

**PERBANDINGAN AKURASI PERAMALAN INDEKS HARGA
KONSUMEN DENGAN MENGGUNAKAN METODE GARCH DAN ANN**

(Skripsi)

Oleh

**ZAENAL MUKHLISIN
NPM 1817031014**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

**PERBANDINGAN AKURASI PERAMALAN INDEKS HARGA
KONSUMEN DENGAN MENGGUNAKAN METODE GARCH DAN ANN**

Oleh

ZAENAL MUKHLISIN

Skripsi

**Sebagai Salah Satu Syarat untuk Memperoleh 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
2022**

ABSTRACT

COMPARISON OF THE ACCURACY OF FORECASTING CONSUMER PRICE INDEX USING GARCH AND ANN METHODS

By

ZAENAL MUKHLISIN

The Consumer Price Index (CPI) is the most widely used indicator in determining inflation rate. Therefore, it is essential to discover the value of CPI in the future to become the basis of government in making the appropriate and accurate policies. The CPI data used in the current study was obtained from BPS-Statistics Indonesia (BPS) from the period of January 2006 – December 2021. The pattern of CPI data used in this study indicates the presence of heteroskedasticity. Consequently, as a means to overcome the heteroskedasticity indication, researchers applied GARCH and ANN methods to determine the value of CPI in the future. The GARCH method is a method that capable of overcoming heteroskedasticity indication in time series forecasting process whereas ANN method is an effective method for time series forecasting process considering its high accuracy level. The research finding shows that MAPE *error* calculation through ARIMA (4,2,2)-GARCH(1,1) model is 3,19% or with 96,81% accuracy, and ANN with 2 *hidden layers* is 1,24% or with 98,76% accuracy. Hence, the result of this study is that ANN method is the most appropriate method in forecasting Consumer Price Index (CPI)

Keywords: Heteroskedasticity, Consumer Price Index, GARCH, ANN

ABSTRAK

PERBANDINGAN AKURASI PERAMALAN INDEKS HARGA KONSUMEN DENGAN MENGGUNAKAN METODE GARCH DAN ANN

Oleh

ZAENAL MUKHLISIN

Indeks Harga Konsumen (IHK) merupakan indikator yang paling banyak digunakan dalam menentukan tingkat inflasi. Sehingga, nilai IHK dimasa yang akan datang perlu diketahui untuk menjadi dasar pemerintah dalam membuat kebijakan yang tepat dan akurat. Data IHK yang digunakan dalam penelitian ini, diambil dari Badan Pusat Statistik (BPS) dari periode Januari 2006 – Desember 2021. Data IHK yang digunakan, memiliki pola data yang mengandung gejala *heteroskedasticity*. Sehingga untuk mengatasi gejala *heteroskedasticity*, penulis menggunakan metode GARCH dan ANN dalam menentukan nilai IHK di masa yang akan datang. Metode GARCH merupakan sebuah metode yang mampu mengatasi gejala *heteroskedasticity* dalam proses peramalan *time series* sedangkan ANN merupakan sebuah metode yang efektif dalam peramalan *time series* karena tingkat keakuratannya yang tinggi. Dalam penelitian ini didapatkan hasil perhitungan *error* MAPE dengan model ARIMA (4,2,2)~GARCH(1,1) sebesar 3,19% atau dengan akurasi 96,81%, dan ANN dengan menggunakan 2 *hidden layer* sebesar 1,24% atau dengan akurasi 98,76%. Sehingga, hasil dari penelitian ini metode ANN merupakan sebuah metode terbaik dalam meramalkan data Indeks Harga Konsumen (IHK)

Kata kunci : *Heteroskedasticity*, Indeks Harga Konsumen, GARCH, ANN

LEMBAR PENGESAHAN

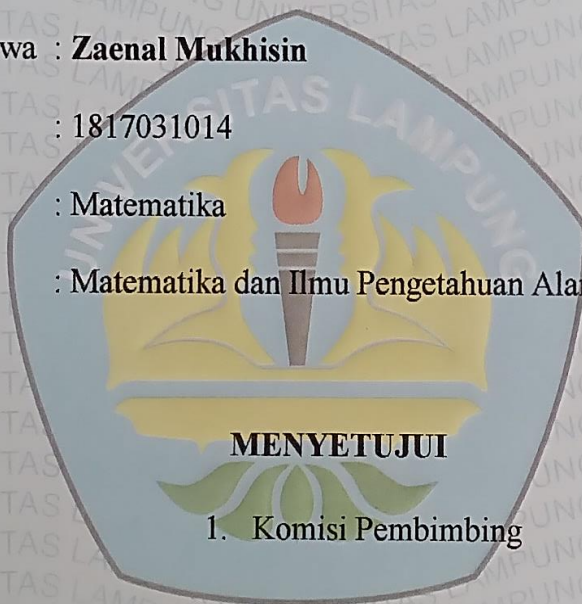
Judul Skripsi : **PERBANDINGAN AKURASI PERAMALAN INDEKS
HARGA KONSUMEN DENGAN MENGGUNAKAN
METODE GARCH DAN ANN**

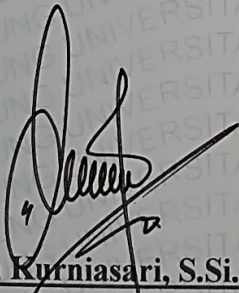
Nama Mahasiswa : **Zaenal Mukhisin**

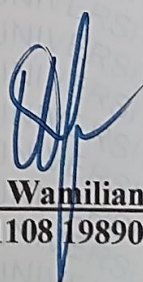
NPM : 1817031014

Jurusan : Matematika

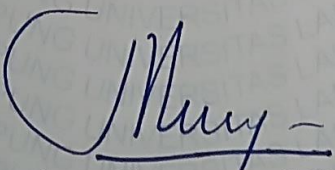
Fakultas : Matematika dan Ilmu Pengetahuan Alam




Dian Kurniasari, S.Si., M.Sc.
NIP. 19690305 199603 2 001


Prof. Dra. Wamiliana, M.A., Ph.D.
NIP. 19631108 198902 2 001

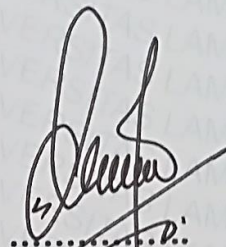
2. Ketua Jurusan Matematika


Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 19740316 200501 1 001

MENGESAHKAN

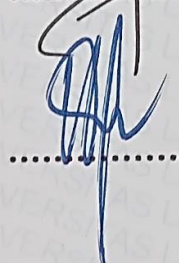
1. Tim Penguji

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



.....D:

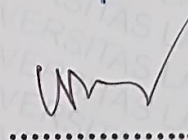
Sekretaris : **Prof. Dra. Wamiliana, M.A., Ph.D.**



.....

Penguji

Bukan Pembimbing : **Ir. Warsono, M.S., Ph.D**

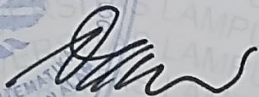


.....

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T.
NIP. 197407052000031001



Tanggal Lulus Ujian Skripsi: 12 Mei 2022

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan dibawah ini :

Nama Mahasiswa : **Zaenal Mukhlisin**
Nomor Pokok Mahasiswa : **1817031014**
Jurusan : **Matematika**
Judul Skripsi : **PERBANDINGAN AKURASI PERAMALAN
INDEKS HARGA KONSUMEN DENGAN
MENGUNAKAN METODE GARCH DAN
ANN**

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

Bandar Lampung, 12 Mei 2022

Penulis



Zaenal Mukhlisin

RIWAYAT HIDUP

Penulis bernama Zaenal Mukhlisin, dilahirkan di Mojopahit, Kecamatan Punggur, Kabupaten Lampung Tengah, Provinsi Lampung pada 20 Mei 2000. Penulis merupakan anak ke-4 dari pasangan Bapak Samad dan Ibu Buniah.

Penulis mengawali pendidikan Sekolah Dasar (SD) di SDN 02 Mojopahit pada tahun 2006-2012. Melanjutkan ke Sekolah Menengah Pertama di SMPN 02 Punggur lulus pada tahun 2015. Sekolah Menengah Atas di SMAN 1 Kotagajah dan lulus pada tahun 2018.

Pada tahun 2018 penulis terdaftar sebagai mahasiswa S1 Jurusan Matematika FMIPA UNILA melalui jalur SNMPTN. Selama menjadi mahasiswa penulis juga aktif dalam organisasi Rohani Islam (ROIS) FMIPA UNILA di Bidang Kajian dan Keumatan. Pada tahun 2021 penulis melakukan Kuliah Praktik (KP) di Badan Pusat Statistik Kabupaten Lampung Tengah dan Kuliah Kerja Nyata (KKN) di Desa Pajar Mataram, Kecamatan Seputih Mataram, Kabupaten Lampung Tengah. Pada bulan Agustus 2021 - Desember 2021 penulis juga mengikuti Program Merdeka Belajar Kampus Merdeka (MBKM) Kampus Mengajar Angkatan 2 yang diadakan oleh Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi RI dengan penempatan di SDN 01 Totokaton, Kecamatan Punggur, Kabupaten Lampung Tengah, Provinsi Lampung.

KATA INSPIRASI

“Sesungguhnya Allah tidak akan mengubah keadaan suatu kaum sebelum mereka mengubah keadaan diri mereka sendiri”

(Q.S. Ar-Ra’d: 11)

“Maka sesungguhnya Bersama kesulitan itu ada kemudahan”

(Q.S. Al-Insyirah: 5)

“Sesungguhnya jika kamu bersyukur, niscaya Aku akan menambah (nikmat) kepadamu, tetapi jika kamu mengingkari (nikmat-Ku), maka pasti azab-Ku sangat berat”

(Q.S. Ibrahim: 7)

“Sesungguhnya orang-orang yang mengatakan: "Tuhan kami ialah Allah", kemudian mereka tetap istiqamah maka tidak ada kekhawatiran terhadap mereka dan mereka tiada (pula) berduka cita.”

