

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR) -
CONVOLUTIONAL NEURAL NETWORK (CNN)* DALAM PERAMALAN
JUMLAH UANG BEREDAR DI INDONESIA**

(Skripsi)

Oleh

ARDELIA MAHARANI SULANDRA



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

ABSTRAK

IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR)* - *CONVOLUTIONAL NEURAL NETWORK (CNN)* DALAM PERAMALAN JUMLAH UANG BEREDAR DI INDONESIA

Oleh

ARDELIA MAHARANI SULANDRA

Peramalan ekonomi telah menjadi komponen penting dalam pengambilan keputusan di berbagai sektor. Salah satu aspek yang menjadi perhatian utama dalam peramalan ekonomi adalah jumlah uang beredar dalam suatu perekonomian. *Vector Autoregressive (VAR)* merupakan metode yang cocok digunakan untuk melakukan peramalan, tetapi mengalami kesulitan untuk menghadapi pola data nonlinier. *Convolutional Neural Network (CNN)* merupakan metode yang diharapkan mampu untuk menangkap pola data nonlinier pada data yang sulit diatasi oleh model VAR. Oleh karena itu, digunakan metode *hybrid VAR-CNN* yang diharapkan mampu melakukan prediksi dan peramalan yang lebih akurat. Dalam penelitian ini dilakukan peramalan menggunakan metode *hybrid VAR –CNN* untuk periode satu tahun yang akan datang yaitu Juli 2022 hingga Juni 2023. Metode *hybrid VAR-CNN* terdiri dari 2 model utama yaitu model pertama yang dibangun dengan data prediksi VAR sedangkan model kedua dibangun dengan data residual dari VAR. Metode *hybrid VAR-CNN* dengan skema 80% data *training* dan 20% data *testing* menghasilkan model peramalan terbaik dibandingkan dengan metode lainnya berdasarkan nilai MAPE, nilai supremum (D) dan statistik uji (*p-value*) yang diperoleh.

Kata Kunci : VAR, CNN, *Hybrid VAR-CNN*, Peramalan , Jumlah Uang Beredar

ABSTRACT

IMPLEMENTATION OF THE HYBRID METHOD VECTOR AUTOREGRESSIVE (VAR) - CONVOLUTIONAL NEURAL NETWORK (CNN) IN FORECASTING THE AMOUNT OF MONEY CIRCULATING IN INDONESIA

By

ARDELIA MAHARANI SULANDRA

Economic forecasting has become an important component of decision-making in various sectors. One aspect that is of major concern in economic forecasting is the money supply in an economy. Vector Autoregressive (VAR) is a suitable method for forecasting, but has difficulty dealing with nonlinear data patterns. Convolutional Neural Network (CNN) is a method that is expected to be able to capture nonlinear data patterns in data that are difficult to overcome by the VAR model. Therefore, a hybrid VAR-CNN method is used which is expected to perform more accurate prediction and forecasting. In this research, forecasting is done using the hybrid VAR -CNN method for the upcoming one-year period, namely July 2022 to June 2023. The hybrid VAR-CNN method consists of 2 main models, namely the first model built with VAR prediction data while the second model is built with residual data from VAR. The hybrid VAR-CNN method with 80% training data and 20% testing data scheme produces the best forecasting model compared to other methods based on the MAPE value, supremum value (D) and test statistics (p-value) obtained.

Keywords : VAR, CNN, Hybrid VAR-CNN, Forecasting, Money Circulating

**IMPLEMENTASI METODE *HYBRID VECTOR AUTOREGRESSIVE (VAR) -
CONVOLUTIONAL NEURAL NETWORK (CNN)* DALAM PERAMALAN
JUMLAH UANG BEREDAR DI INDONESIA**

Oleh

ARDELIA MAHARANI SULANDRA

Skripsi

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

Pada

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



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

Judul Skripsi : **IMPLEMENTASI METODE HYBRID
VECTOR AUTOREGRESSIVE (VAR) –
CONVOLUTIONAL NEURAL NETWORK
(CNN) DALAM PERAMALAN JUMLAH
UANG BEREDAR DI INDONESIA**

Nama Mahasiswa : **Ardelia Maharani Sulandra**


Nomor Pokok Mahasiswa : **1917031026**

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

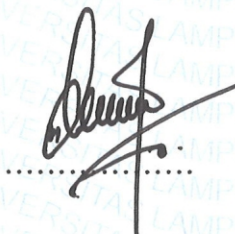
MENGESAHKAN

1. Tim Penguji

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



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



Penguji Bukan Pembimbing : Prof. Drs. Mustofa Usman, M.A., Ph. D.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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

Tanggal Lulus Ujian Skripsi: 01 November 2023

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini :

Nama : **Ardelia Maharani Sulandra**
Nomor Pokok Mahasiswa : **1917031026**
Jurusan : **Matematika**
Judul Skripsi : **Implementasi Metode *Hybrid Vector Autoregressive (VAR) – Convolutional Neural Network (CNN)* dalam Peramalan Jumlah Uang Beredar di Indonesia**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah karya penulisan ilmiah Universitas Lampung.

Bandar Lampung, 01 November 2023
Penulis.



Ardelia Maharani Sulandra

RIWAYAT HIDUP

Penulis bernama lengkap Ardelia Maharani Sulandra dilahirkan di Bandar Lampung pada tanggal 08 April 2001, sebagai anak kedua dari tiga bersaudara. Penulis merupakan putri dari Bapak Indra Umpusinga (Alm) dan Ibu Susilawati.

Penulis menyelesaikan pendidikan di TK Al Hanif 1 pada tahun 2006 s.d. 2007, sekolah dasar di SD Negeri 2 Rajabasa pada tahun 2007 s.d 2013, sekolah menengah pertama di SMP Negeri 22 Bandar Lampung pada tahun 2013 s.d. 2016, dan sekolah menengah atas di SMA Negeri 7 Bandar Lampung pada tahun 2016 s.d 2019.

Pada tahun 2019 penulis diterima sebagai mahasiswa S1 di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SNMPTN. Selama aktif menjadi mahasiswa, penulis ikut serta dalam Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) sebagai anggota Biro Dana dan Usaha pada tahun 2020 dan aktif menjadi Staff Bidang Humas Koperasi Mahasiswa Universitas Lampung pada tahun 2021.

Pada tahun 2022, sebagai bentuk penerapan bidang ilmu di dunia kerja, penulis melaksanakan Kerja Praktik (KP) di Badan Pengelola Pajak dan Retribusi Daerah Kota Bandar Lampung dan sebagai bentuk pengabdian kepada masyarakat penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Adi Luhur, Kecamatan Jabung, Kabupaten Lampung Timur.

KATA INSPIRASI

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.”
(Q.S. Al-Baqarah: 286)

“Dan barang siapa yang bertakwa kepada Allah, niscaya Allah menjadikan baginya kemudahan dalam urusannya.”
(Q.S. At-Talaq: 4)

“Karena sesungguhnya sesudah kesulitan itu ada kemudahan, sesungguhnya sesudah kesulitan itu ada kemudahan”
(Q.S. Al-Insyirah: 5-6)

“Kita lebih kuat dari apa yang kita bayangkan.”
(Penulis)

PERSEMBAHAN

Alhamdulillah Rabbil 'Alamin, dengan mengucapkan puji dan syukur kepada Allah SWT atas segala limpah rahmat, hidayah dan karuniaNya, Saya persembahkan skripsi ini yang dibuat dengan kesabaran dan ketulusan hati kepada:

Kedua Orang Tua dan Keluarga.

