelitian lain tentang *hybrid* juga pernah dilakukan oleh Le, dkk. (2019), hasil dari penelitian ini menunjukkan

bahwa model yang dikombinasikan dari CNN dan (*Bidirectional - Long Short Term Memory* (Bi-LSTM) menghasilkan hasil prediksi yang lebih baik daripada model yang hanya menggunakan CNN atau Bi-LSTM.

Dalam peramalan, tidak ada metode peramalan yang sangat tepat untuk meramalkan keadaan data di masa yang akan datang, sehingga dalam tiap metode peramalan pasti melakukan kesalahan atau error. Alat yang digunakan untuk menghitung kesalahan pada peramalan menggunakan *Mean Absolute Percentage Error* (MAPE). Berdasarkan pemaparan di atas, penulis tertarik untuk melakukan penelitian tentang penerapan metode *hybrid VARX-CNN* yang berjudul “Penerapan Metode *Hybrid Vector Autoregressive Exogenous-Convolutional Neural Network* (VARX-CNN) Untuk Peramalan Ekspor Impor Indonesia”.

1.2 Tujuan Penelitian

Tujuan dari penelitian ini yaitu :

1. Menentukan model terbaik dari metode *hybrid VARX-CNN* pada data ekspor dan impor Indonesia.
2. Melakukan peramalan dari model *hybrid VARX-CNN* nilai ekspor dan impor Indonesia untuk beberapa periode yang akan datang.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut :

1. Memberikan pengetahuan terkait pemodelan dan prediksi nilai ekspor dan impor Indonesia.
2. Sebagai sumber ilmu pengetahuan bagi penulis maupun pembaca.
3. Dapat menjadi referensi bagi peneliti selanjutnya terkait metode *hybrid VARX-CNN* maupun tentang prediksi nilai ekspor dan impor.

II. TINJUAN PUSTAKA

2.1 Peramalan

Forecasting (Peramalan) merupakan suatu ilmu yang digunakan untuk meramalkan atau memprediksi kejadian di waktu mendatang. Sebagai bidang seperti ekonomi, keuangan, pemasaran, produksi, riset operasional, administrasi Negara, kependudukan, dan pendidikan dapat menggunakan peramalan. Berdasarkan pendapat Montgomery, dkk. (2015), metode peramalan dibagi dalam dua kategori, yaitu :

1. Metode kualitatif adalah analisis yang didasarkan dengan pemikiran yang bersifat intuitif, logis dan pengetahuan yang telah diperoleh oleh peneliti sebelumnya. Peramalan ini biasanya digunakan untuk peramalan jangka pendek, adapun ciri dari metode ini adalah faktor yang mempengaruhi ramalan dan cara menilainya bersifat pribadi dan sulit ditirukan orang lain.
2. Metode kuantitatif merupakan peramalan yang membutuhkan informasi masa lalu yang dikuantitatifkan dalam bentuk data numerik. Ada dua jenis dalam metode peramalan kuantitatif yaitu, model regresi dan model deret waktu (time series). Model regresi menguji variabel yang dapat diduga mempengaruhi variabel terikat yang bertujuan menemukan hubungan sebab akibat dari keduanya. Model deret waktu berupaya untuk meramalkan kondisi masa yang akan datang dengan menggunakan data historis dan mengeksplorasikannya ke masa depan.

2.1.1 *Time Series* (Deret Waktu)

Time Series (Deret Waktu) merupakan salah satu metode peramalan kuantitatif. *Time series* yaitu kumpulan data observasi yang diambil secara beruntun sepanjang waktu dalam interval waktu yang tetap (Wei, 2006). Analisis deret waktu merupakan prosedur analisis yang dapat digunakan untuk mengetahui gerak perubahan atau perkembangan nilai suatu variabel sebagai akibat dari perubahan waktu. Data dikumpulkan secara periodik berdasarkan urutan waktu, bisa dalam jam, hari, minggu, bulan, kuartal dan tahun. Menganalisis *time series* berarti membagi data masa lalu menjadi komponen-komponen dan memproyeksikan ke masa depan. Analisis *time series* dipelajari karena dengan mengamati data *time series* akan terlihat empat komponen yang mempengaruhi suatu pola data masa lalu dan sekarang yang cenderung berulang dimasa mendatang. Empat komponen pola deret waktu antara lain (Makridakis, dkk., 1999):

1. Pola Horizontal

Pola ini terjadi bila data berfluktuasi disekitar rata-ratanya.

2. Pola Musiman

Pola musiman terjadi bila nilai data dipengaruhi oleh faktor musiman (misalnya : kuartal tahun tertentu, bulanan atau hari-hari pada minggu tertentu).

3. Pola Siklis

Pola ini terjadi bila data dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis.

4. Pola Tren

Pola tren terjadi bila ada kenaikan atau penurunan sekuler jangka panjang dalam data.

Deret waktu dibagi menjadi dua, yaitu univariat dan multivariat. Data dengan satu variabel pengamatan disebut univariat. Metode yang termasuk ke dalam univariat antara lain *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA) atau *Autoregressive Integrated Moving Average* (ARIMA). Sedangkan deret waktu multivariat ialah salah satu analisis *time series*

yang mengaitkan banyak variabel di dalam modelnya. Metode yang termasuk dalam deret waktu multivariate salah satunya yaitu *Vector Autoregressive* (VAR) yang merupakan perkembangan dari model *Autoregressive* (AR). Model VAR dengan penambahan variabel eksogen ke dalam persamaan maka dikembangkan menjadi model *Vector Autoregressive Exogenous* (VARX).

2.1.1.1 Model *Vector Autoregressive* (VAR)

Model VAR merupakan pengembangan dari model *autoregressive* (AR) dengan lebih dari 1 variabel. Model VAR dapat digunakan untuk menjelaskan hubungan timbal balik antar variabel-variabel dan digunakan untuk memodelkan beberapa variabel endogen secara bersamaan. Setiap variabel endogen dijelaskan oleh nilai-nilai masa lalu dan nilai-nilai masa lalu dari semua variabel endogen lainnya dalam model (Gujarati, 2004). Model VAR (p) secara umum dapat ditulis sebagai berikut: (Lütkepohl, 2005)

$$\mathbf{y}_t = \boldsymbol{\alpha} + \boldsymbol{\phi}_1 \mathbf{y}_{t-1} + \boldsymbol{\phi}_2 \mathbf{y}_{t-2} + \cdots + \boldsymbol{\phi}_p \mathbf{y}_{t-p} + \boldsymbol{\varepsilon}_t \quad (2.1)$$

dengan :

- \mathbf{y}_t : vektor berukuran $m \times 1$ berisi m variabel yang masuk dalam model VAR pada waktu t dan $t - i$, dimana $i = 1, 2, \dots, p$
- $\boldsymbol{\alpha}$: vektor berukuran $m \times 1$ berisi konstanta
- $\boldsymbol{\phi}_i$: matriks parameter variabel endogen berukuran $m \times m$ untuk setiap $i = 1, 2, \dots, p$
- $\boldsymbol{\varepsilon}_t$: vektor galat berukuran $m \times 1$. ($\boldsymbol{\varepsilon} \sim N_p(0, \Sigma)$)

Model VAR(1) yang terdiri dari 2 variabel dapat ditulis:

$$\mathbf{y}_{1,t} = \boldsymbol{\alpha}_1 + \boldsymbol{\phi}_{11} \mathbf{y}_{1,t-1} + \boldsymbol{\phi}_{12} \mathbf{y}_{2,t-1} + \boldsymbol{\varepsilon}_{1,t} \quad (2.2)$$

$$\mathbf{y}_{2,t} = \boldsymbol{\alpha}_2 + \boldsymbol{\phi}_{21} \mathbf{y}_{1,t-1} + \boldsymbol{\phi}_{22} \mathbf{y}_{2,t-1} + \boldsymbol{\varepsilon}_{2,t} \quad (2.3)$$

Persamaan (2.2) dan (2.3) dapat ditulis menjadi:

$$\begin{bmatrix} \mathbf{y}_{1,t} \\ \mathbf{y}_{2,t} \end{bmatrix} = \begin{bmatrix} \boldsymbol{\alpha}_1 \\ \boldsymbol{\alpha}_2 \end{bmatrix} + \begin{bmatrix} \boldsymbol{\phi}_{11} & \boldsymbol{\phi}_{12} \\ \boldsymbol{\phi}_{21} & \boldsymbol{\phi}_{22} \end{bmatrix} \begin{bmatrix} \mathbf{y}_{1,t-1} \\ \mathbf{y}_{2,t-1} \end{bmatrix} + \begin{bmatrix} \boldsymbol{\varepsilon}_{1,t} \\ \boldsymbol{\varepsilon}_{2,t} \end{bmatrix} \quad (2.4)$$

dengan

$$y_t = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} \quad \alpha = \begin{bmatrix} \alpha_1 \\ \alpha_2 \end{bmatrix} \quad \phi = \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{bmatrix} \quad \varepsilon_t = \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix}$$

Sehingga didapatkan model VAR orde p atau VAR(1)

$$y_t = \alpha + \phi y_{t-1} + \varepsilon_t \quad (2.5)$$

2.1.1.2 Model *Vector Autoregressive Exogenous* (VARX)

VARX merupakan pengembangan dari model *Vector Autoregressive* (VAR) yang menggunakan variabel eksogen dalam sistem persamaanya. Model VARX memiliki dua orde, yaitu p yang merupakan orde variabel endogen dan q merupakan orde variabel eksogen (Ocampo & Rodriguez, 2012). Model *Vector Autoregressive Exogenous* (VARX) adalah model deret waktu untuk memodelkan beberapa variabel endogen yang saling berhubungan dan dipengaruhi waktu sebelumnya dan terdapat variabel eksogen yang mempengaruhi variabel endogen. Variabel eksogen (variabel independen) pada VARX ditentukan diluar model dan bersifat mempengaruhi variabel endogen dalam suatu sistem persamaan. Sedangkan variabel endogen (variabel dependen) dalam VARX ditentukan di dalam model dan dapat dipengaruhi oleh variabel eksogen.