(Q.S. Al-Ahqaaf: 13)

KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadirat Allah SWT karena berkat limpahan rahmat dan karunia-Nya penulis dapat menyusun skripsi dengan judul **“Perbandingan Akurasi Peramalan Indeks Harga Konsumen Dengan Menggunakan Metode GARCH dan ANN”** dengan baik dan tepat pada waktu.

Dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Ibu Dian Kurniasari, S.Si., M.Sc., selaku dosen pembimbing utama. Terima kasih telah membimbing penulis, menyumbangkan ilmu, memberikan motivasi dan pengarahan, serta kesedian waktu yang diberikan.
2. Ibu Prof. Dra. Wamiliana, M.A., Ph.D., selaku dosen pembimbing kedua. Terimakasih telah membimbing penulis, menyumbangkan ilmu, memberikan motivasi dan pengarahan, serta kesedian waktu yang diberikan.
3. Bapak Ir. Warsono, M.S., Ph.D., selaku dosen pembahas. Terima kasih atas kesediaan waktu, semangat dan motivasi, serta kritik dan saran yang membangun dalam proses penyusunan skripsi ini.
4. Bapak Prof. Drs. Mustofa Usman, M.A., Ph.D., selaku dosen pembimbing Akademik. Terima kasih atas kesedian waktu, semangat dan motivasi yang membangun dalam proses penyusunan skripsi ini.

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. Suropto Dwi Yuwono, M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh civitas akademik, dosen dan staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Ibu, Bapak dan Anggota Keluarga yang selalu memberikan dukungan dan doa terbaik agar penulis diberikan kelancaran serta kemudahan dalam menyelesaikan skripsi ini.
9. Teman – teman satu bimbingan skripsi (Ferzy, Farrel, Luthfia, Maydia, Virda, Alif, Dalfa, Putri, Sulis, Febi, Oktin, Josoa, Rekti, dan Shavira)
10. Teman – teman belajar kelompok selama perkuliahan (Rendi, Jani, Wayan, Rika dan Inka)
11. Seluruh teman-teman mahasiswa jurusan matematika angkatan 2018

Penulis menyadari bahwa dalam penyusunan skripsi ini masih banyak kekurangan. Oleh karena itu, kritik dan saran yang membangun sangat dibutuhkan, guna menyempurnakan skripsi ini.

Bandar Lampung, 12 Mei 2022

Penulis

Zaenal Mukhlisin
NPM. 1817031014

DAFTAR ISI

	Halaman
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
I. PENDAHULUAN	
1.1 Latar Belakang Masalah	1
1.2 Tujuan	3
1.3 Manfaat	4
II. TINJAUAN PUSTAKA	
2.1 Peramalan atau <i>forecasting</i>	5
2.2 Data Deret Waktu (<i>time series</i>)	6
2.3 Model Deret Waktu ARIMA (<i>Box-Jenkins</i>).....	7
2.4 Model ARIMA (<i>Box-Jenkins</i>)	10
2.5 <i>Generalize Autoregressive Conditional Heteroskedasticity (GARCH)</i>	12
2.6 <i>Knowledge Discovery in Database (KDD)</i>	13
2.7 <i>Artificial Neural Network (ANN)</i>	14
2.8 Komponen-Komponen ANN	15
2.9 Fungsi Aktivasi	17
2.10 <i>Perceptron</i>	17

2.11	Algoritma <i>Backpropagation</i>	19
2.11.1	Lapisan Tersembunyi (<i>Hidden layer</i>)	20
2.11.2	Propagasi Maju, Mundur dan Modifikasi Bobot	21
2.12	Validasi Model.....	23
III.	METODOLOGI PENELITIAN	
3.1	Waktu dan Tempat Penelitian.....	25
3.2	Data Penelitian	25
3.3	Metode Penelitian	25
IV.	HASIL DAN PEMBAHASAN	
4.1	Identifikasi Plot.....	30
4.2	Identifikasi Model ARIMA	33
4.3	Estimasi Paramater Model ARIMA.....	34
4.4	Identifikasi Model GARCH.....	36
4.5	Proses <i>Knowledge Discovery in Database</i> (KDD).....	39
4.5.1	Seleksi Data.....	39
4.5.2	<i>Preprocessing</i> Data.....	40
4.5.3	<i>Scaling</i> Data	42
4.5.4	Pembagian Data <i>Training</i> dan <i>Testing</i>	43
4.6	Menentukan <i>Hidden layer</i>	44
4.7	Menentukan <i>Threshold</i>	45
4.8	Membangun <i>Neural Network</i> Menggunakan Algoritma <i>Backpropagation</i>	45
4.9	Hasil Peramalan Indeks Harga Konsumen	48
4.10	Evaluasi Model GARCH dan ANN.....	49
V.	KESIMPULAN	50
VI.	DAFTAR PUSTAKA	51

DAFTAR TABEL

	Halaman
Tabel 1. Menentukan Jumlah <i>Hidden layer</i>	20
Table 2. Kriteria Nilai MAPE	24
Table 3. Hasil Uji ADF Data Indeks Harga Konsumen.....	31
Table 4. Hasil Uji ADF Data IHK <i>differencing ke-2</i>	32
Table 5. Keputusan Estimasi Parameter dan Nilai AIC Model ARIMA	35
Table 6. Uji <i>Lagrange Multiplier</i>	36
Tabel 7. Estimasi dan Nilai AIC Model GARCH.....	38
Tabel 8. Data Awal	39
Tabel 9. Data <i>lag k=1</i>	42
Tabel 10. Dataset tanpa <i>missing data</i>	42
Table 11. Nilai <i>Error Data Training dan Testing</i>	43
Table 12. Perbandingan <i>Error Penggunaan Hidden Layer</i>	44
Tabel 13. Hasil Peramalan IHK	48
Tabel 14. Nilai MAPE.....	49

DAFTAR GAMBAR

	Halaman
Gambar 1. Alur <i>Neural Network</i>	16
Gambar 2. <i>Single-Layer Perceptron</i>	18
Gambar 3. <i>Multi-Layer Perceptron</i>	18
Gambar 4. Arsitektur Jaringan <i>Backpropagation</i>	22
Gambar 5. <i>Flowchart</i> Proses GARCH.....	28
Gambar 6. <i>Flowchart</i> Proses ANN	29
Gambar 7. Plot Data Indeks Harga Konsumen	31
Gambar 8. Plot Data Indeks Harga Konsumen <i>differencing</i>	32
Gambar 9. Plot ACF dan PACF	33
Gambar 10. Plot ACF Kuadrat Residual.....	37
Gambar 11. Plot PACF Kuadrat Residual.....	37
Gambar 12. Plot Data IHK.....	41
Gambar 13. Plot PACF IHK	41
Gambar 14. <i>Summary Min-Max Normalization</i>	43

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Indeks Harga konsumen (IHK) merupakan indikator yang digunakan untuk mengukur inflasi maupun deflasi dari sekelompok barang dan jasa secara umum. Peramalan IHK menjadi penting sebagai deteksi dini dalam menghadapi lonjakan harga (Deltha, 2017). IHK sangat penting untuk diketahui karena nilai IHK merupakan salah satu indikator yang banyak dijadikan dasar dalam menentukan tingkat inflasi. Sehingga, penelitian untuk mengetahui nilai IHK yang akan datang perlu untuk dilakukan, agar pemerintah atau lembaga yang berwenang bisa mengendalikan nilai inflasi.

Pada kasus ketika menemui jenis data yang memiliki kondisi cenderung menunjukkan adanya heterokedastisitas seperti data IHK, diperlukan penanganan khusus untuk analisis data tersebut. Menurut Ramadhan (2013), varians galat yang berubah-ubah terjadi karena varians galat tidak hanya tergantung dari variabel bebas akan tetapi juga tergantung seberapa besar kuadrat galat di periode sebelumnya. Rumusan tersebut bersumber pada tahun 1982 oleh seorang ilmuwan bernama Engle memiliki solusi dan memperkenalkan metode peramalan yang dapat digunakan untuk mengatasi variansi *error* yang tidak konstan dan juga yang kebanyakan diantaranya memperlihatkan adanya periode yang relatif tidak stabil. Variansi yang tidak konstan tersebut dinamakan heterokedastisitas bersyarat yang dijuluki dengan sebutan model *Autoregressive Conditional Heteroscedasticity* (ARCH).

Pengembangan model ARCH tersebut dilakukan pada tahun 1986 oleh Bollerslev yang dikembangkan untuk mengatasi masalah orde yang terlalu tinggi yang tidak teratasi oleh model ARCH yang disebut model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Diasumsikan pada metode GARCH ini merupakan model yang lebih baik jika dibandingkan dengan metode AR, MA dan ARMA. Menurut Enders (1995), dalam model GARCH ini berpotensi untuk menghindari *lag* yang terlalu tinggi pada model ARCH dengan berdasar pada prinsip parsimoni atau memilih model yang lebih sederhana, sehingga akan menjamin variansnya selalu positif.

