

**PERBANDINGAN METODE ARIMA-GARCH DAN *FUZZY*  
*TIME SERIES MARKOV CHAIN* DALAM PERAMALAN DATA  
HARGA MINYAK MENTAH DUNIA  
(Studi Kasus: Data Harga Minyak Mentah Dunia Tahun 2001-2017)**

**TUGAS AKHIR**



**Nur Fadlilah Nurul Hikmah**

**14 611 060**

**JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS ISLAM INDONESIA  
YOGYAKARTA  
2018**

**PERBANDINGAN METODE ARIMA-GARCH DAN *FUZZY*  
*TIME SERIES MARKOV CHAIN* DALAM PERAMALAN DATA  
HARGA MINYAK MENTAH DUNIA  
(Studi Kasus: Data Harga Minyak Mentah Dunia Tahun 2001-2017)**

**TUGAS AKHIR**

**Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana  
Jurusan Statistika**



**Nur Fadlilah Nurul Hikmah**

**14 611 060**

**JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS ISLAM INDONESIA  
YOGYAKARTA  
2018**

**HALAMAN PERSETUJUAN PEMBIMBING**

TUGAS AKHIR

**TUGAS AKHIR**

Judul : Perbandingan Metode ARIMA-GARCH dan *Fuzzy Time Series Markov-Chain* dalam Peramalan Data Minyak Mentah Dunia (Studi Kasus: Data Harga Minyak Mentah Dunia Tahun 2001-2017)

Nama Mahasiswa : Nur Fadlilah Nurul Hikmah

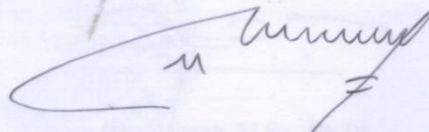
Nomor Mahasiswa : 14 611 060



**TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK  
DIUJIKAN**

Yogyakarta, 30 April 2018

**Pembimbing**

  
(Muhammad Muhajir S.Si., M.Sc.)

**HALAMAN PENGESAHAN  
TUGAS AKHIR**

**PERBANDINGAN METODE ARIMA-GARCH DAN FUZZY TIME  
SERIES MARKOV-CHAIN DALAM PERAMALAN DATA HARGA  
MINYAK MENTAH DUNIA**

(Studi Kasus: Data Harga Minyak Mentah Dunia Tahun 2001-2017)

Nama Mahasiswa: Nur Fadlilah Nurul Hikmah

Nomor Mahasiswa: 14 611 060

**TUGAS AKHIR INI TELAH DIUJIKAN  
PADA TANGGAL 8 MEI 2018**

Nama Penguji

Tanda Tangan

1. Ir. Ali Parkhan, M.T.

2. Dr. Jaka Nugraha, M.Si.

3. Muhammad Muhajir, S.Si., M.Sc

Mengetahui,

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



(Dr. Alwar, M.Sc., Ph.D)

## KATA PENGANTAR



Puji syukur penulis panjatkan kehadirat Allah SWT yang telah melimpahkan rahmat, hidayah, serta kasih sayang-Nya kepada penulis sehingga penulis diberikan kesehatan, kekuatan serta kesabaran selama menyelesaikan Tugas Akhir ini. Tak lupa pula shalawat dan salam penulis panjatkan kepada Nabi Muhammad SAW yang telah diutus ke bumi sebagai lentera bagi hati manusia, Nabi yang telah membawa manusia dari zaman kebodohan menuju zaman penuh dengan pengetahuan yang luar biasa seperti saat ini.

Laporan ini tersusun sebagai hasil akhir Tugas Akhir (TA) di Universitas Islam Indonesia Yogyakarta. Laporan yang berjudul **“Perbandingan Metode ARIMA-GARCH dan *Fuzzy Time Series Markov-Chain* dalam Peramalan Minyak Mentah Dunia”** dengan studi kasus Data Harga Minyak Mentah Dunia Tahun 2001-2017 ini disusun guna memenuhi persyaratan untuk memperoleh gelar sarjana di Jurusan Statistika Universitas Islam Indonesia, selain itu juga untuk memberikan pengetahuan kepada pemerintah dan masyarakat umum khususnya dalam menyikapi harga minyak mentah dan mengetahui perkembangan harga minyak mentah.

Selama penulis melaksanakan Tugas Akhir dan menyusun laporan, penulis telah banyak mendapat bimbingan dan bantuan dari berbagai pihak. Untuk itu pada kesempatan ini penulis bermaksud menyampaikan ucapan terimakasih yang tak terhingga kepada :

1. Bapak, Ibu, dan Kakak tercinta yang telah memberikan doa dan dukungan kepada penulis.
2. Bapak Drs. Allwar., M.Sc., Ph.D. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia beserta seluruh jajarannya.
3. Bapak Dr. RB. Fajriya Hakim, S.Si., M.Si. selaku Ketua Jurusan Statistika beserta seluruh jajarannya.

4. Bapak Muhammad Muhajir S.Si., M.Sc. yang telah membimbing penulis selama menyusun Laporan Tugas Akhir.
5. Dosen-dosen Statistika Universitas Islam Indonesia yang telah mendidik dan memberikan ilmu kepada penulis.
6. Sahabat-sahabat seperjuangan Avit, Emil, Evi, Ita, Indri, Kia, Kiki, Yulina, Woro yang selalu berbagi ilmu dan pengalaman.
7. Rekan-rekan Statistika 2014, Keluarga besar Ikatan Keluarga Statistika (IKS) yang telah memberikan motivasi, dukungan, dan semangat kepada penulis.
8. Semua pihak yang turut membantu penulis dalam penyusunan tugas akhir ini, penulis mengucapkan trimakasih.

Penulis menyadari bahwa laporan ini masih jauh dalam kesempurnaan, oleh karena itu kritik dan saran yang membangun sangat penulis harapkan demi kesempurnaan laporan ini. Akhir kata, penulis mohon maaf yang setulus-tulusnya apabila dalam penyusunan laporan ini terdapat banyak kesalahan. Semoga laporan ini dapat bermanfaat khususnya bagi penulis laporan ini dan pada umumnya bagi para pembaca.

*Wassalamu'alaikum wr. wb*

Yogyakarta, 30 April 2018

Penyusun

Nur Fadlilah Nurul Hikmah

## DAFTAR ISI

HALAMAN JUDUL .....	i
HALAMAN JUDUL .....	ii
HALAMAN PERSETUJUAN PEMBIMBING.....	iii
HALAMAN PENGESAHAN .....	iv
KATA PENGANTAR .....	v
DAFTAR ISI .....	vii
DAFTAR TABEL .....	ix
DAFTAR GAMBAR.....	xi
DAFTAR LAMPIRAN .....	xii
PERNYATAAN .....	xiii
INTISARI .....	xv
ABSTRACT .....	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah .....	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	5
1.5 Manfaat Penelitian.....	5
1.6 Sistematika Penulisan.....	5
BAB II TINJAUAN PUSTAKA .....	7
2.1 Minyak Mentah .....	7
2.2 ARIMA-GARCH .....	8
2.3 <i>Fuzzy Time Series Markov Chain</i> .....	9
BAB III LANDASAN TEORI .....	10
3.1 Minyak Mentah .....	10
3.2 <i>Time Series</i> (Runtun Waktu) .....	11
3.3 Stasioneritas.....	11
3.4 Uji Akar Unit Dickey-Fuller .....	12

3.5 <i>Differencing</i> .....	12
3.6 <i>Autocorrelation Function/ Fungsi Autokorelasi (ACF)</i> .....	13
3.7 <i>Partial Autocorrelation Function (PACF)</i> .....	16
3.8 Proses <i>White Noise</i> .....	17
3.9 Uji Normalitas Galat .....	19
3.10 Uji Homoskedastisitas Galat ( <i>error</i> ) .....	19
3.11 Uji Autokorelasi Galat.....	20
3.12 Metode Maksimum <i>Likelihood</i> .....	20
3.13 <i>Autoregressive Integrated Moving Average (ARIMA)</i> .....	21
3.14 Prosedur Pemodelan ARIMA.....	25
3.15 ARCH-GARCH.....	26
3.16 Fuzzy Time Series .....	27
3.17 Rantai Markov ( <i>Markov Chain</i> ) .....	30
3.18 Model <i>Fuzzy Time Series Markov-Chain</i> .....	32
3.19 Pengukuran Kesalahan Peramalan .....	34
BAB IV METODOLOGI PENELITIAN .....	36
4.1 Populasi dan Sampel Penelitian .....	36
4.2 Jenis dan Sumber Data .....	36
4.3 Variabel Penelitian .....	36
4.4 Metode Analisis Data .....	36
4.5 Tahapan Penelitian .....	37
BAB V PEMBAHASAN.....	39
5.1 Analisis Deskriptif.....	39
5.2 Peramalan ARIMA-GARCH .....	40
5.3 <i>Fuzzy Time Series Markov-Chain</i> .....	64
BAB VI PENUTUP .....	80
6.1 Kesimpulan.....	80
6.2 Saran .....	80
DAFTAR PUSTAKA .....	82
LAMPIRAN	



## DAFTAR TABEL

No	Judul	Halaman
4.1	Nama Variabel dan Definisi Operasional Variabel	36
5.1	Analisis Deskriptif Harga Minyak Mentah	39
5.2	Hasil Uji ADF Sebelum Transformasi	42
5.3	Hasil Uji ADF Setelah Transformasi	43
5.4	Hasil Uji Kecocokan Model ARIMA (1,1,2)	44
5.5	Hasil Uji Kecocokan Model ARIMA (1,1,1)	45
5.6	Hasil Uji Kecocokan Model ARIMA (1,1,0)	46
5.7	Hasil Uji Kecocokan Model ARIMA (0,1,2)	47
5.8	Hasil Uji Kecocokan Model ARIMA (0,1,1)	48
5.9	Hasil Estimasi Parameter ARIMA	48
5.10	Nilai Statistik <i>Ljung-Box</i> ARIMA (1,1,0)	50
5.11	Nilai <i>Jarque Bera Test</i> ARIMA (1,1,0)	52
5.12	Nilai Statistik <i>Ljung-Box</i> ARIMA (0,1,2)	54
5.13	Nilai <i>Jarque Bera Test</i> ARIMA (0,1,2)	55
5.14	Nilai Statistik <i>Ljung-Box</i> ARIMA (0,1,1)	57
5.15	Nilai <i>Jarque Bera Test</i> ARIMA (0,1,1)	59
5.16	Hasil Uji Diagnostik	60
5.17	<i>AIC</i> dan <i>BIC</i>	61
5.18	Hasil Estimasi GARCH (2,1)	61
5.19	Hasil Estimasi GARCH (1,1)	62
5.20	Hasil Estimasi GARCH (1,0)	62
5.21	Hasil Estimasi Model GARCH (p,q)	62
5.22	Uji Diagnostik Model ARIMA (1,1,0)-GARCH (1,0)	63
5.23	Pembagian Semesta	65
5.24	Data <i>Fuzzyfikasi</i>	66
5.25	<i>Fuzzy Logical Relation</i> (FLR)	69

