

**PERAMALAN HARGA EMAS DUNIA DENGAN PENDEKATAN ARIMA
DAN *FEED FORWARD NEURAL NETWORK***

(Skripsi)

Oleh

Karina Relita



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2021**

ABSTRAK

PERAMALAN HARGA EMAS DUNIA DENGAN PENDEKATAN ARIMA DAN *FEED FORWARD NEURAL NETWORK*

Oleh

Karina Relita

Emas menjadi salah satu komoditas investasi jangka panjang yang dipandang aman bagi para investor. Harganya sangat dipengaruhi oleh kondisi sosial ekonomi global yang mengakibatkan terjadinya perubahan harga secara fluktuatif. Investasi yang dilakukan masyarakat diharapkan beruntung, untuk itu perlu diprediksi kapan emas itu dibeli dan dijual. Pada awalnya, metode peramalan didominasi oleh metode linier. Namun demikian, metode linier tidak dapat menangkap hubungan nonlinier yang seringkali dijumpai pada kondisi riil. Tujuan dari penelitian ini adalah untuk meramalkan harga emas dunia dengan metode linier serta nonlinier. Penelitian ini menerapkan ARIMA untuk model linier, sedangkan untuk metode nonlinier yang diterapkan adalah *Feed Forward Neural Network* (FFNN). Penelitian ini menggunakan *open source R package statistics program*. Dari hasil analisis yang telah dilakukan model ARIMA terbaik yaitu ARIMA (0,1,0) atau *random walk model* dengan nilai RMSE *in-sample* sebesar 45.37506 dan RMSE *out-of-sample* sebesar 288.8484. Model FFNN terbaik yaitu FFNN (1;4;1) dengan z_{t-1} sebagai variabel input dengan nilai RMSE *in-sample* sebesar 41.96074 dan RMSE *out-of-sample* 257.0647. Dari kedua model tersebut pemodelan terbaik adalah dengan menggunakan pendekatan model FFNN (1;4;1) karena memiliki nilai RMSE *out-of-sample* terkecil.

Kata kunci: *peramalan, arima, feed forward neural network, harga emas*

ABSTRACT

FORECASTING GOLD PRICES USING ARIMA AND FEED FORWARD NEURAL NETWORK

By

Karina Relita

Gold was the one of the long-term investment commodities that were considered as the safe heaven for investors. The gold price was strongly influenced by global socioeconomic that causing fluctuations in price changes. Investments made by the community are expected to be successful, for that it is necessary to predict when gold is bought and sold. At first, the method of forecasting is dominated by linear methods. However, the linear method can not capture non-linear relationships that are often found in real conditions. The aim of this study is to predict the gold prices to the method of linear and nonlinear. Linear methods used are ARIMA, whereas nonlinear method used is Feed Forward Neural Network (FFNN). This research use open source R package statistics program. From the analysis that have conducted, the best ARIMA model is ARIMA (0,1,0) or random walk model with in-sample RMSE of 45.37506 and out-of-sample RMSE of 288.8484. Best FFNN model is FFNN (1;4;1) with z_{t-1} as an input and in-sample RMSE of 41.96074 and out-of-sample RMSE of 288.8484. From the two models, the best model is using model FFNN (1;4;1) in having the smallest out-of-sample RMSE.

Keywords: *forecast, arima, feed forward neural network, gold prices*

**PERAMALAN HARGA EMAS DUNIA DENGAN PENDEKATAN ARIMA
DAN *FEED FORWARD NEURAL NETWORK***

Oleh

KARINA RELITA

Skripsi

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

Pada

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



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2021**

Judul Skripsi : **PERAMALAN HARGA EMAS DUNIA
DENGAN PENDEKATAN ARIMA DAN FEED
FORWARD NEURAL NETWORK**

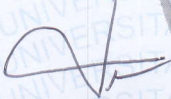
Nama Mahasiswa : **Karina Refita**

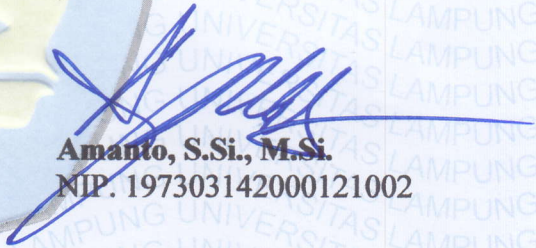
Nomor Pokok mahasiswa : **1717031068**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**




Drs. Nusyirwan, M.Si.
NIP. 196610101992051001


Amanto, S.Si., M.Si.
NIP. 197303142000121002

2. **Ketua Jurusan Matematika**

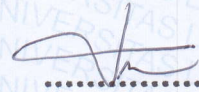

Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

1. Tim Penguji

Ketua

: Drs. Nusyirwan, M.Si.



Sekretaris

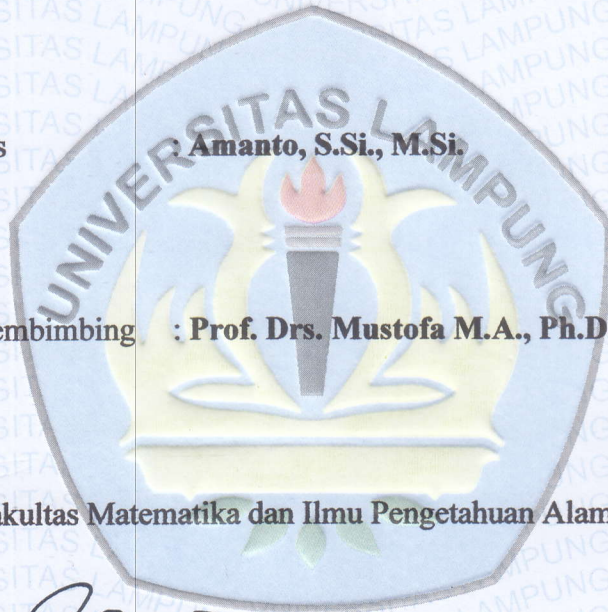
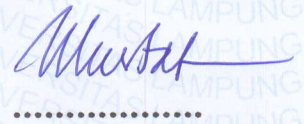
: Amanto, S.Si., M.Si.



Penguji

Bukan Pembimbing

: Prof. Drs. Mustofa M.A., Ph.D.

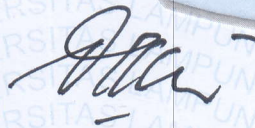


2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Suripto Dwi Yuwono, M.T.