Terima kasih atas kasih sayang, dukungan, motivasi, nasihat dan doa yang tidak berhenti sampai saat ini, karena doa dan didikan kalianlah yang membawaku bertahan dan kuat sampai sejauh ini

Dosen Pembimbing dan Pembahas

Terima Kasih kepada dosen pembimbing dan pembahas yang telah memberikan ilmu, bimbingan, serta dukungan yang sangat membangun sehingga penulis dapat menyelesaikan skripsi ini

Almamater Tercinta Universitas Lampung

SANWACANA

Puji syukur kehadiran Allah SWT atas segala limpahan rahmat, nikmat, dan karunianya sehingga penulis mampu menyelesaikan skripsi yang berjudul **“Implementasi Metode Hybrid Vector Autoregressive (VAR) – Convolutional Neural Network (CNN) dalam Peramalan Jumlah Uang Beredar di Indonesia”** sebagai salah satu syarat untuk mencapai gelar Sarjana Matematika Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

Dalam penyelesaian skripsi ini, penulis mendapat dukungan, bimbingan, dan bantuan dari beberapa pihak. Oleh karena itu, penulis berterima kasih kepada :

1. Bapak Ir. Warsono, M.S, Ph.D., selaku pembimbing pertama atas segala bimbingan, ilmu, nasihat, saran, dan motivasi yang telah diberikan selama mengikuti pendidikan S1- Matematika.
2. Ibu Dian Kurniasari, S.Si., M.Sc., selaku pembimbing kedua atas segala bimbingan, ilmu, motivasi, semangat, dan saran yang telah diberikan selama mengikuti pendidikan S1- Matematika.
3. Bapak Prof. Drs. Mustofa Usman, M.A., Ph.D, selaku dosen penguji atas segala ilmu, motivasi, nasihat, kritik dan saran yang telah diberikan selama mengikuti pendidikan S1- Matematika.
4. Bapak Prof. Dr. Lazakaria, S.Si., M.Sc., selaku pembimbing akademik atas segala bimbingan, nasihat dan motivasi yang telah diberikan selama mengikuti pendidikan S1- Matematika.
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 Satriai, S.Si, M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh Dosen dan Staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung yang telah memberikan ilmu, wawasan dan pengetahuan yang berharga bagi penulis selama proses perkuliahan berlangsung
8. Orangtuaku tercinta, Ayah Indra Umpusinga (Alm) dan Bunda Susilawati yang telah memberikan segala kasih sayang, nasihat, motivasi, dukungan dan materi yang tak sedikit kepada Penulis.
9. Saudaraku, Tiara Cahyarani Sulandra dan Sabrina Paramitha Sulandra yang selalu memberikan keceriaan, bantuan, serta dukungan kepada Penulis.
10. Keluarga besar yang telah mendukung, mendoakan dan selalu memberikan motivasi kepada Penulis.
11. Teman seperjuangan di Jurusan Matematika yang banyak membantu dan saling mengasihi disaat suka maupun duka pada masa perkuliahan, Surya, Jijah, Odey, Intan, Valen, Irma, Dea, Yusril, Yoga, Kenny dan yang lainnya.
12. Semua pihak yang telah membantu dan mendoakan Penulis dengan tulus dalam proses penyelesaian skripsi ini yang tidak dapat disebutkan satu- persatu.

Penulis menyadari bahwa dalam penulisan skripsi ini masih jauh dari kata sempurna. Oleh karena itu, penulis memohon maaf atas segala kekurangan tersebut dan berharap skripsi ini dapat bermanfaat bagi siapapun yang membaca.

Bandar Lampung, 01 November 2023
Penulis,

Ardelia Maharani Sulandra

DAFTAR ISI

	Halaman
DAFTAR ISI	xiii
DAFTAR TABEL	xv
DAFTAR GAMBAR	xvi
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian.....	4
1.3 Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA	5
2.1 <i>Time Series</i>	5
2.2 <i>Cross-Correlation</i>	5
2.3 Stasioneritas Data	6
2.4 Uji Kointegrasi	7
2.5 Model <i>Vector Autoregressive (VAR)</i>	8
2.5.1 Identifikasi Model	9
2.5.2 Uji Asumsi Residual	9
2.6 Validasi Model	11
2.6.1 <i>Akaike Information Criteria (AIC)</i>	12
2.6.2 <i>Mean Absolute Percentage Error (MAPE)</i>	12
2.7 <i>Convolutional Neural Network (CNN)</i>	13
2.8 <i>Splitting Data</i>	15
2.9 <i>Scaling Data</i>	15
2.10 <i>Unscaling Data</i>	16
2.11 Fungsi Aktivasi.....	16
2.11.1 Fungsi Aktivasi ReLU	16
2.11.2 Fungsi Aktivasi Sigmoid.....	17
2.12 <i>Dropout</i>	18
2.13 <i>Hybrid VAR-CNN</i>	18

III. METODOLOGI PENELITIAN	20
3.1 Waktu dan Tempat Penelitian	20
3.2 Data Penelitian	20
3.3 Metode Penelitian.....	21
IV. HASIL DAN PEMBAHASAN.....	24
4.1 Proses <i>Input Data</i>	24
4.2 Visualisasi Data.....	25
4.3 Metode <i>Vector Autoregressive (VAR)</i>	25
4.3.1 <i>Cross Correlation</i>	26
4.3.2 Stasioneritas Data	27
4.3.3 Uji Kointegrasi.....	28
4.3.4 Prediksi dan Evaluasi Model VAR.....	29
4.3.5 Residual Model VAR.....	31
4.3.6 Peramalan VAR	33
4.4 <i>Splitting dan Scaling Data</i>	34
4.5 Model <i>Hybrid VAR-CNN</i>	35
4.5.1 Membangun Model CNN Data Prediksi VAR	35
4.5.2 Membangun Model CNN Data Residual VAR	38
4.6 Melakukan Prediksi dengan Model <i>Hybrid VAR-CNN</i>	41
4.7 Peramalan Model Hybrid VAR-CNN	42
4.8 <i>Goodness of Fit</i> (Uji Kesesuaian Model).....	43
V. KESIMPULAN DAN SARAN	46
5.1 Kesimpulan.....	46
5.2 Saran.....	46
DAFTAR PUSTAKA	47
LAMPIRAN.....	50

DAFTAR TABEL

Tabel 1. Kriteria nilai MAPE (Zhang dkk, 2015).....	13
Tabel 2. Data Jumlah Uang Beredar	21
Tabel 3. Data <i>Input</i> Penelitian.....	24
Tabel 4. Hasil <i>Cross Correlation</i>	26
Tabel 5. Representasi Skematik <i>Cross Correlation</i>	27
Tabel 6. Hasil Uji ADF	27
Tabel 7. Hasil Uji ADF Setelah <i>Differencing</i>	28
Tabel 8. Hasil Uji Kointegrasi Johansen.....	29
Tabel 9. Hasil Model <i>Select Order</i>	30
Tabel 10. Hasil Uji Jarque-Bera.....	32
Tabel 11. Hasil Uji Portmanteau	33
Tabel 12. <i>Splitting Data</i>	35
Tabel 13. <i>Goodness of Fit</i> M1.....	44
Tabel 14. <i>Goodness of Fit</i> M2.....	45