Menurut Ocampo & Rodriguez (2012), bentuk umum model VARX adalah sebagai berikut:

$$y_t = \alpha + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 x_{t-1} + \dots + \theta_q x_{t-q} + \varepsilon_t \quad (2.6)$$

dengan :

y_t, y_{t-i} : vektor berukuran $m \times 1$ berisi m endogen pada waktu t dan $t - i$,
dimana $i = 1, 2, \dots, p$

α : vektor berukuran $m \times 1$ berisi konstanta

ϕ_i : matriks parameter variabel endogen berukuran $m \times m$ untuk setiap
 $i = 1, 2, \dots, p$

y_{t-j} : vektor variabel eksogen pada waktu $t - j$, dimana $j = 1, 2, \dots, q$

- θ_j : matriks parameter variabel eksogen berukuran $m \times m$ untuk setiap $j=1,2, \dots, q$
- ε_t : vektor galat berukuran $m \times 1$. ($\varepsilon \sim N_p(0, \Sigma)$)
- p : lag variabel endogen
- q : lag variabel eksogen

Persamaan (2.6) dapat dituliskan dalam matriks berikut:

$$\begin{aligned}
 \begin{bmatrix} y_{1,t} \\ y_{2,t} \\ \vdots \\ y_{K,t} \end{bmatrix} &= \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_K \end{bmatrix} + \begin{bmatrix} \phi_{11(1)} & \phi_{12(1)} & \dots & \phi_{1K(1)} \\ \phi_{21(1)} & \phi_{22(1)} & \dots & \phi_{2K(1)} \\ \vdots & \vdots & \dots & \vdots \\ \phi_{K1(1)} & \phi_{K2(1)} & \dots & \phi_{KK(1)} \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \\ \vdots \\ y_{K,t-1} \end{bmatrix} + \dots + \\
 \begin{bmatrix} \phi_{11(p)} & \phi_{12(p)} & \dots & \phi_{1K(p)} \\ \phi_{21(p)} & \phi_{22(p)} & \dots & \phi_{2K(p)} \\ \vdots & \vdots & \dots & \vdots \\ \phi_{K1(p)} & \phi_{K2(p)} & \dots & \phi_{KK(p)} \end{bmatrix} \begin{bmatrix} y_{1,t-p} \\ y_{2,t-p} \\ \vdots \\ y_{K,t-p} \end{bmatrix} + \begin{bmatrix} \theta_{11(1)} & \theta_{12(1)} & \dots & \theta_{1T(1)} \\ \theta_{21(1)} & \theta_{22(1)} & \dots & \theta_{2T(1)} \\ \vdots & \vdots & \dots & \vdots \\ \theta_{T1(1)} & \theta_{T2(1)} & \dots & \theta_{TT(1)} \end{bmatrix} \\
 \begin{bmatrix} x_{1,t-1} \\ x_{2,t-1} \\ \vdots \\ x_{T,t-1} \end{bmatrix} + \dots + \begin{bmatrix} \theta_{11(q)} & \theta_{12(q)} & \dots & \theta_{1T(q)} \\ \theta_{21(q)} & \theta_{22(q)} & \dots & \theta_{2T(q)} \\ \vdots & \vdots & \dots & \vdots \\ \theta_{T1(q)} & \theta_{T2(q)} & \dots & \theta_{TT(q)} \end{bmatrix} \begin{bmatrix} x_{1,t-q} \\ x_{2,t-q} \\ \vdots \\ x_{T,t-q} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \vdots \\ \varepsilon_{K,t} \end{bmatrix} \quad (2.7)
 \end{aligned}$$

dengan:

- $y_{j,t}$: Data variabel endogen ke j pada waktu t dengan $j = 1,2, \dots, K$ dan $t = 1,2, \dots, n$
- $y_{j,t-i}$: Data variabel endogen ke j pada waktu $t-i$ dengan $j = 1,2, \dots, K$; $t = 1,2, \dots, n$ dan $i = 1,2, \dots, p$
- $x_{m,t-i}$: Data variabel eksogen ke m pada waktu $t-i$ dengan $m = 1,2, \dots, T$; $t = 1,2, \dots, n$ dan $i = 1,2, \dots, q$
- α_j : Konstanta persamaan variabel endogen ke j dengan $j = 1,2, \dots, K$
- $\phi_{jj(i)}$: Koefisien parameter persamaan variabel endogen ke j untuk variabel ke j pada lag i dengan $i = 1,2, \dots, p$
- $\theta_{mm(i)}$: Koefisien parameter persamaan variabel eksogen ke m untuk variabel ke m pada lag i dengan $i = 1,2, \dots, q$
- $\varepsilon_{j,t}$: Residual variabel endogen ke j pada waktu ke t dengan $j = 1,2, \dots, K$ dan $t = 1,2, \dots, n$ ($\varepsilon \sim N_p(0, \Sigma)$)

Model VARX terdiri dari beberapa langkah dasar yaitu:

1. Uji Korelasi Pearson

Uji korelasi Pearson adalah pengujian korelasi yang digunakan untuk mengetahui keeratan hubungan linier antara dua variabel numerik dengan menghitung koefisien korelasi Pearson (r) yang berkisar antara -1 hingga +1. Nilai positif yaitu nilai +1, nilai -1 yaitu nilai negatif, dan nilai 0 yaitu nilai yang tidak terdapat korelasi atau tidak adanya hubungan linear antara kedua variabel (Fu, dkk., 2020). Untuk menentukan Korelasi Pearson dapat ditunjukkan pada persamaan sebagai berikut:

$$r_{xy} = \frac{n\Sigma xy - (\Sigma x)(\Sigma y)}{\sqrt{[(n\Sigma x^2 - (\Sigma x)^2)][n\Sigma y^2 - (\Sigma y)^2]}} \quad (2.8)$$

dengan:

x : variabel pertama

y : variabel kedua

n : banyaknya pengamatan

2. Uji Kointegrasi

Uji kointegrasi merupakan suatu teknik yang digunakan untuk mengetahui hubungan keseimbangan jangka panjang dari beberapa variabel. 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, 2003). Uji kointegrasi Johansen menggunakan statistik uji yaitu *trace statistic* dengan hipotesis sebagai berikut:

H_0 : banyaknya vektor kointegrasi (r) = 0

H_1 : banyaknya vektor kointegrasi (r) > 0

$$Tr(r) = -T \sum_{i=r+1}^k \ln(1 - \hat{\lambda}_i) \quad (2.9)$$

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 unilai nilai yang lebih besar dari uji statistiknya, atau p-value lebih kecil dari nilai signifikansi α .

3. Uji Kausalitas *Granger*

Salah satu masalah yang menarik dalam mempelajari deret waktu vektor adalah kita sering ingin mengetahui apakah ada efek kausalitas diantara variabel-variabel berikut. Dengan kata lain, uji kausalitas *granger* menguji hubungan antara variabel satu dengan variabel lainnya. Ada 4 hal yang dapat diinterpretasikan dari hasil pengujian kausalitas Granger sebagai berikut (Gujarati, 2004):

1. Terdapat kausalitas satu arah dari variabel Y ke X.
2. Terdapat kausalitas satu arah dari variabel X ke Y.
3. Terdapat kausalitas timbal balik (dua arah) dari X ke Y dan Y ke X.
4. Tidak saling ketergantungan atau X dan Y bebas antara satu dengan yang lain.

4. Panjang *Lag* Optimal

Penentuan panjang *lag* optimal harus dilakukan dengan tepat, karena penentuan panjang *lag* optimal dilakukan untuk mencari nilai orde p dan q sehingga nantinya model yang dihasilkan akan memenuhi asumsi yang ada. Penentuan panjang *lag* optimal dapat menggunakan nilai kriteria informasi yang biasa digunakan yaitu *Akaike Information Criterion* (AIC) (Montgomery, dkk., 2015). Panjang *lag* yang optimal yaitu *lag* dengan nilai AIC yang terkecil dapat menentukan mana model terbaik diantara model-model yang memungkinkan

5. Identifikasi Model VARX

Langkah awal dalam mendefinisikan model VARX (p, q) yaitu dengan menentukan orde p dari VAR(p) dan setelah itu menentukan orde q dari variabel

eksogen. Dalam menentukan orde p dan q , dapat menggunakan nilai minimum dari nilai kriteria pemilihan model. Kriteria pemilihan model yang biasa digunakan adalah *Akaike Information Criterion* (AIC). AIC merupakan metode yang digunakan untuk memilih model regresi terbaik yang ditemukan oleh Akaike. Nilai AIC dirumuskan dengan persamaan sebagai berikut (Wei,2006) :

$$AIC(p) = \ln(|\Sigma p|) + \frac{2m^2h}{n} \quad (2.10)$$

dengan :

$|\Sigma p|$: determinan matriks kovarian *residual* model VAR (p)

n : banyaknya pengamatan

h : panjang lag

m : banyaknya variabel endogen dalam model

Pada umumnya, nilai AIC akan sangat kecil dan juga dapat bernilai negatif. Ketika dalam kecocokan model meningkat, maka nilai AIC akan mendekati $-\infty$.