NIP. 197407052000031001



Tanggal Lulus Ujian Skripsi: 9 Agustus 2021

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Karina Relita**

Nomor Pokok Mahasiswa : **1717031068**

Jurusan : **Matematika**

Judul : **PERAMALAN HARGA EMAS DUNIA
DENGAN PENDEKATAN ARIMA DAN *FEED
FORWARD NEURAL NETWORK***

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, 09 Agustus 2021
Penulis,



Karina Relita

RIWAYAT HIDUP

Penulis bernama lengkap Karina Relita, anak terakhir dari tiga bersaudara yang dilahirkan di Bekasi pada tanggal 11 Januari 1999 oleh pasangan Bapak Pakibo Simanjuntak dan Ibu Seni Ginting.

Penulis menempuh pendidikan di TK Santa Maria Monica yang diselesaikan pada tahun 2005, kemudian melanjutkan sekolah di SD Santa Maria Monica yang diselesaikan pada tahun 2011, kemudian melanjutkan sekolah di SMP Santa Maria Monica yang diselesaikan pada tahun 2014, dan kemudian melanjutkan sekolah di SMA Negeri 4 Bekasi yang diselesaikan pada tahun 2017.

Pada tahun 2017 penulis terdaftar sebagai Mahasiswa Program Studi S1 Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SBMPTN. Selama menjadi mahasiswa penulis pernah bergabung menjadi Staf Media dan Informasi (MEDINFO) BEM FMIPA Unila 2018, juga aktif berpelayanan dalam organisasi berbasis pelayanan, yaitu Persekutuan Oikumene Mahasiswa MIPA (POM MIPA) sebagai anggota Doa dan Pemerhati.

Pada bulan Januari sampai dengan Februari 2020, penulis melakukan Kuliah Kerja Nyata (KKN) di Desa Penawar Baru, Kecamatan Gedung Aji, Tulang Bawang. Pada bulan Juli sampai dengan Agustus 2020, penulis melaksanakan Kerja Praktik (KP) di Kantor Pelayanan Perbendaharaan Negara (KPPN) Jakarta IV.

KATA INSPIRASI

For I say, through the grace given unto me, to every man that is among you, not to think of himself more highly than he ought to think; but to think soberly, according as God hath dealt to every man the measure of faith.

(Romans 12:3)

Never stop learning, because life never stops teaching.

(Goutham Buddha)

The only true wisdom is in knowing you know nothing.

(Socrates)

What doesn't kill you, makes you stronger.

(Friedrich Nietzsche)

Bergembiralah dalam duka, duka adalah cara melebur denganNya.

Kenaikan, di jalan ini, berpindah dari ketinggian ke kedalaman.

(Maulana Jalaludin Rumi)

PERSEMBAHAN

Terpujilah Allah, sumber segala hikmat, yang telah menjadi dasar dari segala pengharapan dan senantiasa mengaruniakan damai sejahtera yang melampaui segala akal sehingga penulis dapat menyelesaikan skripsi ini.

Kupersembahkan skripsi ini kepada Bapak dan Mama, orang tua terhebat didunia versiku. Terima kasih sudah berkorban banyak hal sehingga aku bisa memiliki kesempatan untuk bahagia bersama kalian. Hanya karena doa dan didikan kalian yang membawaku bertahan sampai sejauh ini.

Juga kepada abang dan kakak, terima kasih telah mengajarkan adikmu banyak hal tentang kehidupan. Memberikan arahan dalam setiap langkah yang kutempuh.

Serta teman-temanku yang memberikan begitu banyak memori dalam perkuliahan. Hal yang akan kusimpan selalu selama hidup.

SANWACANA

Puji syukur kepada Tuhan Yang Maha Esa yang telah memberikan karunia serta kasihNya sehingga penulis dapat menyelesaikan skripsi yang berjudul

“Peramalan Harga Emas Dunia dengan Pendekatan Arima dan *Feed Forward Neural Network*”. Semua hal yang telah dicapai dan diselesaikan tidak terlepas dari bantuan berbagai pihak. Oleh karena itu penulis mengucapkan terima kasih yang tak terhingga kepada:

1. Bapak Drs. Nusyirwan, M.Si., selaku pembimbing utama dan pembimbing akademik atas kesediaan waktu, pemikiran dalam memberikan evaluasi, arahan, dan saran yang membangun dalam proses penyusunan skripsi ini.
2. Bapak Amanto, S.Si., M.Si., selaku pembimbing kedua atas kesediaan waktu, saran, dan arahan selama proses penyusunan skripsi ini.
3. Bapak Prof. Drs. Mustofa M.A., Ph.D., selaku dosen penguji atas kesediaan waktu, saran, dan masukan yang membangun selama proses penyusunan skripsi ini.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Kepala Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

5. Bapak Dr. Eng. Suropto Dwi Yuwono, M.T., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Para Dosen dan Staf Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Bapak dan Mama, serta abang dan kakakku yang selalu mendoakan dan memberi dukungan kepada penulis dalam menyelesaikan perkuliahan.
8. Fauzan Andi dan Yohana Devega dua insan terkasih dalam hidup yang senantiasa memberikan semangat dan doa meski jauh.
9. Nana Lovers, PI Bersahaja, Sahabat Doa, Yok, dan KKN PNB atas canda dan tawanya selama perkuliahan. Manusia-manusia terdekat yang senantiasa memberikan semangat, bantuan, dan doa. Terima kasih tak terhingga untuk segalanya.
10. Mas Hendri yang sangat membantu dalam penyelesaian skripsi.
11. Serta semua pihak yang tak bisa disebutkan satu persatu yang telah menjadi bagian dari awal hingga akhir perkuliahan.

Kiranya skripsi ini dapat memberikan sumbangan yang berarti bagi semua pihak yang berkepentingan. Penulis menyadari dalam penyusunan skripsi masih memiliki kekurangan, karena itu kritik dan saran yang membangun diharapkan untuk penyempurnaan skripsi.