DAFTAR GAMBAR

Gambar 1. Arsitektur CNN (Sumber: Lewinson, 2020).	14
Gambar 2. <i>Flowchart</i> Metode Penelitian.	23
Gambar 3. <i>Syntax Input Data</i>	24
Gambar 4. Plot Visualisasi Data M1 dan M2.	25
Gambar 5. <i>Syntax Uji Stasioneritas</i>	27
Gambar 6. <i>Syntax Uji Kointegrasi Trace</i>	28
Gambar 7. <i>Syntax Memilih Model Terbaik VAR</i>	29
Gambar 8. Plot Data Aktual dan Prediksi M1.....	30
Gambar 9. Plot Data Aktual dan Prediksi M2.....	31
Gambar 10. Nilai MAPE dan Akurasi VAR.....	31
Gambar 11. Plot Residual M1 dan M2.....	32
Gambar 12. Plot Data Aktual dan Peramalan Uang M1.	33
Gambar 13. Plot Data Aktual dan Peramalan Uang M2.	34
Gambar 14. <i>Hypertuning Model CNN Data Prediksi VAR 70:30</i>	36
Gambar 15. Grafik <i>Loss Function Model CNN Data Prediksi 70:30</i>	36
Gambar 16. <i>Hypertuning Model CNN Data Prediksi VAR 80:20</i>	37
Gambar 17. Grafik <i>Loss Function Model CNN Data Prediksi VAR 80:20</i>	38
Gambar 18. <i>Hypertuning Model CNN Data Residual VAR 70:30</i>	39
Gambar 19. Grafik <i>Loss Function Model CNN Data Residual VAR 70:30</i>	39
Gambar 20. <i>Hypertuning Model CNN Data Residual VAR 80:20</i>	40
Gambar 21. Grafik <i>Loss Function Model CNN Data Residual VAR 80:20</i>	41
Gambar 22. <i>Syntax Prediksi Model Hybrid</i>	41
Gambar 23. Plot Prediksi dengan Model <i>Hybrid VAR-CNN</i>	42
Gambar 24. <i>Syntax Peramalan Model Hybrid</i>	42
Gambar 25. Plot Peramalan dengan Model <i>Hybrid VAR-CNN</i>	43

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Dalam era globalisasi dan perubahan yang cepat, peramalan ekonomi telah menjadi komponen penting dalam pengambilan keputusan di berbagai sektor. Peramalan yang akurat dan baik mengenai perkembangan ekonomi memiliki dampak yang signifikan terhadap efisiensi alokasi sumber daya, stabilitas finansial, dan keberlanjutan pertumbuhan ekonomi. Salah satu aspek yang menjadi perhatian utama dalam peramalan ekonomi adalah jumlah uang beredar dalam suatu perekonomian. Uang beredar dapat didefinisikan dalam arti sempit (M1) yang terdiri dari uang kartal yang dipegang oleh masyarakat dan uang giral rupiah, serta dalam arti luas (M2) yang terdiri dari M1, uang kuasi (mencakup tabungan, simpanan berjangka dalam rupiah dan valas, serta giro dalam valuta asing), surat berharga yang diterbitkan oleh sistem moneter (Bank Indonesia, 2023). Jumlah uang beredar, yang terdiri dari uang tunai dan berbagai bentuk deposito, memiliki peran sentral dalam membentuk keadaan ekonomi suatu negara.

Time series merupakan serangkaian pengamatan pada suatu variabel yang diperoleh secara berurutan serta disusun berdasarkan waktu ke waktu dengan interval yang tetap dalam bentuk tahunan, triwulan, bulanan, harian, dan lain sebagainya (Wei, 2006). Analisis *time series* digunakan untuk peramalan atau prediksi nilai runtun waktu di masa yang akan datang menggunakan hubungan antar variabel. Metode prediksi data *time series* dapat digolongkan berdasarkan banyaknya peubah yang menjadi pengamatan yaitu metode univariat dan multivariat. Metode peramalan univariat adalah metode dimana hanya digunakan satu variabel pengamatan,

sedangkan metode multivariat memiliki lebih dari satu variabel pengamatan dan saling berkaitan.

Model *Vector Autoregressive* (VAR) adalah model *time series* multivariat yang merupakan pengembangan dari model *Autoregressive* (AR) dengan menggunakan lebih dari satu variabel untuk melakukan peramalan data *time series* (Lutkepohl, 2005). *Vector Autoregressive* (VAR) memiliki asumsi bahwa data atau variabel yang digunakan harus stasioner. Model VAR dapat digunakan untuk memodelkan hubungan linier antar variabel, tetapi mengalami kesulitan menghadapi pola data nonlinier. Sehingga perlu dilakukan hybrid untuk mengatasi pola data nonlinier. *Convolutional Neural Network* (CNN) adalah algoritma yang merupakan pengembangan dari *Artificial Neural Network* (ANN) yang mempunyai nilai akurasi cukup baik dalam melakukan peramalan data *time series*. (Fausett, 1994). *Convolutional Neural Network* (CNN) digunakan untuk memproses data spesial dan dapat menangkap komponen nonlinier dari data deret waktu, tetapi mengalami kesulitan untuk memodelkan hubungan antar variabel. Pengembangan peramalan model multivariat menggunakan metode *hybrid* VAR-CNN diharapkan mampu mengatasi keterbatasan dari masing-masing metode sehingga dapat memperoleh hasil peramalan yang lebih akurat.

Penelitian terdahulu menggunakan metode *Vector Autoregressive* (VAR) dilakukan oleh Febrianti, dkk (2021) untuk menganalisis pengaruh kurs mata uang terhadap ekspor dan impor di Indonesia menghasilkan bahwa ketiga variabel yaitu kurs mata uang, ekspor, dan impor terdapat dua hubungan satu arah (*unindirectional*). Penelitian selanjutnya dilakukan oleh Abdullah (2022) untuk menganalisis hubungan antara harga minyak dan harga emas bulanan serta melakukan peramalan. Diperoleh hasil bahwa harga minyak dan emas saling mempengaruhi untuk setiap lag dan model peramalan terbaik berdasarkan nilai AIC adalah model VAR(7), sedangkan berdasarkan nilai MSE adalah model VAR(10). Penelitian lainnya dilakukan oleh Rajab, dkk (2022) untuk meramalkan penyebaran pandemi menghasilkan nilai MAPE sebesar 0.35%, 2.03%, dan 3.75% dalam memprediksi

jumlah kasus baru harian untuk ketiga negara tersebut dimana nilai tersebut kurang dari 10% sehingga metode tersebut sangat baik untuk digunakan.

Penelitian terdahulu menggunakan metode *Convolutional Neural Network* (CNN) dilakukan oleh Halimi, dkk (2019) untuk memprediksi harga emas menunjukkan bahwa univariate CNN cocok digunakan untuk memprediksi beberapa nilai jangka pendek. Penelitian selanjutnya dilakukan oleh Semenoglou, dkk (2023) untuk menyelidiki apakah penggunaan representasi deret waktu gambar dapat menghasilkan akurasi prediksi yang unggul jika dibandingkan dengan metode peramalan deret waktu lainnya. Diperoleh hasil bahwa prediksi deret waktu berbasis gambar dapat menghasilkan prediksi yang akurat dan mengungguli metode prediksi standar dan lanjutan baik yang bersifat statistik atau *machine learning*..

Penelitian terdahulu menggunakan metode *hybrid* dilakukan oleh Parot, dkk (2019) menggunakan metode *hybrid* ANN dan VAR untuk meramalkan nilai tukar EUR/USD yang menunjukkan hasil bahwa metode *hybrid* menurunkan RMSE sebesar 19,3% yang menunjukkan peningkatan akurasi peramalan. Penelitian selanjutnya dilakukan oleh Barzagar, dkk (2020) menggunakan metode *hybrid* CNN-LSTM untuk memprediksi variabel kualitas air jangka pendek, diperoleh hasil bahwa model *hybrid* CNN-LSTM mengungguli model mandiri (LSTM, CNN, SVR, dan DT) dalam memprediksi kualitas air. Penelitian lainnya dilakukan oleh Caraka, dkk (2021) menggunakan metode *hybrid* VAR-FFNN untuk meramalkan tingkat paparan polusi udara di Taiwan memberikan hasil bahwa *hybrid* VAR-FFNN memberikan akurasi peramalan yang lebih baik.