5.26	<i>Fuzzy Logical Relation Group (FLRG)</i>	72
5.27	Hasil Peramalan Awal	74
5.28	Hasil Peramalan Akhir	77

## DAFTAR GAMBAR

No	Judul	Halaman
1.1	Grafik Harga Minyak Mentah Tahun 2014-2017	1
3.1	Kurva Penolakan dan Penerimaan $H_0$	15
4.1	Tahapan Penelitian ARIMA-GARCH	37
4.2	Tahapan Penelitian <i>Fuzzy Time Series Markov-Chain</i>	38
5.1	Grafik Harga Minyak Mentah	40
5.2	Plot Data Runtun Waktu	41
5.3	ACF dan PACF Data	41
5.4	ACF dan PACF Data Stasioner	44
5.5	ACF dan PACF Residual ARIMA (1,1,0)	50
5.6	ACF dan PACF <i>Squared</i> Residual ARIMA (1,1,0)	53
5.7	ACF dan PACF Residual ARIMA (0,1,2)	53
5.8	ACF dan PACF <i>Squared</i> Residual ARIMA (0,1,2)	56
5.9	ACF dan PACF Residual ARIMA (0,1,1)	57
5.10	ACF dan PACF <i>Squared</i> Residual ARIMA (0,1,1)	60
5.11	Proses Transisi Peramalan Berdasarkan FLRG	73
5.12	Plot Nilai Aktual dengan Hasil Peramalan	79

## **DAFTAR LAMPIRAN**

Lampiran 1. Data Bulanan Harga Minyak Mentah

PERBANDINGAN METODE **PERNYATAAN** DAN **FUZZY TIME**  
SERIES MARKOV CHAIN PADA PERAMALAN HARGA MINYAK

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu perguruan tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang dicantumkan dalam naskah ini dan diterbitkan dalam daftar pustaka.

Yogyakarta, 30 April 2018



Nur Fadlilah Nurul Hikmah

**PERBANDINGAN METODE ARIMA-GARCH DAN FUZZY TIME  
SERIES MARKOV CHAIN PADA PERAMALAN HARGA MINYAK  
MENTAH DUNIA**

(Studi Kasus: Data Harga Minyak Mentah Dunia Tahun 2001-2017)

Oleh: Nur Fadlilah Nurul Hikmah  
Program Studi Statistika Fakultas MIPA  
Universitas Islam Indonesia

*INTISARI*

*Minyak mentah merupakan salah satu komoditas yang diperdagangkan secara luas dan laris. Naik turunnya (fluktuasi) harga minyak diseluruh dunia dapat berdampak besar pada perekonomian negara baik negara produsen maupun konsumen. Peramalan dirasa penting pada data time series karena diperlukan dalam proses pengambilan keputusan seperti penyusunan APBN khususnya pada Indonesia untuk menyediakan subsidi rakyat. Perkembangan metode time series yang cukup pesat mengakibatkan terdapat banyak pilihan metode untuk meramalkan. Oleh karena itu perlu dilakukan perbandingan metode untuk memperoleh nilai kesalahan yang rendah yaitu model ARIMA-GARCH dan Fuzzy Time Series Markov-Chain. Model ARIMA-GARCH merupakan model penggabungan dari model ARIMA dan GARCH yang digunakan untuk menangani terjadinya heteroskedastistik dalam variansi residual. Sedangkan Fuzzy Time Series Markov Chain adalah model peramalan Fuzzy Time Series yang dikombinasikan dengan Markov Chain (Rantai Markov). Hasil dari analisis peramalan ARIMA-GARCH terdapat tiga asumsi yang harus dipenuhi namun terdapat asumsi klasik yang dilanggar yaitu tidak terpenuhinya asumsi no autokorelasi sedangkan yang terpenuhi adalah asumsi normalitas dan asumsi homoskedastisitas. Pada Fuzzy Time Series Markov Chain menunjukkan nilai kesalahan MAPE yang diperoleh sebesar 6,7%. Dapat dikatakan bahwa metode peramalan terbaik yang diperoleh adalah Fuzzy Time Series Markov Chain.*

**Kata Kunci:** *Minyak mentah, peramalan, ARIMA-GARCH, Fuzzy Time Series Markov Chain*

**COMPARISON A METHOD OF ARIMA-GARCH AND FUZZY TIME  
SERIES MARKOV CHAIN IN FORECASTING WORLD CRUDE OIL  
PRICE**

(Case Study: World Crude Oil Price Year 2001-2017)

By: Nur Fadlilah Nurul Hikmah

*Department of Statistics, Faculty of Mathematics and Science*

*Islamic University of Indonesia*

**ABSTRACT**

*Crude oil is one of the most widely and well traded commodities. The ups and downs (fluctuations) of oil prices around the world can have a major impact on the economy of the country for producer and consumer countries. Forecasting is important in time series data bcs it is needed for decision making process such as the preparation of the state budget, especially APBN preparation in Indonesia to provide subsidies for people. The rapid development of time series method resulted in many choices of methods for forecasting. Therefore, it is necessary compare the method to obtain a low error value that is ARIMA-GARCH model and Fuzzy time Series Markov-chain. the ARIMA-GARCH model is a merging model of the ARIMA and GARCH models used to deal with the occurrence of heteroscedasticity in residual variation. while the Fuzzy time Series Markov-chain is a Fuzzy time Series forecasting model combined with Markov-chain. The result of ARIMA GARCH method there are three assumptions that must be fulfilled but there is a classic assumption which broken that is not fulfilled assumption no autocorrelation while that is fulfilled is assumption of normality and assumption homoskedastisitas. In Fuzzy time Series Markov-chain shows the value of MAPE error obtained by 6.7%. It can be said that the best forecasting method obtained is the Markov-chain Fuzzy time Series.*

**Keyword:** *Crude Oil, forecasting, ARIMA-GARCH, Fuzzy Time series Markov-Chain*

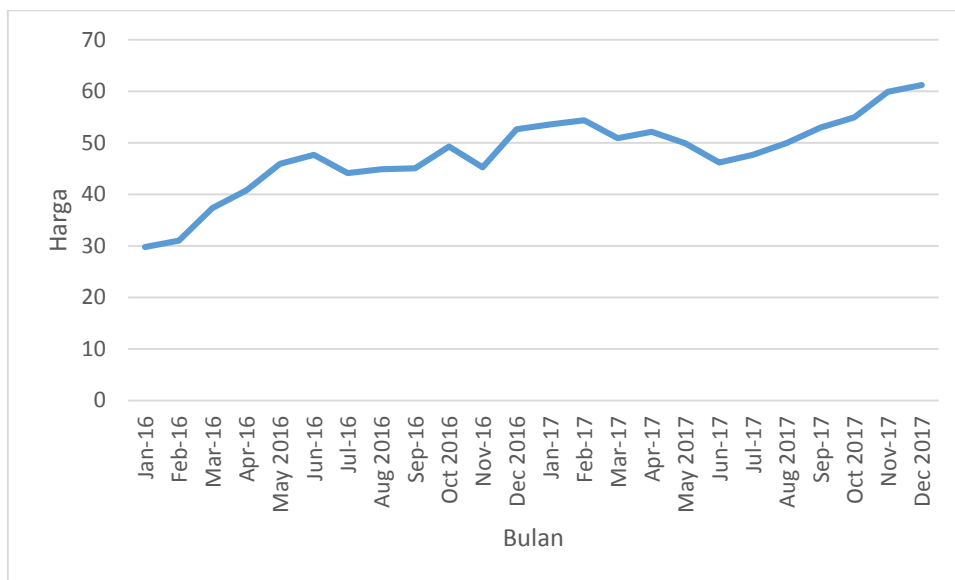
# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Minyak mentah adalah bahan bakar fosil yang terdapat di bumi dan berasal dari tumbuhan atau hewan fosil selama jutaan tahun. Minyak mentah diproduksi menjadi berbagai produk minyak bumi diantaranya yaitu bensin atau gasolin. Minyak merupakan salah satu komoditas yang diperdagangkan secara luas dan laris. Naik turunnya (fluktuasi) harga minyak diseluruh dunia dapat berdampak besar pada perekonomian negara baik negara produsen maupun konsumen. Terlebih kepada negara pengimpor minyak tentunya lebih rentan terhadap perubahan harga minyak dikarenakan minyak dihargai dalam dolar.

Harga minyak mentah dunia mengalami penurunan pada akhir tahun 2014 dari US\$100 per barel hingga US\$40 per barel pada tahun 2016 dan mulai naik pada tahun 2017.



**Gambar 1.1.** Grafik Harga Minyak Mentah Tahun 2016-2017

Sumber: Harga Komoditi (data diolah)



Penurunan harga komoditas minyak di pasar internasional menyebabkan ketidakstabilan perekonomian termasuk di Indonesia. Secara umum terdapat tiga penyebab penurunan harga minyak mentah yaitu:

1. Pasokan Berlebih

Penambahan produksi minyak (*shale oil*) oleh Amerika Serikat yang berusaha menjadi eksportir minyak di dunia. Pada tahun 2014 OPEC (*Organization of the Petroleum Exporting Countries*) atau organisasi negara pengeksportir minyak bumi tidak menyeimbangkan pasar namun malah terus menambah produksi minyak. Semakin banyaknya stok minyak di dunia maka harga minyak semakin menurun.

2. Permintaan Menurun

Perlambatan ekonomi di China membuat harga komoditas dunia menurun termasuk minyak mentah. Sementara di negara yang perekonomiannya membaik seperti Amerika sedang mengimplementasikan standar efisiensi agar permintaan minyak dibatasi. Tingginya teknologi serta sikap masyarakat yang sadar akan bahaya penggunaan minyak membuat permintaan minyak global menurun.