6. Estimasi Parameter Model VARX

Estimasi parameter yaitu pendugaan sementara parameter-parameter yang terdapat dalam suatu model. Salah satu metode yang dapat mengestimasi parameter model VARX adalah metode *Maximum Likelihood*. Model regresi *multivariate* adalah sebagai berikut:

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \cdots + \beta_k X_{1k} + \varepsilon_1 \\ Y_2 &= \beta_0 + \beta_1 X_{21} + \beta_2 X_{22} + \cdots + \beta_k X_{2k} + \varepsilon_2 \\ &\vdots \\ Y_n &= \beta_0 + \beta_1 X_{n1} + \beta_2 X_{n2} + \cdots + \beta_k X_{nk} + \varepsilon_n \end{aligned} \quad (2.11)$$

Berikut bentuk matriksnya:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \cdots & X_{1k} \\ 1 & X_{21} & X_{22} & \cdots & X_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \cdots & X_{nk} \end{bmatrix} \times \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad (2.12)$$

Misalkan,

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{nx1} ; X = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{bmatrix}_{nx(p+q+1)}$$

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix}_{(p+q+1) \times 1} ; \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}_{nx1}$$

dengan:

- β : pendugaan persamaan parameter
- y : data variabel endogen (p)
- x : data variabel eksogen (q)
- Φ : parameter orde p
- θ : parameter orde q
- X : nilai suatu konstanta

Maka matriks pada (2.12) dapat ditulis menjadi persamaan dibawah ini:

$$Y = X\beta + \varepsilon \quad (2.13)$$

dengan $Y \sim N(X\beta, \Sigma)$

Konstruksi fungsi *likelihood* dimulai dengan pembentukan fungsi kepadatan peluang model VARX. Jika persamaan (2.13) diasumsikan berdistribusi normal dengan *mean* 0 dan memiliki variansi, maka terbentuk fungsi kepadatan peluang dari Y dengan parameter β dan Σ yaitu:

$$f(Y_j | \beta, \Sigma) = 2\pi^{-\frac{n}{2}} |\Sigma^{-1}|^{\frac{1}{2}} \exp\left[-\frac{1}{2}(Y_j - X_j\beta)^T \Sigma^{-1}(Y_j - X_j\beta)\right] \quad (2.14)$$

Berdasarkan persamaan (2.14) diperoleh fungsi *likelihood*nya adalah

$$\begin{aligned}
 f(Y_j|\beta, \Sigma) &= \prod_{j=1}^m (2\pi)^{-\frac{n}{2}} |\Sigma|^{-\frac{1}{2}} \exp[-\frac{1}{2}(Y_j - X_j\beta)^T \Sigma^{-1}(Y_j - X_j\beta)] \\
 &= (2\pi)^{-\frac{mn}{2}} |\Sigma|^{-\frac{m}{2}} \exp^{\Sigma_{j=1}^m}[-\frac{1}{2}(Y_j - X_j\beta)^T \Sigma^{-1}(Y_j - X_j\beta)] \\
 &= (2\pi)^{-\frac{mn}{2}} |\Sigma|^{-\frac{m}{2}} \exp[-\frac{1}{2}(Y_j - X_j\beta)^T \Sigma^{-1}(Y_j - X_j\beta)] \quad (2.15)
 \end{aligned}$$

Selanjutnya fungsi *log-likelihood* dari persamaan (2.15)

$$\begin{aligned}
 L &= \ln l \\
 &= \ln[(2\pi)^{-\frac{mn}{2}} |\Sigma|^{-\frac{m}{2}} \exp[-\frac{1}{2}(Y - X\beta)^T \Sigma^{-1}(Y - X\beta)]] \\
 &= -\frac{mn}{2} \ln(2\pi) - \frac{m}{2} \ln(|\Sigma|) \ln(\exp[-\frac{1}{2}(Y - X\beta)^T \Sigma^{-1}(Y - X\beta)]) \\
 &= -\frac{mn}{2} \ln(2\pi) - \frac{m}{2} \ln(|\Sigma|) - \frac{1}{2}(Y^T - X^T \beta^T) \Sigma^{-1}(Y - X\beta) \\
 &= -\frac{mn}{2} \ln(2\pi) - \frac{m}{2} \ln(|\Sigma|) - \frac{1}{2}(Y^T \Sigma^{-1} Y - Y^T \Sigma^{-1} X \beta - X^T \beta^T \Sigma^{-1} Y + \\
 &\quad X^T \beta^T \Sigma^{-1} X \beta) \\
 &= -\frac{mn}{2} \ln(2\pi) - \frac{m}{2} \ln(|\Sigma|) - \frac{1}{2}(Y^T \Sigma^{-1} Y - (Y^T \Sigma^{-1} X \beta)^T - X^T \beta^T \Sigma^{-1} Y + \\
 &\quad X^T \beta^T \Sigma^{-1} X \beta) \\
 &= -\frac{mn}{2} \ln(2\pi) - \frac{m}{2} \ln(|\Sigma|) - \frac{1}{2}(Y^T \Sigma^{-1} Y - 2Y \Sigma^{-1} \beta^T X^T + \beta^T X^T \Sigma^{-1} X \beta) \quad (2.16)
 \end{aligned}$$

Setelah mendapatkan fungsi *log-likelihood* pada persamaan (2.16), langkah selanjutnya yaitu mendapatkan turunan pertama dan menyamakan hasilnya dengan nol. Diperoleh sebagai berikut

$$\begin{aligned}
 \frac{\partial L}{\partial \beta} &= \frac{\partial}{\partial \beta} \left(-\frac{mn}{2} \ln(2\pi) - \frac{m}{2} \ln(|\Sigma|) - \frac{1}{2}(Y^T \Sigma^{-1} Y - 2Y \Sigma^{-1} \beta^T X^T + \beta^T X^T \Sigma^{-1} X \beta) \right) \\
 0 &= -\frac{1}{2}(-2 X^T \Sigma^{-1} Y + X^T \Sigma^{-1} X \beta + (\beta^T X^T \Sigma^{-1})^T) \\
 &= -\frac{1}{2}(-2 X^T \Sigma^{-1} Y + X^T \Sigma^{-1} X \beta + X^T (\Sigma^{-1})^T X \beta) \\
 &= -\frac{1}{2}(-2 X^T \Sigma^{-1} Y + X^T \Sigma^{-1} X \beta + X^T \Sigma^{-1} X \beta) \\
 &= -\frac{1}{2}(-2 X^T \Sigma^{-1} Y + 2 X^T \Sigma^{-1} X \beta) \\
 &= (X^T \Sigma^{-1} Y + X^T \Sigma^{-1} X \beta)
 \end{aligned}$$

$$\begin{aligned}
X^T \Sigma^{-1} Y + X^T \Sigma^{-1} X \beta &= 0 \\
X^T \Sigma^{-1} X \beta &= X^T \Sigma^{-1} Y \\
\beta &= (X^T \Sigma^{-1} X)^{-1} X^T \Sigma^{-1} Y
\end{aligned} \tag{2.17}$$

Jadi, estimasi parameter dari β yaitu $(X^T \Sigma^{-1} X)^{-1} X^T \Sigma^{-1} Y$

Untuk menentukan estimasi parameter Σ^{-1} pada model dapat diperoleh melalui penaksir kuadrat terkecil sehingga diperoleh:

$$\begin{aligned}
\beta_{OLS} &= (X^T X)^{-1} X^T Y \\
&= (X^T X)^{-1} X^T (X\beta + \varepsilon) \\
&= (X^T X)^{-1} X^T X\beta + (X^T X)^{-1} X^T \varepsilon \\
&= I\beta + (X^T X)^{-1} X^T \varepsilon \\
&= \beta + (X^T X)^{-1} X^T \varepsilon
\end{aligned}$$

7. Uji Signifikansi Parameter Model VARX

Uji signifikansi parameter digunakan untuk mengetahui parameter mana saja yang berpengaruh signifikan terhadap model (Montgomery et al., 2015). Uji t dapat digunakan untuk menguji signifikansi parameter pada model Vector Autoregressive Exogenous (VARX) dengan hipotesis sebagai berikut:

H_0 : parameter tidak berpengaruh signifikan terhadap model

H_1 : parameter berpengaruh signifikan terhadap model

dimana uji t statistik untuk parameter endogen memiliki rumus yaitu:

$$t_{hitung} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \tag{2.18}$$

dan uji t statistik untuk parameter eksogen memiliki rumus yaitu:

$$t_{hitung} = \frac{\hat{\phi}_j}{SE(\hat{\phi}_j)} \tag{2.19}$$

dengan:

$\hat{\phi}_i$: nilai dugaan parameter endogen ke- i

$\hat{\phi}_j$: nilai dugaan parameter eksogen ke- j

SE : *standard error*

jika nilai $|t_{hitung}| > t_{\frac{\alpha}{2}(n-m)}$ atau $p - value < \alpha$ maka H_0 ditolak atau dengan kata lain paramter berpengaruh signifikansi terhadap model VARX. Dimana n adalah jumlah pengamatan dan m adalah jumlah variabel endogen atau eksogen.