Berdasarkan uraian di atas dan penelitian terdahulu, penulis tertarik untuk melakukan peramalan jumlah uang beredar menggunakan pendekatan yang menggabungkan kekuatan dari metode VAR dan CNN dalam penelitian yang berjudul “Implementasi Metode *Hybrid Vector Autoregressive* (VAR) – *Convolutional Neural Network* (CNN) dalam Peramalan Jumlah Uang Beredar di Indonesia”

1.2 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Membangun model VAR dan CNN terhadap jumlah uang beredar.
2. Melakukan pengembangan metode *hybrid* VAR-CNN untuk mendapatkan hasil peramalan yang lebih akurat.
3. Memperoleh hasil peramalan jumlah uang beredar menggunakan metode *hybrid* VAR-CNN.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah:

1. Memperoleh pengetahuan tentang peramalan menggunakan metode hybrid.
2. Mampu mengembangkan dan mengevaluasi metode *hybrid* VAR-CNN untuk mendapatkan hasil peramalan yang lebih akurat.
3. Dapat menambah sumber keilmuan dan menjadi referensi bagi pembaca.

II. TINJAUAN PUSTAKA

2.1 *Time Series*

Time series atau deret waktu merupakan serangkaian pengamatan pada suatu variabel yang diperoleh secara berurutan serta disusun berdasarkan waktu ke waktu dengan interval yang tetap dalam bentuk tahunan, triwulan, bulanan, harian, dan lain sebagainya (Wei, 2006). Analisis *time series* digunakan dalam analisis deret waktu dengan membangun suatu model untuk peramalan atau prediksi nilai runtun waktu di masa yang akan datang menggunakan hubungan antar variabel. *Time series* adalah pengamatan pada suatu variabel dari waktu lampau dan dicatat secara berurutan menurut urutan waktu dengan periode yang tetap (Hanke & Wichern, 2005).

2.2 *Cross-Correlation*

Cross-correlation (korelasi silang) merupakan salah satu metode yang banyak digunakan dalam analisis data secara *time series*. *Cross-correlation* dilakukan untuk mencari hubungan keselarasan antara dua variabel data *time series*. Bentuk umum *cross-correlation* dapat dituliskan sebagai berikut (Boyd, 2000):

$$\rho_k = \rho_{i,j}(k) = \frac{\frac{1}{N} \sum_{t=k+1}^N (X_{i,t} - \bar{X}_i)(X_{j,t-k} - \bar{X}_j)}{\sqrt{\sum_{t=1}^{N-k} (X_i - \bar{X}_i)^2} \sqrt{\sum_{t=1}^{N-k} (X_j - \bar{X}_j)^2}} \quad (2.1)$$

dengan:

$\rho_{i,j}(k)$: koefisien korelasi antara X_i dan X_j pada lag k
$X_{i,t}$: nilai variabel X_i pada waktu ke- t
$X_{j,t-k}$: nilai variabel X_j pada waktu ke- $(t - k)$
\bar{X}_i	: rata-rata variabel X_i
\bar{X}_j	: rata-rata variabel X_j
N	: banyaknya variabel

2.3 Stasioneritas Data

Salah satu asumsi yang harus dimiliki pada analisis *time series* adalah stasioneritas data. Stasioner merupakan suatu keadaan dimana tidak terjadinya kenaikan atau penurunan dalam data. Fluktuasi data tersebut berada di sekitar nilai rata-rata secara konstan dan tidak tergantung pada waktu serta memiliki varian yang konstan (Makridakis dkk, 1999). Stasioneritas data dapat di uji menggunakan uji akar unit. Salah satu metode pengujian akar unit yang dapat digunakan adalah *Augmented Dickey Fuller* (ADF).

Langkah-langkah pengujian ADF:

a. Hipotesis

H_0 : data tidak memenuhi asumsi stasioneritas

H_1 : data memenuhi asumsi stasioneritas

b. Tingkat signifikansi: $\alpha = 0.05$

c. Statistik uji

Statistik uji yang digunakan adalah sebagai berikut:

$$t_{hitung} = \frac{\hat{\eta} - 1}{S_{\hat{\eta}}} \quad (2.2)$$

dengan:

Y_t : data pengamatan ke- t

Y_{t-1} : data pengamatan ke- $(t - 1)$

n : jumlah pengamatan.

d. Daerah Kritis:

Daerah kritis uji t adalah

$$DK = \{t_{hitung} | t_{hitung} < Mackinon\ critical\ value\}.$$

e. Keputusan:

H_0 ditolak jika $t_{hitung} \in DK$ atau H_0 ditolak jika $pvalue < 0.05$

Jika hasil uji ADF menunjukkan data tidak stasioner maka data harus ditransformasikan agar berubah menjadi stasioner dengan melakukan *differencing* (Makridakis dkk, 1999). Bentuk umum *differencing* adalah sebagai berikut:

$$\nabla^d Y_t = Y_t - Y_{t-d} \quad (2.3)$$

dengan:

Y_t : pengamatan pada waktu ke- t

Y_{t-d} : pengamatan pada waktu ke- $(t - d)$

2.4 Uji Kointegrasi

Metode *vector autoregressive* memiliki asumsi bahwa tidak ada kointegrasi antar variabel. Konsep kointegrasi dikemukakan pertama kali oleh Engle & Granger yang didefinisikan sebagai keseimbangan jangka panjang pada variabel deret waktu. Uji kointegrasi digunakan untuk menentukan apakah terdapat suatu hubungan jangka panjang di antara data deret waktu (Engle & Granger, 1987). Uji kointegrasi multivariat dapat dilakukan menggunakan uji kointegrasi Johansen.

Langkah-langkah uji kointegrasi Johansen *trace statistic*:

a. Hipotesis

H_0 : tidak ada kointegrasi

H_1 : terdapat kointegrasi

b. Tingkat signifikansi: $\alpha = 0.05$

c. Statistik uji

Statistik uji yang digunakan adalah sebagai berikut:

$$\lambda_{trace}(r) = -T \sum_{i=r+1}^n \ln(1 - \hat{\lambda}_i) \quad (2.4)$$

dengan:

r : rank kointegrasi

T : jumlah pengamatan

$\hat{\lambda}_i$: *eigen value*

d. Keputusan:

H_0 ditolak jika $\lambda_{trace}(r) > critical\ values$ atau H_0 ditolak jika $pvalue < 0.05$

2.5 Model Vector Autoregressive (VAR)

Vector Autoregressive (VAR) adalah model *time series* multivariat yang merupakan pengembangan dari model *Autoregressive* (AR) dengan menggunakan lebih dari satu variabel. Metode VAR adalah suatu sistem persamaan dinamis dimana pendugaan suatu variabel pada periode-periode tertentu tergantung pada pergerakan variabel tersebut dan variabel-variabel lain yang terlibat dalam sistem pada periode-periode sebelumnya (Enders, 2004). Model VAR dinotasikan dengan VAR (p). Bentuk umum model VAR dituliskan sebagai berikut (Wei, 2006):

$$Z_t = \beta_0 + \beta_1 Z_{t-1} + \beta_2 Z_{t-2} + \dots + \beta_p Z_{t-p} + \varepsilon_t \quad (2.5)$$

dengan:

Z_t : vektor dari variabel yang diamati pada waktu ke- t

Z_{t-p} : vektor dari variabel yang diamati pada waktu ke- $(t - p)$

β_0 : vektor intersep

β_p : matriks parameter AR berukuran $m \times m$

ε_t : vektor residual pada waktu ke- t

Terdapat beberapa keuntungan ketika menggunakan metode VAR yaitu tidak perlu membedakan variabel endogen dan eksogen, estimasi sederhana karena menggunakan metode *Ordinary Least Square* (OLS), dan hasil estimasi lebih baik dibandingkan metode simultan yang lebih kompleks (Gujarati & Porter, 2009). Selain memiliki keuntungan, metode VAR juga memiliki beberapa kelemahan yaitu tidak berkointegrasi dan data yang digunakan harus stasioner.