3. Kenaikan Nilai Dolar Amerika

Minyak mentah dihargai dengan satuan dolar Amerika. Akibatnya, ketika nilai dolar naik maka harga minyakpun naik dan membuat permintaan minyak dipasar global menurun. (May, 2017)

Sedangkan pada tahun 2016 harga minyak mentah mulai mengalami kenaikan. Hal tersebut dikarenakan perusahaan energi Amerika Serikat memangkas delapan sumur pengeboran minyak dan jumlah sumur pengeboran turun menjadi 729 buah. Pada tahun tersebut pasar terus mencari dukungan untuk mendorong kenaikan harga minyak hingga bulan Desember 2017 mencapai 61,19 US\$. (Gideon, 2017)

Semakin naiknya harga minyak mentah didukung oleh jumlah penduduk yang semakin banyak. Dengan semakin banyaknya jumlah penduduk maka permintaan minyakpun semakin banyak. Sebagai contoh pada negara Indonesia, Indonesia merupakan salah satu negara yang kaya akan hasil minyak buminya. Namun pada

kenyataannya Indonesia sudah menjadi negara pengimpor minyak karena banyaknya permintaan minyak. Pada tahun 2016 kebutuhan minyak di Indonesia setara dengan 1,6 juta *barrel* per hari namun produksi dalam negeri hanya sekitar 831 ribu barel perhari. Kenyataannya, permintaan minyak mentah masih tinggi namun ketersediaannya terbatas yang menuntut negara harus melakukan impor minyak.

Minyak yang diimpor sebagai bahan baku untuk menghasilkan energi memiliki harga yang cukup mahal dan tidak sepadan dengan kemampuan ekonomi rakyat Indonesia sehingga diperlukan subsidi agar dapat diterapkan di Indonesia. Kenaikan harga minyak bumi menyebabkan beberapa dampak diantaranya yaitu mendorong tingkat inflasi dan kegiatan ekonomi. Harga minyak yang berubah-ubah digambarkan oleh grafik harga minyak yang mengalami fluktuasi. Permasalahan yang terjadi yaitu BBM dalam negeri tidak dapat dengan mudah mengikuti perubahan harga minyak dunia. Akibatnya, pemerintah perlu melakukan revisi terhadap APBN setiap terjadi kenaikan harga minyak agar tetap dapat menyediakan subsidi untuk rakyat. Salah satu alat yang digunakan untuk mengatasi hal tersebut yaitu dengan analisis peramalan. Teknik peramalan adalah suatu teknik yang digunakan untuk memperkirakan yang akan terjadi pada masa yang akan datang. Terdapat beberapa metode peramalan yang dapat digunakan untuk meramalkan harga minyak mentah antara lain ARIMA dengan efek GARCH dan *Fuzzy Time Series Markov-Chain*.

ARIMA-GARCH digunakan untuk memprediksi data *time series* untuk periode jangka pendek. Metode ARIMA-GARCH menyaratkan asumsi-asumsi yang harus dipenuhi seperti asumsi normalitas, homoskedastisitas, dan no autokorelasi. Namun, pada kenyataannya tidak semua asumsi dapat terpenuhi sehingga pada saat ini telah berkembang metode-metode peramalan yang tidak menyaratkan asumsi tersebut. Salah satu metode yang tidak menggunakan asumsi yaitu *Fuzzy Time Series Markov-Chain*. Metode peramalan *Fuzzy Time Series Markov-Chain* dikembangkan oleh Tsaur. Penerapan metode runtun waktu *fuzzy* sederhana dan berdasarkan beberapa penelitian membuktikan bahwa metode *Fuzzy*

*Time Series Markov-Chain* memiliki tingkat kesalahan yang rendah dibandingkan dengan metode *fuzzy time series* lainnya.

Berdasarkan latar belakang tersebut, penelitian berjudul “Perbandingan Metode ARIMA-GARCH dan *Fuzzy Time Series Markov Chain* dalam Peramalan Harga Minyak Mentah Dunia” dengan studi kasus data harga minyak mentah tahun 2001-2017 dilaksanakan dengan harapan agar dapat diketahui perkiraan perubahan harga minyak mentah setiap bulannya. Hasil peramalan tersebut dapat digunakan juga sebagai acuan bagi para ahli yang memikirkan strategi dan bahan pengganti minyak sebagai bahan bakar mengingat semakin banyaknya permintaan minyak mentah. Selain itu, dapat juga digunakan sebagai wawasan agar penulis dan masyarakat pada umumnya untuk mengetahui perkembangan harga minyak mentah yang sangat berpengaruh dengan perekonomian di negara.

## **1.2 Rumusan Masalah**

Berdasarkan penjelasan latar belakang, maka rumusan masalah yang dapat diidentifikasi dalam penelitian ini sebagai berikut:

1. Bagaimana gambaran umum mengenai harga minyak mentah?
2. Bagaimana hasil peramalan minyak mentah menggunakan metode ARIMA-GARCH dan metode *Fuzzy Time Series Markov Chain*?
3. Metode apakah yang terbaik digunakan untuk meramalkan harga minyak mentah?

## **1.3 Batasan Masalah**

Batasan masalah diperlukan untuk menghindari adanya penyimpangan. Batasan-batasan pada penelitian ini sebagai berikut:

1. Penelitian ini fokus pada peramalan harga minyak mentah dengan menggunakan data bulanan tahun 2001-2017.
2. Data yang digunakan yaitu data sekunder yang diperoleh dari data harga saham dengan variabel harga minyak mentah dalam US\$ per barel.
3. Metode yang digunakan adalah analisis deskriptif dan analisis peramalan (ARIMA-GARCH dan *Fuzzy Time Series Markov Chain*).
4. Data diolah menggunakan *software Microsoft Excel* dan R.

#### **1.4 Tujuan Penelitian**

Tujuan dari penelitian tugas akhir ini sebagai berikut:

1. Mengetahui gambaran umum mengenai harga minyak mentah.
2. Mengetahui hasil peramalan minyak mentah dengan menggunakan metode ARIMA-GARCH dan metode *Fuzzy Time Series Markov-Chain*.
3. Mengetahui metode terbaik yang digunakan untuk meramalkan minyak mentah.

#### **1.5 Manfaat Penelitian**

Manfaat yang diperoleh dari penelitian ini adalah sebagai berikut:

1. Sebagai acuan untuk pihak pemerintah yang terkait di Indonesia untuk memilih strategi terbaik dalam mengelola dan menghadapi harga minyak dunia.
2. Menambah wawasan dan penerapan ilmu yang diperoleh tentang metode ARIMA-GARCH dan *Fuzzy Time Series Markov-Chain* dalam peramalan harga minyak mentah.

#### **1.6 Sistematika Penulisan**

##### **BAB I PENDAHULUAN**

Pada Bab I Pendahuluan ini menjelaskan latar belakang masalah, rumusan masalah, batasan masalah, jenis penelitian dan metode analisis, tujuan penelitian, manfaat penelitian, dan sistematika penulisan penelitian.

##### **BAB II TINJAUAN PUSTAKA**

Pada Bab II Tinjauan Pustaka ini menjelaskan tentang penelitian terdahulu yang berkaitan dengan analisis peramalan harga minyak mentah dunia.

##### **BAB III LANDASAN TEORI**

Pada Bab III Landasan Teori ini memaparkan kajian teoritis tentang harga minyak mentah dan analisis peramalan untuk menyelesaikan permasalahan dalam penelitian ini.

##### **BAB IV METODOLOGI PENELITIAN**

Pada Bab IV Metodologi Penelitian ini menjelaskan populasi penelitian, metode pengambilan data, variabel penelitian, metode analisis data, dan tahapan penelitian.

## BAB V HASIL DAN PEMBAHASAN

Pada Bab V Hasil dan Pembahasan ini menjelaskan tentang peramalan harga minyak mentah menggunakan analisis deskriptif dan meramalkan harga minyak mentah menggunakan analisis peramalan.

## BAB VI PENUTUP

Pada Bab VI Penutup ini mencakup hasil dari rumusan masalah yang berupa kesimpulan dan saran.

## **BAB II**

### **TINJAUAN PUSTAKA**

Pada penelitian ini digunakan beberapa penelitian terdahulu sebagai kajian untuk mengetahui keterkaitan antara penelitian terdahulu dengan penelitian yang akan dilakukan. Tujuan dari tinjauan pustaka ini adalah untuk menunjukkan bahwa penelitian yang dilakukan sangat bermanfaat bagi ilmu pengetahuan. Terdapat beberapa penelitian tentang minyak mentah, ARIMA-GARCH, dan *Fuzzy Time Series Markov-Chain* yang telah dilakukan oleh peneliti-peneliti sebelumnya yaitu sebagai berikut:

#### **2.1 Minyak Mentah**

Penelitian yang dilakukan oleh (Caraka & Yasin, 2014) dengan judul “Peramalan Harga Minyak Mentah Dunia dengan *General Regression Neural Network* (GRNN) dalam Rangka Mengukur Kestabilan Perekonomian Indonesia”. Penelitian ini menghasilkan pemodelan GRNN dengan nilai *Mean Square Error* (MSE) *training* sebesar 1.0033 dan MSE *testing* sebesar 2.2148. Berdasarkan hasil ramalan dengan metode GRNN didapatkan nilai ramalan harga minyak mentah dunia berkisaran di US\$80 per barel. Hal tersebut akan memberikan dampak yaitu mendorong tingkat inflasi dan kegiatan ekonomi.

Penelitian yang dilakukan oleh (Fauzannissa, Yasin, & Ispriyanti, 2015) dengan judul “Peramalan Harga Minyak Mentah Dunia Menggunakan Metode *Radial Basis Function Neural Network*”. Penelitian ini menghasilkan pemodelan dengan nilai MSE *training* sebesar 0,9141 dan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,74%. Sedangkan untuk *testing* diperoleh nilai MSE sebesar 4,2739 dan nilai MAPE sebesar 1,63%. Berdasarkan nilai ramalan yang didapatkan harga minyak mentah dunia diwaktu yang akan datang (2016) berkisar antara 55,91 US\$ per barel setiap harinya. Jika dirupiahkan menjadi Rp 754785,00 per barel.

Penelitian yang dilakukan oleh (Herawati & Djunaidy, 2014) dengan judul “Peramalan Harga Minyak Mentah Menggunakan Gabungan Metode *Ensemble Empirical Mode Decomposition* (EEMD) dan Jaringan Syaraf Tiruan (JST)”. Penelitian ini menghasilkan nilai *Root Mean Square Error* (RMSE) yang lebih kecil dan Dstat lebih tinggi untuk metode EEMD-JST dibandingkan metode EMD-JST. Nilai RMSE dan Dstat terbaik sebesar 0,0330 dan 65,3061%, sedangkan untuk jenis data minyak Brent dihasilkan RMSE dan Dstat terbaik sebesar 0,0433 dan 78,0488%.