8. Uji Asumsi *Residual*

Pada pemodelan VARX asumsi yang sebaiknya dipenuhi yaitu asumsi *residual white noise* dan berdistribusi normal multivariate (Wei, 2006).

a. Uji Asumsi *Residual White Noise*

Residual yang bersifat *white noise* artinya tidak terdapat korelasi dari vektor residual di dalam model hingga lag ke h . Pengujian yang dilakukan yang bisa digunakan adalah Portmanteau Tes (Lutkepohl, 2005). Uji Portmanteau merupakan generalisasi dari uji L-jung Box pada kasus multivariate. Uji ini diperkenalkan pertama kali oleh Box dan Pierce pada tahun 1970. Berikut adalah hipotesis pengujian :

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual memenuhi asumsi *white noise*)

$H_1 : \text{minimal ada satu } \rho_j \neq 0, j = 1, 2, 3, \dots, k$ (residual tidak memenuhi asumsi *white noise*)

Statistik uji:

$$Q = n(n + 2) \sum_{k=1}^k (n - k)^{-1} \hat{\rho}_{k-p-q}^2 \quad (2.20)$$

dengan:

$\hat{\rho}$: autokorelasi *residual*

K : banyaknya *lag residual*

N : banyaknya pengamatan

Ketika $Q > X_{k-p-q}^2$ atau $p - value < \alpha$, maka tolak H_0 yang artinya residual tidak memenuhi asumsi *white noise*.

b. Uji Normalitas Multivariat

Uji normalitas residual digunakan untuk mengetahui normal data residual pada suatu model multivariate. Uji normalitas bertujuan untuk mengetahui apakah sebaran data mengikuti sebaran normal, yaitu data mengikuti atau mendekati sebaran yang datanya berbentuk lonceng (Santoso, 2018). Data yang baik yaitu

ketika data memiliki pola seperti sebaran normal. Uji normal residual dapat menggunakan *Jarque-Bera Test of Normality*. Tahapan uji normal residual adalah sebagai berikut:

1. Hipotesis

H_0 : data residual berdistribusi normal

H_1 : data residual tidak berdistribusi normal

2. Taraf signifikan

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

3. Daerah kritis

- Jika $JB_{hitung} > X^2_{(tabel)}$ atau $P\text{-value} < \alpha$ maka tolak H_0
- Jika $JB_{hitung} < X^2_{(tabel)}$ atau $P\text{-value} > \alpha$ maka tidak tolak H_0

4. Statistik uji

$$JB_{hitung} = \left[\frac{N}{6} b_1^2 + \frac{N}{24} (b_2 - 3)^2 \right] \quad (2.21)$$

5. Keputusan dan kesimpulan

2.2 Stasioneritas Data

Stasioner berarti bahwa tidak terdapat perubahan drastis pada data. Sebelum menganalisis data, asumsi penting tentang stasioneritas dalam analisis data deret waktu harus diperiksa. *Time series* dikatakan stasioner keseluruhan apabila tidak terjadi kenaikan ataupun penurunan nilai secara tajam pada data (fluktuasi data berada pada sekitar nilai rata-rata yang konstan). Data deret waktu dikatakan stasioner apabila nilai ragam dan rata-rata konstan pada setiap waktu (Wei, 2006). 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 signifikan

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

3. Daerah kritis

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

4. Statistik uji

$$ADF_{hitung} = \frac{\hat{\phi}-1}{SE(\hat{\phi})} \quad (2.22)$$

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 . Berikut bentuk dari persamaan *backward shift*.

$$By_t = y_{t-1} \quad (2.23)$$

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

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

$$y_t' = \Delta y_t = y_t - y_{t-1} = y_t - By_t = (1 - B)y_t \quad t = 2,3, \dots n \quad (2.24)$$

Adapun persamaan untuk orde *difference* = 2

$$y_t'' = \Delta^2 y_t = (y_t' - y_{t-1}') = (1 - 2B + B^2)y_t = (1 - B)^2 y_t, \quad t = 3,4, \dots n \quad (2.25)$$

Dengan demikian bentuk umum untuk *differencing* sebanyak d kali yaitu sebagai berikut :

$$(1 - B)^d y_t \quad (2.26)$$

2.3 *Machine Learning* (Pembelajaran Mesin)

Machine Learning adalah salah satu cabang dari ilmu kecerdasan buatan yang mempelajari tentang bagaimana komputer mampu mempelajari pola data sehingga dapat meningkatkan kecerdasannya. Teknologi *machine learning* dikembangkan agar komputer bisa belajar dengan sendirinya tanpa arahan dari penggunanya.

Ciri khas dari *machine learning* adalah adanya proses pembelajaran atau training dan pelatihan (Mitchell, T., 1997). Training data adalah hal yang penting, apabila training data tidak mampu merepresentasikan populasi, maka model yang dihasilkan pembelajaran (training) tidak baik. Tujuan dari *machine learning* adalah untuk mengembangkan metode yang dapat secara otomatis mendeteksi pola dalam data dan menggunakan pola yang tidak terungkap untuk memprediksi data di masa mendatang atau hasil lain yang menarik. *Machine learning* mempunyai 3 teknik atau algoritma pembelajaran yaitu (Goodfellow, dkk., 2016):

1. *Supervised Learning*

Dalam *supervised learning*, algoritma mempelajari hubungan antara *input* dan *output* yang telah diberi label. Ini berarti data pelatihan yang digunakan untuk melatih model memiliki pasangan input dan output yang diketahui. Tujuannya adalah untuk membuat prediksi yang akurat untuk *input* baru yang tidak diketahui. Contoh algoritma dalam *supervised learning* termasuk regresi linier, *decision tree*, dan *neural networks*.

2. *Semi-Supervised Learning*

Semi-supervised learning adalah pendekatan di mana algoritma menggunakan kombinasi data yang diberi label dan tidak diberi label untuk melakukan pembelajaran. Jumlah data yang dilabeli umumnya lebih sedikit daripada data yang tidak dilabeli. Contoh algoritma dalam *semi-supervised learning* termasuk metode *Expectation-Maximization* (EM) dan *Co-Training*.

3. *Unsupervised Learning*

Dalam *unsupervised learning*, algoritma belajar dari data yang tidak dilabeli tanpa memiliki informasi output yang diinginkan. Tujuannya adalah untuk

menemukan pola, struktur, atau kategori yang tersembunyi dalam data. Contoh algoritma dalam *unsupervised learning* termasuk *K-means clustering*, *hierarchical clustering*, dan *Principal Component Analysis (PCA)*

2.4 Deep Learning

Deep learning merupakan salah satu cabang dari *machine learning* yang menggunakan *neural networks* dengan banyak lapisan (*layer*) untuk mempelajari representasi data yang kompleks dan abstrak. Prinsip *deep learning* adalah *Artificial Neural Network (ANN)* yang memiliki banyak lapisan tersembunyi (Pumsirirat & Yan, 2018). *Deep learning* merupakan algoritma dalam *machine learning* yang belajar dalam berbagai tingkatan dan biasanya menggunakan jaringan syaraf tiruan, tingkatan dalam model statistik yang dipelajari sesuai dengan tingkat konsep yang berbeda, di mana konsep tingkat yang lebih tinggi ditentukan dari tingkat yang lebih rendah, dan konsep tingkat yang lebih rendah dapat membantu untuk mendefinisikan banyak konsep tingkat yang lebih tinggi.

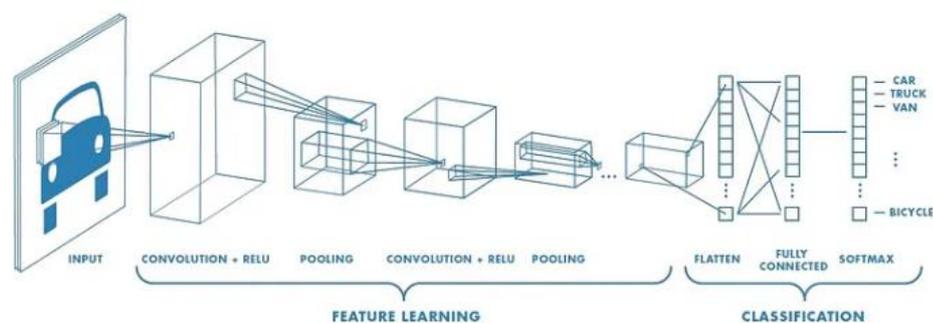
Deep learning telah memberikan hasil yang sangat baik dalam berbagai bidang, termasuk pengenalan wajah, klasifikasi gambar, dan pengenalan suara. *Deep learning* juga digunakan dalam peramalan untuk menghasilkan model yang lebih akurat dalam memprediksi data waktu atau data numerik. Lapisan pada *deep learning* biasanya memiliki jumlah puluhan hingga ratusan lapisan yang berurutan dan lapisan-lapisan dan secara otomatis dapat mempelajari data *training* yang diberikan. Lapisan representasi pada *deep learning* tersebut bernama *neural networks*. *Neural Networks* mengambil konsep dari bidang *neurobiology* dan terinspirasi dari kemampuan dalam memahami sesuatu seperti yang dilakukan oleh otak manusia.