Metode *Artificial Neural Network* merupakan salah satu metode kecerdasan buatan yang mampu mengidentifikasi pola, *signal processing* serta peramalan dari sistem dengan metode pembelajaran khususnya peramalan *time series* (Muharsyah, 2009). Kelebihan *neural network* adalah didapatkan hasil yang optimal jika dibandingkan dengan metode peramalan *time series* konvensional lainnya baik jangka waktu panjang maupun tingkat akurasi. Metode *Artificial Neural Network* memberikan hasil prediksi yang akurat dan banyak digunakan untuk peramalan pada data *time series*. Metode *Artificial Neural Network* mampu digunakan untuk peramalan karena mampu memberi kesimpulan dengan benar walaupun data berisi informasi yang bersifat *noisy* (Zhang, *et al.* 1998).

Model *Artificial Neural Network* yang mampu diterapkan dalam peramalan, salah satunya yaitu *Artificial Neural Network Backpropagation* (ANNB). ANNB menggunakan *feedback* dari nilai *error* pelatihan, sehingga jaringan dapat memperkirakan *output* dari pola pelatihan lebih dekat ke nilai sebenarnya. ANNB sangat populer digunakan karena mudah digunakan dengan menyesuaikan beberapa parameter pada jaringan, mudah dalam pengimplementasian, dan bisa digunakan untuk berbagai masalah (Priddy dan Keller, 2005).

Mengacu pada penelitian sebelumnya oleh Notobroto (2019) tentang metode *Artificial Neural Network*, didapatkan rata-rata persentase *error* berdasarkan perbandingan dengan data aktual adalah 0,1854 atau memiliki akurasi 99,81 persen.

Sehingga kesimpulan dari penelitian tersebut adalah metode *Artificial Neural Network* memiliki nilai *error* yang rendah dan akurasi yang baik. Selanjutnya penelitian yang dikaji oleh Kustiara (2020) tentang penerapan metode ARCH GARCH, didapatkan model terbaik ARIMA (1,1,1) ~ GARCH (1,0) dengan prediksi dari volatilitas dengan nilai standar deviasi 0,98. Kemudian penelitian yang dikaji oleh Simanjuntak (2019) tentang perbandingan Metode GARCH dan ANN, didapatkan hasil perhitungan *error* dalam peramalan RMSE dengan model GARCH (1,0) sebesar 0,3234 dan ANN menggunakan 21 *hidden layer* sebesar 0,0091.

Dengan adanya berbagai macam metode peramalan dan perkembangan metode peramalan dengan data runtun waktu yang cukup pesat sehingga terdapat banyak pilihan metode yang dapat digunakan. Hal tersebut dilakukan sesuai dengan kebutuhan, dan diperlukan membandingkan metode yang satu dengan yang lain sehingga mendapatkan hasil ramalan dengan nilai akurasi yang tinggi.

Berdasarkan uraian tersebut, maka penulis tertarik mengajukan penelitian dengan judul “Perbandingan Akurasi Peramalan Indeks Harga Konsumen dengan Menggunakan Metode GARCH dan ANN”.

1.2 Tujuan

Tujuan penelitian ini adalah:

1. Memperoleh model terbaik untuk meramalkan nilai Indeks Harga Konsumen dengan menggunakan model GARCH dan ANN
2. Melakukan peramalan nilai Indeks Harga Konsumen dengan menggunakan model GARCH dan ANN

1.3 Manfaat

Manfaat dari penelitian ini adalah menambah pengetahuan bagi penulis dan memberi masukan kepada para peneliti dan pembaca tentang penerapan model GARCH dan ANN untuk meramalkan nilai Indeks Harga Konsumen.

II. TINJAUAN PUSTAKA

2.1 Peramalan atau *Forecasting*

Peramalan adalah perkiraan dari nilai atau kondisi di masa yang akan datang. Asumsi yang umum dipakai dalam peramalan adalah pola masa lampau akan berlanjut ke masa yang akan datang. Peramalan merupakan prediksi nilai-nilai sebuah peubah kepada nilai yang diketahui dari peubah tersebut. Meramal juga dapat didasarkan pada keahlian penilaian, yang pada gilirannya didasarkan pada data historis dan pengalaman (Makridakis, 1999).

Peramalan dapat diartikan sebagai penggunaan data masa lalu, sebuah kumpulan variabel untuk mengestimasi nilai di masa yang akan datang. Untuk membuat peramalan dimulai dengan mengeksplorasi data dari waktu yang lalu dengan mengembangkan data tersebut. Peranan peramalan sangat penting baik tidaknya hasil suatu penelitian dalam bidang ekonomi, usaha, dan lain-lain sangat ditentukan oleh ketepatan peramalan yang dibuat. Oleh karena itu, ketepatan dari peramalan tersebut merupakan hal yang sangat penting. Walaupun demikian, perlu disadari bahwa suatu ramalan selalu ada unsur kesalahannya. Sehingga yang perlu diperhatikan adalah usaha untuk memperkecil kemungkinan kesalahan tersebut (Makridakis, 1999).

2.2 Data Deret Waktu (*Time Series*)

Data deret waktu adalah data yang dikumpulkan menurut aturan waktu dalam suatu rentang waktu tertentu. Jika waktu dipandang bersifat diskrit (waktu dapat dimodelkan bersifat kontinu), frekuensi pengumpulan selalu sama. Dalam kasus diskrit, frekuensi dapat berupa detik, menit, jam, hari, minggu, bulan, atau tahun (Montgomery, 2008).

Menurut Hanke dan Wichern (2004), ada empat macam pola data yaitu :

1. Pola Data Horizontal

Pola data horizontal terjadi saat data observasi berfluktuasi di sekitaran suatu nilai konstan atau *mean* yang membentuk garis horizontal. Data ini disebut juga dengan data stasioner.

2. Pola Data *Trend*

Pola data *trend* terjadi apabila data pengamatan mengalami kenaikan atau penurunan selama periode jangka panjang. Suatu data pengamatan yang mempunyai *trend* disebut data nonstasioner.

3. Pola Data Musiman

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

4. Pola Data Siklis

Pola data siklis terjadi apabila deret data dipengaruhi oleh fluktuasi ekonomi jangka panjang, seperti yang berhubungan dengan siklus bisnis.

2.3 Model Deret Waktu ARIMA (*Box-Jenkins*)

Model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins tahun 1976, nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis deret berkala, peramalan dan pengendalian.

Menurut Gujarati (2003), ada beberapa model *Box-Jenkins* yang digunakan untuk melakukan analisis terhadap data *time series* yaitu:

1. Model *Autoregressive* (AR)

Bentuk umum model *autoregressive* dengan ordo p (AR) atau model ARIMA $(p, 0, 0)$ dinyatakan sebagai berikut :

$$Y_t = \mu + e_t + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} \dots\dots\dots(2.1)$$

dengan :

Y_t = peubah yang diramalkan pada waktu ke- t

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ = peubah bebas

$\phi_1, \phi_2, \dots, \phi_p$ = parameter dari persamaan *autoregressive*

μ = konstanta

e_t = nilai kesalahan pada saat t

2. Model *Moving Average* (MA)

Bentuk umum model *moving average* ordo q (MA) atau ARIMA $(0, 0, q)$ dinyatakan sebagai berikut :

$$Y_t = \mu + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-k} \dots\dots\dots(2.2)$$

dengan :

Y_t = peubah yang diramalkan pada waktu ke- t

μ = konstanta

$\theta_1, \theta_2, \dots, \theta_q$ = parameter-parameter *moving average*

e_{t-k} = kesalahan pada saat $t - k$

3. Model *Autoregressive Moving Average* (ARMA)

Model umum untuk campuran proses AR(1) murni dan MA(1) murni misal ARIMA $(1, 0, 1)$ dinyatakan sebagai berikut :

$$Y_t = \mu + \phi_1 Y_{t-1} + e_t + \theta_1 e_{t-1} \dots \dots \dots (2.3)$$

dengan :

Y_t	= peubah yang diramalkan pada waktu ke- t
μ	= konstanta
$\phi_1, \phi_2, \dots, \phi_p$	= parameter dari persamaan <i>autoregressive</i>
$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$	= peubah bebas
$\theta_1, \theta_2, \dots, \theta_q$	= parameter-parameter <i>moving average</i>
e_t	= nilai kesalahan pada saat t
e_{t-1}	= kesalahan pada saat $t - 1$

4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA adalah model yang secara penuh mengabaikan independen variabel dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat. ARIMA sangat baik ketepatannya untuk peramalan jangka pendek, sedangkan untuk peramalan jangka panjang peramalannya kurang baik. Biasanya akan cenderung mendatar atau konstan untuk periode yang cukup panjang (Kuncoro, 1991).

Bentuk umum model ARIMA (p,d,q) adalah:

$$Y_t^* = \mu + \phi_1 Y_{t-1}^* + \phi_2 Y_{t-2}^* + \dots + \phi_p Y_{t-p}^* + \mu_t + \theta_1 \mu_{t-1} + \dots + \theta_q \mu_{t-q} \quad (2.4)$$

Model AR, MA, dan ARMA yang telah dibahas sebelumnya menggunakan asumsi bahwa data *time series* yang dianalisis sudah bersifat stasioner. Rata-rata dan ragam data *time series* bersifat konstan dan keragamannya tidak terpengaruh oleh waktu. ARIMA sering juga disebut metode runtun waktu *Box-Jenkins*.

Model ARIMA terdiri dari tiga langkah dasar yaitu tahap identifikasi, tahap penaksiran dan pengujian, dan tahap pemeriksaan diagnostik. Selanjutnya model ARIMA dapat digunakan untuk melakukan peramalan jika model yang diperoleh memadai.