## **2.2 ARIMA-GARCH**

Penelitian yang dilakukan oleh (Fanstina, Agoestanto, & Hendikawati, 2017) dengan judul “Model *Hybrid* ARIMA-GARCH Untuk Estimasi Volatilitas Harga Emas Menggunakan *Software R*”. Hasil dari penelitian tersebut diperoleh model terbaik untuk harga emas adalah *hybrid* ARIMA(2,1,3)-GARCH(1,1) dengan nilai MAPE = 2,2685% dan nilai *Mean Percentage Error* (MPE) = -0,01543. Berdasarkan model terbaik tersebut diperoleh hasil peramalan untuk periode Juni sampai Oktober 2016 berturut-turut adalah Rp524.722,5276; Rp522.404,5077; Rp501.819,4615; Rp501.514,1764; Rp505.704,409, yang menunjukkan bahwa harga emas pada bulan Juni sampai dengan September 2016 mengalami penurunan harga.

Penelitian yang dilakukan oleh (Larasati, Hendikawati, & Zaenuri, 2016) dengan judul “Analisis *Volatility Forecasting* Sembilan Bahan Pokok Menggunakan Metode GARCH dengan Program R”. Hasil dari penelitian tersebut model GARCH terbaik yang diperoleh yaitu GARCH (1,1) untuk kenaikan harga minyak, bawang, cabai, ayam dan tepung terigu, model GARCH (2,1) untuk harga beras, gula, susu, dan telur.

Penelitian yang dilakukan oleh (Pahlavani & Roshan, 2015) dengan judul “*The Comparison Among ARIMA and Hybrid ARIMA-GARCH Models in Forecasting the Exchange Rate of Iran*”. Hasil dari penelitian tersebut diperoleh model terbaik ARIMA((7.2),(12))-EGARCH (2,1) dengan nilai *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Theil Inequality Coefficient*

(TIC) terkecil. Model tersebut menangkap bahwa efek volatility dalam nilai tukar adalah model yang baik untuk meramalkan.

### **2.3 Fuzzy Time Series Markov Chain**

Penelitian yang dilakukan oleh (Nurkhasanah, Suparti, & Sudarno, 2015) dengan judul “Perbandingan Metode Runtun Waktu *Fuzzy-Chain* dan *Fuzzy-Markov Chain* Untuk Meramalkan Data Inflasi di Indonesia”. Hasil dari penelitian tersebut yaitu pada metode *fuzzy-chen* menghasilkan MSE sebesar 0,656 sedangkan metode *fuzzy-markov chain* menghasilkan MSE sebesar 0,216. Model runtun waktu *fuzzy-markov chain* menghasilkan kinerja yang bagus karena memiliki nilai MAPE dibawah 10% yaitu 6,610%.

Penelitian yang dilakukan oleh (Noh, Wijono, & Yudaningtyas, 2015) yang berjudul “Model *Average Based FTS Markov Chain* untuk Peramalan Penggunaan *Bandwidth* Jaringan Komputer”. Hasil dari penelitian tersebut yaitu peramalan menggunakan metode *average based FTS markov chain* memiliki nilai kesalahan peramalan lebih kecil jika dibandingkan menggunakan *average based FTS*.



## **BAB III**

### **LANDASAN TEORI**

#### **3.1 Minyak Mentah**

Minyak mentah adalah hasil dari penguraian materi tumbuhan dan hewan disuatu daerah yang turun secara perlahan. Daerah yang menghasilkan minyak bumi biasanya berupa laut, danau sepanjang pantai, dan rawa didaratan. Sedimen diendapkan dengan kecepatan pengendapan yang cukup cepat sehingga bagian materi organik dapat tersimpan dan tertimbun dengan baik sebelum pembusukan. Pada kondisi sirkulasi dan reduksi tertentu akumulasi hidrokarbon banyak ditemukan pada bagian air laut dalam.

Minyak mentah (*crude oil*) yang baru keluar dari sumur eksplorasi mengandung bermacam-macam zat kimia yang berbeda baik dalam bentuk cair, gas, ataupun padatan. Lebih dari 50-98% zat-zat kimia tersebut merupakan hidrokarbon dan sisanya merupakan senawa non-hidrokarbon seperti sulfur, nitrogen, oksigen, dan beberapa logam seperti V, Ni, dan Cu. Senyawa utama yang terkandung didalam minyak bumi adalah alifatik, alisiklik, dan aromatik. Minyak mentah adalah campuran yang kompleks dengan komponen utama alkana dan sebagian kecil alkuna, siklo-alkana, aromatik, dan senyawa anorganik. (Supriharyono, 2000)

Minyak mentah dapat dibedakan menjadi dua yaitu:

- a. Minyak mentah yang ringan (*light crude oil*), yaitu mengandung kadar logam dan belerang yang rendah, bersifat encer dan berwarna terang.
- b. Minyak mentah berat (*heavy crude oil*), yaitu mengandung kadar logam dan belerang tinggi, memiliki viskositas tinggi dan harus dipanaskan agar meleleh.

Minyak mentah didunia secara umum menggunakan satuan harga per barel. Satuan barel digunakan secara umum di benua Amerika (United States) dan Inggris (United Kingdom) atau benua Eropa. Penggunaan satuan barel untuk menyatakan satuan volume minyak bumi dimulai sekitar tahun 1860. Satu barel sama dengan

159 liter. Wadah yang biasa digunakan untuk minyak bumi adalah sejenis tong biru atau *blue barrel* sehingga sering disebut juga bbl.

### **3.2 Time Series (Runtun Waktu)**

*Time series* (runtun waktu) merupakan himpunan observasi data terurut dalam waktu. Metode *time series* adalah metode peramalan dengan menggunakan analisis pola hubungan antara variabel waktu dengan variabel yang akan dipikirkan. Peramalan data *time series* perlu memperhatikan tipe atau pola data. Secara umum terdapat empat macam pola data *time series*, yaitu horizontal, *trend*, musiman, dan siklis. Pola horizontal adalah kejadian yang tidak terduga dan bersifat acak, tetapi kemunculannya dapat memengaruhi fluktuasi data *time series*. Pola *trend* adalah kecenderungan arah data dalam jangka panjang, dapat berupa kenaikan maupun penurunan. Pola musiman adalah fluktuasi dari data yang terjadi secara periodik dalam kurun waktu satu tahun, seperti kuartalan, triwulan, bulanan, mingguan, atau harian. Sedangkan pola siklis adalah fluktuasi dari data untuk waktu yang lebih dari satu tahun. (Hanke & Wichern, 2005)

### **3.3 Stasioneritas**

Suatu data dikatakan stasioner jika tidak terjadi pertumbuhan, penurunan, dan pola data tersebut berada disekitar nilai rata-rata yang konstan dan variansi disekitar rata-rata tersebut konstan selama waktu tertentu. *Time series* dikatakan stasioner apabila rata-rata dan variansinya tetap, tidak ada unsur *trend* dalam data dan tidak ada unsur musiman.

Stasioner dapat dilihat dari plot *Autocorrelation Function* (ACF) data tersebut. Jika plot data *Autocorrelation Function* (ACF) turun mendekati nol secara cepat, maka pada umumnya setelah *lag* kedua atau ketiga maka dapat dikatakan stasioner. Data nonstasioner apabila terdapat unsur *trend* dalam data, ditandai dengan adanya kenaikan dan penurunan seiring bertambahnya periode waktu. Pada data nonstasioner yang memiliki *trend* akan memiliki nilai *Autocorrelation Function* (ACF) yang signifikan pada *lag-lag* awal kemudian mengecil secara bertahap. (Makridakis, 1988)

### 3.4 Uji Akar Unit Dickey-Fuller

Uji *Augmented Dickey Fuller* (ADF) merupakan salah satu uji yang sering digunakan dalam pengujian stasioneritas data, yaitu dengan melihat terdapat akar unit didalam model atau tidak dalam persamaan sebagai berikut:

$$X_t = \alpha + \delta_t + \rho X_{t-1} + \sum_{j=1}^k \phi_j X_{t-j} + e_t \quad (3.1)$$

Dengan:

$X_t$  = nilai variabel X pada waktu ke-t

$\alpha, \delta$  = parameter estimasi

$e_t$  = *white noise error*

Dimana:

$$\rho = \sum_{j=1}^k \alpha_j - 1 \text{ dan } \phi_j = \sum_{i=1}^k \alpha_i$$

Pengujian dilakukan dengan menguji hipotesis sebagai berikut:

- Hipotesis

$H_0$ : Terdapat akar unit dalam data ( $\rho = 0$ )

$H_1$ : Tidak terdapat akar unit dalam data ( $\rho < 0$ )

- Daerah Kritis

$H_0$  ditolak jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$

- Statistik Uji

$$t = \frac{\hat{\rho} - \rho}{se(\hat{\rho})}$$

dengan:

$\hat{\rho}$  = penaksir kuadrat terkecil dari  $\rho$

- Keputusan

Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$  maka tolak  $H_0$ , artinya data tidak terdapat akar unit (stasioner).