Bandar Lampung, 09 Agustus 2021
Penulis,

Karina Relita

DAFTAR ISI

	Halaman
DAFTAR TABEL	xvi
DAFTAR GAMBAR	xvii
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 Peramalan	4
2.2 Analisis Deret Waktu.....	5
2.3 Model ARIMA (<i>Autoregressive Integrated Moving Average</i>).....	6
2.3.1 Stasioneritas	6
2.3.2 Klasifikasi Model ARIMA	7
2.3.3 Identifikasi Model ARIMA.....	10
2.3.4 Estimasi Parameter.....	11
2.3.5 Pengujian Signifikansi Parameter	12
2.3.6 Pengujian Asumsi Residual	13
2.4 Kriteria Model Terbaik.....	15
2.5 Uji Nonlinieritas	15
2.6 <i>Artificial Neural Network</i>	16
2.6.1 <i>Feed Forward Neural Network</i>	18
2.6.2 Algoritma <i>Backpropagation Learning</i>	18
2.7 Emas	22
III. METODOLOGI PENELITIAN	23
3.1 Waktu dan Tempat Penelitian.....	23
3.2 Data Penelitian.....	23
3.3 Metode Penelitian	24
3.3.1 Pemodelan dengan Metode ARIMA.....	24
3.3.2 Pemodelan dengan Metode FFNN	25

III. HASIL DAN PEMBAHASAN.....	27
4.1 Analisis Deskriptif	27
4.2 Pemodelan dengan ARIMA.....	28
4.2.1 Plot Data <i>Training</i> , ACF, PACF Setelah Stasioner	30
4.2.2 Uji Kesesuaian Model.....	31
4.2.3 Peramalan ARIMA(0,1,0).....	33
4.5. Pemodelan dengan <i>Feed Forward Neural Network</i>	33
4.4. Pemilihan Model Terbaik	37

V. KESIMPULAN

DAFTAR PUSTAKA

LAMPIRAN

DAFTAR TABEL

Tabel	Halaman
1. Identifikasi Model <i>Time Series</i>	10
2. Karakteristik Harga Emas Dunia.....	28
3. Uji Stasioner dalam Ragam.....	28
4. Uji Stasioner dalam Rata-Rata	29
5. Uji Stasioner dalam Rata-Rata Diferensiasi Tingkat 1	30
6. Uji Kesesuaian Model	32
7. Uji Terasvirta	34
8. Pemodelan Metode <i>Neural Network</i> Data Harga Emas Dunia	35
9. Bobot Unit dalam Lapisan Tersembunyi	36
10. Bobot Unit Output.....	37
11. Perbandingan Hasil Metode Terbaik Data Harga Emas Dunia.....	37

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur <i>Backpropagation</i>	19
2. Plot Deret Waktu Harga Emas Dunia	27
3. Plot Deret Waktu Setelah Stasioner	30
4. Pola ACF dan Pola PACF Setelah Stasioner	31
5. Peramalan ARIMA(0,1,0)	33
6. Arsitektur NN Harga Emas Dunia	36
7. Plot Akurasi <i>In-Sample</i> dan <i>Out-of-Sample</i> Data Harga Emas Dunia.....	38

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Emas adalah logam mulia yang mempunyai dwifungsi yaitu sebagai fungsi investasi dan fungsi permata atau perhiasan. Dalam penelitian ini yang dibahas adalah emas sebagai fungsi investasi. Investasi emas merupakan salah satu jenis investasi yang banyak diminati masyarakat dan dipandang oleh sebagian besar investor sebagai alat investasi aman dan sudah dilakukan sejak dulu.

Emas pada hakikatnya berfungsi untuk menahan inflasi. Sejak tahun 1998 hingga tahun 2010, harga emas mengalami kenaikan secara kumulatif jauh di atas perubahan kumulatif inflasi. Selama terjadi krisis finansial 2008-2009, banyak harga komoditi mengalami penurunan kurang lebih 40%, tetapi harga emas global cenderung naik rata-rata 6% (Tripathy, 2017). Dalam kondisi yang tidak stabil, langkah terbaik untuk seorang investor adalah memiliki beberapa jaminan dalam aset fisik dan aset likuid yang dapat dilikuidasi sewaktu-waktu. Investor menginvestasikan asetnya dalam bentuk emas untuk mengurangi kerugian, sehingga peramalan harga emas menjadi permasalahan yang sangat penting di bidang ekonomi keuangan (Tripathy, 2017).

Dalam berinvestasi yang diharap adalah keuntungan yaitu selisih harga antara membeli dan menjual emas. Untuk itu diperlukan prediksi harga emas yang akan datang untuk mengetahui harus membeli atau menjual emas. Untuk memprediksi harga emas banyak digunakan model peramalan secara statistika atau model kecerdasan buatan.

Pada awal perkembangan *time series*, Yale memberikan kontribusi besar dengan memperkenalkan gagasan bahwa setiap *time series* dapat direalisasikan dari sebuah proses stokastik. Berawal dari ide ini maka berkembang berbagai metode *time series*. Salah satu metode yang banyak digunakan adalah model ARIMA. Model ARIMA ini diperkenalkan oleh Box dan Jenkins pada tahun 1976. Model ini sampai saat ini masih banyak digunakan terutama sebagai metode pembandingan.

Beberapa tahun belakangan ini mulai berkembang model nonlinier, yang artinya hubungan antara kejadian di masa lalu dan sekarang bersifat nonlinier. Model nonlinier ini dianggap lebih mewakili kondisi data yang ada, karena jarang ditemui data yang memenuhi asumsi-asumsi yang terdapat pada model linier. Sampai saat ini model nonlinier ini masih terus mengalami perkembangan.

Artificial Neural Network (ANN) atau biasa disebut dengan *Neural Network* (NN) adalah salah satu model nonlinier yang sering digunakan. Gagasan utama dari NN adalah input atau variabel dependen, melalui satu atau lebih *layer* tersembunyi sebelum mencapai *output*. Menurut Zhang (2003) keunggulan utama dari NN adalah kemampuan yang fleksibel dalam memodelkan data nonlinier.

Model ARIMA dan NN merupakan model yang sering digunakan dalam pemodelan linier maupun nonlinier. Pada penelitian ini peramalan menggunakan metode ARIMA dan *Feed Forward Neural Network* dalam memodelkan peramalan harga emas di Indonesia.

1.2 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan diatas, maka tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Mendapatkan model ARIMA yang sesuai untuk peramalan harga emas.
2. Mendapatkan desain FFNN terbaik yang memiliki kombinasi input dan jumlah *hidden neuron* yang sesuai untuk peramalan data.
3. Melakukan perbandingan metode peramalan konvensional yakni ARIMA dengan metode peramalan modern yakni *Feed Forward Neural Network*.

1.3 Manfaat Penelitian

Secara umum, penelitian ini diharapkan dapat dimanfaatkan oleh pembaca.