2.5 Convolutional Neural Network (CNN)

CNN adalah salah satu algoritma perkembangan dari *Artificial Neural Network* (ANN) dan variasi dari *Multilayer Perceptron* (MLP) yang dirancang untuk mengolah data dua dimensi dengan kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN merupakan jenis *neural network* yang memiliki lapisan konvolusi (*convolutional layer*) yang memungkinkan jaringan untuk mempelajari fitur-fitur pada gambar secara hierarkis (Goodyellow, dkk., 2016). Pada jaringan *deep learning*, fitur yang berbeda dari CNN adalah penggunaan *convolutional layer*. Untuk data *time series* dalam satu dimensi, CNN juga baik dalam melakukan analisis yang sesuai dengan menggunakan *convolutional layer 1D*.

2.5.1 Arsitektur Convolutional Neural Network

Convolutional Neural Network (CNN) terdiri dari *input layer*, *output layer* dan sejumlah *hidden Layers*. Pada *hidden layers* atau lapisan tersembunyi berisi *convolutional layers*, *pooling layers* dan *fully connected layers*. Berikut ini adalah gambar lapisan pada metode *Convolutional Neural Network* :



Gambar 1. Arsitektur *Convolutional Neural Network* (Fadli, dkk., 2022)

Berdasarkan Gambar 1, tahap pertama pada arsitektur CNN adalah tahap konvolusi. Pada setiap layer konvolusi, operasi konvolusi dilakukan dengan menggunakan kernel konvolusi dengan ukuran tertentu dan jumlah filter pada *layer* tersebut. Setelah dilakukan operasi konvolusi, hasilnya ditransformasi menggunakan fungsi aktivasi seperti ReLU. Kemudian, pada *layer* pooling, data diubah menjadi data dengan dimensi yang lebih kecil dengan mengambil nilai maksimum atau rata-rata pada tiap daerah pada data input. Setelah beberapa *layer* konvolusi dan pooling, hasilnya kemudian diflatten menjadi satu dimensi dan dihubungkan dengan beberapa *layer fully connected* untuk menghasilkan output dalam bentuk kelas atau kategori.

Berdasarkan Gambar 1, dapat dijelaskan untuk masing-masing *layer* sebagai berikut:

1. *Layer Input*

Layer ini berfungsi untuk menerima input data dalam bentuk gambar atau vektor fitur lainnya. Pada *layer* ini, data akan diolah dan dikirim ke *layer* selanjutnya.

2. *Convolutional Layer*

Convolution layer berfungsi untuk mengekstrak fitur dari data *input* (Azmi, 2023). *Layer* ini telah mempelajari pelajari filter-filter secara acak yang digunakan untuk melakukan operasi konvolusi, sehingga dapat mengidentifikasi pola dan tren dalam *data time series* yang relevan untuk peramalan. Dalam pelatihan CNN, bobot pada *layer* konvolusi akan menspesifikasikan kernel konvolusi yang digunakan untuk melatih model. Dengan demikian, konvolusi *layer* memiliki peran penting dalam mempelajari representasi fitur dari *input layer*.

3. *Pooling Layer*

Pooling layer berfungsi untuk mengurangi ukuran spasial dari fitur konvolusi dan mempercepat proses pelatihan model dengan pengurangan dimensi dari *feature map*. Tujuan dari penggunaan pooling layer adalah mengurangi dimensi dari feature map (*downsampling*), sehingga mempercepat komputasi karena parameter yang harus di update semakin sedikit dan mengatasi overfitting (Kholik, 2021).

4. *Flatten Layer*

Layer ini mengubah *output* dari *layer* sebelumnya (yang berupa matriks 2D) menjadi vektor 1D untuk kemudian disimpan sebagai *input* pada *layer fully connected* (Nugroho, dkk. 2020). Dalam peramalan, *layer flatten* membantu mengubah *output* dari lapisan konvolusi menjadi bentuk yang dapat diproses oleh lapisan *dense*.

5. *Fully Connected Layer*

Lapisan *fully connected* atau *dense layer* berfungsi untuk menghubungkan setiap neuron dari *layer* sebelumnya ke setiap neuron pada *layer* berikutnya dengan koneksi penuh. Dalam peramalan, lapisan ini dapat digunakan untuk memprediksi *output* berdasarkan fitur-fitur yang telah diekstrak dari data *input*.

2.5.2 Fungsi Aktivasi

Fungsi aktivasi digunakan agar *neural network* mengenali data yang non-linear, karena *output* yang dihasilkan dari *neural network* jarang sekali bersifat linear. Fungsi aktivasi membantu dalam menentukan apakah suatu neuron harus aktif atau tidak (Goodfellow, dkk., 2016).

Fungsi aktivasi pada arsitektur Convolutional Neural Network (CNN) terletak pada perhitungan akhir keluaran *feature map* atau sesudah proses perhitungan konvolusi atau pooling untuk menghasilkan suatu pola fitur. Fungsi aktivasi nonlinear yang sering digunakan adalah sebagai berikut (Nwankpa, dkk., 2018):

1). Fungsi Sigmoid

Fungsi sigmoid digunakan untuk memperoleh *output* yang bersifat nonlinear, dirumuskan sebagai berikut:

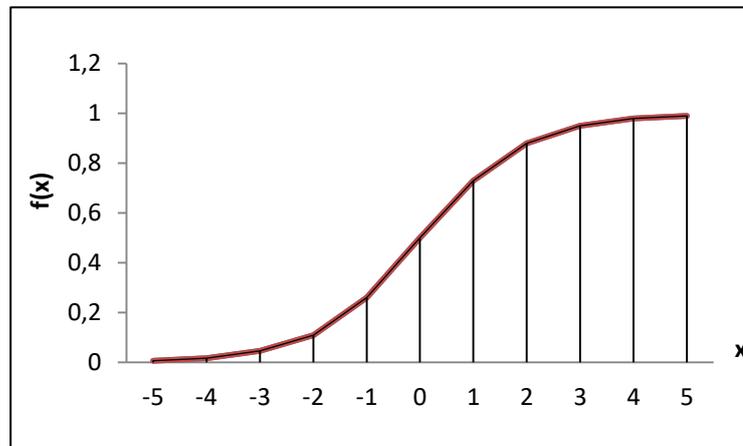
$$f(x) = \frac{1}{1+e^{-x}} \quad (2.27)$$

dengan:

x : data

e : bilangan euler

Output yang dihasilkan oleh fungsi sigmoid akan membentuk grafik yang ditunjukkan oleh Gambar 2



Gambar 2. Fungsi Aktivasi Sigmoid

Pada fungsi sigmoid apabila semakin kecil input maka *output* yang dihasilkan akan mendekati nol dan jika semakin besar input maka *output* yang dihasilkan akan mendekati satu. Fungsi ini digunakan untuk model di mana kita harus memprediksi probabilitas sebagai *output*. Karena probabilitas apa pun hanya ada di antara rentang 0 dan 1.

2). Fungsi Tanh

Fungsi aktivasi Tanh merupakan fungsi non linear. Input untuk fungsi aktivasi ini berupa bilangan *real* dan *output* dari fungsi tersebut memiliki range antara -1 sampai 1 (Nwankpa, dkk., 2018). Fungsi tanh merupakan pengembangan dari fungsi sigmoid.

Fungsi aktivasi tanh memiliki persamaan sebagai berikut:

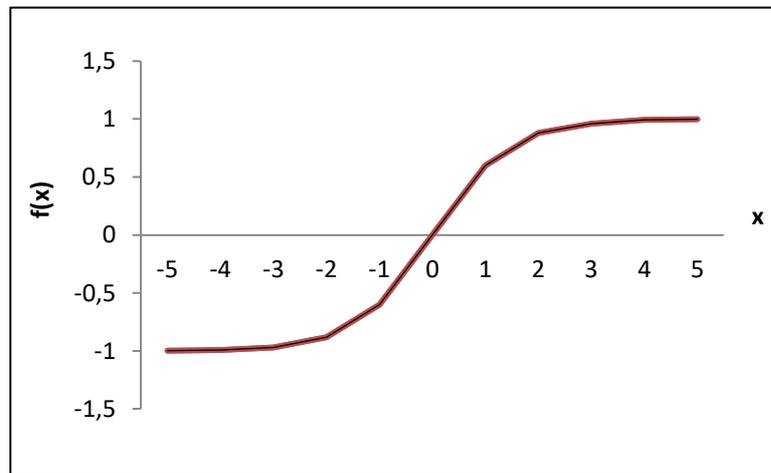
$$f(x) = \frac{2}{1+e^{-2x}} - 1 \quad (2.28)$$

dengan:

x : data

e : bilangan euler

Output yang dihasilkan oleh fungsi sigmoid akan membentuk grafik yang ditunjukkan oleh Gambar 3



Gambar 3. Fungsi Aktivasi Tanh

Keuntungan dari fungsi ini yaitu inputan *negative* akan dipetakan *negative* dan inputan nol akan dipetakan mendekati nol dalam grafik tanh.

