

**PENERAPAN METODE *HYBRID AUTOREGRESSIVE INTEGRATED
MOVING AVERAGE (ARIMA)-ARTIFICIAL NEURAL NETWORK (ANN)*
DALAM MERAMALKAN TINGKAT INFLASI DI INDONESIA**

(Skripsi)

Oleh

ANISA APRILIA



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

ABSTRAK

PENERAPAN METODE *HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA)-*ARTIFICIAL NEURAL NETWORK* (ANN) DALAM MERAMALKAN TINGKAT INFLASI DI INDONESIA

Oleh

ANISA APRILIA

Time series adalah data yang disusun berdasarkan urutan waktu, data *time series* digunakan untuk meramalkan kejadian di masa depan. Metode deret waktu yang sering digunakan yaitu *Autoregressive Integrated Moving Average* (ARIMA) yang merupakan model univariate yang menangkap pola linear pada suatu data. Metode *Artificial Neural Network* (ANN) merupakan metode yang menggunakan prinsip jaringan syaraf manusia keuntungan dari metode ini yaitu memiliki kemampuan yang fleksibel dalam memodelkan pola nonlinear pada deret waktu. Sehingga penggunaan Metode *hybrid* ARIMA-ANN dapat memaksimalkan hasil peramalan yang berbentuk pola linear dan nonlinear. Penelitian ini bertujuan untuk menerapkan metode *hybrid* ARIMA-ANN untuk meramalkan tingkat inflasi di Indonesia. Hasil analisis menunjukkan penggunaan metode ARIMA menghasilkan nilai MAPE sebesar 0.0850 dan MSE sebesar 6.3713e-05. Kemudian dengan metode *hybrid* ARIMA-ANN diperoleh penggunaan *splitting* data dengan skema 70% data *training* 30% data *testing* memiliki performa yang terbaik dengan nilai MSE sebesar 1.2997e-05, MAPE sebesar 0.0968, dan akurasi sebesar 99.9032%. Berdasarkan hasil yang diperoleh nilai MSE metode *hybrid* dan hasil visualisasi peramalan metode *hybrid* lebih baik sehingga metode *hybrid* lebih baik digunakan dalam peramalan jangka panjang.

Kata Kunci: *Hybrid* ARIMA-ANN, ARIMA, ANN, Peramalan, Inflasi

ABSTRACT

APPLICATION OF HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)-ARTIFICIAL NEURAL NETWORK (ANN) METHOD IN FORECASTING INFLATION RATE IN INDONESIA

By

ANISA APRILIA

Time series is data organized by time sequence, time series data is used to forecast future events. Time series method that often used is Autoregressive Moving Average (ARIMA) which is a univariate model that capture linear pattern in a data. Artificial Neural Network (ANN) method is a method that used a principle of human neural network which have a benefit to had a flexible capabilities to model a nonlinear pattern in time series. Regardy this capabilities, the us of hybrid ARIMA-ANN method can maximize the result of forecast that had the linear and nonlinear pattern. This study had a purpose to apply hybrid ARIMA-ANN method for forecasting inflation rate in Indonesia. The analysis shows that the use of the ARIMA method produces a MAPE value of 0.0850 and MSE of $6.3713e-05$. Then with the hybrid ARIMA-ANN method, it is found that the use of data splitting with 70% training data 30% testing data scheme has the best performance with MSE value of $1.2997e-05$, MAPE of 0.0968, and accuracy of 99.9032%. Based on the result, MSE value from hybrid method and visualization forecasting result of hybrid method are better to use for forecasting in a long time period.

Keywords: Hybrid ARIMA-ANN, ARIMA, ANN, Forecasting, Inflation

**PENERAPAN METODE *HYBRID AUTOREGRESSIVE INTEGRATED
MOVING AVERAGE (ARIMA)-ARTIFICIAL NEURAL NETWORK (ANN)*
DALAM MERAMALKAN TINGKAT INFLASI DI INDONESIA**

Oleh
ANISA APRILIA
2017031007

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



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

Judul Skripsi : Penerapan Metode *Hybrid Autoregressive Integrated Moving Average (ARIMA)*-*Artificial Neural Network (ANN)* Dalam Meramalkan Tingkat Inflasi Di Indonesia

Nama Mahasiswa : Anisa Aprifia

Nomor Pokok Mahasiswa : 2017031007

Jurusan : Matematika

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

Dr. Khoirin Nisa, S.Si., M.Si.
NIP. NIP. 197407262000032001

Drs. Tiryono Ruby, M.Sc., Ph.D.
NIP. 196207041988031002

2. Ketua Jurusan Matematika

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

MENGESAHKAN

1. Tim Penguji

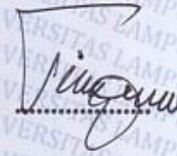
Ketua

: **Dr. Khoirin Nisa, S.Si., M.Si.**



Sekretaris

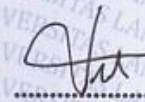
: **Drs. Tiryono Ruby, M.Sc., Ph.D.**



Penguji

Bukan Pembimbing

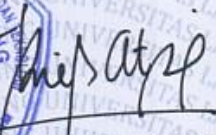
: **Drs. Nusyirwan, M.Si.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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



Tanggal Lulus Ujian Skripsi: 1 April 2024

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Anisa Aprilia**
Nomor Pokok Mahasiswa : **2017031007**
Jurusan : **Matematika**
Judul Skripsi : **Penerapan Metode *Hybrid Autoregressive Integrated Moving Average (ARIMA)*-*Artificial Neural Network (ANN)* Dalam Meramalkan Tingkat Inflasi 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, 1 April 2024

Penulis



Anisa Aprilia
NPM. 2017031007

RIWAYAT HIDUP

Penulis bernama lengkap Anisa Aprilia dilahirkan pada tanggal 24 April 2002. Penulis merupakan anak terakhir dari tiga bersaudara dari Bapak Krusman dan Ibu Aspawati, S.Pd.

Penulis menempuh Pendidikan pertama di Taman Kanak-Kanak di YP Yasri Bandar Lampung pada tahun 2007-2008. Kemudian menempuh Pendidikan Sekolah Dasar di SDN 3 Gunung Terang Bandar Lampung pada tahun 2008-2014. Kemudian penulis melanjutkan Pendidikan ke Sekolah Menengah Pertama di SMPN 22 Bandar Lampung pada tahun 2014-2017. Selanjutnya penulis melanjutkan pendidikan Sekolah Menengah Atas di SMA YP UNILA Bandar Lampung pada tahun 2017-2020.

Pada tahun 2020 penulis diterima sebagai mahasiswa Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN). Selama menjadi mahasiswa penulis bergabung dalam organisasi Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) pada tahun 2021 dan bergabung dengan organisasi Badan Eksekutif Mahasiswa Fakultas Matematika dan Ilmu Pengetahuan Alam (BEM-FMIPA) pada tahun 2022.

Pada tahun 2023 penulis melaksanakan Kerja Praktik (KP) di Dinas Komunikasi Informatika dan Statistik Provinsi Lampung dan pada tahun yang sama penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Cimanuk, Kecamatan Way Lima, Kabupaten Pesawaran.

PERSEMBAHAN

Dengan mengucapkan puji dan syukur atas kehadiran Allah SWT, atas rahmat dan hidayah-Nya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Dengan penuh ketulusan dan rasa syukur saya persembahkan rasa terimakasih kepada

Ibu dan Ayah

Terimakasih saya ucapkan sebesar-besarnya kepada Ibu dan Ayah atas segala doa, dukungan, kasih sayang yang telah kalian berikan. Terimakasih karena selalu mendampingi dan mendukung saya dengan ridho dan doa dalam setiap langkah yang saya jalani

Kanjeng dan Gusti

Terimakasih kepada kakak-kakakku yang telah memberi doa, dukungan, dan perhatian kepada saya

Dosen Pembimbing dan Pembahas

Terimakasih kepada bapak dan ibu dosen yang sangat berjasa telah memberi arahan, bantuan, dukungan serta ilmu yang bermanfaat

Orang Tersayang

Terimakasih kepada keluarga dan sahabat-sahabat yang dengan tulus memberi dukungan, doa, semangat dan cinta kasih kepada saya.