2.5.1 Identifikasi Model

Identifikasi model merupakan langkah awal dalam menentukan orde model VAR (p). Untuk menentukan estimasi model VAR digunakan Pengujian lag digunakan untuk menentukan panjang lag optimal yang akan digunakan dalam menentukan estimasi parameter model VAR. Dalam memilih jumlah lag optimal, model VAR diestimasi dengan jumlah lag yang berbeda-beda kemudian dibandingkan nilai *Akaike Information Criteria* (AIC). Dalam penentuan lag optimal digunakan AIC yang paling kecil diantara berbagai lag yang diajukan.

2.5.2 Uji Asumsi Residual

2.5.2.1 Uji Normalitas

Pengujian asumsi normalitas dapat dilakukan dengan menggunakan uji normalitas *Jarque-Bera* (Aslam dkk, 2021):

a. Hipotesis

H_0 : data residual berdistribusi normal

H_1 : data residual tidak berdistribusi normal

b. Tingkat signifikansi: $\alpha = 0.05$

c. Statistik uji

Statistik uji yang digunakan pada pengujian ini adalah sebagai berikut:

$$JB = \frac{n}{6} \left(S^2 + \frac{(K - 3)^2}{4} \right) \quad (2.6)$$

dengan:

- JB : statistik uji JB
- n : ukuran sampel
- S : koefisien skewness
- ρ : koefisien kurtosis

d. Daerah Kritis:

Daerah kritis uji ini adalah

$$DK = \{JB | JB > \chi_2^2\}.$$

dengan:

- JB : statistik uji JB
- χ_2^2 : distribusi chi-kuadrat

e. Keputusan:

H_0 ditolak jika $JB \in DK$ atau H_0 ditolak jika $pvalue < 0.05$

2.5.2.2 Uji White Noise

Pengujian asumsi *white noise* (independensi residual) dapat dilakukan menggunakan uji *Portmanteau Test* (Lutkephol, 2005) :

a. Hipotesis

H_0 : residual memenuhi asumsi *white noise*

H_1 : residual tidak memenuhi asumsi *white noise*

b. Tingkat signifikansi: $\alpha = 0.05$

c. Statistik uji

Statistik uji yang digunakan pada pengujian ini adalah sebagai berikut:

$$Q = m \sum_{\ell=1}^m r_{\ell}^2 \quad \ell = 1, 2, \dots, m \quad (2.7)$$

dengan:

- Q : statistik uji Q
- ℓ : beda lag
- m : banyaknya variabel
- r_{ℓ} : residu autokorelasi

d. Daerah Kritis:

Daerah kritis uji ini adalah

$$DK = \{Q_h | Q_h > \chi_{\alpha; (m^2(h-n^*))}^2\}.$$

dengan:

- Q : statistik uji Q
- m : banyaknya variabel
- h : banyaknya lag
- n^* : banyaknya koefisien selain konstanta yang diamati

e. Keputusan:

H_0 ditolak jika $Q_h \in DK$ atau H_0 ditolak jika $pvalue < 0.05$

2.6 Validasi Model

Validasi model peramalan digunakan sebagai ukuran ketepatan model. Ketepatan model adalah hal yang penting dalam melakukan peramalan dikarenakan ketepatan model digunakan untuk mengevaluasi hasil dari peramalan yang telah dilakukan (Hanke & Wichern, 2005). Dalam penelitian ini, metode yang digunakan untuk menghitung ketepatan model yaitu : *Akaike Information Criteria* (AIC) dan *Mean Absolute Percentage Error* (MAPE).

2.6.1 Akaike Information Criteria (AIC)

Akaike Information Criteria (AIC) digunakan untuk memilih di antara model statistik atau ekonometrik bertingkat. AIC merupakan salah satu kriteria pemilihan model terbaik yang mempertimbangkan banyaknya parameter dalam model. Semakin kecil nilai AIC maka semakin baik pula model yang diperoleh. Persamaan AIC adalah sebagai berikut (Lutkepohl, 2005):

$$AIC(p) = \ln|\Sigma(p)| + \frac{2pk^2}{T} \quad (2.8)$$

dengan:

- \ln : natural log
- p : lag untuk AR
- Σ : matriks kovarian residual
- k : banyaknya variabel
- T : banyaknya pengamatan

2.6.2 Mean Absolute Percentage Error (MAPE)

MAPE digunakan dalam menghitung persentase dari kesalahan *absolute* antar target yang diamati dengan nilai yang diramalkan. Semakin kecil nilai dari MAPE maka semakin baik pula model hasil peramalan yang diperoleh. Persamaan MAPE adalah sebagai berikut (Makridakis, dkk, 1999):

$$MAPE = \frac{\sum_{t=1}^T \frac{|(Y_T - F_T)|}{Y_T}}{T} * 100 \quad (2.9)$$

dengan:

- Y_T : data aktual pada periode ke- t
- F_T : data prediksi periode ke- t
- T : banyaknya pengamatan

Tabel 1. Kriteria nilai MAPE (Zhang dkk, 2015).

MAPE	Kekuatan Peramalan
< 10%	Peramalan akurat
10-20 %	Peramalan baik
20-50%	Peramalan cukup baik
> 50 %	Peramalan tidak akurat

2.7 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu metode *deep learning* yang merupakan pengembangan dari *Artificial Neural Network (ANN)* yang digunakan untuk mengenali objek pada citra digital. Terdapat beberapa parameter yang digunakan CNN yaitu :

1. Ukuran Jendela

Ukuran jendela menunjukkan jumlah nilai masa lalu yang digunakan saat melakukan peramalan di masa yang akan datang.

2. Jumlah Filter

Jumlah filter menunjukkan jumlah filter/kernel konvolusi yang digunakan untuk mempelajari fitur-fitur pada data.

3. Fungsi Aktivasi

Fungsi aktivasi digunakan untuk mengaktifkan neuron dan menentukan *output* model.

4. Jumlah Lapisan

Jumlah lapisan ideal bergantung pada kompleksitas data dan ukuran jendela.

5. *Dropout Rate*

Dropout rate untuk mencegah *overfitting* pada model.

6. *Batch Size*

Batch size untuk menentukan jumlah sampel yang diproses pada satu waktu.

7. *Epoch*

Epoch digunakan untuk menentukan berapa kali algoritma bekerja melewati seluruh dataset.

8. *Learning Rate*

Learning rate digunakan untuk menentukan seberapa cepat model belajar selama pelatihan.

Proses CNN akan dilakukan melalui beberapa tahapan dari awal masukan yaitu melewati beberapa lapisan utama yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer* (Hidayat & Hermawan, 2018):

1. *Convolutional Layer*


Convolution layer digunakan untuk mengekstrak fitur data yang akan digunakan untuk training.

2. *Pooling Layer*

Pooling layer digunakan untuk membuat filter baru berdasarkan aturan yang diinginkan.