Secara khusus, manfaat yang diharapkan tersebut dirinci sebagai berikut:

1. Mampu memahami cara penerapan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Feed Forward Neural Network*.
2. Dapat menilai dan membandingkan hasil terbaik antara metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Feed Forward Neural Network*.

II. TINJAUAN PUSTAKA

2.1 Peramalan

Perkembangan dalam bidang pendugaan (*prediction*) dan penaksiran (*estimation*) yang memiliki kaitan dan dapat digunakan secara langsung dalam peramalan telah terjadi dalam beberapa dekade. Peramalan merupakan proses yang dilakukan ketika ada kesenjangan waktu (*lag*) dari data aktual pada waktu tertentu dengan data yang ingin diketahui di masa yang akan datang. Peramalan diperlukan untuk mengetahui kapan suatu peristiwa akan terjadi, sehingga tindakan yang tepat dapat dilakukan (Makridakis, Wheelwright, dan Hyndman, 1998).

Dengan adanya sejumlah besar metode peramalan yang tersedia, maka masalah yang timbul bagi para praktisi adalah memahami bagaimana karakteristik suatu metode peramalan akan cocok bagi situasi pengambilan keputusan tertentu. Untuk itu, sejumlah teknik telah dikembangkan dan dikelompokkan menjadi dua kategori utama, yakni metode kuantitatif dan metode kualitatif. Metode kuantitatif meliputi deret waktu (*time series*) dan metode kausal. Sedangkan metode kualitatif meliputi metode eksplorasi dan normatif. Pada model deret waktu, pendugaan masa depan dilakukan berdasarkan nilai masa lalu dari suatu variabel dan/atau kesalahan masa lalu.

2.2 Analisis Deret Waktu

Setiap nilai dari hasil pengamatan pada dasarnya selalu memiliki keterkaitan dengan waktu pengamatannya. Namun demikian, dalam melakukan analisis, seringkali variabel waktu dengan pengamatan tidak dikaitkan. Data deret waktu merupakan serangkaian data yang berupa nilai pengamatan yang diukur selama kurun waktu tertentu, berdasarkan interval waktu yang tetap (Wei, 2006). Sifat alami dari data deret waktu adalah antar pengamatan tidak independen.

Pengamatan yang berdekatan saling berhubungan atau berkorelasi, dimana data saat ini dipengaruhi oleh satu atau beberapa data sebelumnya.

Berbeda dengan analisis data lainnya, analisis deret waktu lebih memfokuskan untuk melihat perilaku data, bagaimana data bergerak, tanpa mengkaji faktor-faktor apa yang menyebabkan pergerakan data tersebut. Terdapat dua alasan mengapa analisis deret waktu tidak mengkaji faktor-faktor penyebab pergerakan data. Pertama, faktor-faktor penyebab pergerakan data tidak dimengerti, dan walaupun hal itu diketahui, sangat sulit mengukur hubungan sebab akibatnya. Kedua, perhatian utama peneliti hanya untuk meramalkan apa yang akan terjadi dan bukan mengetahui mengapa hal itu terjadi (Makridakis, Wheelwright, dan Hyndman, 1998)

2.3 Model ARIMA (*Autoregressive Integrated Moving Average*)

ARIMA sering juga disebut metode runtun waktu Box-Jenkins. ARIMA sangat baik ketepatannya untuk peramalan jangka pendek, sedangkan untuk peramalan jangka panjang ketepatan peramalannya kurang baik. Biasanya akan cenderung *flat* (mendatar/konstan) untuk periode yang cukup panjang (Wei, 2006).

ARIMA merupakan gabungan dari model *Autoregressive* (AR) dan *Moving Average* (MA). AR merupakan model yang menyatakan bahwa kejadian sekarang berkaitan dengan kejadian waktu lalu. Sedangkan MA adalah model yang menyatakan bahwa kejadian sekarang berkaitan *error* waktu lalu.

2.3.1 Stasioneritas

Dalam analisis deret waktu asumsi yang penting adalah kestasioneran data yang diperoleh. Deret waktu yang stasioner adalah deret waktu yang mempunyai rata-rata dan ragam konstan sepanjang waktu. Dengan kata lain data deret waktu yang stasioner adalah data yang tidak mengalami kenaikan atau penurunan yang signifikan atau secara matematis dapat dikatakan bahwa data yang dimiliki berfluktuasi di sekitar nilai rata-rata atau berada di antara dua standar galat (Soejoeti, 1987).

Tidak stasionernya data akan mengakibatkan kurang baiknya model yang diestimasi dan data tersebut dipertimbangkan kembali validitas dan kestabilannya.

Salah satu penyebab tidak stasionernya sebuah data adalah adanya autokorelasi. Bila data distasionerkan maka autokorelasi akan hilang dengan sendirinya, karena itu transformasi data untuk membuat data yang tidak stasioner menjadi stasioner sama dengan transformasi data untuk menghilangkan autokorelasi.

a. Stasioner dalam Ragam

Apabila ketidakstasioneran terjadi dalam ragam, untuk menstabilkan ragam dilakukan dengan *Box-Cox transformation* yang di definisikan dengan:

$$Z^* = \frac{Z^\lambda - 1}{\lambda} \quad (2.1)$$

b. Stasioner dalam Rata-Rata

Tidak stasionernya data terhadap mean dapat diatasi dengan melakukan *differencing*. Persamaan *differencing* pada orde ke-d adalah sebagai berikut.

$$\textit{differencing pada orde ke } - d = (1 - B)^d Z_t \quad (2.2)$$

2.3.2 Klasifikasi Model ARIMA

Model Box-Jenkins (ARIMA) dibagi kedalam beberapa kelompok, yaitu model *Autoregressive (AR)*, *Moving Average (MA)*, model campuran *Autoregressive Integrated Moving Average (ARIMA)*, model *Random Walk*, dan model *Random Walk with Drift* yang mempunyai karakteristik dari dua model pertama.