Almamater Tercinta, Universitas Lampung

KATA INSPIRASI

“Maka sesungguhnya bersama kesulitan ada kemudahan”

(Q.S Al-Insyirah : 5)

“Jangan engkau bersedih, sesungguhnya Allah bersama kita”

(Q.S At-Taubah : 40)

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”

(Q.S Al-Baqarah : 286)

“Jika kamu berbuat baik (berarti) kamu berbuat baik untuk dirimu sendiri. Dan jika kamu berbuat jahat, maka (kerugian kejahatan) itu untuk dirimu sendiri”

(Q.S Al-Isra : 7)

“Maka, barangsiapa mengejar kebaikan seberat zarah, niscaya dia akan melihat (balasan)nya”

(Q.S Alz-Zalzalah : 7)

“Bersyukur dan berbahagialah, tanpa merusak dan menyakiti kebahagiaan orang lain”

(Penulis)

SANWACANA

Puji syukur kehadirat Allah SWT, atas segala rahmat dan karunianya sehingga penulis dapat menyelesaikan skripsi yang berjudul “**Penerapan Metode *Hybrid Autoregressive Integrated Moving Average (ARIMA)-Artificial Neural Network (ANN) Dalam Meramalkan Tingkat Inflasi Di Indonesia***”. Dalam menyelesaikan skripsi ini, penulis mendapat dukungan, bimbingan, bantuan dan doa dari berbagai pihak. Oleh karena itu, penulis mengucapkan terimakasih kepada :

1. Ibu Dr. Khoirin Nisa, S.Si., M.Si. selaku dosen pembimbing I yang senantiasa memberi bimbingan, bantuan, motivasi, masukan serta dukungan kepada penulis dalam menyelesaikan skripsi ini.
2. Bapak Drs. Tiryono Ruby, M.Sc., Ph.D. selaku pembimbing II yang telah memberikan arahan, dukungan serta saran yang membantu kepada penulis dalam menyelesaikan skripsi ini.
3. Bapak Drs. Nusyirwan, M.Si. selaku dosen penguji yang telah memberikan kritikan, evaluasi, serta saran yang membangun kepada penulis dalam menyelesaikan skripsi ini.
4. Ibu Dina Eka Nurvazly, S.Pd., M.Si. selaku dosen pembimbing akademik yang telah memberikan bimbingan dan saran kepada penulis selama perkuliahan.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
7. Seluruh dosen, staf dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam.

8. Ayahanda tercinta, ayah Krusman terimakasih atas segala pengorbanan, telah berjuang tanpa rasa lelah untuk kehidupan penulis, telah mendidik, memberi dukungan, doa hingga penulis dapat menyelesaikan skripsi ini, pencapaian ini menjadi langkah awal membuat ayah bangga dan semoga ayah selalu sehat untuk selalu ada di samping penulis dalam pencapaian selanjutnya.
9. Ibundaku tercinta, ibu Aspawati, S.Pd. terimakasih atas segala jasa yang ibu berikan, pengorbanan, yang tak henti-hentinya memberi kasih sayang dengan tulus, mendoakan, memberi dukungan, dan selalu ada untuk penulis selama menyelesaikan skripsi ini, terimakasih sudah mengantarkan penulis sampai di titik ini, semoga pencapaian ini menjadi langkah awal membuat ibu bangga, dan semoga ibu selalu sehat dapat mendampingi penulis dalam pencapaian selanjutnya.
10. Kedua Kakakku, Kanjeng dan Gusti terimakasih selalu memberikan semangat, doa, telah menjaga, memberi perhatian dan dukungan kepada penulis, semoga selalu kompak dan memberi kebahagiaan untuk keluarga.
11. Teruntuk Sahabatku Marudut J.C dan Femmy V.H, S.I.K., terimakasih kalian selalu ada di setiap waktu dan menemani penulis di keadaan apapun, selalu memberi semangat, dukungan, dan bantuan untuk penulis.
12. Teruntuk Sahabatku Feni, Kika, Dafa, dan Anggi, terimakasih selalu ada dalam kondisi apapun dan selalu memberi apresiasi setiap apapun yang penulis lakukan.
13. Teruntuk Sahabat-sahabatku Winda, Hanafi, Yulian, Hilal, Fegy, Sisil, Muhtarom terimakasih atas segala bantuan selama perkuliahan, selalu ada untuk penulis, telah melewati masa-masa sulit bersama, dan memberi banyak cerita selama masa perkuliahan.
14. Teruntuk teman-teman seperjuangan Azzura, Nurul, Maya, Citra, Agis, Nadia, terimakasih selalu memberi dukungan, bantuan, dan selalu bersama-sama selama menyelesaikan skripsi ini.
15. Seluruh pihak terkait yang membantu dalam menyelesaikan skripsi ini yang tidak dapat penulis sebutkan satu persatu.

16. Dan yang terakhir terimakasih kepada diri sendiri, Anisa Aprilia, sangat bangga padamu telah berusaha dan berjuang sejauh ini, terimakasih telah bertahan, tidak menyerah dalam kesulitan apapun dan semangat belajar dalam proses penyelesaian skripsi ini, ini merupakan suatu pencapaian awal yang patut dibanggakan untuk diri sendiri sampai jumpa di pencapaian selanjutnya.

Penulis menyadari skripsi ini masih jauh dari kata sempurna dalam penulisan skripsi ini. Oleh karena itu penulis mengharapkan masukan serta saran untuk dijadikan pelajaran kedepannya.

Bandar Lampung, 1 April 2024

Penulis

Anisa Aprilia

NPM. 2017031007

DAFTAR ISI

	Halaman
DAFTAR TABEL	xvii
DAFTAR GAMBAR	xviii
I. PENDAHULUAN	1
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian.....	3
1.3 Manfaat Penelitian.....	3
II. TINJAUAN PUSTAKA	4
2.1 Data Deret Waktu	4
2.2 Peramalan	5
2.3 Stasioneritas.....	5
2.4 <i>Autocorrelation Function (ACF)</i>	6
2.5 <i>Partial Autocorrelation Function (PACF)</i>	7
2.6 Model Autoregressive (AR)	7
2.7 Model Moving Average (MA)	8
2.8 Model <i>Autoregressive Moving Average (ARMA)</i>	9
2.9 <i>Autoregressive Integrated Moving Average (ARIMA)</i>	9
2.10 Uji Independensi <i>White Noise</i>	12
2.11 Artificial Neural Network (ANN)	13
2.11.1 Arsitektur Jaringan	14

2.11.2	Fungsi Aktivasi	15
2.11.3	<i>Hyperparameter</i>	16
2.11.4	Algoritma <i>Backpropagation</i>	17
2.12	<i>Hybrid</i> ARIMA-ANN	18
2.13	Evaluasi Model.....	19
2.14	Inflasi.....	21
III.	METODELOGI PENELITIAN	22
3.1	Waktu dan Tempat Penelitian	22
3.2	Data Penelitian	22
3.3	Metode Penelitian.....	22
IV.	HASIL DAN PEMBAHASAN.....	25
4.1	Analisis Deskriptif Data Inflasi	25
4.2	Uji Augmented Dickey Fuller (ADF).....	26
4.3	Identifikasi Model ARIMA	28
4.4	Estimasi Parameter Model ARIMA	29
4.5	Evaluasi Parameter Model ARIMA	31
4.6	Uji Signifikansi Parameter Model ARIMA.....	32
4.7	Prediksi Data dengan Model <i>Hybrid</i> ARIMA-ANN.....	34
4.7.1	Menginput Data Prediksi ARIMA dan Data Residual ARIMA.....	34
4.7.2	<i>Splitting</i> Data.....	35
4.7.3	Analisis Komponen Model <i>Lt</i> ANN Menggunakan Prediksi ARIMA	35
4.7.3.1	Hyperparameter Tuning Komponen Model <i>Lt</i> dengan Splitting Data 70% Data Training dan 30% Data Testing (Skema 70% 30%)	36