3. Fungsi ReLU

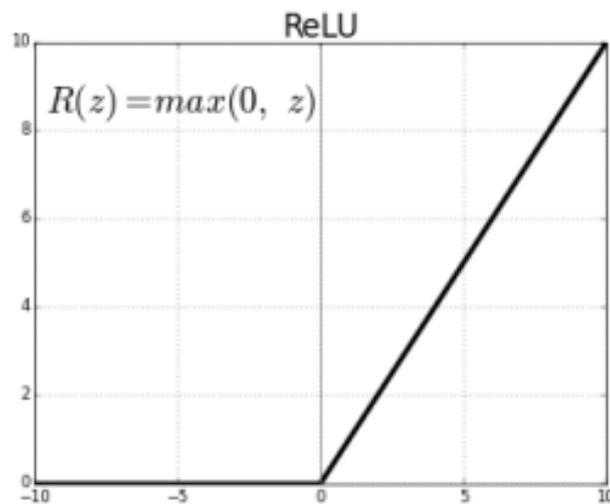
Fungsi aktivasi ReLU (*Rectified Linear Unit*) digunakan untuk mengaktifkan atau menonaktifkan neuron pada suatu *layer* (Nwankpa, dkk., 2018). ReLU hanya menghasilkan keluaran positif dari neuron dan nol untuk *input* negatif. ReLU bekerja dengan cara mengubah nilai negatif menjadi 0, sedangkan nilai positif dipertahankan. Secara matematis, fungsi ReLU dapat diwakili dengan rumus:

$$f(x) = \max(0, x) \quad (2.29)$$

dengan:

x : data

Output yang dihasilkan oleh fungsi ReLU akan membentuk grafik yang ditunjukkan oleh Gambar 4



Gambar 4. Fungsi Aktivasi ReLU

Seperti yang terlihat pada grafik, ReLU memberikan *output* 0 untuk nilai *input* yang kurang dari atau sama dengan 0 dan *output* sama dengan nilai *input* untuk nilai *input* yang lebih besar dari 0.

2.6 Normalisasi Data

Normalisasi data adalah elemen dasar data mining untuk memastikan record pada dataset tetap konsisten. Tujuan utama dari normalisasi data yakni menghilangkan pengulangan data dan menstandarisasi informasi untuk alur kerja data yang lebih baik. Ada beberapa metode dalam normalisasi data, yaitu :

a. Normalisasi Min-Max

Proses ini dilakukan untuk membuat data-data tidak memiliki range yang jauh satu sama lain. Metode ini mengubah sebuah kumpulan data menjadi skala mulai dari 0 hingga 1 (Izonin, dkk., 2022). Teknik ini digunakan jika standar deviasinya kecil dan ketika bukan distribusi normal. Nilai minimum dan maksimum dari data diambil dan setiap nilai diubah menggunakan rumus berikut:

$$Z = \frac{x - \min(x)}{[\max(x) - \min(x)]} \quad (2.30)$$

dengan :

z : data hasil normalisasi

x : data asli

$\min(x)$: nilai minimum dari data x

$\max(x)$: nilai maximum dari data x

b. Normalisasi Z-score

Normalisasi Z-score atau biasa dikenal dengan standarisasi merupakan teknik dimana nilai pada atribut akan dinormalisasi berdasarkan mean dan standar deviasi. Teknik ini mentransformasikan data dari nilai ke skala umum di mana angka rata-rata (mean) sama dengan nol dan standar deviasi adalah 1 (Izonin, dkk., 2022). Berikut rumus dari normalisasi Z-score:

$$z = \frac{x - \text{mean}(x)}{\text{stdev}(x)} \quad (2.31)$$

dengan :

z : data hasil normalisasi

x : data asli

$\text{mean}(x)$: nilai rata-rata dari x

$\text{stdev}(x)$: nilai standar deviasi dari x

2.7. Hybrid VARX-CNN

Metode *hybrid* adalah perkembangan peramalan dalam *time series* yang menggabungkan dua metode tunggal, salah satunya yaitu penggabungan metode VARX dan metode CNN. Model VARX dan CNN merupakan model untuk mengatasi masalah linier atau nonlinier. Zhang (2003) menjelaskan bahwa pengembangan metode *hybrid* dilakukan untuk meningkatkan efisiensi dalam tahapan analisis peramalan deret waktu. Sulit untuk menentukan apakah deret waktu mengandung pola linier ataupun pola nonlinier, sehingga membuat peneliti menggunakan lebih dari satu metode untuk dilakukan perbandingan. Dengan melakukan kombinasi *hybrid*, maka permasalahan seleksi model dapat

diminimalisir. Secara umum, kombinasi dari model *time series* yang memiliki struktur autokorelasi linier dan nonlinier dapat dituliskan sebagai berikut:

$$y_t = L_t + N_t \quad (2.32)$$

dengan:

- y_t : nilai aktual ke t
- L_t : komponen linear ke t
- N_t : komponen nonlinear ke t
- t : indeks waktu

Misal e_t menunjukkan residual pada saat t dari model linear, maka:

$$e_t = y_t - L'_t \quad (2.33)$$

dengan:

- y_t : nilai aktual ke t
- L'_t : nilai peramalan untuk t waktu
- e_t : nilai residual ke t
- t : indeks waktu

Residual sangat penting dalam mendiagnosa model-model linear. Pemodelan residual menggunakan CNN dapat menemukan hubungan nonlinear pada data *time series*. Sehingga pemodelan residual menggunakan CNN dengan n input akan menjadi:

$$e_t = f(e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-n)} + \varepsilon_t) \quad (2.34)$$

dengan:

- ε_t : nilai residual ke t
- f : fungsi nonlinear dari CNN
- t : indeks waktu

Sehingga, kombinasi peramalan akan menjadi:

$$y'_t = L'_t + N'_t \quad (2.35)$$

dengan:

- y'_t : prediksi dari model hybrid ke t
- L'_t : prediksi komponen linear dari CNN ke t

N'_t : prediksi komponen residual dari CNN ke t
 t : indeks waktu

Tujuan dari metodologi system *hybrid* ada dua tahap. Tahap pertama, model VARX digunakan untuk menganalisis bagian linear. Dan tahap kedua, model CNN dibangun untuk memodelkan nilai residual dari model VARX. Karena model VARX tidak dapat menangkap struktur nonlinear dari data, model residual dari linear akan memiliki informasi tentang nonlinear dan hasil dari CNN dapat digunakan untuk meramalkan *error* untuk model VARX.

2.8 Validasi Model

Validasi model peramalan digunakan sebagai ukuran ketepatan model. Teknik peramalan yang menggunakan data kuantitatif dengan data runtut waktu tertentu, terdapat *error* atau kesalahan yang dihasilkan dari teknik tersebut. Oleh karena itu, dibutuhkan metode untuk mengukur seberapa besar *error* yang dihasilkan dari metode-metode peramalan sebagai pertimbangan kembali sebelum dibuat keputusan. Metode-metode yang paling umum digunakan untuk mengevaluasi *error* pada teknik peramalan antara lain *Mean Absolute Percentage Error* (MAPE), *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE).

Mean Absolute Percentage Error (MAPE) merupakan pengukuran kesalahan yang menghitung ukuran persentase penyimpangan antara data aktual dengan data peramalan. Nilai MAPE dapat dihitung dengan persamaan berikut (Khasanah, dkk., 2020):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left(\frac{|X_t - F_t|}{X_t} \times 100\% \right) \quad (2.36)$$

dengan:

X_t : data aktual pada periode ke- t
 F_t : nilai peramalan pada periode ke- t
 n : jumlah data

Mean Square Error (MSE) digunakan untuk mengukur rata-rata *error* atau kesalahan kuadrat antara nilai aktual dan nilai peramalan. Semakin kecil nilai MSE, maka semakin baik hasil peramalan yang dihasilkan.

$$MSE = \frac{1}{n} \sum_{t=1}^n (X_t - F_t)^2 \quad (2.37)$$

dengan:

X_t : data aktual pada periode ke- t

F_t : nilai peramalan pada periode ke- t

n : jumlah data

Root Mean Square Error (RMSE) dapat ditafsirkan sebagai akar dari rata-rata *error* atau kesalahan prediksi dikuadratkan. Semakin kecil atau mendekati nol nilai RMSE maka hasil prediksi semakin baik atau akurat.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (X_t - F_t)^2} \quad (2.38)$$