3. *Fully Connected Layer*

Fully Connected Layer adalah lapisan yang digunakan dalam penerapan *Multilayer Perceptron* (MLP) yang merupakan bagian dari ANN dan terdiri dari sejumlah neuron yang dihubungkan dengan bobot-bobot penghubung.



Gambar 1. Arsitektur CNN (Sumber: Lewinson, 2020).

2.8 *Splitting Data*

Splitting data (pembagian data) dilakukan dengan cara melakukan pembagian proporsi data untuk mencari hasil pembagian data terbaik dengan menggunakan proporsi data *training* dan data *testing* yaitu 70:30 dan 80:20. *Splitting data* berfungsi untuk melatih dan menguji performa model dari metode yang akan digunakan. Data *training* adalah data yang akan digunakan dalam melatih algoritma serta akan dilakukan pencarian model yang tepat dari metode yang digunakan yang akan dimulai dengan memasukan data pelatihannya ke dalam suatu jaringan. Data *testing* adalah data yang akan diuji untuk melihat keakuratan model yang telah diperoleh sebelumnya (Warsito, 2009).

2.9 *Scaling Data*

Scaling data atau normalisasi data adalah teknik yang dilakukan untuk mengubah nilai numerik dalam dataset ke skala umum tanpa mengubah makna dalam rentang nilainya. Salah satu metode yang digunakan pada *scaling data* adalah *min-max scaling*. *Min-max scaling* adalah teknik normalisasi data yang dapat dilakukan dengan cara mengubah data aktual menjadi nilai dengan interval [0,1] sehingga menghasilkan perbandingan nilai yang seimbang antara data sebelum dan sesudah proses (Mukhtar, dkk, 2022). Bentuk persamaan *min-max scaling* adalah sebagai berikut:

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.10)$$

dengan:

x^* : nilai sesudah dinormalisasi.

x : nilai sebelum dinormalisasi.

$\min(x)$: data dengan nilai minimum.

$\max(x)$: data dengan nilai maksimum.

2.10 *Unscaling Data*

Unscaling data atau denormalisasi data adalah tahapan yang dapat mengembalikan data ke dalam nilai data semula, sehingga didapatkan hasil peramalan dari data latih (Mukhtar, dkk, 2022). Bentuk rumus denormalisasi data adalah sebagai berikut:

$$x_i = y_i(\max(x) - \min(x)) + \min(x) \quad (2.11)$$

dengan:

- x_i : nilai data normal
- y_i : hasil *output* jaringan
- $\min(x)$: data dengan nilai minimum.
- $\max(x)$: data dengan nilai maksimum.

2.11 Fungsi Aktivasi

Fungsi aktivasi adalah fungsi yang menggambarkan hubungan antara tingkat aktivitas internal (*summation function*) yang mungkin berbentuk linier ataupun nonlinier serta berfungsi untuk menentukan apakah suatu neuron harus diaktifkan atau tidak aktif (Feng & Lu, 2019). Fungsi aktivasi digunakan agar *neural network* dapat mengenali data nonlinier. Fungsi aktivasi bekerja menunggu rangsangan dan meresponnya dengan efek tertentu, sehingga fungsi aktivasi juga digunakan sebagai penyaring nilai yang masuk menjadi keluaran dengan rentang tertentu. Beberapa fungsi aktivasi yang sering digunakan dalam metode CNN yaitu:

2.11.1 Fungsi Aktivasi ReLU

Fungsi aktivasi *Rectified Linear Unit* (ReLU) adalah fungsi nonlinier dimana pengaktifan *neuron* dilakukan tidak secara bersamaan dan hanya ketika *output* dari

transformasi linier bernilai nol. Persamaan fungsi ReLu adalah sebagai berikut (Firmansyah & Hayadi, 2022):

$$f(x) = \max(0, x) \quad (2.12)$$

dengan:

x : nilai data *input*

$f(x)$: *output* fungsi ReLu berupa nilai dalam bentuk 0 dan 1

2.11.2 Fungsi Aktivasi Sigmoid

Fungsi sigmoid adalah fungsi yang digunakan untuk mengukur seberapa besar informasi bisa lewat. Fungsi sigmoid biasanya digunakan pada lapisan keluaran klasifikasi biner, dimana hasilnya adalah 0 atau 1. Karena nilai dari fungsi sigmoid hanya terletak antara 0 dan 1, sehingga hasil yang dapat diprediksi dengan mudah menjadi 1 jika nilainya lebih besar dari 0.5 dan 0 jika tidak. Persamaan fungsi sigmoid adalah sebagai berikut (Nielsen, 2013) :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.13)$$

dengan:

x : nilai data *input*

e^x : nilai eksponensial positif dari nilai data *input*

e^{-x} : nilai eksponensial negatif dari nilai data *input*

$f(x)$: *output* fungsi Tanh berupa nilai dalam rentang antara -1 hingga 1

2.12 Dropout

Dropout adalah salah satu teknik dalam pelatihan model jaringan saraf tiruan (*neural network*) yang digunakan untuk mencegah terjadinya *overfitting*. Pada setiap langkah pelatihan, beberapa unit secara acak akan dinonaktifkan secara sementara. *Dropout* akan digunakan di akhir dari beberapa *layer* untuk memastikan bahwa tidak ada unit yang terlalu bergantung pada unit lain (Abhinowo, dkk, 2023)

2.13 Hybrid VAR-CNN

Vector Autoregressive (VAR) dan *Convolutional Neural Network* (CNN) adalah dua buah metode yang sering digunakan untuk melakukan peramalan data *time series*. Metode VAR memiliki kelebihan memberikan akurasi peramalan yang lebih baik untuk data deret waktu stasioner dan dapat digunakan untuk analisis *time series* multivariat, tetapi memiliki kekurangan mengalami kesulitan ketika mengatasi pola data nonlinier (Gujarati & Porter, 2009). Metode CNN memiliki kelebihan bisa menangkap komponen nonlinier dari data *time series*, tetapi memiliki kekurangan yaitu tidak dapat memodelkan hubungan antar variabel. Oleh karena itu, dilakukan hybrid VAR dan CNN untuk memperoleh kelebihan dan mengatasi kekurangan dari masing-masing metode tersebut. Diasumsikan bahwa deret waktu berisi dua komponen dasar, yaitu komponen linier (L_t) dan komponen nonlinier (NL_t). Model hybrid dapat ditulis sebagai berikut (Zhang, 2004):

$$Y_t = L_t + NL_t + a_t \quad (2.14)$$

dengan:

- Y_t : pengamatan deret waktu periode waktu ke-t
- L_t : komponen linier deret waktu
- NL_t : komponen nonlinier deret waktu
- a_t : residual deret waktu

Ide awal dari metode *hybrid* adalah menggunakan VAR memodelkan bagian linier dan menggunakan CNN memodelkan bagian nonlinier yang kemudian menggabungkan hasilnya. Proses pembangunan model hybrid memiliki tiga tahapan (Zhang, 2004). Tahap pertama yaitu membangun model VAR berdasarkan data asli untuk mengestimasi komponen linier. Residual dari model VAR seharusnya mengandung beberapa nonlinier (Zhang, 2004). Tahap kedua menggunakan CNN ke residual yang diperoleh dari model VAR untuk mengestimasi komponen nonlinier. Tahap akhir yaitu menggabungkan keduanya untuk memperoleh hasil peramalan.