4.7.3.2	Hyperparameter Tuning Komponen Model <i>Lt</i> dengan Splitting Data 80% Data Training dan 20% Data Testing (Skema 80% 20%).....	37
4.7.4	Analisis Komponen Model <i>Nt</i> ANN dengan Residual ARIMA	38
4.7.4.1	Hyperparameter Tuning Komponen Model <i>Nt</i> dengan Splitting Data 70% Data Training dan 30% Data Testing (Skema 70% 30%).....	38
4.7.4.2	Hyperparameter Tuning Komponen Model <i>Nt</i> dengan Splitting Data 80% Data Training dan 20% Data Testing (Skema 80% 20%).....	39
4.7.5	Melakukan Prediksi dengan Komponen Model <i>Lt</i> ANN.....	40
4.7.6	Melakukan Prediksi dengan Komponen Model <i>Nt</i> ANN.....	41
4.7.7	Model <i>Hybrid</i> ARIMA-ANN.....	41
4.7.8	Melakukan Peramalan Model <i>Hybrid</i> ARIMA-ANN.....	43
4.7.8.1	Peramalan Komponen Model <i>Lt</i> dengan Prediksi ARIMA	43
4.7.8.2	Peramalan Komponen Model <i>Nt</i> dengan Residual ARIMA	44
4.7.8.3	Peramalan Model <i>Hybrid</i> ARIMA-ANN	45
V.	KESIMPULAN	48
	DAFTAR PUSTAKA	49
	LAMPIRAN	52

DAFTAR TABEL

Tabel	Halaman
1. Kriteria nilai MAPE	21
2. Analisis Deskriptif.....	25
3. Uji <i>Augmented</i> Dickey Fuller.....	26
4. Uji <i>Augmented</i> Dickey Fuller setelah <i>differencing</i> 1	27
5. Perbandingan nilai AIC dan MAPE model ARIMA sementara	30
6. Uji <i>Ljung-Box</i> Model ARIMA (0,1,1)	31
7. Uji Signifikansi Parameter ARIMA (0,1,1)	32
8. Hasil Peramalan Model ARIMA.....	33
9. Data Prediksi ARIMA dan Data Residual ARIMA	34
10. Data <i>Traning</i> dan data <i>Testing</i>	35
11. Hasil <i>Hyperparameter Tuning</i> Komponen Model L_t dengan Skema 70% Data <i>Training</i> dan 30% Data <i>Testing</i>	36
12. Hasil <i>Hyperparameter Tuning</i> Komponen Model L_t dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	37
13. Hasil <i>Hyperparameter Tuning</i> Komponen Model N_t dengan Skema 70% Data <i>Training</i> dan 30% Data <i>Testing</i>	38
14. Hasil <i>Hyperparameter Tuning</i> Komponen Model N_t dengan Skema 80% Data <i>Training</i> dan 20% Data <i>Testing</i>	39
15. Hasil Evaluasi Model	42
16. Hasil Peramalan Model <i>Hybrid</i> dengan skema 70% <i>training</i> dan 30% <i>testing</i>	46
17. Hasil Peramalan dan Data <i>Update</i>	47

DAFTAR GAMBAR

Gambar	Halaman
1. Struktur <i>Single Layer</i>	14
2. Struktur <i>Multilayer</i>	15
3. <i>Flowchart</i> ARIMA-ANN.....	24
4. Plot data inflasi.....	26
5. Plot ACF setelah <i>differencing</i> 1	28
6. Plot PACF setelah <i>differencing</i> 1	29
7. Plot Prediksi Model ARIMA (0,1,1).....	33
8. Hasil Visualisasi Prediksi Menggunakan Model L_t ANN.....	40
9. Hasil Visualisasi Prediksi Menggunakan Model N_t ANN	41
10. Hasil Visualisasi Model <i>Hybrid</i>	42
11. Visualisasi Peramalan dengan Model L_t	44
12. Visualisasi Peramalan dengan Model N_t	44
13. Visualisasi Peramalan dengan Model <i>Hybrid</i>	45

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Time series adalah data yang disusun berdasarkan urutan waktu atau data yang dikumpulkan dari waktu ke waktu. Data *time series* digunakan untuk mengambil keputusan dalam memperkirakan atau meramalkan kejadian di masa depan (Nababan & Alexander, 2010). Peramalan merupakan suatu cara digunakan untuk memprediksi suatu nilai di masa mendatang dengan memperhatikan data masa lalu.

Salah satu metode *time series* yang sering digunakan yaitu *Autoregressive Integrated Moving Average* (ARIMA) merupakan gabungan dari proses *Autoregressive* (AR) dengan proses *Moving Average* (MA) yang sudah mengalami *differencing* (*Integrated*). Model ARIMA merupakan model univariate, dimana kekurangan dari ARIMA adalah model ini hanya mengasumsikan model yang linier (Wardani, 2023). Hal ini menyebabkan model ARIMA tidak dapat menangkap pola-pola nonlinier yang terdapat pada *time series*.

Artificial Neural Network (ANN) atau jaringan syaraf tiruan merupakan metode yang menggunakan prinsip jaringan syaraf manusia. Keuntungan dari metode ini yaitu ANN memiliki kemampuan yang fleksibel dalam memodelkan pola nonlinier pada *time series*. Model ANN tidak memerlukan bentuk model yang tetap melainkan akan terbentuk secara adaptif berdasarkan data yang ada (Zhang, 2001). Sehingga keterbatasan yang dimiliki metode ARIMA dapat diatasi oleh

metode ANN. Kombinasi antara metode ARIMA dan ANN dapat memaksimalkan hasil peramalan yang berbentuk pola linier dan nonlinier. Sebelumnya sudah ada penelitian yang menggunakan metode *Hybrid ARIMA-ANN* antara lain, Supriyanto (2017) meneliti tentang peramalan jumlah penumpang penerbangan di terminal 1 Bandara Internasional Juanda menggunakan metode ARIMA-ANN, dimana pada penelitian ini diperoleh nilai MAPE metode *hybrid ARIMA-ANN* sebesar 4,13%.

Penelitian lainnya dilakukan oleh Wahyudin (2019) yang memprediksi inflasi Indonesia memakai model ARIMA dan ANN dalam penelitian ini diperoleh nilai MAPE metode *hybrid ARIMA-ANN* sebesar 4,82%. Kemudian Melyani, dkk. (2021), melakukan penelitian mengenai peramalan tingkat inflasi Indonesia menggunakan metode ARMA dimana diperoleh nilai AIC sebesar 0,2373 dan RMSE sebesar 7,81.

Obyek penelitian ini adalah tingkat inflasi, dimana inflasi merupakan salah satu indikator makro dalam pertumbuhan ekonomi. Perekonomian suatu negara dianggap baik jika menunjukkan pertumbuhan ekonomi yang stabil. Hal ini menyebabkan kestabilan inflasi menjadi perhatian utama bagi pertumbuhan ekonomi yang pada akhirnya akan memberikan manfaat bagi peningkatan kesejahteraan masyarakat. Inflasi yang tidak stabil akan memberikan dampak negatif pada kondisi sosial ekonomi masyarakat. Penelitian mengenai peramalan inflasi membantu untuk mengetahui tingkat inflasi yang akan datang, sehingga pemerintah dapat menentukan kebijakan yang akan diambil.

Berdasarkan pemaparan yang telah dijelaskan, penulis memiliki gagasan untuk melakukan penelitian mengenai “Penerapan *Metode Hybrid Autoregressive Integrated Moving Average-Artificial Neural Network* Dalam Meramalkan Tingkat Inflasi di Indonesia”.

1.2 Tujuan Penelitian

Tujuan dari penelitian ini adalah menerapkan metode *hybrid autoregressive integrated moving average (ARIMA)-artificial neural network (ANN)* untuk meramalkan tingkat inflasi di Indonesia.