1. Model *Autoregressive* (AR)

Bentuk umum model *autoregressive* dengan ordo p (AR(p)) atau model

ARIMA ($p, 0, 0$) dinyatakan sebagai berikut (Gujarati, 2003):

$$Z_t = \mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (2.3)$$

dengan,

Z_t = peubah yang diramalkan pada waktu ke- t

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

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

μ = rata-rata dari Y

ε_t = nilai residual pada saat t

2. Model *Moving Average* (MA)

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

dinyatakan sebagai berikut (Gujarati, 2003):

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.4)$$

dengan,

Z_t = peubah yang diramalkan pada waktu ke- t

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

$\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ = nilai-nilai residual

3. Model ARIMA

Persyaratan utama model AR dan MA adalah kestasioneran data deret waktu yang digunakan. Jika data tidak stasioner terhadap rata-rata maka dilakukan *differencing* dan jika data tidak stasioner terhadap ragam maka pada umumnya data dilakukan transformasi terhadap logaritma natural. Bentuk umum model $ARIMA(p, d, q)$ adalah:

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B)\varepsilon_t \quad (2.5)$$

dengan,

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

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

Model AR atau MA yang stasioner melalui proses *differencing* disebut dengan *Autoregressive Integrated Moving Average* (ARIMA) (Juanda dan Junaidi, 2012).

4. Model Random Walk

Model *random walk* adalah model deret waktu dimana nilai variabel dalam periode t adalah sama dengan nilai pengamatan pada periode terakhir, $t - 1$, ditambah dengan *error* acak yang tak terduga. Model *random walk* memiliki persamaan (Defusco et al, 2007),

$$Z_t = Z_{t-1} + \varepsilon_t \quad (2.6)$$

Model tersebut menunjukkan bahwa deret waktu Z_t dalam setiap periode merupakan fungsi dari nilai pada periode sebelumnya ditambah ε_t .

5. Model *Random Walk with Drift*

Model *random walk with drift* adalah model *random walk* dengan $E(\varepsilon_t) \neq 0$.

Model ini memiliki persamaan (Hyndman dan Athanasopoulos, 2013),

$$Z_t = \mu + Z_{t-1} + \varepsilon_t \quad (2.7)$$

Konstanta μ merupakan rata-rata perubahan deret waktu dari semua periode.

Jika μ adalah positif maka Z_t akan cenderung mempunyai *drift* dengan arah naik dan sebaliknya. Model *drift* ekuivalen dengan model AR(1) dengan $\phi_1 = 1$ dan $\mu \neq 0$.

2.3.3 Identifikasi Model ARIMA

Identifikasi awal untuk membentuk model ARIMA yang tepat dapat dilakukan dengan memperhatikan pola plot ACF dan PACF untuk mengidentifikasi orde dari p dan q .

Tabel 1. Identifikasi Model *Time Series*

Model	ACF	PACF
AR(p)	Menurun secara eksponensial	Terpotong setelah <i>lag p</i>
MA(q)	Terpotong setelah <i>lag q</i>	Menurun secara eksponensial
ARIMA(p, d, q)	Menurun secara eksponensial setelah <i>lag q</i>	Menurun secara eksponensial setelah <i>lag p</i>

a. *Autocorrelation Function* (ACF)

Autocorrelation Function (ACF) merupakan suatu fungsi yang menjelaskan korelasi antara Z_t dan Z_{t+k} dari proses yang sama dan hanya terpisah oleh *lag* waktu ke- k . Rumus perhitungan ACF sebagai berikut:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, k = 0, 1, 2, \dots \quad (2.8)$$

Dimana \bar{Z} merupakan nilai rata-rata dari *time series* ($\bar{Z} = \sum_{t=1}^n \frac{Z_t}{n}$)

b. *Partial Autocorrelation Function* (PACF)

Partial Autocorrelation Function (PACF) digunakan untuk mengukur korelasi antara Z_t dan Z_{t+k} . Nilai PACF disimbolkan ϕ_{kk} , nilai ϕ_{kk} dapat dihitung dengan Persamaan (2.9) dan (2.10) berikut

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.9)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, j = 1, 2, \dots, k \quad (2.10)$$

2.3.4 Estimasi Parameter

Setelah melakukan identifikasi model ARIMA secara sementara kemudian dilanjutkan dengan mengestimasi parameter-parameternya. Secara umum estimasi parameter dapat dilakukan dengan menggunakan beberapa cara atau metode antara lain *least square*, *moment*, *maximum likelihood*, dan *unconditional least square*. Dalam pemodelan linier, metode *least square* merupakan metode yang paling sering digunakan dalam estimasi parameter (Cryer dan Chan, 2008).

Untuk contoh penerapan metode *least square* dapat dilihat pada model AR (1) sebagai berikut,

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + \varepsilon_t \quad (2.11)$$

dengan Z_t sebagai variabel respon dan Z_{t-1} sebagai variabel prediktor. Estimasi dengan metode *least square* didapatkan dengan meminimumkan jumlah kuadrat residual, dengan residual sebagai berikut,

$$\varepsilon_t = (Z_t - \mu) - \phi(Z_{t-1} - \mu) \quad (2.12)$$

karena hanya Z_1, Z_2, \dots, Z_n yang diamati maka hanya didapatkan penjumlahan dari $t = 2$ hingga $t = n$ sebagai berikut,

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (2.13)$$

selanjutnya dilakukan estimasi parameter μ dan ϕ dengan cara persamaan (2.13) diturunkan terhadap μ dan ϕ kemudian menyamakan dengan 0 maka akan diperoleh hasil estimasi parameter sebagai berikut,

$$\hat{\mu} = \frac{1}{(1-\phi)} \bar{Z} - \phi \bar{Z} \quad (2.14)$$

dengan menggunakan cara yang sama, maka akan diperoleh hasil sebagai berikut,

$$\bar{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.15)$$

2.3.5 Pengujian Signifikansi Parameter

Uji signifikansi parameter dilakukan untuk mengetahui apakah parameter model ARIMA yang telah diperoleh signifikan atau tidak. Berikut merupakan hipotesis yang akan diuji, dengan β merupakan simbol parameter untuk ϕ (AR) atau θ (MA) sebagai berikut,

$H_0: \beta = 0$ (parameter tidak signifikan dalam model)

$H_1: \beta \neq 0$ (parameter signifikan dalam model)

Statistik uji,

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (2.16)$$

dimana,

$\hat{\beta}$ = estimasi setiap parameter ϕ (AR) atau θ (MA) pada model

$SE(\hat{\beta})$ = standar residual dari setiap estimasi $\hat{\beta}$

Dengan daerah penolakan adalah tolak H_0 apabila $|t| > t_{\frac{\alpha}{2}, n-p}$ atau $P_{value} < \alpha$.

2.3.6 Pengujian Asumsi Residual

Untuk mendapatkan model ARIMA yang terbaik setelah mengestimasi dan menguji signifikansi semua parameter terdapat beberapa asumsi yang harus dipenuhi terhadap residual yaitu uji *white noise* dan uji distribusi normal.