Beberapa konsep penting dalam analisis runtun waktu sebagai berikut:

a. Konsep Stokastik

Dalam runtun waktu data disimbolkan dengan Z_t mengikuti proses stokastik dimana urutan pengamatan variabel random $Z_{\omega-k}$ dengan ruang sampel ω dan satuan waktu t dikatakan sebagai proses stokastik.

b. Konsep Stasioneritas

Suatu data runtun waktu dikatakan stasioner dalam variansi jika struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah atau tidak ada perubahan variansi dalam besarnya fluktuasi. Suatu data runtun waktu dikatakan stasioner dalam *mean* jika rata-rata data *time series* tersebut relatif konstan dari waktu ke waktu, atau dapat dilihat tidak ada unsur *trend* dalam data. Jika data runtun waktu bersifat stasioner, maka besarnya mean dari sebagian data runtun waktu tersebut tidak akan jauh berbeda secara signifikan dengan *mean* dari sebagian data lainnya.

c. Konsep *Differencing*

Konsep *Differencing* berfungsi untuk mengatasi persolan pemodelan jika terdapat data yang tidak stasioner terhadap *mean*. Yang dimaksud diferensiasi adalah menghitung perubahan atau selisih nilai observasi.

Menurut Hendikawati (2015), konsep *differencing* dapat diformulasikan secara matematis dengan persamaan sebagai berikut:

Untuk orde *difference* = 1

$$\Delta Z_t = Z_t - Z_{t-1}, t = 2, 3, \dots, n \dots\dots\dots(2.5)$$

Untuk orde *difference* = 2

$$\Delta Z_t = (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}), t = 3, 4, \dots, n \dots\dots\dots(2.6)$$

d. Konsep Tranformasi *Box-Cox*

Konsep transformasi *Box-Cox* berfungsi untuk mengatasi persoalan pemodelan jika terdapat proses yang tidak stasioner dalam varian atau ragam.

Rumus matematis transformasi ditampilkan sebagai berikut (Wei, 2006).

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda}$$

dengan

$T(Z_t)$ = transformasi *Box-Cox*

λ = nilai koefisien transformasi *Box-Cox*

e. Konsep *Autocorrelation Function* (ACF)

Fungsi ini digunakan untuk pendeteksian awal sebuah model dan kestasioneran data. Fungsi *autokorelasi* (ACF) adalah suatu fungsi yang menunjukkan besarnya korelasi (hubungan linier) antara pengamatan pada waktu t saat sekarang dengan pengamatan pada waktu-waktu sebelumnya. Jika diagram ACF turun lambat atau turun secara linier maka dapat disimpulkan bahwa data tersebut belum stasioner. Nilai ACF dianggap signifikan jika di luar garis (Wei, 2006).

f. Konsep *Partial Autocorrelation Function* (PACF)

Fungsi ini menunjukkan besarnya korelasi parsial (hubungan linear secara terpisah) antara pengamatan pada waktu t saat sekarang dengan pengamatan pada waktu-waktu sebelumnya. Nilai PACF dianggap signifikan jika di luar garis (Wei, 2006).

2.4 Metode ARIMA (*Box-Jenkins*)

Model ARIMA (*Box-Jenkins*) berbeda dengan model peramalan lainnya, karena model ini tidak mensyaratkan suatu pola tertentu agar model dapat bekerja dengan baik. Model ARIMA akan bekerja dengan baik apabila data deret berkala yang dipergunakan bersifat dependen atau berhubungan satu sama lain secara statistik (Widarjono, 2009).

Untuk menentukan perilaku data mengikuti pola AR, MA, ARMA atau ARIMA, dan untuk menentukan ordo AR, MA serta tingkat proses diferensiasi untuk menjadi data stasioner, Box dan Jenkins telah mengembangkan suatu metode yang dikenal prosedur *Box-Jenkins*. Terdapat empat tahapan prosedur *Box-Jenkins*, yaitu:

1. Identifikasi model

Langkah pertama yang perlu dilakukan dalam membangun model ARIMA adalah mendeteksi masalah stasioner data yang digunakan. Jika tidak stasioner, lakukan proses diferensiasi untuk mendapatkan data stasioner. Setelah mendapatkan data yang stasioner, selanjutnya adalah identifikasi model ARIMA melalui *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

2. Estimasi parameter model

Pada tahap ini dilakukan penentuan parameter-parameter model untuk menduga parameter ARMA. Dan pada tahap ini juga dilakukan pengujian kelayakan model dengan mencari model yang signifikan. Model signifikan yaitu model yang nilai *P-value* $< \alpha$ pada *Final Estimation of Parameters*.

3. Evaluasi parameter model

Pada tahap ini dilakukan pengujian terhadap residual model yang dipilih. Model yang baik bersifat random (*white noise*). Analisis residual dilakukan dengan pengujian signifikan ACF dan PACF yang dapat dilakukan dengan melihat nilai *P-value* pada uji *Ljung-Box*.

4. Peramalan

Tujuan paling penting pada analisis *time series* adalah untuk meramalkan nilai masa depan (Wei, 2006). Jika semua tahap sudah dilakukandan diperoleh suatu model, maka tahap terakhir adalah melakukan peramalan berdasarkan model ARIMA (p,d,q) terbaik yaitu model yang memiliki ordo signifikan dan bersifat *white noise* (Juanda dan Junaidi, 2012)

2.5 Generalize Autoregressive Conditional Heteroskedasticity (GARCH)

Metode *Generalize Autoregressive Conditional Heteroskedasticity* (GARCH) (p, q) merupakan pengembangan dari model *Autoregressive Conditional Heteroskedasticity* (ARCH). Model ini dikembangkan untuk menghindari orde yang terlalu tinggi pada model ARCH dengan memilih model yang lebih sederhana sehingga akan menjamin variansi selalu positif (Enders, 1995).

Menurut Marta (2016), Bentuk umum model GARCH (p, q) yaitu :

$$Y_t = b_0 + b_1 X_t + \varepsilon_t$$

$$\sigma = \sqrt{\alpha_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{i=1}^q \beta_i \sigma_{t-i}^2}$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_p e_{t-p}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_q \sigma_{t-q}^2$$

Model GARCH (1,0) dapat didefinisikan sebagai berikut:

$$\sigma_t = \sqrt{\alpha_0 + \alpha_1 e_{t-1}^2}$$

Dimana $\alpha_0, \alpha_1, \beta_1$ adalah parameter dari model GARCH, e_t adalah nilai residual. Untuk menghindari variansi GARCH bernilai negatif, maka syaratnya $\alpha_0 > 0, \alpha_1 > 0, \beta_1 > 0$ dan $\alpha_1 + \beta_1 < 1$.

Dalam metode time series, untuk mengidentifikasi model dari data yang akan diprediksi adalah menggunakan *Autocorrelation Function* (ACF) dan fungsi *Partial Autocorrelation Function* (PACF). Untuk model GARCH digunakan fungsi PACF. *Partial Autocorrelation Function* (PACF) digunakan untuk mengukur tingkat kerataan, apabila pengaruh dari waktu lag 1, 2, 3, ..., k-1 dianggap terpisah. Sehingga PACF dapat digunakan menentukan nilai orde p dari model GARCH sesuai dengan *cut off* di lag beberapa.

Menurut Spyros (1995), fungsi PACF adalah sebagai berikut:

$$\rho_k = \phi_1\rho_{k-1} + \phi_2\rho_{k-2} + \dots + \phi_p\rho_{k-p}$$

dengan ρ_k adalah fungsi ACF, ϕ_k adalah fungsi PACF, dan $k = \text{time lag } 1, 2, \dots, p$.

2.6 *Knowledge Discovery in Database (KDD)*

Knowledge Discovery in Database dapat mengolah sebuah data yang berukuran besar menjadi sebuah informasi yang bermanfaat. Menurut Fayyad (1996), proses KDD dapat dijelaskan sebagai berikut:

1. Seleksi Data

Pemilihan (seleksi) data dari sekumpulan data operasional perlu dilakukan sebelum tahap penggalian informasi dalam KDD dimulai.

2. *Preprocessing* Data

Preprocessing data mencakup membuang duplikasi data, memeriksa data yang inkonsisten, dan memperbaiki kesalahan pada data, seperti kesalahan cetak (tipografi).

3. Transformasi Data

Transformasi data digunakan untuk merubah skala pengukuran dari bentuk asli ke dalam bentuk lain sehingga data dapat digunakan untuk analisis dan asumsi-asumsi tertentu. Terdapat beberapa cara untuk merubah *dataset* yaitu dengan *min-max normalization*, *z-score normalization* dan *decimal scaling*. Dalam penelitian ini penulis menggunakan proses *min-max normalization* yang akan menghasilkan nilai dengan rentang (0,1).

4. Data Mining

Data mining adalah proses mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik atau metode tertentu. Teknik, metode, atau algoritma dalam data mining sangat bervariasi. Pemilihan metode atau algoritma yang tepat sangat bergantung pada tujuan dan proses KDD secara keseluruhan.

5. Interpretasi/Evaluasi

Pola informasi yang dihasilkan dari proses perlu ditampilkan dalam bentuk yang mudah dimengerti oleh pihak yang berkepentingan.

2.7 *Artificial Neural Network (ANN)*

Artificial Neural Networks atau Jaringan Syaraf Tiruan (JST) merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia. Menurut Pandjaitan (2007), mendefinisikan JST sebagai suatu teknologi komputasi yang berbasis pada model syaraf biologis dan mencoba mensimulasikan tingkah laku dan kerja model syaraf terhadap berbagai macam masukan. Pada dasarnya, baik jaringan syaraf biologi maupun JST merupakan unit –unit pemrosesan informasi.