1.3 Manfaat Penelitian

Adapun manfaat dari penelitian ini adalah:

1. Memberikan wawasan terkait metode *hybrid ARIMA-ANN*.
2. Menambah sumber ilmu pengetahuan bagi penulis maupun pembaca.
3. Dapat menjadi referensi bagi peneliti selanjutnya untuk jenis data yang lain dengan menggunakan metode *hybrid ARIMA-ANN*.

II. TINJAUAN PUSTAKA

2.1 Data Deret Waktu

Data deret waktu adalah suatu data yang dikumpulkan selama retan waktu tertentu. Jika waktu dianggap diskrit, maka frekuensi pengumpulan data selalu sama. Seperti, detik, menit, jam, hari, bulan, dan tahun (Rosadi, 2006). Menurut Makridakis, dkk. (1995), Data deret waktu memiliki empat macam pola data, yaitu:

1. Pola horizontal atau konstan

Pola data horizontal atau konstan terjadi apabila data pengamatan berfluktuasi berada di sekitar nilai rata-rata yang membentuk garis lurus, sehingga disebut juga sebagai data stasioner.

2. Pola *trend*

Pola data *trend* terjadi apabila data pengamatan mengalami kenaikan atau penurunan dalam kurun waktu tertentu secara terus menerus, sehingga disebut juga sebagai data tidak stasioner.

3. Pola musiman

Pola data musiman terjadi apabila data pengamatan dipengaruhi faktor musiman. Pola data musiman dapat mempunyai pola musim yang berulang dari periode ke periode berikutnya. Misalnya pola yang berulang setiap bulan tertentu, tahun tertentu atau pada minggu tertentu.

4. Pola siklis

Pola data siklis terjadi apabila data pengamatan berfluktuasi secara berkepanjangan.

2.2 Peramalan

Peramalan adalah salah satu teknik yang digunakan untuk memprediksi suatu nilai di masa mendatang dengan memperhatikan data masa lalu. Menurut Miraswan, *et al.* (2022), Peramalan adalah perkiraan sistematis bahwa informasi dapat diambil dari data masa lalu. Tujuan dari peramalan ialah mencari *error* atau kesalahan terkecil. Menurut Montgomery, *et al.* (2015) terdapat dua jenis metode peramalan yaitu:

1. Metode kuantitatif adalah peramalan yang menggunakan data kuantitatif pada masa lalu. Hasil peramalan kuantitatif sangat tergantung pada metode yang diterapkan dalam peramalan, sehingga setiap metode akan memiliki hasil peramalan yang bervariasi.
2. Metode kualitatif adalah peramalan yang menggunakan data kualitatif pada masa lalu. Hasil peramalan kualitatif berdasarkan pada pendapat, emosi, pengetahuan, dan pengalaman pribadi peneliti.

2.3 Stasioneritas

Dalam analisis deret waktu salah satu asumsi yang paling penting adalah kestasioneran data. Stasioneritas adalah tidak terdapat perubahan yang drastis pada data. Dengan kata lain, fluktuasi beresada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut (Makridakis, dkk., 1995).

Uji *Augmented Dickey Fuller* (ADF) merupakan salah satu uji yang digunakan untuk melihat apakah data stasioner atau tidak. Persamaan uji ADF sebagai berikut:

$$\Delta Y_t = \phi Y_{t-1} + \sum_{j=1}^{p-1} a_j^* \Delta Y_{t-j} + \varepsilon_t \quad (2.1)$$

dimana:

ΔY_t = bentuk dari pembeda pertama

Y_{t-1} = nilai variabel pada waktu ke $t-1$

ϕ = parameter

p = panjang lag

a_j^* = konstanta

ε_t = residual pada waktu ke $t-1$

Hipotesis yang diuji

$H_0: \phi \geq 1$ (data tidak stasioner)

$H_1: \phi \leq 1$ (data stasioner)

Statistik uji:

$$t_{hitung} = \frac{\hat{\phi} - 1}{sd(\hat{\phi})} \quad (2.2)$$

dimana:

$\hat{\phi}$ = koefisien autoregressive (AR)

$sd(\hat{\phi})$ = varians dari $\hat{\phi}$

Taraf signifikansi:

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

Dengan kriteria uji:

Tolak H_0 apabila p-value $< \alpha$ artinya data stasioner.

2.4 Autocorrelation Function (ACF)

ACF merupakan hubungan yang terjadi antar variabel satu atau lebih.

Autokorelasi juga ialah hubungan yang terjadi pada data deret waktu terhadap selang waktu atau lag yang berlainan. ACF artinya suatu hubungan linier antara pengamatan Y_t dengan pengamatan Y_{t-k} (Machmudin & Brodjol, 2012).

Menurut Andalita & Irhamah (2015), Hanya 10% lag awal yang menghasilkan

model *moving average* yang akurat. Ini dapat digunakan untuk menentukan apakah data stasioner atau tidak.

Koefisien autokorelasi untuk lag- k dari data deret waktu dapat ditulis sebagai berikut:

$$r_k = \text{Corr}(Y_t, Y_{t-k}) = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^{n-k} (Y_t - \bar{Y})^2} \quad (2.3)$$

2.5 Partial Autocorrelation Function (PACF)

PACF adalah hubungan antar deret pengamatan dalam lag-lag pengamatan yang mengukur keeratan antar variabel satu dengan yang lainnya. Menurut Andalita & Irhamah (2015), Hanya 10% lag awal yang menghasilkan model rata-rata pergerakan yang akurat. Ini dapat digunakan untuk menentukan apakah data stasioner atau tidak. PACF digunakan untuk mengukur tingkat keeratan hubungan antara Y_t dan Y_{t-k} setelah menghilangkan pengaruh variabel $Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1}$. Berikut notasi yang digunakan untuk PACF:

$$r_{kk} = \text{Corr}(Y_t, Y_{t-k} | Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1}) \quad (2.4)$$

2.6 Model Autoregressive (AR)

Model AR adalah model data stasioner dari deret waktu yang mengasumsikan bahwa suatu kejadian saat ini dipengaruhi oleh kejadian yang sama pada periode sebelumnya. Model AR(p) secara umum ditulis sebagai berikut (Montgomery, dkk., 2015):

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.5)$$

atau dengan menggunakan operator backshift dapat ditulis persamaan sebagai berikut:

$$Y_t = \phi_0 + \phi_1 B + \phi_2 B^2 + \dots + \phi_p B^p + \varepsilon_t \quad (2.6)$$

dimana:

Y_t	= data pada waktu ke-t
Y_{t-1}, \dots, Y_{t-p}	= nilai masa lalu pada data yang bersangkutan
ϕ_0	= konstanta
$\phi_1, \phi_2, \dots, \phi_p$	= parameter AR
ε_t	= nilai <i>error</i> waktu ke-t
B	= operator backshift

2.7 Model Moving Average (MA)

Model MA adalah model yang mengasumsikan bahwa prediksi suatu nilai saat ini dipengaruhi oleh error oleh error periode sebelumnya. Model MA(q) secara umum ditulis sebagai berikut:

$$Y_t = \theta_0 + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (2.7)$$

atau dengan menggunakan operator backshift dapat ditulis persamaan sebagai berikut:

$$Y_t = \varepsilon_t (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \quad (2.8)$$

dimana:

Y_t	= nilai data pada waktu ke-t
$\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$	= nilai <i>error</i> pada data yang bersangkutan
θ_0	= konstanta
$\theta_1, \theta_2, \dots, \theta_q$	= parameter MA
ε_t	= nilai <i>error</i> pada waktu ke-t
B	= operator backshift

2.8 Model *Autoregressive Moving Average* (ARMA)

Model ARMA merupakan gabungan dari model AR dan MA yang mengasumsikan bahwa kejadian saat ini dipengaruhi oleh kejadian yang sama dan nilai *error* pada periode sebelumnya. Model ARMA (p, q) secara umum ditulis sebagai berikut:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (2.9)$$

atau dengan menggunakan operator backshift dapat ditulis persamaan sebagai berikut:

$$\phi_p(B)Y_t = c + \theta_q(B)\varepsilon_t \quad (2.10)$$

dimana:

Y_t	= nilai data pada waktu ke-t
Y_{t-1}, \dots, Y_{t-p}	= nilai masa lalu pada data yang bersangkutan
$\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$	= nilai <i>error</i> data yang bersangkutan
ϕ_0	= konstanta
$\phi_1, \phi_2, \dots, \phi_p$	= parameter AR
$\theta_1, \theta_2, \dots, \theta_q$	= parameter MA
ε_t	= nilai <i>error</i> pada waktu ke-t
B	= operator backshift

2.9 *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA merupakan model ARMA yang tidak stasioner sehingga dilakukan *differencing* yang membuat model menjadi stasioner. Model ARIMA

(p, d, q) terdiri dari order (p) bagian dari model AR, order (d) hasil *differencing* yang dilakukan pada data, dan order (q) bagian dari model MA. Model ARIMA (p, d, q) secara umum ditulis sebagai berikut (Montgomery, dkk., 2015):

$$\phi_p(B)(1 - B)^d Y_t = c + \theta_q(B)\varepsilon_t \quad (2.11)$$

dimana:

$(1 - B)^d$ = proses *differencing* orde ke- d

$\phi_p(B)$ = $(1 + \phi_1 B + \phi_2 B^2 + \dots + B^p)$

$\theta_q(B)$ = $(1 + \theta_1 B + \theta_2 B^2 + \dots + B^q)$

c = konstanta

ε_t = nilai *error* pada waktu ke- t

Kemudian setelah model didapat maka selanjutnya mencari estimasi dari model tersebut. Estimasi dilakukan dengan menggunakan metode *least square* atau kuadrat terkecil. Selanjutnya dilakukan uji signifikan parameter pada model. Uji signifikan dilakukan pada tahap estimasi parameter dimana membandingkan nilai *P-value* pada *output* estimasi parameter dengan taraf signifikansi (α) yaitu 5% atau 0,05 dengan hipotesis uji sebagai berikut:

H_0 : parameter tidak signifikan

H_1 : parameter signifikan

Tolak H_0 jika nilai *P-value* $< \alpha$. Metode kuadrat terkecil adalah metode yang digunakan untuk menaksirkan parameter dengan cara meminimumkan jumlah kuadrat *error*, jumlah kuadrat *error* untuk persamaan time series tingkat satu analog dengan persamaan kuadrat *error* regresi linier sederhana, yaitu:

$$J = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.12)$$

Untuk persamaan regresi linier sederhana, sebagai berikut:

$$\hat{y}_i = \alpha + \beta x_i \quad (2.13)$$

Tetapi untuk mengestimasi parameter pada model *time series* maka mengganti $e_i = \varepsilon_t$, $y_i = Y_t$, dan $\hat{y}_i = \hat{Y}_t$ maka persamaan (2.12) menjadi sebagai berikut:

$$J = \sum_{i=1}^n \varepsilon_t^2 = \sum_{i=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.14)$$

Misalkan metode least squares diaplikasikan pada model AR (1) dapat ditulis sebagai berikut:

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \varepsilon_t \quad (2.15)$$

Maka persamaan model AR (1) dapat ditulis sebagai berikut:

$$J(\phi, \mu) = \sum_{t=2}^n \varepsilon_t^2 = \sum_{t=2}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu)]^2 \quad (2.16)$$

Pendugaan parameter ϕ dan μ dapat dilakukan dengan cara meminimumkan $J(\phi, \mu)$. Dengan cara menurunkan $J(\phi, \mu)$ terhadap ϕ dan μ selanjutnya desama dengankan dengan nol. Berikut turunan $J(\phi, \mu)$ terhadap μ diperoleh:

$$\frac{\partial J}{\partial \mu} = 2 \sum_{t=2}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.17)$$

Sehingga diperoleh nilai estimasi parameter μ dari model AR (1) sebagai berikut:

$$\hat{\mu} = \frac{\sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1}}{(n-1)(1-\phi)} \quad (2.18)$$

Selanjutnya turunan $J(\phi, \mu)$ terhadap ϕ diperoleh:

$$\frac{\partial J}{\partial \phi} = -2 \sum_{t=2}^n [(Y_t - \mu) - \phi_1(Y_{t-1} - \mu)](Y_{t-1} - \mu) = 0 \quad (2.19)$$

Sehingga diperoleh nilai estimasi parameter ϕ dari model AR (1) sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \mu)(Y_{t-1} - \mu)}{\sum_{t=2}^n (Y_{t-1} - \mu)^2} \quad (2.20)$$

2.10 Uji Independensi *White Noise*

Kestasioneran suatu data dapat dilihat dari uji *white noise*. Suatu model dikatakan baik jika nilai residual memenuhi uji *white noise*. Menurut Lestari & Wahyuningsih(2014), Suatu model bersifat *white noise* artinya bahwa nilai residual dari model tersebut memenuhi asumsi variasi residual homogen dan bersifat independen (tidak ada korelasi antar residual). Uji yang digunakan biasanya ialah uji *Ljung-Box*. Berikut Langkah-langkah melakukan uji *Ljung-Box*:

1. Hipotesis

H_0 : tidak ada korelasi dari residual (bersifat *white noise*)

H_1 : ada korelasi dari residual (tidak bersifat *white noise*)

2. Taraf signifikansi:

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

3. Statistik uji

$$Q = n(n + 2) \sum_{k=1}^K \frac{\widehat{\rho}_k^2}{n - k} \quad (2.21)$$

dimana:

n = banyaknya data

k = nilai pada lag

K = maksimum lag

ρ_k = nilai autokorelasi pada lag ke- k

4. Dengan kriteria uji

Tolak H_0 jika $|Q| \geq \chi_{\alpha; (K-p)}^2$ atau $p\text{-value} \leq \alpha$ artinya ada korelasi dari residual (tidak bersifat *white noise*)

5. Keputusan

6. Kesimpulan.

2.11 Artificial Neural Network (ANN)

ANN atau jaringan syaraf tiruan merupakan suatu sistem yang digunakan dalam pengelolaan informasi dengan karakteristik yang serupa dengan syaraf biologis (Arhami & Nasir, 2020). ANN mempresentasikan cara kerja dari otak manusia yang selalu melakukan proses pembelajaran. ANN adalah suatu model yang menangkap pola-pola nonlinier pada data deret waktu. Dalam ANN terdapat tiga elemen yang berperan penting sebagai berikut:

1. Arsitektur jaringan yang disebut sebagai pola hubungan antar *neuron*.
2. Algoritma pembelajaran yang berfungsi untuk penggunaan penemuan bobot pada jaringan.
3. Fungsi dari aktivasi yang digunakan.

Komponen-komponen pada *neural network* sebagai berikut:

1. *Neuron*

ANN terdiri dari elemen-elemen sederhana yang disebut *neuron* (unit atau node). Setiap unit berfungsi menerima data *input* dan memproses informasi.

2. *Layer*

Layer atau jaringan merupakan kumpulan-kumpulan dari *neuron* kemudian membentuk suatu lapisan yang saling terhubung.

3. *Input*

Input suatu nilai yang akan diproses dan menghasilkan nilai output.

4. *Output*

Output suatu proses pemecahan masalah atau proses perhitungan dari fungsi aktivasi yang menghasilkan suatu *output* dari jaringan yang telah di *input*.

5. Bobot


Bobot merupakan nilai matematis antar *neuron* dari sebuah koneksi, kemudian akan mentransfer data satu lapisan ke lapisan lainnya. Bobot berfungsi untuk mengoptimalkan dan mengatur jaringan sehingga menghasilkan sebuah *output* yang diinginkan.

2.11.1 Arsitektur Jaringan

Menurut Kusumadewi (2003), Arsitektur jaringan yang sering digunakan sebagai berikut:

1. *Single layer*


Single layer atau jaringan lapisan tunggal hanya memiliki satu lapisan untuk menghubungkan nilai bobotnya. Pada jaringan ini, hanya menerima *input* dan dihubungkan langsung pada *output*-nya tanpa melalui *hidden layer*.