1. Uji Asumsi *White Noise*

Residual dari suatu model dikatakan *white noise* apabila antar residual tidak ada hubungan dan ragam homogen, dengan kata lain adalah independen.

Untuk menguji asumsi *white noise* dapat dilakukan menggunakan uji Ljung-Box (Wei, 2006). Dengan hipotesis sebagai berikut,

$H_0: \rho_k = 0, \forall_i$ (residual memenuhi asumsi *white noise*)

$H_1: \rho_k \neq 0, \exists_i$ untuk $i = 1, 2, \dots, K$ (residual tidak memenuhi asumsi *white noise*)

Statistik uji,

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.17)$$

n = banyak pengamatan

$\hat{\rho}_k^2$ = autokorelasi residual lag ke-k

Dengan daerah penolakan adalah tolak H_0 apabila $Q > \chi_{\alpha; (K-p-q)}^2$ atau

$P_{value} < \alpha$.

2. Uji Distribusi Normal

Pengujian residual berdistribusi normal dapat dilakukan dengan menggunakan

Uji Kolmogorov-Smirnov. Dengan hipotesis,

$H_0: F_0(x) = F(x)$ (data berdistribusi normal)

$H_1: F_0(x) \neq F(x)$ (data berdistribusi tidak normal)

Statistik uji,

$$D = maks |F_0(x) - S_n(x)| \quad (2.18)$$

$F_0(x)$ = fungsi distribusi kumulatif

$S_n(x) = \frac{m}{n}$ = fungsi peluang kumulatif dengan n observasi dan m

banyak observasi yang sama atau kurang dari x

Dengan daerah penolakan adalah tolak H_0 apabila $|D| > D_{(1-\alpha)}^*$ dimana nilai

D^* berdasarkan tabel Kolmogorov-Smirnov atau $P_{value} < \alpha$.

2.4 Kriteria Model Terbaik

Pemilihan model terbaik mempertimbangkan nilai dari residual. Residual merupakan selisih dari hasil estimasi dengan nilai sesungguhnya. Pada penelitian ini digunakan dua pendekatan yaitu pendekatan *in-sample* dan *out-of-sample*.

Pada pendekatan *in-sample* maupun *out-of-sample* kriteria yang digunakan untuk memilih model terbaik didasarkan pada nilai RMSE (*Root Mean Square Error*) dengan rumus sebagai berikut:

$$RMSE = \sqrt{\frac{1}{r} \sum_{i=1}^r e_i^2} \quad (2.19)$$

dimana,

e_i = selisih nilai pengamatan dan hasil ramalan

r = banyak data *out-of-sample* atau ramalan

2.5 Uji Nonlinieritas

Sebelum menerapkan model nonlinier terlebih dahulu lakukan uji nonlinieritas pada data *time series*, hal ini dilakukan untuk memastikan bahwa metode yang digunakan sudah sesuai dengan datanya. Uji Terasvirta merupakan salah satu uji untuk mendeteksi hubungan nonlinier antar variabel yang dikembangkan berdasarkan model *neural network* dan termasuk dalam kelompok uji tipe Lagrangre Multiplier dengan ekspansi Taylor (Terasvirta, Lin dan Granger, 1993) dengan hipotesis sebagai berikut:

$H_0 = f(x)$ adalah fungsi linier dalam x (model linier)

$H_1 = f(x)$ adalah fungsi nonlinier dalam x (model nonlinier)

Statistik uji yang digunakan adalah:

$$F = \frac{SSR_0 - SSR/m}{SSR/(N-r-1-m)} \quad (2.20)$$

dengan,

SSR_0 = jumlah kuadrat residual dari regresi $f(x)$ dengan x dimana menghasilkan residual u_t

SSR = jumlah kuadrat residual dari regresi u_t dengan x dan m

r = jumlah variabel prediktor awal

m = jumlah variabel prediktor kuadratik dan kubik

N = jumlah data

Daerah kritis atau daerah penolakan H_0 adalah apabila nilai F_{hitung} lebih besar dari nilai F_{tabel} dengan derajat bebas m dan $N - r - 1 - m$ atau nilai P_{value} lebih kecil dari nilai α (0,05) maka $f(x)$ merupakan fungsi nonlinier dalam x .

2.6 Artificial Neural Network

Kelebihan ARIMA adalah cukup fleksibel dalam memodelkan sebagian besar pola *time series*, tetapi ARIMA hanya dapat mengasumsikan model yang linier. Hal ini menyebabkan model ARIMA tidak menangkap pola-pola nonlinier yang umum terdapat pada *time series*. Oleh karena itu, model tersebut memerlukan model yang dapat menangkap pola-pola nonlinier. Model tersebut adalah model ANN (*Artificial Neural Network*). *Neural Network* ditentukan oleh tiga hal diantaranya yaitu pola hubungan antar unit (arsitektur jaringan), metode untuk melakukann *update* bobot dalam *link* koneksi (metode pelatihan atau algoritma), dan fungsi aktivasi (Zhang, 2004).

Seperti jaringan manusia, jaringan saraf tiruan memiliki komponen sebagai berikut,

a. Neuron Tiruan (*Artificial Neuron*)

ANN disusun oleh unit dasar yang disebut dengan neuron tiruan yang merupakan elemen pemrosesan dalam jaringan, dimana semua proses perhitungan dilakukan disini.

b. Lapisan (*Layer*)

ANN disusun oleh kumpulan neuron yang berhubungan dan dikelompokkan pada lapisan-lapisan. Dalam ANN terdapat tiga lapisan diantaranya: *input layer*, *hidden layer*, dan *output layer*

c. Masukan (*Input*)

ANN hanya dapat memproses data yang memiliki masukan berjenis numerik. Sehingga apabila masalah melibatkan data kualitatif seperti grafik, gambar, sinyal suara, dan data tersebut akan dirubah ke dalam data numerik yang ekuivalen sebelum data dapat diproses oleh ANN.

d. Keluaran (*Output*)

Keluaran dari ANN adalah berupa pemecahan terhadap masalah yang berupa data numerik.

e. Bobot (*Weight*)

Bobot di dalam ANN menyatakan bahwa suatu sistem memiliki tingkat kepintaran. Bobot dari sebuah ANN berupa deretan angka yang sangat penting untuk mengoptimalkan dan akan memungkinkan sebuah sistem menerjemahkan data masukan secara benar dan menghasilkan sebuah keluaran yang diinginkan.