Jika  $t_{hit} < t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} > \alpha$  maka gagal tolak

$H_0$ , artinya data terdapat akar unit (tidak stasioner). (Rosadi, 2011)

### 3.5 Differencing

*Differencing* (pembedaan) dilakukan untuk menstasionerkan data yang belum stasioner. Operator *shift* mundur (*backward shift*) sangat tepat untuk

menggambarkan proses *differencing*. Penggunaan *backward shift* adalah sebagai berikut: (Makridakis, 1988)

$$BX_t = X_{t-1} \quad (3.2)$$

Dengan:

- $X_t$  = nilai variabel  $X$  pada waktu ke- $t$
- $X_{t-1}$  = nilai variabel  $X$  pada waktu ke  $t - 1$
- $B$  = *backward shift*

Notasi  $B$  pada  $X$  dapat menggeser data satu waktu kebelakang. Sebagai contoh, jika suatu data *time series* tidak stasioner maka data tersebut dibuat mendekati stasioner dengan melakukan *differencing* orde pertama dari data. Rumus untuk *differencing* orde pertama sebagai berikut:

$$X'_t = X_t - X_{t-1} \quad (3.3)$$

Dengan:

$X'_t$  = nilai variabel  $X$  pada waktu  $t$  setelah *differencing*

Sehingga persamaan (3.2) menggunakan *backward shift* dapat ditulis sebagai berikut:

$$X'_t = X_t - BX_t \quad (3.4)$$

Atau

$$X'_t = (1 - B)X_t \quad (3.5)$$

Penurunan (*differencing*) pertama pada persamaan (3.3) dinyatakan oleh  $(1-B)$ . (Makridakis, 1988)

### 3.6 Autocorrelation Function/ Fungsi Autokorelasi (ACF)

Koefisien autokorelasi runtun waktu dengan selisih waktu (*lag*) 0,1,2 periode atau lebih, autokorelasi menghitung dan membuat plot nilai autokorelasi dari suatu data runtun waktu (*time series*). Untuk menghitung koefisien korelasi antar dua variabel  $X$  dan  $Y$  yang dinotasikan sebagai  $r_{xy}$  untu  $n$  pasangan observasi  $(X_i, Y_i)$ ,  $i = 1,2,3,\dots,n$  digunakan rumus sebagai berikut:

$$r_{xy} = \frac{Cov_{xy}}{\sqrt{Cov_{xx}Cov_{yy}}} = \frac{Cov_{xy}}{S_x S_y} \quad (3.6)$$

Dengan:

$r_{xy}$  = korelasi antara variabel acak  $X$  dan variabel acak  $Y$

$Cov_{xy}$  = kovariansi variabel acak X dan variabel acak Y

$S_x$  = standar deviasi variabel acak X

$S_y$  = standar deviasi variabel acak Y

Autokorelasi adalah korelasi antara suatu variabel dengan variabel tersebut dengan lag 1, 2, 3 periode atau lebih misalnya  $X_t$  dan  $X_{t-1}$ . Koefisien autokorelasi untuk lag 1, 2, 3,...,k dengan banyak pengamatan  $n$ , dapat dicari dengan menggunakan rumus  $r_{xy}$ . Data  $X_t$  diasumsikan stasioner, jadi kedua nilai tengah  $X_t$  dan  $X_{t-k}$  dapat diasumsikan bernilai sama dan dua nilai variansi atau standar deviasi dapat diukur satu kali menggunakan seluruh data  $X_t$  yang diketahui, sebagai berikut: (Makridakis, 1988)

$$r_k = \frac{Cov(X_t, X_{t-1})}{S_{x_t} S_{x_{t-1}}}$$

$$r_k = \frac{\sum_{t=2}^n (X_t - \bar{X}_t)(X_{t-1} - \bar{X}_{t-1})}{\sqrt{\sum_{t=1}^n (X_t - \bar{X}_t)^2} \sqrt{\sum_{t=2}^n (X_{t-1} - \bar{X}_{t-1})^2}}$$

$$r_k = \frac{\sum_{t=2}^n (X_t - \bar{X})(X_{t-1} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2}$$

Dengan asumsi-asumsi tersebut, dapat disederhanakan menjadi seperti berikut:

$$r_k = \frac{\sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (3.7)$$

Dengan:

$r_k$  = koefisien autokorelasi pada lag-k,  $j = 0, 1, 2, \dots, k$

$k$  = selisih waktu

$n$  = jumlah data

$\bar{x}$  = rata-rata dari pengamatan  $\{z_t\}$

$x_t$  = nilai pengamatan waktu ke- $t$

$x_{t+k}$  = pengamatan waktu ke  $t + k$ ,  $k = 1, 2, 3, \dots$

Untuk mengetahui koefisien autokorelasi signifikan atau tidak, perlu dilakukan uji. Pengujian dapat dilakukan hipotesis sebagai berikut:

i. Hipotesis

$H_0$ : koefisien autokorelasi tidak signifikan ( $\rho_k = 0$ )

$H_1$ : koefisien autokorelasi signifikan ( $\rho_k \neq 0$ )

ii. Tingkat Signifikansi

$$\alpha = 5\% \text{ atau } 0,05$$

iii. Statistika Uji

$$t = \frac{r_k}{SEr_k} \tag{3.8}$$

$$\text{Dengan } SE = \frac{1}{\sqrt{n}}$$

iv. Daerah Kritis

$H_0$  ditolak jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$

v. Keputusan


Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$  maka tolak  $H_0$  yang berarti koefisien autokorelasi signifikan.

Jika  $t_{hit} < t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} > \alpha$  maka gagal tolak

$H_0$  yang berarti koefisien autokorelasi tidak signifikan. (Makridakis, 1988)

*P-value* merupakan besarnya peluang melakukan kesalahan apabila akan memutuskan untuk menolak  $H_0$ . *P-value* lebih sering digunakan untuk mengambil keputusan karena *p-value* memberikan dua informasi sekaligus yaitu petunjuk  $H_0$  ditolak atau gagal tolak dan memberikan informasi mengenai peluang terjadinya kejadian yang disebutkan didalam  $H_0$  ( $H_0$  dianggap benar).

Basis hitung *p-value* dari distribusi t adalah t tabel, jadi dalam pengambilan keputusan kesimpulannya sudah pasti sama. Peneliti menggambarkan kurva penolakan/ penerimaan hipotesis sebagai berikut:



**Gambar 3.1.** Kurva Penolakan dan Penerimaan  $H_0$

Berdasarkan nilai  $t_{hit}$  dan t tabel dapat ditentukan wilayah penerimaan atau penolakan  $H_0$  (pada  $\alpha = 5\%$ , *2-tailed*). Tidak ada perbedaan pengambilan kesimpulan melalui *t-value* maupun *p-value*.

Selain menggunakan uji tersebut, untuk mengetahui apakah koefisien autokorelasi yang diperoleh signifikan atau tidak dapat dilihat pada grafik *ACF* residual. Jika pada grafik *ACF* tidak ada *lag* yang melebihi garis batas signifikansi (garis putus-putus), maka koefisien autokorelasi yang diperoleh signifikan atau tidak terjadi korelasi antar *lag*.

### 3.7 Partial Autocorrelation Function/ Fungsi Autokorelasi Parsial (PACF)

Fungsi autokorelasi parsial (PACF) adalah himpunan autokorelasi parsial untuk berbagai *lag* yang ditulis dengan  $(\varphi_{kk}; j = 1, 2, 3, \dots, k)$  yaitu himpunan autokorelasi parsial untuk berbagai *lag*  $k$  fungsi autokorelasi parsial digunakan untuk mengatur tingkat keeratan antara  $X_t$  dan  $X_{t-k}$ , apabila pengaruh dari selisih waktu 1, 2, 3, ..., k-1 dianggap terpisah. Didefinisikan sebagai berikut:

$$\varphi_{kk} = \frac{\rho_{\sim k}^*}{\rho_{\sim k}} \quad (3.9)$$

Dengan:

$\rho_{\sim k}$  adalah matrik autokorelasi k x k

$\rho_{\sim k}^*$  adalah  $\rho_{\sim k}$  adalah kolom terakhir diganti dengan  $\begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix}$  sehingga diperoleh

$$\varphi_{11} = \rho_1$$

$$\varphi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$

$$\varphi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

⋮

$$\varphi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_{k-3} & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_{k-3} & 1 \end{vmatrix}} \quad (3.10)$$

Nilai estimasi  $\varphi_{kk}$  dapat diperoleh dengan mengamati  $\rho_i$  dengan  $r_i$  untuk selisih waktu yang cukup besar, fungsi autokorelasi parsial menjadi kecil (tidak signifikan berbeda dengan nol), Quenouille memberikan rumus variansi  $\varphi_{kk}$  sebagai berikut:

$$\text{Var}(\varphi_{kk}) \approx \frac{1}{N} \quad (3.11)$$

Untuk  $N$  sangat besar,  $\varphi_{kk}$  dapat dianggap mendekati distribusi normal.

Karena  $\varphi_{kk}$  adalah fungsi atas  $k$ , maka  $\varphi_{kk}$  disebut fungsi autokorelasi parsial. Pengujian hipotesis untuk menguji koefisien autokorelasi parsial adalah sebagai berikut:

i. Hipotesis

$H_0$ : koefisien autokorelasi parsial tidak signifikan ( $\varphi_{kk} = 0$ )

$H_1$ : koefisien autokorelasi parsial signifikan ( $\varphi_{kk} \neq 0$ )

ii. Tingkat Signifikansi

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

iii. Statistika Uji

$$t = \frac{\varphi_{kk}}{SE(\varphi_{kk})} \quad (3.12)$$

Dengan  $SE(\varphi_{kk}) = \frac{1}{\sqrt{n}}$

iv. Daerah Kritis

$H_0$  ditolak jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas  $(n-1)$  atau  $p\text{-value} < \alpha$

v. Keputusan

Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas  $(n-1)$  atau  $p\text{-value} < \alpha$  maka tolak  $H_0$  yang berarti koefisien autokorelasi parsial signifikan.

Jika  $t_{hit} < t_{\frac{\alpha}{2}}$  dengan derajat bebas  $(n-1)$  atau  $p\text{-value} > \alpha$  maka tolak  $H_0$  yang berarti koefisien autokorelasi parsial signifikan. (Makridakis, 1988)

### 3.8 Proses *White Noise*

Terjadi *white noise* ( $e_t$ ) ketika barisan variabel acak yang berkorelasi dengan rata-rata  $E(e_t) = 0$ , varians konstan  $\text{var}(e_t) = \sigma_e^2$ . Oleh karena itu, suatu proses *white noise* adalah stasioner dengan fungsi autokovariansi.



$$\gamma_k \begin{cases} \sigma_t^2, & \text{jika } j = 0 \\ 0, & \text{jika } j \neq 0 \end{cases} \quad (3.13)$$

Fungsi autokorelasi

$$\rho_k \begin{cases} 1, & \text{jika } j = 0 \\ 0, & \text{jika } j \neq 0 \end{cases} \quad (3.14)$$

Fungsi autokorelasi parsial

$$\varphi_{kk} \begin{cases} 1, & \text{jika } j = 0 \\ 0, & \text{jika } j \neq 0 \end{cases} \quad (3.15)$$

Pada pengujian *white noise* digunakan pengujian *Ljung Box* untuk menguji keacakan pada setiap *lag* yang berbeda berdasarkan jumlah kelambatan. Uji *Ljung Box* dikenal sebagai uji *Ljung Box Q* dan terkait erat dengan uji *Box Pierce*. Uji *white noise* menggunakan statistik *chi-square* dengan hipotesis untuk menguji koefisien autokorelasi parsial adalah sebagai berikut: (Box & Pierce, 1970)

i. Hipotesis

$H_0$ : Residu memenuhi proses *white noise* ( $\rho_1 = \rho_2 = \rho_3 = \dots = \rho_k = 0$ )

$H_1$ : Residu tidak memenuhi proses *white noise* ( $\exists \rho_j \neq 0, j = 1, 2, \dots, k$ )

ii. Tingkat Signifikansi

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

iii. Statistika Uji

$$Q_k = n(n+2) \sum_{k=1}^j \frac{r_k^2}{n-k} \quad (3.16)$$

Dengan:

$n$  = banyaknya observasi dalam runtun waktu

$k$  = banyaknya *lag* yang diuji

$r_k$  = nilai koefisien autokorelasi pada *lag-k*

iv. Daerah Kritis

$H_0$  ditolak jika  $Q > X_{\alpha}^2$  dengan derajat bebas =  $(r-1)(c-1)$  atau  $p\text{-value} < \alpha$

v. Keputusan

Jika  $Q > X_{\alpha}^2$  dengan derajat bebas =  $(r-1)(c-1)$  atau  $p\text{-value} < \alpha$  maka tolak  $H_0$  yang berarti residu tidak memenuhi proses *white noise*.