Gambar 1. Struktur *Single Layer*. (Sumber: Haykin, 2009)

2. *Multilayer*

Multilayer merupakan pengembangan dari *single layer*, dimana pada jaringan ini memiliki *input layer*, *output layer*, dan satu *layer* tambahan yang disebut *hidden layer* atau lapisan tersembunyi.



Gambar 2. Struktur *Multilayer*. (Sumber: Haykin, 2009)

2.11.2 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang berperan untuk menentukan setiap *neuron* dalam jaringan diaktifkan atau tidak. Fungsi aktivasi memiliki peran yang penting dalam suatu *neural network* dimana penggunaannya tergantung dengan kebutuhan yang diinginkan. Adapun fungsi aktivasi yang sering digunakan antara lain:

1. Fungsi *Rectified Linier Unit* (ReLU)

Rectified Linier Unit (ReLU) merupakan fungsi aktivasi yang memiliki perhitungan yang sederhana dan digunakan untuk menormalisasikan nilai yang dihasilkan *layer*. Persamaan fungsi aktivasi ReLU dapat ditulis sebagai berikut:

$$f(x) = \max(0, x) \quad (2.22)$$

dimana:

x = nilai data *input*

$f(x)$ = hasil *output* fungsi ReLU

2. Fungsi *Tan Hiperbolik* (TanH)

Tan Hiperbolik (TanH) digunakan untuk menormalisasikan *output* dari setiap *neuron* yang dilewati memiliki rentang nilai antara -1 dan 1 (Putra, dkk., 2022).

Persamaan fungsi aktivasi TanH dapat ditulis sebagai berikut:

$$\tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (2.23)$$

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} \quad (2.24)$$

dimana:

e = bilangan euler

x = data

2.11.3 *Hyperparameter*

Pemilihan parameter pada model digunakan untuk mendapatkan hasil yang maksimal. Adapun parameter yang digunakan sebagai berikut:

1. Nodes pada *Hidden Layer*

Perubahan hasil pelatihan bergantung dengan banyaknya *hidden layer* yang digunakan. Penggunaan jumlah *nodes* terlalu sedikit menyebabkan model *underfitting*, sebaliknya penggunaan jumlah *nodes* terlalu banyak menyebabkan model menjadi kompleks sehingga terjadinya *overfitting*.

Beberapa aturan untuk menentukan jumlah nodes pada hidden layer sebagai berikut:

1. Jumlah *nodes* pada *hidden layer* diantara jumlah *nodes* pada *input* dan *output*.
2. Jumlah *nodes* pada *hidden layer* $2/3$ dari jumlah *nodes* pada *input* kemudian dijumlahkan dengan *nodes* pada *output*.
3. Jumlah modes pada *hidden layer* harus kurang dari 2 kali jumlah nodes pada *input*.

2. *Epoch*

Epoch merupakan parameter yang digunakan untuk menentukan jumlah iterasi dalam proses pelatihan untuk mengelola keseluruhan dataset. Proses pelatihan tersebut ketika keseluruhan dataset sudah melalui proses pelatihan pada *neural network* sampai kembali lagi ke awal.

3. *Learning Rate*

Learning rate digunakan untuk mengontrol seberapa besar langkah-langkah yang diambil dalam proses optimisasi atau penyesuaian bobot model selama pelatihan.

2.11.4 Algoritma *Backpropagation*

Pada tahun 1986 Hinton dkk pertama kali memperkenalkan ANN dengan algoritma *backpropagation* yang kemudian pada tahun 1988 Rumelhart dan McClelland algoritma tersebut.

Menurut Fausett (1994), Pelatihan *backpropagation* meliputi 3 fase sebagai berikut:

1. Propagasi maju (*feedforward*)

Pola *input* dihitung secara maju dari lapisan *input* hingga lapisan *output* menggunakan fungsi aktivasi yang telah ditetapkan.

2. Propagasi mundur/eror (*backpropagation of error*)

Kesalahan yang timbul karena terdapat perbedaan antara *output* jaringan dengan target yang diinginkan. Kesalahan tersebut kemudian dipropagasi mundur, dimulai dari jalur yang terhubung secara langsung dengan unit di lapisan *output*.

3. Modifikasi bobot serta bias (*adjustment*)

Backpropagation beroperasi dengan mencari *error output* melalui arah maju (*forward*) untuk mengoreksi bobot kemudian dilakukan melalui arah mundur (*backward*). Pada saat melakukan *forward* fungsi aktivasi akan mengaktifkan *neuron-neuron* untuk menghasilkan *output*. Umumnya fungsi aktivasi yang

digunakan dalam *backpropagation* bersifat kontinu, terdiferensial, dan tidak menurun.

2.12 Hybrid ARIMA-ANN

Model *hybrid* adalah kombinasi dua atau lebih model dalam satu system (Fitriani, dkk., 2015). Model ARIMA dan ANN merupakan model *hybrid* yang digunakan mengatasi masalah linier dan nonlinier (Zhang, 2001). Pada kasus deret waktu jarang terjadi yang murni linier dan nonlinier, pola data lebih sering mengandung campuran keduanya. Secara umum kombinasi model deret waktu yang memiliki struktur autokorelasi linier dan nonlinier dapat ditulis sebagai berikut:

$$y_t = L_t + N_t \quad (2.25)$$

dimana:

- y_t = nilai aktual
- L_t = komponen linier
- N_t = komponen nonlinier

Dua komponen di atas dapat digunakan untuk meramalkan data. Hasil peramalan model ARIMA digunakan sebagai komponen linier. Kemudian residual dari model linier digunakan sebagai komponen nonlinier. Misalkan e_t merupakan residual pada saat t waktu dari model linier, sehingga:

$$e_t = y_t - L'_t \quad (2.26)$$

dimana:

- y_t = nilai aktual
- L'_t = nilai peramalan dari komponen linier

Dari setiap pola nonlinier residual model ARIMA memiliki batasan. Pemodelan residual menggunakan ANN, hubungan nonlinier dapat dibangun. Dengan n unit *input*, model ANN untuk residual dapat ditulis sebagai berikut:

$$e_t = f(e_{(t-1)}, e_{(t-1)}, \dots, e_{(t-n)}) + \varepsilon_t \quad (2.27)$$

dimana:

e_t = nilai residual

f = fungsi nonlinier dari ANN

ε_t = nilai *error*

Persamaan di atas dapat ditulis sebagai N'_t . Sehingga peramalan model *hybrid* dapat ditulis sebagai berikut:

$$y'_t = L'_t + N'_t \quad (2.28)$$

dimana:

y'_t = peramalan dari model *hybrid*

L'_t = peramalan komponen linier dari ANN

N'_t = peramalan komponen non linier dari ANN

2.13 Evaluasi Model

Mengukur tingkat akurasi suatu periode peramalan dapat dilakukan dengan mencari selisih besaran (ukuran kesalahan peramalan) data peramalan terdapat data aktual. Hal tersebut dapat dilihat pada kesalahan (*error*) yang semakin kecil, (Vivianti, dkk., 2020). Mengukur tingkat kesalahan dapat diuji menggunakan beberapa metode diantaranya sebagai berikut:

1. Akaike information Criterion (AIC)

AIC merupakan ukuran perbandingan yang digunakan untuk memilih model sebagai penentuan model terbaik dan juga digunakan untuk mendeskripsikan data yang memiliki sejumlah parameter terbaik untuk digunakan dalam meramalkan

data. Jika nilai AIC yang dihasilkan semakin kecil maka model tersebut semakin baik digunakan untuk peramalan. Suatu model dikatakan baik jika diperoleh nilai AIC yang paling kecil. Berikut perhitungan AIC:

$$AIC = \ln\left(\frac{\sum_{i=1}^n \varepsilon_i^2}{n}\right) + \frac{2k}{n} \quad (2.9)$$

dengan :

ε_i^2 = residual

k = jumlah parameter yang diestimasi dalam model

n = jumlah sampel

2. Mean Squared Error (MSE)

MSE dihitung berdasarkan jumlah dari selisih data peramalan dengan data aktual.