2.6.1 *Feed Forward Neural Network*


Feed Forward Neural Networks atau FFNN yang juga dikenal dengan *Multi Layer Perceptrons* (MLP) adalah bentuk arsitektur NN yang secara umum paling banyak digunakan dalam aplikasi di bidang teknik atau rekayasa. Biasanya, aplikasi NN untuk pemodelan *time series* dan *signal processing* adalah berdasarkan pada arsitektur FFNN. FFNN merupakan arsitektur NN yang tersusun dari beberapa *layer*. Sebuah FFNN memiliki satu input *layer*, satu atau lebih *hidden layer*, dan satu *output layer*. Masing-masing *layer* memiliki neuron sejumlah satu atau lebih yang menerima input dari neuron-neuron pada *layer* sebelumnya dan meneruskan *output* ke neuron-neuron pada *layer* sesudahnya. Tidak ada koneksi antar neuron dalam satu *layer*.

2.6.2 *Algoritma Backpropagation Learning*

Backpropagation merupakan algoritma pembelajaran *neural network* dan biasanya digunakan oleh *perceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada lapisan tersembunyi

(Kusumadewi, 2004). Pembelajaran dari jaringan *backpropagation* terdiri dari tiga tahapan, yaitu menghitung arah maju dari pola input pembelajaran, menghitung *error backpropagation*, dan menentukan peubah bobot (Fausett, 1994).

Secara umum, bentuk arsitektur FFNN adalah sebagai berikut:



Gambar 1. Arsitektur *Backpropagation*.

Gambar 1 menunjukkan arsitektur *backpropagation* dengan satu *hidden layer*, n neuron input, p neuron di *hidden layer*, dan m neuron *output*. Fungsi aktivasi merupakan suatu fungsi yang digunakan untuk membandingkan antara hasil penjumlahan nilai-nilai semua bobot yang datang dengan suatu nilai ambang (*threshold*) tertentu pada tiap neuron (Kusumadewi, 2004).

Dalam *backpropagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat, yaitu:

1. Kontinu.
2. Terdiferensial dengan mudah.
3. Merupakan fungsi yang tidak turun.

Salah satu fungsi yang memenuhi ketiga syarat tersebut adalah fungsi sigmoid biner yang memiliki *range* (0,1).

$$f_1(x) = \frac{1}{1+e^{-x}} \quad (2.21)$$

Agar semua pola memiliki range yang sama seperti sigmoid yang dipakai, maka pola yang target nilainya lebih dari 1, pola masukan, dan keluaran harus ditransformasi lebih dulu. Algoritma pembelajaran *backpropagation* ini terdiri dari tiga proses antara lain *feed forward*, *backpropagation*, serta *update* bobot dan bias (Fausett, 1994) yang akan dijelaskan secara terperinci sebagai berikut:

1. Inisialisasi bobot dengan bilangan acak kecil.
2. Ketika kondisi *stop* belum terpenuhi, dilakukan langkah sebagai berikut:

Untuk setiap pasang data dilakukan langkah i hingga vii.

Tahap *feed forward*

- i) Setiap unit input menerima sinyal dan meneruskannya ke *hidden layer*.
- ii) Hitung semua sinyal input terboboti di unit *hidden* ($Z_j, j = 1, 2, \dots, p$)

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.22)$$

Gunakan fungsi aktivasi untuk menghitung sinyal tersembunyi yang selanjutnya akan diteruskan menuju *output* unit. Fungsi aktivasi yang digunakan pada *hidden layer* adalah fungsi sigmoid biner dengan rumus

yang dapat dilihat pada Persamaan (2.21).

$$z_j = f(z_in_j) \quad (2.23)$$

iii) Hitung semua sinyal input terboboti pada unit *output* y.

$$y_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (2.24)$$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*. Fungsi aktivasi *output* yang digunakan adalah fungsi linier,

$$y_k = f(y_in_k) \quad (2.25)$$

Tahap *backpropagation*

iv) Hitung faktor δ unit *output* berdasarkan kesalahan setiap unit keluaran y.

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad (2.26)$$

Hitung suku perubahan bobot w_{jk} dengan laju percepatan α

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (2.27)$$

v) Setiap *hidden* unit z menjumlah input δ yang sudah berbobot

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (2.28)$$

Kalikan dengan turunan dari fungsi aktivasi untuk menghitung *error*nya

$$\delta_j = \delta_in_j f'(z_in_j) \quad (2.29)$$

Hitung suku perubahan bobot v_{ij}

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (2.30)$$

Tahap *update* bobot dan bias

vi) Hitung semua perubahan bobot. Perubahan bobot garis yang menuju ke unit *output*:

$$w_{jk} \text{baru} = w_{jk} \text{lama} + \Delta w_{jk} \quad (2.31)$$

Perubahan bobot yang menuju unit *hidden*

$$v_{ij}baru = v_{ij}lama + \Delta v_{ij} \quad (2.32)$$

vii) Uji kondisi *stop*

Jika kondisi stop telah terpenuhi, maka pelatihan jaringan dapat dihentikan. Untuk menentukan *stopping condition* terdapat 2 cara, yaitu:

- a) Membatasi iterasi yang dilakukan
- b) Membatasi *error*

2.7 Emas

Menurut penelitian emas merupakan instrumen investasi terbaik. Investasi emas ada 3 jenis, yaitu investasi dalam bentuk perhiasan, fisik dan *trading*. Emas adalah komoditi yang diperdagangkan diseluruh dunia sehingga harga emas dunia mengikuti perkembangan perekonomian dunia, namun nilai dari investasi emas dianggap tahan terhadap inflasi. Dalam melakukan portofolio investasi, banyak investor yang meletakkan emas sebagai sarana pelindung untung investasi mereka. Semakin besar permintaan dibandingkan penawaran, semakin tinggi harga, demikian juga sebaliknya. Harga transaksi dunia menggunakan dolar AS. Harga emas menembus rekor baru pada 2006-2008 salah satunya penyebabnya adalah rontoknya harga-harga saham dunia. Sehingga terdapat korelasi yang negatif antara harga emas dan harga saham.

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun akademik 2020/2021.

Bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu data historis harga emas dunia periode Januari 2015 sampai dengan Desember 2020 yang diperoleh dari laman <https://id.investing.com/>.