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun akademik 2022/2023 dengan melakukan penelitian secara studi pustaka 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 bulanan yang diperoleh dari situs resmi Badan Pusat Statistik (2023) dengan link <https://www.bps.go.id/indicator/13/123/1/uang-beredar.html>. Data memiliki 2 variabel yaitu jumlah uang beredar dalam arti sempit (M1) dan jumlah uang beredar dalam arti luas (M2) yang memiliki satuan milyar rupiah. Jumlah uang beredar adalah jumlah uang dalam suatu perekonomian pada periode tertentu. Data yang digunakan dalam penelitian ini adalah data historis yang diambil pada periode Januari 2010 sampai dengan Juni 2022.

Tabel 2. Data Jumlah Uang Beredar

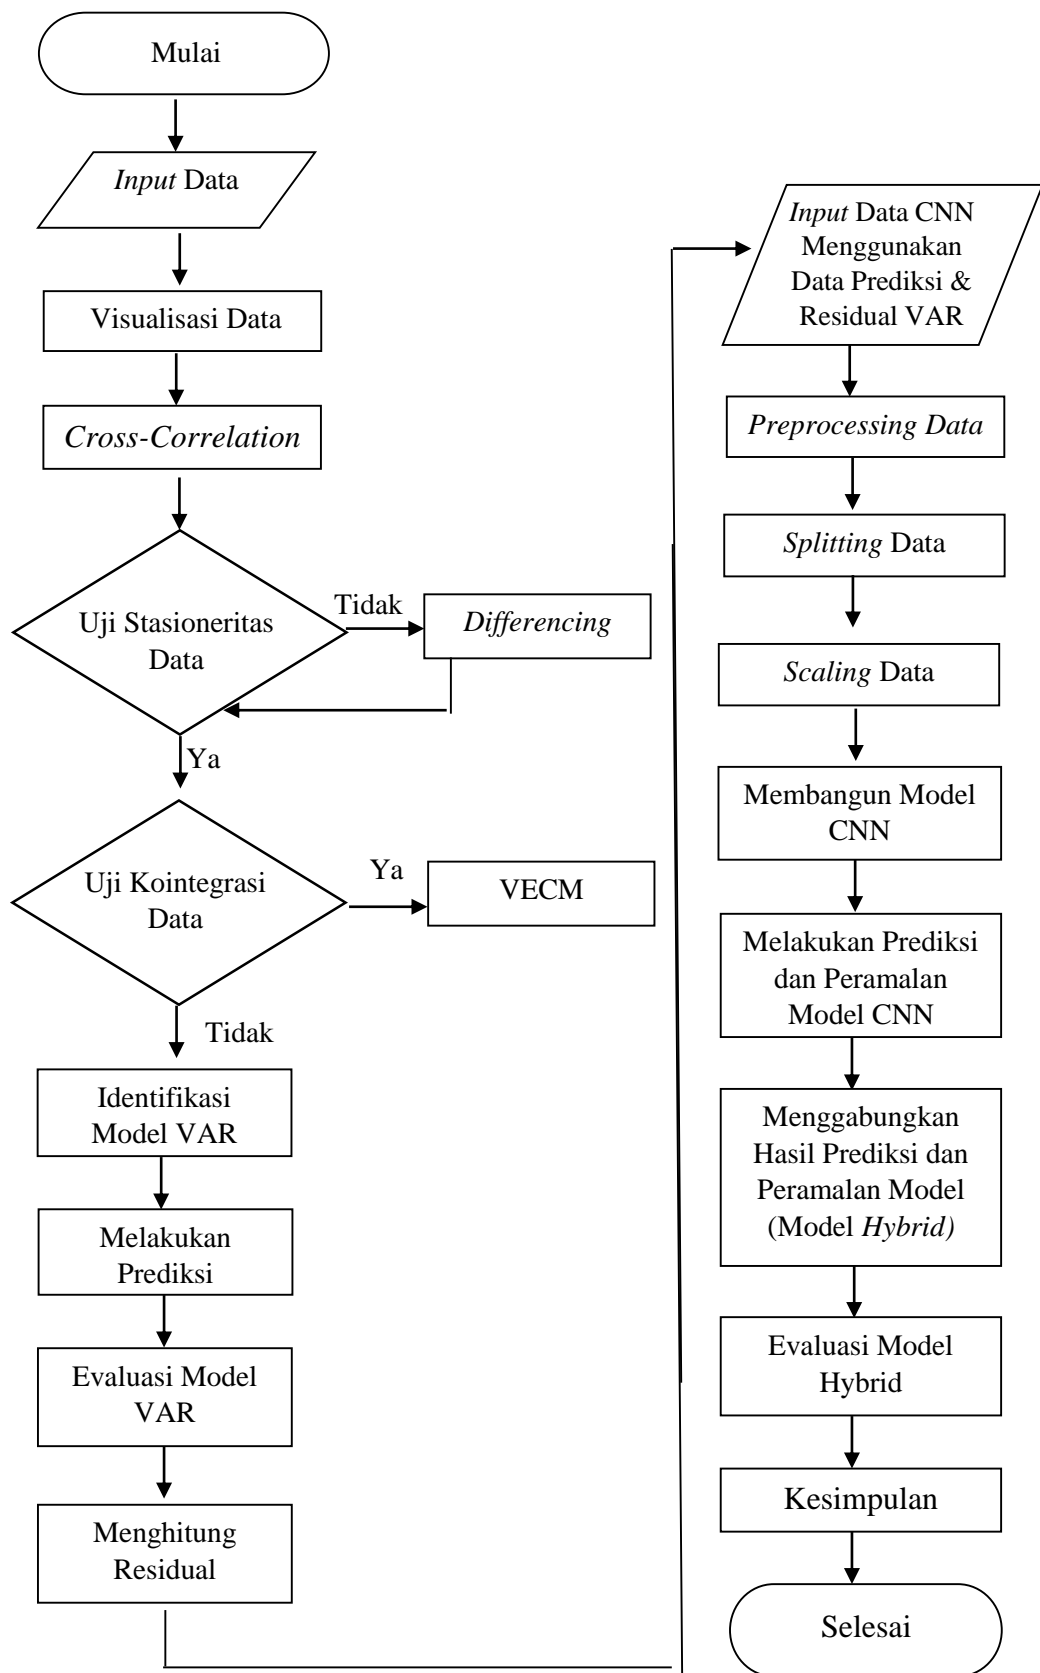
Periode	M1 (Milyar Rupiah)	M2 (Milyar Rupiah)
Jan-10	490083.79	2066480.99
Feb-10	494460.84	2112082.70
Mar-10	494717.69	2116023.54
⋮	⋮	⋮
Apr-22	2327208.49	7911484.49
Mei-22	2302911.17	7854186.71
Jun-22	2339449.79	7890747.01

3.3 Metode Penelitian

Dalam penelitian ini dilakukan analisis menggunakan metode *hybrid Vector Autoregressive (VAR) – Convolutional Neural Network (CNN)*. Langkah-langkah yang dilakukan yaitu:

1. Melakukan *input* data
Data yang di-*input* adalah jumlah uang beredar (M1 dan M2).
2. Melakukan visualisasi data
Visualisasi data digunakan untuk melihat plot data.
3. Melakukan uji korelasi silang (*Cross-Correlation*)
Uji korelasi silang digunakan untuk menguji ada atau tidaknya hubungan serta arah hubungan dari dua variabel.
4. Melakukan uji stasioneritas data
Uji stasioneritas data untuk melihat apakah data sudah stasioner menggunakan ADF, jika tidak stasioner dilakukan *differencing*. Kemudian lakukan uji stasioneritas kembali sampai data stasioner.
5. Membangun model VAR
6. Estimasi parameter model
Estimasi parameter digunakan untuk menentukan model terbaik berdasarkan nilai AIC terkecil.
7. Melakukan prediksi data

8. Menghitung nilai akurasi model terbaik dengan melakukan evaluasi model VAR.
9. Menghitung nilai residual data
Nilai residual diperoleh dengan cara mengurangi data aktual dengan data hasil prediksi.
10. Melakukan peramalan model VAR
11. Melakukan *input* data untuk metode CNN
Data yang di-*input* adalah data hasil prediksi dan residual yang diperoleh dari metode VAR.
12. Melakukan *preprocessing* data
Preprocessing data dengan melakukan normalisasi pada data.
13. Melakukan *splitting* data
Membagi data kedalam data *training* dan data *testing*.
14. Melakukan *scaling* data
Melakukan normalisasi data.
15. Membangun model CNN
16. Melakukan prediksi dan peramalan dengan model pertama CNN menggunakan data prediksi VAR.
17. Melakukan prediksi dan peramalan dengan model pertama CNN menggunakan data residual VAR.
18. Menggabungkan hasil prediksi dan peramalan kedua model CNN.
19. Menghitung nilai akurasi model terbaik dengan melakukan evaluasi model *hybrid*.
20. Melakukan *goodness of fit test* menggunakan uji Kolmogorov-Smirnov.