$$MSE = \frac{\sum_{i=1}^n (A_i - F_i)^2}{n} \quad (2.30)$$

dimana:

A_i = nilai data aktual

F_i = nilai hasil prediksi

n = banyaknya data

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

3. Mean Absolute Percentage Error (MAPE)

MAPE adalah persentase error yang dihasilkan dari nilai minimum selisih antara data aktual dengan data hasil prediksi yang dinyatakan sebagai persentase nilai aktual (Wei, 2006).

$$MAPE = \sum_{i=1}^n \frac{\frac{|A_i - F_i|}{A_i}}{n} \times 100\% \quad (2.31)$$

dimana:

A_i = nilai data aktual

F_i = nilai hasil prediksi

n = banyaknya data

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

Nilai MAPE memiliki kriteria sebagai berikut:

Tabel 1. Kriteria nilai MAPE

Nilai MAPE	Model Prediksi
<10%	Sangat baik
10% - 20%	Baik
20% - 50%	Cukup baik
>50%	Buruk

2.14 Inflasi

Inflasi adalah suatu kondisi dimana harga barang atau jasa di suatu negara mengalami kenaikan secara berkepanjangan selama periode waktu tertentu. Stabilitas ekonomi suatu negara dapat dilihat dari adanya stabilitas harga, dimana tidak ada kenaikan harga secara berkepanjangan yang dapat merugikan masyarakat, baik konsumen maupun produsen yang akan merusak sendi-sendi perekonomian. Tingkat inflasi yang rendah dan stabil akan membuat pertumbuhan ekonomi menjadi meningkat. Inflasi atau deflasi dapat dihitung menggunakan rumus sebagai berikut:

$$INF_t = \left(\frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \right) \times 100 \quad (2.32)$$

dimana:

IHK_t = indeks harga konsumen terbaru

IHK_{t-1} = indeks harga konsumen sebelumnya

III. METODELOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada Semester Ganjil tahun akademik 2023/2024 dengan melakukan penelitian secara studi pustaka di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Data Penelitian

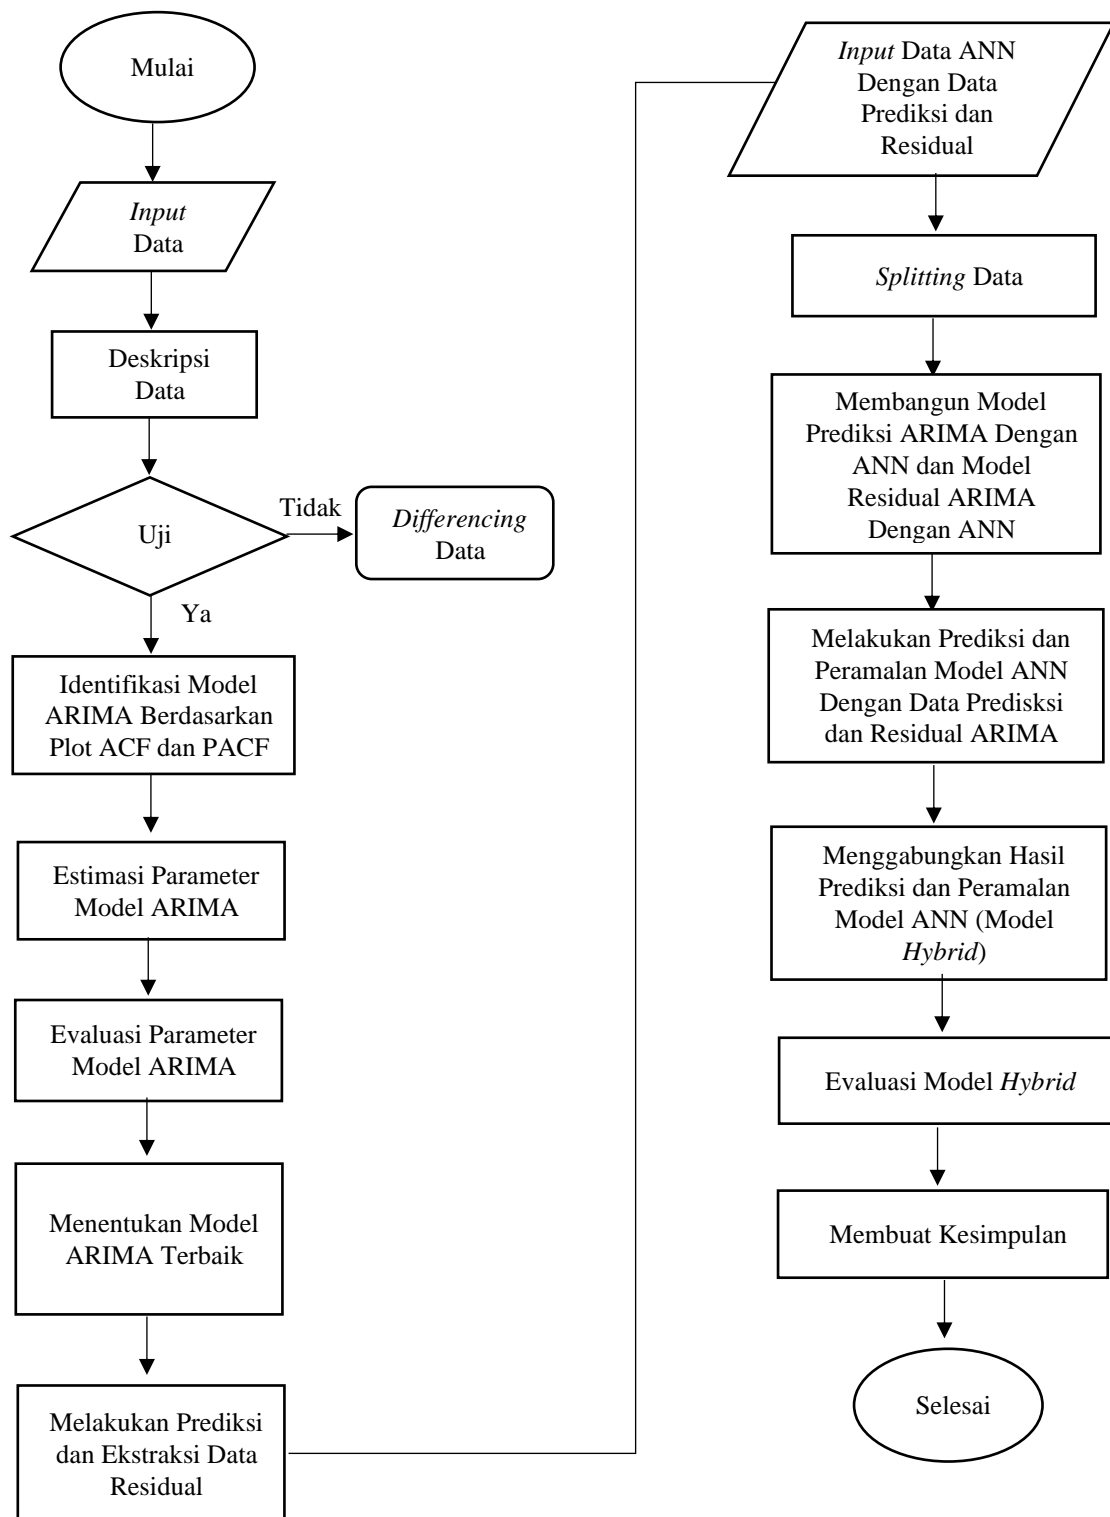
Data yang digunakan merupakan data bulanan inflasi Indonesia yang tersedia pada situs Bank Indonesia. Data inflasi yang digunakan ialah data historis yaitu data bulanan inflasi Indonesia sejak Januari 2006 sampai dengan Agustus 2023 dengan jumlah 212 data. Berikut link web situs Bank Indonesia <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx>.