Jika  $Q < X_{\alpha}^2$  dengan derajat bebas =  $(r-1)(c-1)$  atau  $p\text{-value} > \alpha$  maka gagal tolak  $H_0$  yang berarti residu memenuhi proses *white noise*.

Selain itu, autokorelasi residual dapat dilihat dari plot *ACF* residual. Apabila tidak ada *lag* yang keluar dari garis signifikansi, maka dapat dikatakan bahwa tidak ada autokorelasi.

### 3.9 Uji Normalitas Galat

Uji normalitas residual digunakan untuk mengetahui galat berdistribusi normal atau tidak. Pengujian dapat dilakukan dengan analisis grafik *normal probability plot* atau dengan menggunakan *jarque bera test*. Jika residu berada disekitar garis diagonal maka galat berdistribusi normal. Sebaliknya, jika residu tidak berdistribusi normal, maka residu akan menyebar. Untuk uji asumsi digunakan uji hipotesis sebagai berikut:

i. Hipotesis

$H_0$ : Residual berdistribusi normal

$H_1$ : Residual tidak berdistribusi normal

ii. Tingkat Signifikansi

$\alpha = 5\%$

iii. Statistika Uji

*p-value*

iv. Daerah Kritis

$p\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Jika  $p\text{-value} < \alpha$  maka tolak  $H_0$  yang berarti residual tidak berdistribusi normal.

Jika  $p\text{-value} > \alpha$  maka gagal tolak  $H_0$  yang berarti residual berdistribusi normal.

(Rosadi, 2011)

### 3.10 Uji Homoskedastisitas Galat (*error*)

Uji homoskedastisitas bertujuan untuk menganalisis apakah variansi galat bersifat tetap/ konstan (homoskedastisitas) atau berubah-ubah (heteroskedastisitas). Deteksi adanya heteroskedastisitas dapat dilakukan secara grafis dengan melihat apakah terdapat pola nonacak dari plot residual atau residual kuadratis terhadap suatu variabel independen atau terhadap nilai tersuai (*fitted*) variabel dependen (dengan model yang diestimasi). (Rosadi, 2011)

### 3.11 Uji Autokorelasi Galat

Asumsi autokorelasi galat menandakan residual bersifat independen satu dengan lainnya. Untuk uji asumsi autokorelasi digunakan uji hipotesis sebagai berikut:

H<sub>0</sub>: Tidak terdapat korelasi serial pada residual

H<sub>1</sub>: Terdapat korelasi serial pada residual

Untuk model runtun waktu, korelasi serial diuji dengan uji Portmanteau Q-Ljung-Box terhadap residual. (Rosadi, 2011)

### 3.12 Metode Maksimum *Likelihood*

Untuk mengestimasi harga parameter dari suatu data runtun waktu maka digunakan metode maksimum *likelihood*, untuk mendapatkan metode maksimum *likelihood* akan di berikan definisi fungsi *likelihood* sebagai berikut: (Bain & M.Engelhardt, 1992)

#### Definisi 3.12.1

Fungsi densitas bersama dari n variabel random  $X_1, X_2, \dots, X_k$  dengan nilai pengamatan  $x_1, x_2, \dots, x_n$  dinotasikan dengan  $f(x_1, x_2, \dots, x_k, \theta)$  dan disebut fungsi *likelihood*. Untuk  $x_1, x_2, \dots, x_k$  tetap adalah fungsi dari  $\theta$  dan dinotasikan  $L(\theta)$ . Jika  $X_1, X_2, \dots, X_k$  adalah sampel random dari fungsi densitas  $f(x_j; \theta)$  maka fungsi *likelihood*nya sebagai berikut:

$$L(\theta) = f(x_1; \theta) f(x_2; \theta) \dots f(x_k; \theta) = \prod_{j=1}^n f(x_j; \theta) \quad (3.17)$$

#### Definisi 3.12.2

Misalkan  $L(\theta) = f(x_1; \theta) f(x_2; \theta) \dots f(x_k; \theta) = f(x_j; \theta), \theta \in \Omega$  adalah fungsi densitas bersama  $X_1, X_2, \dots, X_k$ . Bila diberikan himpunan dari pengamatan  $x_1, x_2, \dots, x_k$ , nilai  $\hat{\theta}$  dalam  $\Omega$  yang memaksimumkan  $L(\theta)$  disebut penduga maksimum *likelihood* dari  $\theta$ . Dalam definisi ini  $\hat{\theta}$  adalah nilai dari  $\theta$  yang memenuhi  $f(x_1, \dots, x_k, \hat{\theta}) = \max_{\theta \in \Omega} f(x_1, \dots, x_k, \theta)$

Penduga maksimum *likelihood* untuk  $\theta$  dapat dicari dengan menyelesaikan persamaan  $\frac{d}{d\theta} \ln L(\theta) = 0$ . Sebagai contoh, terdapat  $k$  parameter yang tidak

diketahui, maka pendugaan parameter *likelihood* dari  $\theta_i$  didapat dengan menyelesaikan  $\frac{d}{d\theta_j} \ln L(\theta_1, \theta_2, \dots, \theta_k) = 0$  dengan  $j = 1, 2, \dots, k$ .

### 3.13 Autoregressive Integrated Moving Average (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) adalah model *Autoregressive Moving Average* (ARMA) tidak stasioner yang telah dilakukan *differencing* sehingga menjadi model stasioner. Terdapat beberapa model ARIMA yang dapat digunakan pada data *time series*, yaitu:

#### 3.13.1 Model Autoregressive (AR)

*Autoregressive* (AR) adalah nilai sekarang suatu proses dinyatakan sebagai jumlah tertimbang nilai-nilai yang lalu ditambah nilai guncangan random. Model AR dengan orde  $p$  dinotasikan dengan AR( $p$ ). Bentuk umum dari model AR( $p$ ) sebagai berikut:

$$X_t = \varphi_1 X_{t-1} + k + \varphi_p X_{t-p} + e_t \quad (3.18)$$

Dengan:

$X_t$  = nilai variabel pada waktu ke- $t$

$\varphi_i$  = koefisien *autoregressive*,  $i: 1, 2, 3, \dots, p$

$e_t$  = nilai galat pada waktu ke- $t$

$p$  = order AR

Order AR yang sering digunakan adalah  $p=1$  (AR(1)) atau  $p=2$  (AR(1) atau AR(2)).

#### a. Model AR(1)

Bentuk umum model AR(1) adalah sebagai berikut:

$$X_t = \varphi_1 X_{t-1} + e_t \quad (3.19)$$

Dengan:

$X_t$  = nilai variabel pada waktu ke- $t$

$\varphi_1$  = koefisien *autoregressive* ke-1

$e_t$  = nilai galat pada waktu ke- $t$

#### b. Model AR(2)

Bentuk umum dari model AR(1) adalah sebagai berikut:

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + e_t \quad (3.20)$$

Dengan:

$X_t$  = nilai variabel pada waktu ke-t

$\varphi_i$  = koefisien *autoregressive*,  $i= 1, 2, 3, \dots, p$

$e_t$  = nilai galat pada waktu ke-t

Kurva fungsi autokorelasi akan turun secara eksponensial atau membentuk gelombang sinus. Autokorelasi parsial akan nol setelah *lag p* atau kurva akan terputus setelah suku ke-p untuk setiap proses. Kurva estimasi akan dipandang sebagai himpunan parameter-parameter terakhir yang diperoleh jika berturut-turut model AR(p),  $i=1,2,\dots,p$  yang digunakan pada data. Pengujian koefisien regresi pada parameter AR adalah sebagai berikut:

- Hipotesis

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

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

- Tingkat Signifikansi

$\alpha = 5\%$

- Daerah Kritis

$H_0$  ditolak jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau *p-value*  $< \alpha$

- Statistik Uji

$$t_{hit} = \frac{\hat{\varphi}}{setdev(\varphi)}$$

- Keputusan

Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) maka  $H_0$  ditolak, artinya parameter AR signifikan dalam model.

Jika  $t_{hit} < t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) maka  $H_0$  gagal ditolak, artinya parameter AR tidak signifikan dalam model.

### 3.13.2 Model *Moving Average* (MA)

*Moving Average* (MA) adalah nilai *time series* pada waktu  $t$  yang dipengaruhi oleh unsur kesalahan pada saat ini dan unsur kesalahan terbobot pada masa lalu (Makridakis, 1988).