Gambar 2. Flowchart Metode Penelitian.

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah didapatkan pada bab sebelumnya, maka diperoleh kesimpulan sebagai berikut:

1. Metode *hybrid* VAR-CNN dapat digunakan untuk melakukan prediksi dan peramalan pada data yang menunjukkan adanya *trend*, seperti data jumlah uang beredar di Indonesia.
2. Model VAR merupakan model terbaik untuk melakukan prediksi, tetapi tidak efektif dalam melakukan peramalan.
3. Metode *hybrid* VAR-CNN dengan skema 80% data *training* dan 20% data *testing* menghasilkan model peramalan terbaik dibandingkan dengan metode lainnya berdasarkan nilai MAPE, nilai supremum (D) dan statistik uji (*p-value*) yang diperoleh.

5.2 Saran

Saran yang diberikan untuk peneliti selanjutnya adalah melakukan peningkatan atau modifikasi pada arsitektur CNN atau penyesuaian parameter VAR dan menerapkan metode *hybrid* VAR-CNN pada jenis data lainnya.

DAFTAR PUSTAKA

- Abdullah, L. T. 2022. Forecasting Time Series Using Vector Autoregressive Model. *International Journal of Nonlinear Analysis and Applications (IJNAA)*. **13**(1): 499-511.
- Abhinowo A. A., Isnanto, R. R., & Eridani, D. 2023. Pemilihan Model Terbaik Algoritma Convolutional Neural Network untuk Klasifikasi Jenis Bencana Alam. *Jurnal Teknik Komputer*. **1**(4): 199-208.
- Aslam, M., Sherwani, R. A. K., & Saleem, M. 2021. Vague Data Analysis Using Neutrosophic Jarque-Bera Test. *Public Library of Science (PLoS) ONE*. **10**(1371): 1-9.
- Badan Pusat Statistik (BPS). 2023. Ekonomi dan Perdagangan : Keuangan. <https://www.bps.go.id/indicator/13/123/1/uang-beredar.html>. Diakses pada 19 Agustus 2023.
- Bank Indonesia (BI). 2023. Publikasi : Laporan. <https://www.bi.go.id/id/default.aspx>. Diakses pada 13 Maret 2023.
- 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.
- Boyd, D. W. 2000. *Systems Analysis and Modeling*. 1nd Edition. Academic Press, Bozeman.
- Caraka, R. E., Chen, R. C., Yasin, H., Suhartono, Lee, Y., & Pandamean, B. 2021. Hybrid Vector Autoregressive Feedforward Neural Network with Genetic Algorithm Model for Forecasting Space-Time Pollution Data. *Indonesian Journal of Science & Technology*. **6**(1): 243-266.

- Enders, W. 2004. *Applied Econometrics Time Series*. John Wiley & Sons Inc., New York.
- Engle, R. F. & Granger, C. W. J. 1987. Co-Integration and Error Correction: Representation, Estimation, and Testing. *Econometrica*. **55**(2): 251-276.
- Fausett, L. 1994. *Fundamentals of Neural Networks*. 1st Edition. Prentice Hall Inc., New Jersey.
- Febrianti, D. R., Tiro, M. A., & Sudarmin. 2021. Metode Vector Autoregressive (VAR) dalam Menganalisis Pengaruh Kurs Mata Uang Terhadap Ekspor dan Impor di Indonesia. *Journal of Statistics and Its application on Teaching and Research*. **3**(1): 23-30.
- Feng, J & Lu, S. 2019. Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics Conference Series*. **1237**(2): 1-6.
- Firmansyah, I. & Hayadi, B. H. 2022. Komparasi Fungsi Aktivasi ReLu dan TanH Pada Multilayer Perception. *Jurnal Informatika dan Komputer*. **6**(2):200-206.
- Gujarati, D. N. & Porter, D. C. 2009. *Basic Econometrics*. 5th Edition. McGraw-Hill, New York.
- Halimi, I., Marthasaari, G. I., & Azhar, Y. 2019. Prediksi Harga Emas Menggunakan Univariate Convolutional Neural Network. *Jurnal Repositor*. **1**(2): 105-116.
- Hidayat, B. & Hermawan, G. 2018. Deteksi Hama pada Daun Teh dengan Metode Convolutional Neural Network (CNN). *Jurnal Pengembangan IT (JPIT)*. **6**(2): 87-92.
- Hanke, J. E. & Wichern, D. W. 2005. *Business Forecasting*. 8th Edition. Pearson Prentice Hall, New Jersey.
- Lutkepohl, H. 2005. *New Introduction to Multiple Time Series Analysis*. Springer-Verlag Berlin Heidelberg, Germany.

- Makridakis, S., Wheelwright, S. C., & McGee, V. E. 1999. *Metode dan Aplikasi Peramalan*. 2nd Edition. Terjemah Untung Sus Andriyanto. Erlangga, Jakarta.
- Mukhtar, H., Gunawan, R., Hariyanto, A., Syahril, & Mulyana, W. 2022. Peramalan Kedatangan Wisatawan ke Suatu Negara Menggunakan Metode Support Vector Machine (SVM). *Jurnal Computer Science and Information Technology (CoSciTech)*. 3(3): 274-282.
- Nielsen, M. 2013. *Neural Networks and Deep Learning*. Determination Press, San Francisco.
- Parot, A., Michell, K., & Kristjanpoller, W. D. 2019. Using Artificial Neural Networks to Forecast Exchange Rate, including VAR-VECM Residual Analysis and Prediction Linier Combination. *Intelligent Systems in Accounting, Finance and Management*. 26(1): 3-15.
- Rajab, K., Kamalov, F., & Cheruki, A. K. 2022. Forecasting COVID-19: Vector Autoregression-Based Model. *Arabian Journal for Science and Engineering*. 47(1): 6851-6860.
- Semenoglou, A. A., Spiliotis, E., & Assimakopoulos, V. 2023. Image-based time series forecasting: A deep convolutional neural network approach. *ELSEVIER: Neural Network*. 157(1): 39-53.
- Warsito, B. 2009. *Kapita Sleka Statistika Neural Network*. Badan Penerbit UNDIP, Semarang.
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. 2nd Edition. Pearson Education Hall, New Jersey.
- Zhang, G. P. 2004. *Neural Network in Business Forecasting*. Idea Group Inc., London.
- Zhang, T., Wang, K., & Zhang, X. 2015. Modeling and Analyzing the Transmission Dynamics of HBV Epidemic in Xinjiang, China. *Public Library of Science (PLoS) ONE*. 10(9): 1-14.