Pada proses analisis, data akan dibagi menjadi dua bagian yaitu data *training* untuk pembentukan model dan data *testing* untuk validasi dan pemilihan model terbaik. Untuk pembagiannya, data *training* mengambil 80% dari data aktual dan data *testing* mengambil 20% dari data aktual berdasarkan prinsip pareto. Pada prinsip Pareto dinyatakan bahwa untuk banyak kejadian, 80% dari efeknya disebabkan oleh 20% dari penyebabnya. Maka, dari data aktual diambil data periode Januari 2015 sampai dengan September 2019 digunakan sebagai data

training (in-sample) dan data periode Oktober 2019 sampai dengan Desember 2020 sebagai data *testing (out-of-sample)*.

3.3 Metode Penelitian

Tahapan yang dilakukan dalam penelitian ini meliputi pemodelan dengan model ARIMA dan FFNN. Berdasarkan model-model tersebut maka langkah-langkahnya akan dijabarkan sebagai berikut:

3.3.1 Pemodelan dengan Metode ARIMA

Pemodelan dengan metode ARIMA dilakukan untuk harga emas dunia, selanjutnya dilakukan pengujian melalui prosedur Box-Jenkins. Langkah-langkah yang dilakukan sebagai berikut:

1. Mengambil data *time series* emas dunia dan membagi data emas dunia kedalam *in-sample* dan *out-of-sample*.
2. Membuat plot *time series*, plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data emas dunia.
3. Memeriksa kestasioneran data berdasarkan plot *time series*, plot ACF dan plot PACF. Untuk stasioneritas terhadap varian dilakukan dengan transformasi Box-Cox dan untuk stasioneritas terhadap mean dilakukan dengan uji Augmented Dickey-Fuller. Apabila data tidak stasioner, dapat dilakukan diferensiasi pada data.

4. Apabila stasioner dalam rata-rata dan ragam telah tercapai, selanjutnya adalah identifikasi model berdasarkan plot ACF dan PACF.
5. Mengestimasi parameter model ARIMA (p,d,q).
6. Memeriksa kecukupan model melalui uji Ljung-Box untuk asumsi *white-noise* serta uji Kolmogorov-Smirnov untuk mengetahui apakah residual berdistribusi normal atau tidak.
7. Menghitung RMSE untuk data *in-sample* dan data *out-of-sample*.

3.3.2 Pemodelan dengan Metode FFNN

1. Mendapatkan model terbaik dari ARIMA.
2. Membagi data emas dunia kedalam *in-sample* dan *out-of-sample*.
3. Menentukan variabel input untuk pemodelan *Feed Forward Neural Network* berdasarkan *lag* yang signifikan pada model.
4. Menentukan fungsi aktivasi.
5. Pembelajaran jaringan untuk mendapatkan model FFNN.
6. Memilih model FFNN dengan jumlah terbaik dengan melihat nilai RMSE *in-sample* dan *out-of-sample*.

Uji kesesuaian jumlah neuron pada lapisan tersembunyi untuk memperoleh model FFNN terbaik dilakukan melalui tahapan:

1. Uji pemodelan FFNN dengan variasi jumlah neuron sebanyak 1 sampai dengan 10 neuron pada *hidden neuron*.

2. Analisis besaran nilai RMSE pada data *testing* sebagai dasar dalam pemilihan model FFNN terbaik.

Setelah dilakukan pemodelan untuk masing-masing model dan dihitung kriteria pemilihan model terbaik dari data *in-sample* dan *out-of-sample* untuk masing-masing model, selanjutnya dilakukan perbandingan kriteria pemilihan model yang dihasilkan. Model dengan RMSE (*Root Mean Square Error*) terkecil, dipilih sebagai model terbaik dalam peramalan harga emas dunia.

V. KESIMPULAN

Berdasarkan hasil analisis yang telah diperoleh maka didapat kesimpulan sebagai berikut:

1. Model ARIMA terbaik untuk meramalkan harga emas dunia adalah ARIMA (0,1,0) atau model *random walk*. Model tersebut dipilih karena memiliki plot ACF dan PACF yang sesuai serta seluruh parameternya telah signifikan serta asumsi residualnya telah terpenuhi.
2. Model FFNN terbaik untuk meramalkan harga emas dunia adalah FFNN (1;4;1) dengan variabel input yaitu z_{t-1} dengan nilai RMSE *in-sample* sebesar 41.96074 dan RMSE *out-of-sample* sebesar 257.0647.
3. Peramalan menggunakan metode *feed forward neural network* pada harga emas dunia menghasilkan peramalan yang lebih baik dari metode ARIMA. Dengan kata lain, metode peramalan *feed forward neural network* merupakan metode peramalan yang paling mendekati harga emas dunia.

DAFTAR PUSTAKA

- Cryer, J. D., dan Chan, K.S. 2008. *Time Series Analysis with Application in R*. 2nd Edition. Springer Science+Bussines Media, New York.
- Defusco, R.A., McLeavey, D.W., dan Pinto, J.E. 2007. *Quantitative Investment Analysis*. 2nd Edition. John Wiley & Sons, New Jersey.
- Fausett, L. 1994. *Fundamental of Neural Network : Architectures, algorithm and applications*. Prantice Hall, Hoboken.
- Gujarati, D.N. 2003. *Basic Econometrics*. 4th Edition. McGraw-Hill, New York.
- Hyndman, R.J. dan Athanosopoulos, G. 2013. *Forecasting Principles and Practice*. 2nd Edition. Monash University, Australia.
- Juanda, B. dan Junaidi. 2012. *Ekonometrika Deret Waktu Teori dan Aplikasi*. IPB Press, Bogor.
- Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan (Menggunakan MATLAB & Excel Link)*. Graha Ilmu, Yogyakarta.
- Makridakis, S., Wheelwright, S., dan Hyndman, R.J. 1998. *Forecasting: Methods and Applications*. 5th Edition. Wiley, New York.
- Soejoeti, Z. 1987. *Analisis Runtun Waktu*. Karunia Jakarta, Jakarta.
- Terasvirta, T., Lin, C.F., dan Granger, C.W.J. 1993. *Power of The Neural Network Linierity Test*. Blackwell Publishers, USA.

Tripathy, N. 2017. Forecasting Gold Price with Auto Regressive Integrated Moving Average Model. *International Journal of Economics and Financial Issue*. 7(4):324-329.

Wei, W.W.S. 2006. *Time Series Analysis : Univariate and Multivariate Methods*. 2nd Edition. Pearson Prentice Hall, New Jersey.

Zhang, G. P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 50:159-175.

Zhang, G.P. 2004. *Neural Network in Business Forecasting*. Idea Group, USA.