Terdapat beberapa tipe JST, namun semuanya memiliki komponen-komponen yang sama. Seperti halnya otak manusia, jaringan syaraf terdiri dari beberapa *neuron* (yang sering disebut dengan *nodes*), dan masing-masing *neuron* terhubung satu dengan yang lainnya dan melakukan pemrosesan informasi seperti pada sistem jaringan syaraf biologi. Syaraf (*neuron*) biologi memiliki tiga komponen penting, yaitu *dendrite*, *nucleus*, dan *axon*. *Dendrite* menerima sinyal dari *neuron* lain. Sinyal tersebut dimodifikasi (diperkuat / diperlemah) oleh celah *synopsis*. Selanjutnya, *nucleus* menjumlahkan semua sinyal - sinyal yang masuk. Jika jumlahan tersebut cukup kuat dan melebihi batas ambang (*threshold*), maka sinyal tersebut akan diteruskan ke *neuron* lain melalui *axon* (Jong, 2005).

Menurut Fausett (1994), *Artificial Neural Network* atau biasa disebut jaringan syaraf tiruan adalah sistem komputasi arsitektur dan operasinya yang merupakan sistem pemrosesan informasi dalam menstimulasikan sistem kecerdasan buatan yang karakteristiknya sama dengan cara kerja sistem saraf biologis manusia. Maksud dari sistem kecerdasan buatan disini adalah karena jaringan ini mengimplementasikannya dengan komputer yang akan melakukan proses komputasi arsitektur dan operasinya selama proses pembelajaran. Sebagai suatu generalisasi model matematis dan pemahaman manusia atau suatu syarat biologis manusia, maka jaringan syaraf tiruan dibentuk atas dasar asumsi sebagai berikut:

1. Pemrosesan informasi terjadi pada elemen-elemen sederhana yang disebut *neuron*.
2. Sinyal dilewatkan antara *neuron* melalui jalur yang terhubung.
3. Setiap jalur yang terhubung akan memiliki bobot yang besesuaian kemudian akan dikalikan dengan sinyal yang melewatinya.
4. Setiap *neuron* memiliki fungsi aktivasi dengan cara menjumlahkan bobot-bobot yang masuk untuk menentukan *output*.

Hal yang perlu diperhatikan pada sistem jaringan syaraf tiruan ini bahwa jaringan ini tidak dibuat untuk menghasilkan suatu *output* tertentu melainkan akan mengeluarkan *output* atau kesimpulan dari apa yang telah dipelajari dari pengalaman-pengalaman yang di *input* selama proses pembelajaran.


2.8 Komponen-komponen *Artificial Neural Network*

Menurut Kusumadewi (2004), jaringan syaraf tiruan itu terdiri dari beberapa *neuron* dan terdapat penghubung antara *neuron-neuron* yang dikenal dengan bobot seperti halnya otak manusia. Kemudian dijelaskan komponen-komponen jaringan syaraf tiruan sebagai berikut:

1. *Input*: seperti halnya *dendrit* pada otak manusia yang berfungsi sebagai penerima informasi masukan dari *neuron* lain.
2. *Neuron*: komponen yang bertugas untuk memproses informasi.

3. Bobot: seperti halnya *synopsis* pada otak manusia yang memiliki fungsi yang sama untuk menunjukkan kekuatan hubungan antara *neuron* satu dengan yang lainnya.
4. Fungsi aktivasi: suatu nilai tertentu yang memetakan fungsi hasil penjumlahan yang diterima oleh semua *input* dari suatu *neuron*.
5. *Output*: sama halnya dengan *axon* pada otak manusia yang sama-sama berfungsi sebagai proses pembelajaran atau proses perhitungan suatu fungsi aktivasi yang akan menghasilkan suatu *output* dari jaringan yang telah di *input* atau bahkan akan menjadi *input* bagi *neuron* yang lain.

Jaringan saraf tiruan memiliki beberapa jenis yang berbeda, namun hampir semua jenis memiliki komponen yang sama. Seperti pada otak manusia, jaringan saraf tiruan memiliki *neuron*. Jika pada otak manusia terdapat *dendrit* yang memiliki fungsi sebagai penerima rangsangan, pada jaringan saraf terdapat lapisan *input*. Informasi yang didapat oleh lapisan *input*, akan diteruskan melalui *neuron* dengan bobot tertentu.



Gambar 1. Alur *Neural Network*
(Sumber: Sudarsono, 2016)

Pada Gambar 1. terlihat bahwa *input* ini akan diproses oleh suatu fungsi perambatan yang akan menjumlahkan nilai-nilai semua bobot yang datang. Hasil penjumlahan ini kemudian akan dibandingkan dengan suatu nilai ambang batas (*threshold*) tertentu melalui fungsi aktivasi setiap *neuron*. Apabila *input* tersebut melewati suatu nilai ambang tertentu, maka *neuron* tersebut akan diaktifkan, tetapi jika tidak, maka *neuron* tersebut tidak akan diaktifkan. Apabila *neuron* tersebut diaktifkan, maka *neuron* tersebut akan mengirimkan *output* melalui bobot-bobot *output* ke semua *neuron* yang berhubungan dengannya.


2.9 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi matematis yang digunakan untuk mendapatkan nilai *output* berdasarkan nilai *input*, seperti namanya fungsi ini dapat mengaktifkan *neuron*. Kuncinya di sini adalah bahwa informasi diproses melalui fungsi aktivasi. Setiap fungsi aktivasi meniru *neuron* otak karena mereka tergantung pada kekuatan sinyal *input*. Hasil dari pemrosesan ini kemudian ditimbang dan didistribusikan ke *neuron* di lapisan berikutnya. Intinya, *neuron* saling mengaktifkan melalui jumlah tertimbang. Ini memastikan kekuatan koneksi antara dua *neuron* berukuran sesuai dengan berat informasi yang diproses (Lewis, 2017).

Menurut Fausett (1994), fungsi aktivasi yang digunakan pada algoritma *backpropagation* harus memiliki beberapa karakteristik penting yaitu kontinu, terdiferensial dan monoton. Jaringan saraf tiruan memiliki beberapa fungsi aktivasi seperti fungsi sigmoid, fungsi tanh, fungsi linear, fungsi biner, fungsi hard limit, fungsi ReLU, fungsi leaky ReLU, dan sebagainya. Fungsi aktivasi yang akan digunakan dalam penelitian ini yaitu fungsi aktivasi leaky ReLU.


2.10 Perceptron

Menurut Shynk (1990), *perceptron* merupakan suatu kombinasi linear yang memetakan *output* ke satu dari dua nilai diskrit. Hubungan antara bobot dan *threshold* dapat diperbaiki atau diadaptasi menggunakan berbagai algoritma pembelajaran. Dalam *neural network*, terdapat dua jenis *perceptron* yaitu *single-layer perceptron* dan *multi-layer perceptron*. *Single-layer perceptron* adalah sebuah jaringan saraf tiruan yang hanya terdiri dari layer *input* dan *output*.



Gambar 2. *Single-Layer Perceptron*
(Sumber: Olugbenle, 2019)

Pada *single-layer perceptron*, sinyal input x_m diskalakan oleh satu set bobot yang telah disesuaikan w_m untuk menghasilkan *output* y . Sedangkan, *multi-layer perceptron* merupakan varian lain dari *perceptron* yang memiliki satu atau lebih *hidden layer* antara *input layer* dan *output layer* (Ramchoun, 2016).



Gambar 3. *Multi-Layer Perceptron*
(Sumber: Ezzine, 2018)

2.11 Algoritma *Backpropagation*

Backpropagation merupakan sebuah algoritma pembelajaran dalam *Artificial Neural Network* yang telah banyak digunakan untuk memecahkan kasus-kasus rumit. Di dalam algoritma ini dilakukan dua tahap perhitungan, yaitu perhitungan maju yang dilakukan untuk menghitung *error* antara *output* ANN dengan target yang diinginkan dan yang berikutnya adalah perhitungan mundur yang menggunakan *error* yang telah didapatkan untuk memperbaiki bobot pada semua *neuron* yang ada (Nielsen, 2015). Algoritma *backpropagation* merupakan salah satu algoritma dalam *multi-layer perceptron*. Pelatihan *backpropagation* meliputi 3 fase yaitu fase maju, fase mundur, dan fase modifikasi bobot. Algoritma ini merupakan salah satu metode pembelajaran dengan supervisi (*supervised learning*).

Menurut Kulkarni (2011), *backpropagation* hanyalah sebuah implementasi dari *gradient descent*. Algoritma ini dapat digunakan apabila diketahui turunan dari *error* yang berhubungan dengan bobot. Jika dinotasikan E_m merupakan *error* pada *training* m , *gradient descent* menunjukkan bahwa diperbaharui bobot W_{ij} dengan jumlah berikut (dimana η adalah konstanta).

$$\Delta w_{ij} = -\eta \frac{\partial E_m}{\partial w_{ij}}$$

dengan:

Δw_{ij} : perubahan bobot sambungan dari unit i ke unit j

η : *learning rate*

∂E_m : turunan dari *error* pada *training* m

∂w_{ij} : turunan dari bobot

2.11.1 Lapisan Tersembunyi (*Hidden layer*)

Dikarenakan algoritma *backpropagation* merupakan bagian dari *multi-layer perceptron*, maka dalam struktur jaringannya terdapat *hidden layer* yang harus diperhatikan. Jumlah *hidden layer* juga memberikan dampak yang cukup signifikan bagi nilai *error* yang dihasilkan dari proses *training* dan *testing* dalam *backpropagation*. Seperti halnya penggunaan 1 *hidden layer*, tentu tidak akan sama dengan penggunaan 2 *hidden layer*. Penggunaan 2 *hidden layer* tentu akan menambah iterasi saat proses *looping* atau proses *backward*. Terdapat beberapa *rule* dalam menentukan *hidden layer* yang optimal dari berbagai peneliti.