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun akademik 2022/2023, bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu tentang data ekspor Indonesia (USD), impor Indonesia (USD), kurs (IDR), inflasi (persen) dan BI rate (persen). Dimana data ekspor dan impor Indonesia sebagai variabel endogen, sedangkan data kurs, inflasi dan BI rate sebagai variabel eksogen. Data yang digunakan adalah data bulanan sejak Januari 2014 hingga Desember 2021 Total data yang digunakan sebanyak 96 data. Data yang digunakan diperoleh dari situs berikut ini:

| | |
|--------------|---|
| Data Impor | https://www.bps.go.id/exim/ |
| Data Ekspor | https://www.bps.go.id/exim/ |
| Data BI rate | https://www.bps.go.id/indicator/13/379/10/bi-rate.html |
| Data Inflasi | https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx |
| Data Kurs | https://www.bi.go.id/id/statistik/informasi-kurs/transaksi-bi/default.aspx |

Tabel 1. Data Ekspor, Impor, Kurs, Inflasi, dan BI Rate

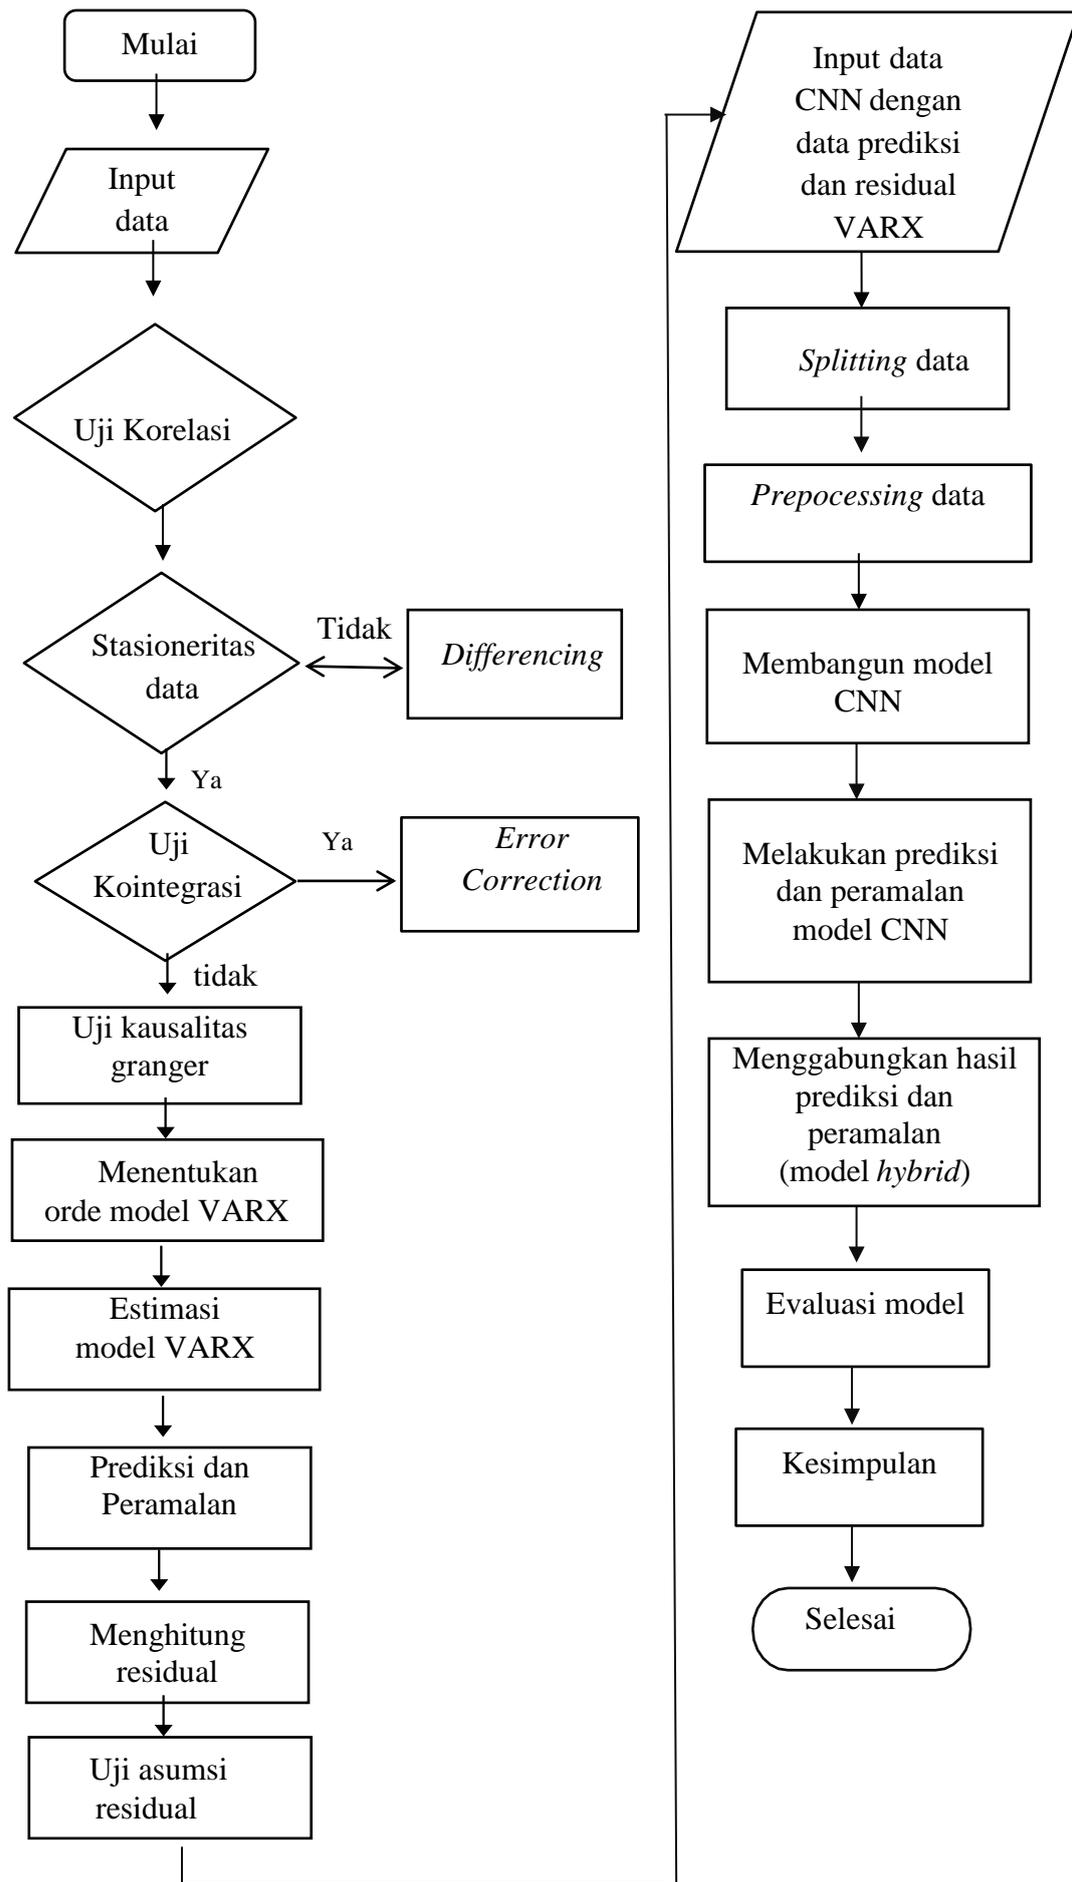
| Periode | Ekspor (USD) | Impor (USD) | Kurs (IDR) | Inflasi (%) | BI rate (%) |
|---------|-----------------|----------------|---------------|----------------|----------------|
| Jan-14 | 1.47E+10 | 1.49E+10 | 10830 | 0.0822 | 7.5 |
| Feb-14 | 1.46E+10 | 1.37E+10 | 10749 | 0.0775 | 7.5 |
| Mar-14 | 1.51E+10 | 1.45E+10 | 10411 | 0.0732 | 7.5 |
| Apr-14 | 1.42E+10 | 1.62E+10 | 10701 | 0.0732 | 7.5 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| Des-21 | 2.23E+10 | 2.13E+10 | 14401 | 0.0187 | 3.5 |

3.3 Metode Penelitian

Berikut merupakan alur dari pengerjaan metode hybrid VARX – CNN :

1. Melakukan input data yang terdiri dari ekspor, impor, kurs, inflasi, dan BI rate.
2. Melakukan Uji Korelasi Pearson variabel endogen.
3. Menguji kestasioneran semua variabel dengan menggunakan plot atau uji akar unit *Augmented Dicky Fuller* (ADF). Jika tidak stasioner maka perlu dilakukan proses *differencing*.
4. Melakukan uji kointegrasi variabel endogen.
5. Menguji hubungan sebab akibat variabel satu dengan variabel lainnya menggunakan uji kausalitas *granger*.
6. Menentukan orde model VARX dengan melihat nilai minimum kriteria informasi yang sering digunakan yaitu *Akaike's Information Criterion* (AIC).
7. Melakukan estimasi parameter model VARX.
8. Melakukan prediksi dan peramalan dengan model VARX yang terpilih
9. Berdasarkan Model VARX yang telah ada, kemudian membuat data residual dari model VARX.