Model *Moving Average* (MA) order  $q$ , dinotasikan menjadi MA( $q$ ). Secara umum, model MA( $q$ ) sebagai berikut:

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.21)$$

Dengan:

- $X_t$  = nilai variabel pada waktu ke- $t$
- $\theta_1$  = parameter model *moving average* (MA)
- $e_t$  = nilai galat pada waktu ke- $t$
- $e_{t-q}$  = nilai kesalahan pada saat  $t-q$
- $q$  = order MA

Secara umum, order MA yang sering digunakan dalam analisis *time series* adalah  $q = 1$  atau  $q = 2$ , yaitu MA(1) dan MA(2). Model *Moving Average* order 1 atau MA(1) secara matematis didefinisikan sebagai berikut:

$$X_t = e_t - \theta_1 e_{t-1} \quad (3.22)$$

Dengan:

- $X_t$  = nilai variabel pada waktu ke- $t$
- $\theta_1$  = parameter model MA
- $e_t$  = nilai galat pada waktu ke- $t$
- $e_{t-1}$  = nilai kesalahan pada saat  $t-1$

Model *Moving Average* order 2 atau MA(2) secara matematis didefinisikan sebagai berikut:

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \quad (3.23)$$

Dengan:

- $X_t$  = nilai variabel pada waktu ke- $t$
- $\theta_1$  = parameter model MA
- $e_t$  = nilai galat pada waktu ke- $t$
- $e_{t-p}$  = nilai kesalahan pada saat  $t-p$

Autokorelasi akan nol setelah *lag*  $q$ , dan kurva fungsi autokorelasi parsial akan turun secara eksponensial atau membentuk gelombang sinus. Pengujian koefisien regresi pada parameter MA adalah sebagai berikut:

- Hipotesis  
 $H_0$ : parameter AR tidak signifikan dalam model ( $\theta = 0$ )  
 $H_1$ : parameter AR signifikan dalam model ( $\theta \neq 0$ )
- Tingkat Signifikansi  
 $\alpha = 5\%$
- Daerah Kritis  
 $H_0$  ditolak jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$
- Statistik Uji  

$$t_{hit} = \frac{\hat{\theta}}{setdev(\theta)}$$
- Keputusan  
 Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$  maka  $H_0$  ditolak, artinya parameter MA signifikan dalam model.  
 Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} > \alpha$  maka  $H_0$  gagal ditolak, artinya parameter MA tidak signifikan dalam model.

### 3.13.3 Model *Autoregressive Moving Average* (ARMA)(p,q)

Model *Autoregressive Moving Average* (ARMA) adalah gabungan model AR(p) dan MA(q). Bentuk umum dari model ARMA(p,q) adalah sebagai berikut:

$$X_t = \varphi_1 X_{t-1} + \dots + \varphi_p X_{t-p} - e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (3.24)$$

Dengan:

- $X_t$  = nilai variabel pada waktu ke-t
- $\varphi_i$  = koefisien *autoregressive* ke-i,  $i = 1, 2, 3, \dots, p$
- $p$  = order AR
- $q$  = order MA
- $\theta_i$  = parameter model MA ke-i,  $i = 1, 2, 3, \dots, q$
- $e_t$  = nilai galat pada waktu ke-t

#### Estimasi parameter model ARMA (p,q)

Estimasi parameter model ARMA(p,q) dilakukan menggunakan metode maksimum *likelihood*. Fungsi *likelihood* untuk model ARMA(p,q) sebagai berikut:

$$\log f(y_t, \dots, y_{p+1} | y_p, \dots, y_1, \varepsilon_p = 0, \dots, \varepsilon_{p-q+1} = 0) = -\frac{T-p}{2} \log(2\pi) - \frac{T-p}{2} \log(\sigma^2) - \sum_{t=p}^T \frac{\varepsilon_t^2}{2\sigma^2} \quad (3.25)$$

Dengan:

$$\varepsilon_t = y_t - c - \varphi_1 Y_{t-1} - \varphi_2 Y_{t-2} - \dots - \varphi_{2p} Y_{t-p} - \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

### 3.14 Prosedur Pemodelan ARIMA

#### 3.14.1 Identifikasi Model

Langkah awal dalam pembentukan model *Autoregressive Integrated Moving Average* (ARIMA) adalah membentuk plot data *time series*. Plot data *time series* dibentuk bertujuan untuk mendeteksi stasioneritas data *time series*. Jika pola data tersebut berada disekitar nilai rata-rata dan variansi yang konstan selama waktu tertentu maka dikatakan stasioner.

#### 3.14.2 Menentukan Orde AR dan MA

Setelah data dinyatakan stasioner, langkah selanjutnya adalah menentukan orde *Autoregressive* (AR) yang sesuai. Hal ini dapat dilakukan dengan cara melihat plot ACF dan PACF dari data tersebut. Plot *Autocorrelation Function* (ACF) dan *Partial Autoregressive Function* (PACF) akan *cut off* setelah proses pada orde ke- $p$  atau *lag-p*. Pemilihan model yang tepat dilakukan dengan mengidentifikasi orde AR dan MA.

#### 3.14.3 Estimasi Parameter

Ketika data sudah stasioner maka langkah selanjutnya adalah mengestimasi parameter model. Metode yang digunakan untuk mengestimasi parameter AR yaitu metode kuadrat terkecil (*least square method*).

#### 3.14.4 Uji Signifikansi Parameter

Uji signifikansi parameter model pada parameter *autoregressive* (AR) sebagai berikut:

- i. Hipotesis
  - $H_0$ : parameter  $\varphi$  tidak signifikan dalam model ( $\varphi = 0$ )
  - $H_1$ : parameter  $\varphi$  signifikan dalam model ( $\varphi \neq 0$ )
- ii. Tingkat Signifikansi
  - $\alpha = 5\%$  atau  $0,05$



iii. Statistika Uji

$$t = \frac{\varphi}{SE(\varphi)} \quad (3.26)$$

iv. Daerah Kritis

$H_0$  ditolak jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$ .

v. Keputusan

Jika  $t_{hit} > t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} < \alpha$  maka tolak  $H_0$  yang berarti parameter  $\varphi$  signifikan dalam model.

Jika  $t_{hit} < t_{\frac{\alpha}{2}}$  dengan derajat bebas (n-1) atau  $p\text{-value} > \alpha$  maka gagal tolak

$H_0$  yang berarti parameter  $\varphi$  tidak signifikan dalam model.

### 3.15 ARCH-GARCH

Metode ARCH (*Autoregressive Conditional Heteroskedasticity*) pertama kali diperkenalkan oleh Engle (1982) yang dikembangkan untuk menjawab persoalan adanya volatilitas pada data keuangan. Selanjutnya metode ini dikembangkan menjadi GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*) oleh Bollerslev pada tahun 1986. Model GARCH adalah suatu model runtun waktu yang dapat digunakan untuk menggambarkan sifat dinamik fungsi volatilitas dari data. Model GARCH orde (p,q) menyatakan baha variansi dari  $y_t$  kondisional terhadap informasi masa lalu dan akan mengikuti bentuk

$$var(y_t | \mathfrak{E}_{t-1}) = E(\varepsilon_t^2 | \mathfrak{E}_{t-1}) = \sigma_t^2 \quad (3.27)$$

Dengan

$$\sigma_t^2 = \omega + \sum_{j=1}^p \alpha_j \varepsilon_{t-j}^2 + \sum_{i=1}^q \beta_i \sigma_{t-i}^2 \quad (3.28)$$

Jika q=0 maka memiliki model ARCH Engle, jika p=q=0 maka memiliki model *white noise* dengan variansi  $\omega$ . Dalam model GARCH (p,q) proses  $\varepsilon_t$  dinyatakan sebagai berikut:

$$\varepsilon_t = \sqrt{\sigma_t} v_t$$

$\sigma_t$  adalah akar dari  $\sigma_t^2$  dan  $v_t$  adalah proses i.i.d (*independent and identically distributed*) sering diasumsikan berdistribusi normal standar  $N(0,1)$ . Koefisien model GARCH (p,q) bersifat seperti berikut:

1.  $\omega > 0$
2.  $\alpha_i \geq 0$  untuk  $i= 1,2,\dots,p$
3.  $\beta_j \geq 0$  untuk  $j= 1,2,\dots,q$
4.  $\sum_{j=1}^p \sum_{i=1}^q (\alpha_i + \beta_j) < 1$

Kondisi 4 diperlukan agar model bersifat stasioner sedangkan kondisi 1, 2, 3 diperlukan agar  $\sigma_t^2 > 0$ . (Rosadi, 2011)

Kelebihan model GARCH dibandingkan dengan metode *time series* yang lain sebagai berikut:

1. Model ini tidak memandang adanya heteroskedastisitas sebagai suatu masalah, namun justru memanfaatkannya untuk membuat model.
2. Model ini tidak hanya menghasilkan peramalan dari variabel Y, tapi juga peramalan dari varians.

### 3.16 Fuzzy Time Series

*Fuzzy Time Series* dikenalkan pertama kali oleh Song dan Chissom pada tahun 1993. Jika U adalah himpunan semesta, maka  $U = \{u_1, u_2, \dots, u_n\}$ , maka suatu himpunan A dari U dapat didefinisikan sebagai berikut:

$$A_i = \frac{f_{A_i}(u_1)}{u_1} + \frac{f_{A_i}(u_2)}{u_2} + \dots + \frac{f_{A_i}(u_n)}{u_n} \quad (3.29)$$

Dengan:

$f_{A_i}$  = fungsi keanggotaan dari himpunan  $A_i$

$u_k$  = elemen dari himpunan  $A_i$

$f_{A_i}(u_k)$  = derajat keanggotaan dari  $u_k$  pada  $A_i, k = 1,2,3, \dots, n$

#### Definisi 3.16.1

Himpunan semesta  $Y(t) (t = \dots, 0,1,2, \dots, n)$  adalah subset dari R yang didefinisikan dengan himpunan  $A_i$ . Jika  $F(t)$  terdiri dari  $A_i (i = 1,2, \dots, n)$  maka  $F(t)$  didefinisikan sebagai FTS pada  $Y(t) (t = \dots, 0,1,2, \dots, n)$ .

#### Definisi 3.16.2

Seandainya  $F(t)$  disebabkan oleh  $F(t - 1)$ , maka dari orde pertama dari  $F(t)$  dapat ditulis sebagai  $F(t) = F(t - 1) \circ R(t, t - 1)$ .

Dengan:

$R(t, t - 1)$  = matriks relasi untuk menggambarkan hubungan *fuzzy* antara  $F(t - 1)$  dan  $F(t)$

◦ = operator komposisi maksimum- minimum

### Definisi 3.16.3

Seandainya  $F(t) = A_i$  disebabkan oleh  $F(t - 1) = A_j$ , maka *Fuzzy Logical Relationship* (FLR) didefinisikan sebagai  $A_i \rightarrow A_j$ .

### Definisi 3.16.4

Ketika terdapat FLR yang diperoleh dari *state*  $A_2$  maka selanjutnya transisi dibuat ke *state* yang lain  $A_j$  dengan  $j = 1, 2, \dots, n$  seperti  $A_2 \rightarrow A_3, A_2 \rightarrow A_2, A_2 \rightarrow A_1$ . Oleh karena itu, *fuzzy logical relation* (FLR) dikelompokkan menjadi *fuzzy logical relationship group* (FLRG).

$$A_2 \rightarrow A_1, A_2, A_3$$

Berikut adalah langkah-langkah untuk menyelesaikan model *Fuzzy Time Series*:

### Langkah 1

Mendefinisikan himpunan semesta  $U$ , dengan  $U$  adalah data historis. Ketika mendefinisikan himpunan semesta, diperoleh data minimum dan data maksimum dari data historis yang diberikan lalu didefinisikan sebagai  $D_{min}$  dan  $D_{maks}$ . Dari  $D_{min}$  dan  $D_{maks}$  didefinisikan himpunan semesta  $U$  seperti  $[D_{min} - D_1; D_{maks} + D_2]$  dengan  $D_1$  dan  $D_2$  merupakan bilangan positif yang sesuai.