Menurut Heaton (2017), kasus yang menggunakan lebih dari 2 *hidden layer* jarang terjadi dalam *deep learning*. 2 atau kurang dari 2 sudah cukup untuk sekumpulan data sederhana. Namun, dengan kumpulan data kompleks yang melibatkan data *time series* atau visi komputer, *layer* tambahan sangat membantu. Tabel 1. merangkum kemampuan beberapa arsitektur lapisan secara umum.

Table 1. Menentukan Jumlah *Hidden layer*

Jumlah <i>hidden layer</i>	Hasil
0	Hanya mampu mewakili fungsi linear
1	Dapat memperkirakan fungsi apa pun yang berisi pemetaan berkelanjutan dari satu ruang terbatas ke ruang lain.
2	Dapat mempresentasikan batas keputusan sembarang terhadap akurasi sembarang dengan fungsi aktivasi rasional dan dapat memperkirakan pemetaan terhadap akurasi apa pun.
>2	<i>layer</i> tambahan dapat mempelajari representasi kompleks (semacam rekayasa fitur otomatis)

Selain menentukan jumlah *hidden layer*, perlu ditentukan juga seberapa banyak *nodes* atau *neuron* yang akan digunakan dalam *hidden layer* tersebut untuk memutuskan arsitektur jaringan secara keseluruhan. Menggunakan terlalu sedikit *neuron* di *hidden layer* akan menghasilkan sesuatu yang disebut *underfitting*. *Underfitting* terjadi ketika ada terlalu sedikit *neuron* di *hidden layer* untuk mendeteksi sinyal secara memadai dalam kumpulan data yang rumit.

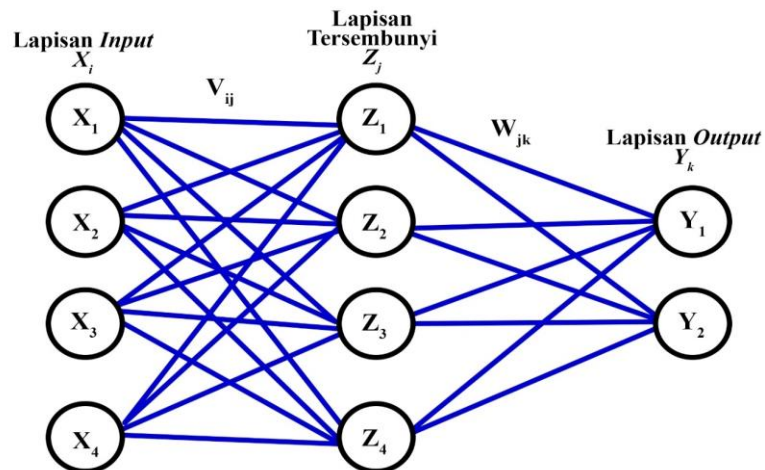
Namun, menggunakan *neuron* dengan jumlah banyak juga akan mengakibatkan masalah seperti *overfitting*. *Overfitting* terjadi ketika jaringan saraf memiliki begitu banyak kapasitas pemrosesan informasi sehingga jumlah informasi terbatas yang terkandung dalam set *training* tidak cukup untuk melatih semua *neuron* di *hidden layer*.

Menurut Heaton (2017), terdapat aturan jumlah *nodes* pada *hidden layer*:

1. Jumlah *nodes* pada *hidden layer* harus berada di antara ukuran *input layer* dan *output layer*.
2. Jumlah *nodes* pada *hidden layer* harus bernilai $\frac{2}{3}$ dari jumlah *input layer* ditambah dengan *output layer* $\left(\frac{2}{3}(\text{input} + \text{Output})\right)$.
3. Jumlah *nodes* pada *hidden layer* harus kurang dari dua kali lipat jumlah *input layer*.

2.11.2 Propagasi Maju, Mundur dan Modifikasi Bobot

Algoritma *backpropagation* merupakan algoritma dengan *multi-layer perceptron* yang artinya pada algoritma ini terdapat *layer input*, *hidden layer*, dan *layer output*. Secara umum arsitektur jaringan algoritma *backpropagation* dapat dilihat pada Gambar 4.



Gambar 4. Arsitektur Jaringan *Backpropagation*.
(Sumber: Widiyanto, 2021)

Dalam algoritma *backpropagation* terdapat 3 fase yaitu fase propagasi maju (*forward pass*), propagasi mundur (*backward pass*) dan update parameter bobot serta bias.

1. Propagasi maju (*forward pass*)

Secara umum proses *forward pass* dilakukan dengan meneruskan sinyal *input* (x_i) menuju *hidden layer* menggunakan fungsi aktivasi yang telah ditentukan. Keluaran dari unit tersembunyi (z_j) kemudian dipropagasi maju lagi ke *hidden layer* selanjutnya (jika ada) dengan fungsi aktivasi yang telah ditentukan, dan seterusnya hingga menghasilkan keluaran jaringan (y_k). Kemudian keluaran jaringan (y_k) dibandingkan dengan target yang ditentukan (t) dan *error* yang dihasilkan merupakan selisih antara (y_k) dan (t). Jika *error* yang dihasilkan lebih kecil dari batas toleransi (*threshold*).

2. Propagasi mundur dan modifikasi bobot

Setelah didapatkan nilai *error*, dapat dilakukan optimasi menggunakan proses *gradient descent*. Bentuk utama untuk memperbaiki suatu bobot yaitu:

$$w_{baru} = w_{lama} - \eta \frac{\partial E}{\partial w}$$

Persamaan juga berlaku untuk memperbaiki nilai bias

$$b_{baru} = b_{lama} - \eta \frac{\partial E}{\partial b}$$

2.12 Validasi Model

Menurut Hanke dan Wichern (2004), teknik peramalan yang menggunakan data kuantitatif dengan data runtun waktu tertentu, terdapat *error* / kesalahan yang dihasilkan oleh teknik tersebut. Oleh sebab itu, dibutuhkan metode untuk mengukur seberapa besar *error* yang dapat dihasilkan oleh metode - metode *forecasting* untuk dipertimbangkan kembali sebelum dibuat keputusan. Metode-metode yang dapat digunakan dalam mengevaluasi *error* pada teknik *forecasting* yaitu RMSE (*root mean square error*), MAPE (*mean absolute percentage error*).

Metode yang paling umum digunakan yaitu MSE (*mean square error*) dan RMSE (*root mean square error*). MSE mengukur rata-rata kuadrat dari kesalahan antara target yang diamati dan nilai yang diprediksi. Semakin kecil MSE, semakin baik hasil prediksi yang dihasilkan.

$$MSE = \frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2$$

dengan:

\hat{y}_t : nilai prediksi pada periode t

y_t : nilai aktual pada periode t

Karena MSE diukur dalam satuan kuadrat, maka RMSE dapat ditafsirkan sebagai jarak rata-rata, antara nilai yang diprediksi dan diamati, diukur dalam satuan variabel target.

$$RMSE = \sqrt{MSE}$$

MAPE merupakan persentase dari rata-rata kesalahan *absolute error* dari kesalahan peramalan tanpa menghiraukan tanda positif atau negative yang dirumuskan (Hanke dan Wichern, 2004)

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \left| \frac{Y' - Y}{Y} \right| \right)$$

Keterangan:

n = banyaknya pengamatan

Y' = hasil prediksi indeks

Y = hasil aktual indeks

Chang, *et al.* (2007), menyatakan bahwa peramalan dikatakan sukses ketika menghasilkan MAPE yang rendah. Tabel 2. menunjukkan keterangan dari tiap nilai MAPE.

Tabel 2. Kriteria Nilai MAPE

No.	MAPE (%)	Penjelasan Nilai
1	<10	Sangat Baik
2	10-20	Baik
3	20-50	Sedang
4	>50	Buruk

III. METODELOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2021/2022. Bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan adalah data Indeks Harga Konsumen (IHK) Indonesia yang diperoleh dari Badan Pusat Statistik (BPS) Pusat diambil dari bulan Januari 2006 sampai Desember 2021.

3.3 Metode Penelitian

Penelitian ini dilakukan dengan menggunakan studi literatur secara sistematis yang diperoleh dari buku-buku maupun media untuk mendapatkan informasi sebanyak mungkin untuk mendukung penulisan skripsi ini. Pengolahan data tersebut dilakukan dengan menggunakan *software R-studio*.

Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Mengambil data Indeks Harga Konsumen Indonesia di *website* Badan Pusat Statistik Indonesia.
2. Melakukan uji asumsi ARIMA, kemudian dilanjutkan dengan proses pemodelan ARIMA dengan menggunakan *software R-Studio*

- a. Melakukan Identifikasi plot
 - b. Melakukan uji stasioneritas
 - c. Melakukan Transformasi dan *Differncing* jika diperlukan
 - d. Mengestimasi parameter model ARIMA dan menentukan Model ARIMA terbaik
 - e. Melakukan Uji efek ARCH
3. Melakukan pemodelan GARCH
 - a. Mengestimasi model GARCH
 - b. Melakukan uji *diagnostic* yaitu berupa tiga uji, diantaranya uji ARCH LM, Uji Korelasi serial untuk residual yang distandarisasi, dan melakukan uji normalitas residual.
 - c. Melakukan pemilihan model terbaik
 - d. Melakukan tahap akhir yaitu peramalan sesuai yang diinginkan.
 4. Melakukan peramalan dengan model GARCH.
 5. Melakukan *scaling* data.
 6. Melakukan *training* dan *testing* data Indeks Harga Konsumen.
 7. Membangun model *neural network* dengan algoritma *backprppagation*..
 8. Melihat akurasi dan validasi model yang terbentuk.
 9. Melakukan peramalan dengan struktur jaringan ANN terbaik.
 10. Menentukan model terbaik berdasarkan nilai MAPE yang terkecil.