10. Menguji asumsi residual model VARX yang meliputi asumsi-asumsi berikut:
 - a. Asumsi *residual white noise* dengan menggunakan uji L-jung Box
 - b. Asumsi normalitas *multivariate* dengan menggunakan uji Jarque-Bera
11. Data prediksi dan data residual dari VARX digunakan sebagai input untuk diolah dengan menggunakan CNN.
12. Melakukan *splitting* untuk data dengan skema training dan testing 70:30 dan 80:20
13. Melakukan *preprocessing* data, yaitu dengan melakukan normalisasi pada data prediksi dan residual menggunakan *min-max normalization*
14. Membangun model CNN berdasarkan data prediksi dan data residual VARX.
15. Melakukan prediksi dan peramalan model CNN berdasarkan data prediksi dan data residual VARX
16. Menggabungkan hasil prediksi dan peramalan dari model *hybrid* dengan penjumlahan.
17. Mengukur ketepatan dan keakuratan model *hybrid* VARX-CNN dengan melihat nilai MAPE dan akurasi.



Gambar 5. Diagram Alir Metode Penelitian

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Setelah melakukan beberapa tahapan dalam proses peramalan model *hybrid*, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Metode *hybrid* VARX-CNN menghasilkan prediksi yang lebih baik untuk data fluktuasi seperti data ekspor impor di Indonesia daripada model yang hanya menggunakan VARX. Metode *hybrid* ini menghasilkan MAPE terbaik yaitu 0,088 dengan akurasi sebesar 99,91% dan skema *splitting* yang terbaik yaitu 80% *training* dan 20% *testing*. Sedangkan untuk metode VARX menghasilkan MAPE yaitu 0,144 dengan akurasi sebesar 99,85%.
2. Peramalan dari metode *hybrid* VARX-CNN menghasilkan peramalan yang lebih baik dan hasilnya mengikuti pola data *ter-update* serta mengalami kenaikan untuk nilai ekspor impor Indonesia dibandingkan dengan peramalan menggunakan metode VARX yang mengalami penurunan nilai untuk ekspor impor Indonesia dari bulan Januari 2022 sampai dengan Maret 2023.

Sehingga dapat disimpulkan dalam penelitian ini bahwa metode *hybrid* VARX-CNN lebih baik daripada hanya menggunakan metode VARX untuk data ekspor dan impor Indonesia.

5.2 Saran

Berdasarkan hasil kesimpulan pada penelitian tersebut, saran yang dapat peneliti berikan untuk penelitian selanjutnya yaitu dengan menggunakan data yang lebih

besar untuk melakukan analisis atau menggunakan data harian. Data yang besar dapat digunakan untuk melakukan *splitting* data dengan skema yang lebih bervariasi contohnya skema 90% *training* dan 10 % *testing*.

DAFTAR PUSTAKA

- Amry, F., Kusnandar, D., & Debataraaja, N.N. 2018. Model Vector Autoregressive (VAR) dalam Meramal Produksi Kelapa Sawit PTPN XIII. *Buletin Ilmiah Matematika, Statistika dan Terapannya*. **7**(2): 77-84
- Azmi, K., Defit, S., & Sumijan, S. 2023. Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat. *Jurnal Unitek*. **16**(1): 28-40.
- Barzagar, R. Alam, M.T., & Adamowski, J. 2020. Short-term water quality variable prediction using a hybrid CNN-LSTM deep learning model. *Stochastic Environmental Research and Risk Assessment*. **34**(1): 415-433.
- Fadli, F., Suwilo, S., & Zarlis, M., 2022. Model Prediksi Data Besar Distribusi Produk Farmasi: Analisis Kinerja Model Deep Learning. *CSRID (Computer Science Research and Its Development Journal)*. **14**(1): 68-80.
- Ferry, C. R., Irwan, & Nurfadilah. 2018. Peramalan Tingkat Suku Bunga Pasar Uang Antar Bank (PUAB) dengan Vector Autoregressive Exogenous (VARX). *Jurnal MSA*. **06**(1): 51-60.
- Fu, T., Tang, X., Cai, Z., Zuo, Y., Tang, Y., & Zhao, X. 2020. Correlation research of phase angle variation and coating performance by means of Pearson's correlation coefficient. *Progress in Organic Coatings*, **139**, p.105459.
- Gujarati, D. N. 2004. *Basic Econometrics*. 4th Edition. McGraw-Hill, New York.
- Gujarati, D.N. 2003. *Ekonometrika dasar (terjemahan)*. Erlangga, Jakarta.
- Goodfellow, I., Bengio, Y., & Courville, A. 2016. *Deep learning*. MIT press.

- Halimi, I., Marthasaari, G. I., & Azhar, Y. 2019. Prediksi Harga Emas Menggunakan Convolutional Neural Network. *Jurnal Repositor*. **1**(2): 105-116.
- Izonin, I., Tkachenko, R., Shakhovska, N., Ilchyshyn, B., & Singh, K.K. 2022. A Two-Step Data Normalization Approach for Improving Classification Accuracy in the Medical Diagnosis Domain. *Mathematics*. **10**(11): 1942.
- Khasanah, S.U., Indriyanti, A.D., & Andriani, A. 2020. Sistem Peramalan Penjualan Tas pada Toko Firdaus Bag Berbasis Web Menggunakan Metode Moving Average. *INOVATE*. **4**(2): 28-36.
- Kholik, A. 2021. Klasifikasi Menggunakan Convolutional Neural Network (Cnn) Pada Tangkapan Layar Halaman Instagram. *Jurnal Data Mining dan Sistem Informasi*. **2**(2): 10-20.
- Le, T., Vo, M.T., Vo, B., Hwang, E., Rho, S., & Baik, S.W. 2019. Improving electric energy consumption prediction using CNN and Bi-LSTM. *Applied Sciences*. **9**(20): 4237.
- Lütkepohl, H. 2005. *New Introduction to Multiple Time Series Analysis*. Springer, Berlin.
- Makridakis, S., Wheelwright, S.C., & McGee, V.E. 1999. *Forecasting Methods and Application*. Erlangga, Jakarta.
- Mitchell, T. 1997. *Machine Learning*. McGraw-Hill, New York.
- Montgomery, D. C., Jennings, L. C., & Kulahci, M. 2015. *Introduction to time series analysis and forecasting*. 2nd edition. John Wiley dan Sons, New Jersey
- Moorey, N.H., Alwi, M., & Yusuf, T. 2021. Pengaruh Inflasi, Suku Bunga, Dan Nilai Tukar Terhadap Indeks Harga Saham Gabungan Di Bursa Efek Indonesia. *Jurnal GeoEkonomi*. **12**(1): 67-78.

- Muschilati, E., & Irsalinda, N. 2020. Forecasting Tourist Visit Using the Vector Autoregressive Exogenous Method (VARX). *Jurnal Ilmiah Matematika*. **7**(2) : 81-87.
- Nugroho, P.A., Fenriana, I., & Arijanto, R. 2021. Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Jurnal ALGOR*. **2**(1): 1-21
- Nwankpa, C. E., Ijomah, W., Gachagan, A., & Marshall, S. 2018. Activation functions: Comparison of trends in practice and research for deep learning. *Open Journal of Statistics*. **1**(1): 1–20
- Ocampo, S. & Rodriguez, N. 2012. An Introductory Review of a Structural VAR-X Estimation and Applications. *Revista Colombiana de Estadística*. **35**(3): 479-508.
- Pumsirirat, A., & Yan, L. 2018. Credit Card Fraud Detection using Deep Learning based on Auto-Encoder and Restricted Boltzmann Machine. *International Journal of Advanced Computer Science and Applications (IJACSA)*. **9**(1): 18–25.
- Rosyidah, H., Rahmawati, R., & Prahutama, A. 2017. Pemodelan Vector Autoregressive X (VARX) Untuk Meramalkan Jumlah Uang Beredar di Indonesia. *Jurnal Gaussian*. **06**(3): 333-343.
- Santoso, S. 2018. *Mahir Statistik Multivariat Dengan SPSS*. PT Elex Media Komputindo, Jakarta.
- Sulaiman, M. 2019. Pengaruh Inflasi, Ekspor Netto dan Cadangan Devisa Terhadap Nilai Tukar Rupiah Terhadap Dollar AS. *Fakultas Ekonomi Dan Bisnis, Universitas Tanjung Pura Pontianak*. **1**(1): 78-89.
- Vinie, R.A.E., Martha, S., & Rizki, S.W. 2019. Model Vector Autoregressive Exogenous (VARX) Dalam Memprediksi Hasil Produksi Karet PTPN XIII Provinsi Kalimantan Barat. *Buletin Ilmiah Math. Stat. dan Terapannya (Bimaster)*. **08**(4): 667-674.

Warsono, Russel, E., Wamilliana, Widiarti, & Usman, M. 2019. Vector Autoregressive with Exogenous Variable Model and its Application in Modeling and Forecasting Energy Data: Case Study of PTBA and HRUM Energy. *International Journal of Energy Economics and Policy*. **09**(2): 390-398.

Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. Ed. ke-2. Pearson Addison-Wesley, New York.

Zhang, G.P., 2003. Time series forecasting using a hybrid ARIMA and Neural Network Model. *Elsevier Neuro Computing*. **1**(50): 159 - 175.