3.3 Metode Penelitian

Berikut merupakan alur dari pengerjaan metode *hybrid* ARIMA-ANN

1. Mendeskripsikan dan melihat plot data inflasi.
2. Melakukan uji stasioneritas menggunakan uji ADF, jika data belum memenuhi uji stasioneritas maka lakukan proses *differencing* pada data.

3. Melakukan pembentukan model ARIMA, tahapan dilakukan dengan melakukan identifikasi orde p , d , dan q untuk model ARIMA yang digunakan untuk melakukan prediksi.
4. Melakukan prediksi model ARIMA dengan menggunakan model ARIMA terbaik.
5. Melakukan ekstraksi data residual yang merupakan selisih antara data prediksi ARIMA dengan data aktual dari data tingkat inflasi.
6. Data prediksi ARIMA dan data residual ARIMA digunakan sebagai input untuk diolah dengan menggunakan ANN.
7. Melakukan *splitting* pada data prediksi ARIMA dan data residual ARIMA dengan skema 70% *training*, 30% *testing* dan skema 80% *training*, 20% *testing*.
8. Membuat dua model utama dengan menggunakan ANN sebagai landasan dalam melakukan proses *hybrid*. Model L_t merupakan model untuk memprediksi data prediksi ARIMA. Model N_t merupakan model untuk memprediksi data residual ARIMA.
9. Penentuan parameter terbaik model ANN, dilakukan dengan menggunakan *hyperparameter tuning* untuk menentukan parameter terbaik.
10. Melakukan prediksi dan peramalan dengan model ANN L_t menggunakan data prediksi dari ARIMA.
11. Melakukan prediksi dan peramalan dengan model ANN N_t menggunakan data residual dari ARIMA.
12. Menggabungkan hasil prediksi dan peramalan dari kedua model ANN.
13. Hasil dari penggabungan kedua model merupakan model *hybrid* ARIMA-ANN.
14. Evaluasi model *hybrid* ARIMA-ANN.



Gambar 3. Flowchart ARIMA-ANN

V. KESIMPULAN

Metode *hybrid* ARIMA-ANN merupakan metode yang baik untuk meramalkan tingkah inflasi di Indonesia. Kesimpulan yang didapat berdasarkan proses penelitian dalam meramalkan tingkat inflasi di Indonesia dengan Metode *hybrid* ARIMA-ANN sebagai berikut:

1. Metode ARIMA menghasilkan nilai MAPE sebesar 0.0850 dengan nilai MSE sebesar $6.3713e-05$. Kemudian dengan metode *hybrid* ARIMA-ANN menggunakan 2 skema yang berbeda, yaitu skema 70% 30% dan skema 80% 20%, diperoleh skema 70% 30% yang terbaik dengan nilai MSE $1.2997e-05$, MAPE 0.0968, dan akurasi sebesar 99.9032%.
2. Berdasarkan hasil yang diperoleh nilai MSE metode *hybrid* dan hasil visualisasi peramalan metode *hybrid* lebih baik dibandingkan metode ARIMA dalam hal ini penulis tetap merekomendasikan penggunaan metode *hybrid* karena kelebihannya dalam meramalkan jangka panjang. Metode *hybrid* ARIMA-ANN dapat digunakan untuk melakukan peramalan tingkat inflasi di Indonesia terutama model dengan skema 70% 30%. Hasil peramalan tingkat inflasi di Indonesia dari bulan September 2023 sampai dengan bulan Agustus 2024 berturut-turut sebagai berikut 0.0327; 0.0326; 0.0322; 0.0318; 0.0313; 0.0309; 0.0306; 0.0303; 0.0300; 0.0297; 0.0295; 0.0292.

DAFTAR PUSTAKA

- Andalita, I., & Irhamah, I. 2016. Peramalan Jumlah Penumpang Kereta Api Kelas Ekonomi Kertajaya Menggunakan ARIMA dan ANFIS. *Jurnal Sains Dan Seni ITS*. 4(2): 311-316.
- Arhami, M., & Nasir, M. 2020. *Data Mining Algoritma dan Pemrograman*. Penerbit Andi, Yogyakarta.
- Bank Indonesia. 2023. Data Inflasi. <https://www.bi.go.id/id/statistik/indikator/data-inflasi.aspx>. Diakses pada 20 September 2023.
- Fausett, L.V. 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice Hall, New Jersey.
- Fitriani, B. E., Ispriyanti, D., & Prahutama, A. 2015. Peramalan Beban Pemakaian Listrik Jawa Tengah dan Daerah Istimewa Yogyakarta dengan Menggunakan Hybrid Autoregressive Integrated Moving Average–Neural Network. *Jurnal Gaussian*. 4(4): 745-754.
- Haykin, S. 2009. *Neural Networks and Learning Machines*. 3rd Edition. Pearson Education, New Jersey.
- Kusumadewi, S. 2003. *Artificial Intelligence (Teknik dan Aplikasinya)*. Graha Ilmu. Yogyakarta.
- Lestari, N., & Wahyuningsih, N. 2012. Peramalan Kunjungan Wisata dengan Pendekatan Model Sarima (Studi Kasus: Kusuma Agrowisata). *Jurnal Sains dan Seni ITS*. 1(1): A29-A33.

- Machmudin, A. & Brodjol, S.S.U. 2012. Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains dan Seni*. **1**(1): 118-123.
- Makridakis, S., Wheelright, S. C., & McGee V. E. 1995. *Forecasting: methods and Applications*. Second Edition. John Wiley and Sons, New Jersey.
- Melyani, C. A., Nurtsabita, A., Shafa, G. Z., & Widodo, E. 2021. Peramalan inflasi di Indonesia menggunakan metode Autoregressive Moving Average (ARMA). *Journal of Mathematics Education and Science*. **4**(2): 67-74.
- Miraswan, K. J., Puspitas, W. A., & Utami, A. S. 2022. Prediction of the Number of New Cases of Covid-19 in Indonesia Using Fuzzy Time Series Model Chen. *Sriwijaya Journal of Informatics and Applications*. **3**(1): 20-28.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. Second Edition. John Wiley and Sons, New Jersey.
- Nababan, D., & Alexander, E. 2020. Implementasi Metode Fuzzy Time Series Dengan Model Algoritma Chen Untuk Memprediksi Harga Emas. *Jurnal Teknik Informatika*. **13**(1): 71-78.
- Putra, T. I. Z. M., Suprpto, S., & Bukhori, A. F. 2022. Model Klasifikasi Berbasis Multiclass Classification dengan Kombinasi Indobert Embedding dan Long Short-Term Memory untuk Tweet Berbahasa Indonesia. *Jurnal Ilmu Siber dan Teknologi Digital*. **1**(1): 1-28.
- Rosadi, D. 2006. Pengantar Analisa Runtun Waktu. *Sains Dan Seni ITS*, **3**(2): A34-A39.
- Supriyanto, P. L. P. 2017. Peramalan Jumlah Penumpang Penerbangan di Terminal 1 Bandara Internasional Juanda Menggunakan Metode Arima Box-Jenkins dan Hybrid Autoregressive Integrated Moving Average-Artificial Neural Network (Arima-ANN). Jurusan Sistem Informasi FTIF ITS, Surabaya.

- Wahyudin, S. 2019. Prediksi Inflasi Indonesia Memakai Model ARIMA dan Artificial Neural Network. *Jurnal Tata Kelola dan Kerangka Kerja Teknologi Informasi*. **5**(2): 57-63.
- Wardani, R. P. 2023. Model Peramalan Laju Inflasi di Jawa Tengah Menggunakan Metode Hybrid ARIMA (Autoregressive Integrated Moving Average)-ANFIS (Adaptive Neuro Fuzzy Inference System), hlm. 739-744. Prosiding Seminar Nasional Matematika, Surakarta.
- Vivianti, V., Aidid, M. K., & Nusrang, M. 2020. Implementasi Metode Fuzzy Time Series untuk Peramalan Jumlah Pengunjung di Benteng Fort Rotterdam. **2**(1): 1-12.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. 2nd Edition. Addison Wesley Publishing Company, USA.
- Zhang, G.P. 2001. Time Series Forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. **50**(17): 159-175.