Perhitungan algoritma *backpropagation* secara manual adalah sebagai berikut:

Langkah 1: inisialisasi bobot dengan nilai *random* yang cukup kecil.

- Fase Maju (*feed forward pass*)

Langkah 2: Lapisan *input* menerima sinyal $X_i, i = 1, 2, 1, \dots, n$ kemudian meneruskan sinyal tersebut ke lapisan berikutnya yaitu lapisan tersembunyi.

Langkah 3: Tiap-tiap unit tersembunyi $Z_j, j = 1, 2, 3, \dots, p$ menjumlahkan sinyal-sinyal terbobot,

$$Z_{in_j} = b1_j + \sum_{i=1}^n X_i W_{ij}$$

digunakan fungsi aktivasi untuk menghitung sinyal *output*,

$$Z_j = f(Z_{in_j})$$

dan dikirimkan sinyal tersebut ke semua unit di lapisan atasnya.

Langkah 4: Tiap unit *output* $Y_k, k = 1, 2, 3, \dots, m$ menjumlahkan sinyal-sinyal *input* terbobot,

$$Y_{in_k} = b_{2_k} + \sum_{i=1}^n Z_i W_{jk}$$

digunakan fungsi aktivasi untuk menghitung sinyal *output*.

$$Y_k = f(Y_{in_k})$$

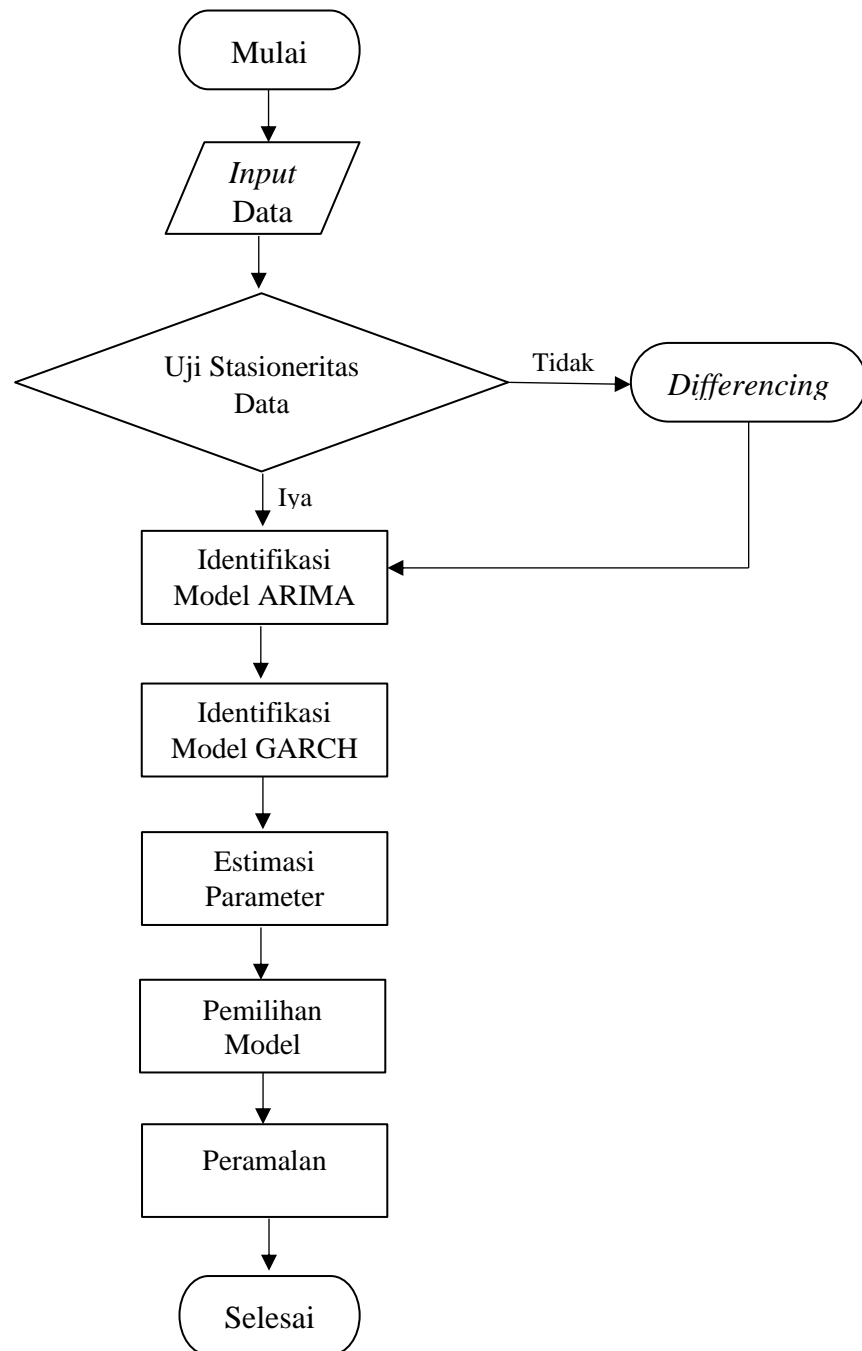
- Fase Mundur (*backward pass*)

Langkah 5: Tiap unit *output* $Y_k, k = 1, 2, 3, \dots, m$ menerima target pola yang berhubungan dengan pola *input*.

Langkah 6: Tiap lapisan tersembunyi $Y_j, j = 1, 2, 3, \dots, p$ menghitung δ_j kemudian digunakan untuk menghitung bobot terkoreksi dan bias antara *input* dan *hidden layer*.

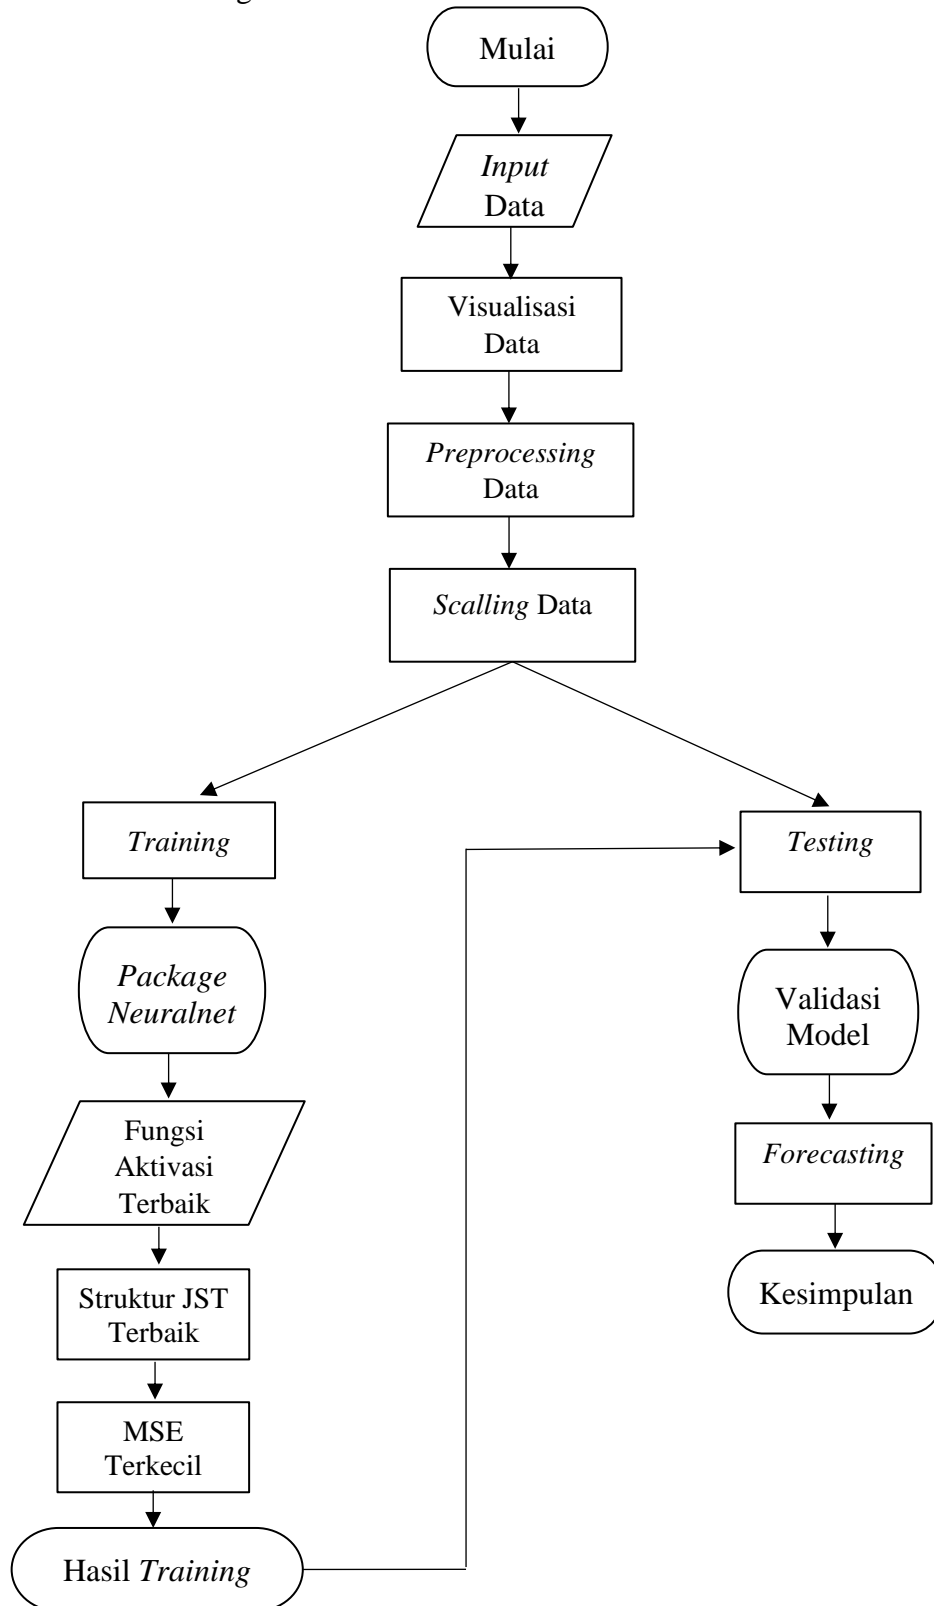
Langkah 7: Masing-masing lapisan *output* $Z_k, k = 1, 2, 3, \dots, m$ memperbaharui nilai bobot dan bias $j = 1, 2, 3, \dots, p$ dan setiap *hidden layer* memperbaharui pembobot dan bias $i = 1, 2, 3, \dots, n$ sehingga didapatkan bobot dan bias baru.

Secara singkat proses peramalan dengan model GARCH menggunakan *software R-Studio* adalah sebagai berikut:



Gambar 5. *Flowchart* Proses GARCH

Secara singkat proses peramalan dengan model ANN menggunakan *software R-Studio* adalah sebagai berikut:



Gambar 6. Flowchart Proses ANN

V. KESIMPULAN

Berdasarkan hasil dan pembahasan pada penelitian ini dapat diambil kesimpulan yaitu:

1. Didapatkan model ARIMA (4, 2, 2) ~ GARCH (1, 1) dengan nilai MAPE 3,19% dan struktur jaringan ANN dengan 1 *input* dan 2 *hidden layer* terbaik dengan nilai MAPE 1,24% untuk meramalkan nilai Indeks Harga Konsumen (IHK).
2. Model ANN menghasilkan tingkat akurasi peramalan yang lebih baik dibandingkan dengan model GARCH. Model ANN memiliki nilai MAPE 1,24% atau akurasi sebesar 98,76%, sedangkan model ARIMA (4,2,2)~GARCH (1,1) memiliki nilai MAPE 3,19% atau akurasi sebesar 96,81%.
3. Model ARIMA (4, 2, 2) yang diperoleh masih terdapat efek ARCH atau dengan kata lain masih adanya gejala *heteroscedasticity* sehingga dianjurkan menggunakan model GARCH. Sedangkan analisis data yang dilakukan dengan menggunakan metode ANN tidak perlu dilakukan asumsi data, tetapi data tersebut merupakan data yang berkualitas baik atau data harus melalui proses KDD agar bisa digunakan dalam membangun struktur jaringan ANN.

DAFTAR PUSTAKA

- Box, George. dan Jenkins, Gwilym. 1976. *Time Series Analysis, Forecasting and Control*. Prentice Hall.
- Chang, P.C., Wang, Y.W. dan Liu, C.H., 2007. The development of a weighted evolving fuzzy neural network for PCB sales forecasting. *Expert Systems with Applications*, Volume 32, pp. 86-96.
- Deltha, L. 2017. Peramalan Indeks Harga Konsumen Dengan Metode Singular Spectral Analysis dan Seasonal Autoregressive Integrated Moving Average. Tesis. Bandung: Universitas Padjajaran.
- Enders, Walter. 1995. *Applied Economis Time Series*. New York.
- Ezzine, Kadria. 2018. Investigation of Glottal Flow Parameters for Voice Pathology detection on SVD and MEEI Database. <https://www.semanticscholar.org>. Diakses Pada 11 April 2022.
- Fausett, L. 1994. *Fundamentals of Neural Network: Architectures, Algorithms and Applications*. New Jersey: Prencite Hall.
- Fayyad, U., Shapiro, G.P., dan Smyth, P. 1996. *Knowledge Discovery and Data Mining: Towards a Unifying Framework*. AAI Press.
- Gujarati, Damodar N. 2003. *Basic Econometrics*. 4th Edition. New York: McGrawHill

- Hanke, J.E. dan Wichern, D. 2004. *Business Forecasting. 8th Edition*. Prentice-Hall, New Jersey,
- Heaton, J. 2017. *The Number of Hidden layers*. New York.
- Hendikawati, Putriaji. 2015. *Peramalan Data Runtun Waktu Metode dan Aplikasinya dengan Minitab dan Eviews*. Semarang: FMIPA Unnes
- Jong, J. S. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Mat lab*. Penerbit Andi, Yogyakarta.
- Juanda, B., dan Junaidi. 2012. *Ekonometrika Deret Waktu: Teori dan Aplikasi*. IPB Press, Bogor.
- Kulkarni, S., dan Harman, G. 2001. *An Elementary Introduction to Statistical Learning Theory*. Wiley and Sons, Canada.
- Kuncoro, M. 1991. *Dasar-dasar Metode ARIMA (Box-Jenkins)*. Skripsi. Fakultas Ekonomi dan Pasca Sarjana UGM.
- Kustiara, Sri. 2020. Penerapan ARCH GARCH Dalam Meramalkan Indeks Harga Konsumen di Kota Semarang. *Jurnal Litbang Edusaintech*. **1**(1).
- Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan Menggunakan Mat lab dan Excel Link*. Yogyakarta: Penerbit Graha Ilmu.
- Lewis, N.D. 2017. *Neural Network for Time Series Forecasting with R*. Crate Space Independent Publishing Platform, US.
- Makridakis. 1999. *Metode dan Aplikasi Peramalan*. Ed. Ke-2. Terjemahan Untung Sus Andriyanto. Erlangga, Jakarta.
- Marta, H.D. 2016. Sifat Asimetris Model Prediksi GARCH & SVAR (Studi Kasus: Indeks Harga Saham Gabungan). *e-Proceeding of Engineering*. **3**(37)

- Montgomery, D.C. 2008. *Introduction to Time Series Analysis and Forecasting*. John Wiley & Sons, New Jersey.
- Muharsyah, R., 2009. Prakiraan Curah Hujan Tahun 2008 Menggunakan Teknik Neural Network dengan Prediktor Sea Surface Temperatur (SST) di Stasiun Mopah Merauke. *Jurnal Meteorologi dan Geofisika*. Volume 10 No.1. hal: 10-21.
- Nielsen, Michael. 2015. *Neural Network And Deep Learning*. New York
- Notobroto, Hari Basuki. 2019. Penerapan Metode Artificial Neural Network Dalam Peramalan Jumlah Kunjungan Ibu Hamil (K4). *Jurnal Biometrika dan Kependudukan*. **8**(1).
- Olugbenle, Michael. 2019. Logistics Regression with Neural Network mindset. <https://medium.com/@mikeolugbenle/logistics-regression-with-neural-network-mindset-66d0d7e91d9f>. Diakses pada 11 April 2022.
- Pandjaitan, L.W. 2007. *Dasar-dasar Komputasi Cerdas*. Penerbit Andi, Yogyakarta.
- Priddy, K. L. dan Keller, P. E. 2005. *Artificial Neural Networks: An Introduction*. Washington: SPIE Publications.
- Ramadhan, B.A. 2013. Analisis Perbandingan Metode ARIMA dan Metode GARCH untuk Memprediksi Harga Saham (Studi Kasus Pada Perusahaan Telekomunikasi yang Terdaftar di Bursa Efek Indonesia Periode Mei 2012-April 2013). *E-Processing of Management*, 2(April), 61–68.
- Ramchoun, H. 2016. Multilayer Perceptron: Architecture Optimization and Training. *International Journal of Interactive Multimedia and Artificial Intelligence*. **4**(1).

- Shynk, J.J. 1990. Performance Surface of a Single-Layer Perceptron. *IEEE Transactions on Neural Networks*. **1**(3).
- Simanjuntak, Justinus Handyka. 2019. Comparison Of Stock Price Prediction With Generalized Autoregressive Conditional Heteroscedasticity Model And Artificial Neural Network. *e-Proceeding of Engineering*. **6**(2).
- Spyros, M. 1995. *Metode dan Aplikasi Peramalan*. Erlangga, Jakarta
- Sudarsono, Aji. 2016. Jaringan Syaraf Tiruan Untuk Memprediksi Laju Pertumbuhan Penduduk Menggunakan Metode Backpropagation (Studi Kasus Di Kota Bengkulu. *Jurnal Media Informasi*. **12**(1)
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*. 2nd Edition. Pearson Education Hall, New Jersey.
- Widarjono, A. 2009. *Ekonometrika: Pengantar Teori dan Aplikasi*. Ekonisia UII, Yogyakarta.
- Widianto, Mochamad Haldi. 2021. Analisis Performa Algoritma Backpropagation Jaringan Syaraf Tiruan. <https://binus.ac.id/bandung/2021/04/analisis-performa-algoritma-backpropagation-jaringan-syaraf-tiruan/>. Diakses 11 April 2022.
- Zhang, P. G., Patuwo, E., dan Hu, M. Y. 1998. Forecasting With Artificial Neural Networks: The State Of The Art. *International Journal Of Forecasting*, Volume 14, pp. 35-62.