### Langkah 2

Himpunan semesta  $U$  dibagi menjadi beberapa bagian dengan interval ( $n$ ) yang sama dengan menggunakan rumus *sturges* sebagai berikut:

$$n = 1 + 3,3 \log N \quad (3.30)$$

Dengan:

$N$  = jumlah data historis.

Panjang interval dapat didefinisikan dengan  $l$  sebagai berikut:

$$l = \frac{(D_{maks} + D_1) - (D_{min} - D_1)}{n} \quad (3.31)$$

Maka setiap interval diperoleh sebagai berikut:

$$\begin{aligned}
u_1 &= [D_{min} - D_1; D_{min} - D_1 + l] \\
u_2 &= [D_{min} - D_1 + l; D_{min} - D_1 + 2l] \\
&\vdots \\
u_n &= [D_{min} - D_1 + (n - 1)l; D_{min} - D_1 + nl]
\end{aligned}$$

### Langkah 3

Mentukan himpunan *fuzzy* untuk seluruh himpunan semesta  $U$ . Tidak terdapat batasan untuk menentukan banyaknya variabel linguistik yang dapat menjadi himpunan *fuzzy*. Setiap himpunan *fuzzy*  $A_i (i = 1, 2, \dots, n)$  didefinisikan dalam jumlah  $n$  interval yaitu  $u_1 = [d_1; d_2]$ ,  $u_2 = [d_2; d_3]$ ,  $u_3 = [d_3; d_4], \dots, u_n = [d_n; d_{n+1}]$ .

Seluruh himpunan *fuzzy* dapat ditentukan berdasarkan persamaan (3.31) dimana  $A_1, A_2, \dots, A_n$  didefinisikan sebagai berikut: (Boaisha & Amaitik, 2010)

$$\begin{aligned}
A_1 &= \left\{ \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \dots + \frac{0}{u_n} \right\} \\
A_2 &= \left\{ \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \dots + \frac{0}{u_n} \right\} \\
A_n &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \dots + \frac{0,5}{u_{n-1}} + \frac{1}{u_n} \right\}
\end{aligned}$$

Aturan untuk menentukan derajat keanggotaan  $u_i$  adalah sebagai berikut:

$$A_i = \sum_{j=1}^n \frac{\mu_{ij}}{u_{ij}}$$

dengan  $\mu_{ij}$  adalah derajat keanggotaan  $u_{ij}$  milik  $A_i$  yang ditentukan sebagai berikut:

$$\mu_{ij} = \begin{cases} 1 & ; i=j \\ 0,5 & ; j = i-1 \text{ atau } i = j-1 \\ 0 & ; \text{lainnya} \end{cases}$$

**Aturan a :** Jika data historis ( $Yt$ ) adalah  $u_i$ , maka derajat keanggotaan  $u_i$  adalah 1.  $u_{i+t}$  adalah 0,5 dan lainnya adalah 0.

**Aturan b :** Jika data historis ( $Yt$ ) adalah  $u_i, 1 < i < n$ , maka derajat keanggotaan  $u_i$  adalah 1.  $u_{i+t}$  adalah 0,5 dan lainnya adalah 0.

**Aturan c :** Jika data historis ( $Yt$ ) adalah  $u_n$ , maka derajat keanggotaan  $u_n$  adalah

1.  $u_{i+t}$  adalah 0,5 dan lainnya adalah 0.

**Langkah 4**

Melakukan *fuzzyfikasi* terhadap data historis. *Fuzzyfikasi* bertujuan untuk menemukan himpunan *fuzzy* yang sesuai untuk setiap data.

**Langkah 5**

- a. Menentukan *Fuzzy Logical Relationship* (FLR)
- b. Menentukan *Fuzzy Logical Relationship Group* (FLRG)

**Langkah 6**

Menghitung *output* yang akan diramalkan. Jika  $F(t - 1) = A_j$ , peramalan dari  $F(t)$  yaitu berlaku peraturan dasar berikut:

- a. Jika FLRG dari  $A_j$  adalah kosong  $A_j \rightarrow \emptyset$ , maka peramalan dari  $F(t)$  adalah  $m_j$ , yaitu titik tengah dari interval  $u_j$ :

$$F(t) = m_j \tag{3.32}$$

- b. Jika FLRG dari  $A_j$  adalah satu ke satu ( $A_j \rightarrow A_k, j, k = 1, 2, \dots, n$ ) maka peramalan  $F(t)$  adalah  $m_k$  yaitu titik tengah dari interval  $u_k$ .

$$F(t) = m_k \tag{3.33}$$

- c. Jika FLRG dari  $A_j$  adalah satu ke banyak  $A_j \rightarrow A_1, A_3, A_5, j = 1, 2, \dots, n$ , maka peramalan dari  $F(t)$  sama untuk perhitungan rata-rata dari  $m_1, m_3, m_5$ , titik tengah dari interval  $u_1, u_3, u_5$ :

$$F(t) = \frac{(m_1 + m_2 + \dots + m_n)}{n} \tag{3.34}$$

**3.17 Rantai Markov (*Markov Chain*)**

Rantai *markov* (*markov chain*) dikembangkan pertama kali oleh ahli Rusia pada tahun 1906 yaitu A. A. Markov. Rantai markov digambarkan dengan menganggap  $\{X_n, n = 0, 1, 2, \dots\}$  sebagai suatu proses stokastik berhingga atau nilai peluangnya yang dapat dihitung. Himpunan nilai peluang dari proses ini dinotasikan integer positif  $\{0, 1, 2, \dots\}$ . (Noh, Wijono, & Yudaningtyas, 2015)

Jika  $X_n = i$ , maka proses ini terjadi pada saat  $n$ . Dengan menganggap bahwa kapanpun proses ini terjadi di *state*  $i$ , terdapat sebuah titik peluang  $P_{ij}$  yang akan

berpindah ke *state j*. Persamaan dari pernyataan tersebut adalah sebagai berikut:  
(Haryono, Widodo, & Abusini, 2013)

$$P\{X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0\} = P_{ij} \quad (3.35)$$

Untuk semua *state*  $i_0, i_1, \dots, i_{n-1}$ ,  $i, j, n \geq 0$ . Proses tersebut disebut sebagai rantai *markov*.

Persamaan tersebut diinterpretasikan dalam rantai *markov* sebagai distribusi bersyarat dari *state* yang akan datang  $X_{n+1}$  yang diperoleh dari *state* sebelumnya  $X_0, X_1, \dots, X_{n-1}$  dan *state* saat ini  $X_n$ , dan tidak bergantung pada *state* sebelumnya tetapi bergantung pada *state* saat ini.

FRLG diperoleh ketika *state*  $A_i$  membuat transisi dengan *state*  $A_j$  dan melewati *state* lainnya  $A_k$ ,  $i, j = 1, 2, \dots, n$ . Penentuan FLRG merupakan pengeompokan dari setiap perpindahan *state*, yaitu *state* saat ini (*current state*) ke *state* selanjutnya (*next state*). Pada setiap FLRG terdapat hubungan antara dua *state* yang disebut dengan *current state* dan *next state*. *Current state* merupakan nilai yang akan dihitung sebagai nilai peramalan. *Next state* merupakan data yang digunakan sebagai syarat untuk memperoleh nilai pada *current state*.

Probabilitas tradisional untuk *state* tersebut ditulis sebagai berikut:

$$P_{ij} = \frac{M_{ij}}{M_i}, i, j = 1, 2, 3, \dots, n \quad (3.36)$$

Dengan:

$P_{ij}$  = probabilitas tradisional dari *state*  $A_i$  ke  $A_j$  dengan satu langkah

$M_{ij}$  = waktu tradisional dari *state*  $A_i$  ke  $A_j$  dengan satu langkah

$M_i$  = jumlah dari *state*  $A_i$

Sehingga matriks probabilitas tradisional R dapat ditulis sebagai berikut:

$$R = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix}$$

Berdasarkan matriks R tersebut didapatkan beberapa definisi yang dapat dikembangkan sebagai berikut:

**Definisi 3.17.1:** Ketika  $P_{ij} \geq 0$ , maka *state*  $A_j$  dapat diakses dari *state*  $A_i$ .

**Definisi 3.17.2:** Ketika *state*  $A_i$  dan  $A_j$  saling dapat diakses, maka  $A_i$  berkomunikasi dengan  $A_j$ .

### 3.18 Model Fuzzy Time Series Markov-Chain

Langkah-langkah peramalan 1-5 *Fuzzy Time Series Markov-Chain* sebagaimana disebutkan pada *fuzzy time series* diatas kemudian dilanjutkan untuk langkah ke-6 sebagai berikut: (Tsaur, 2012)

#### Langkah 6

Menghitung hasil peramalan awal. Menggunakan *Fuzzy Logical Relationship Group* (FLRG) yang informasinya dapat digunakan untuk mendapatkan probabilitas *state* selanjutnya sehingga didapatkan matriks transisi *markov*. *State n* didefinisikan untuk setiap langkah waktu himpunan *fuzzy n* dan diperoleh matriks transisi adalah  $n \times n$ .

Berikut adalah aturan-aturan dalam menentukan nilai hasil peramalan pada model *Fuzzy Time Series Markov-Chain*:

**Aturan 3.18.1:** Jika FLRG  $A_j$  adalah kosong ( $A_j \rightarrow \emptyset$ ) maka hasil peramalan  $F(t)$  adalah  $m_i$  yaitu nilai tengah dari  $u_i$  dengan persamaan sebagai berikut:

$$F(t) = m_i \quad (3.37)$$

**Aturan 3.18.2:** Jika FLRG  $A_i$  adalah satu ke satu ( $A_i \rightarrow A_k$  dengan  $P_{ij} = 0$  dan  $A_{ik} = 1, j \neq k$ ) maka hasil peramalan  $F(t)$  adalah  $m_k$  yaitu nilai tengah dari  $u_k$  dengan persamaan:

$$F(t) = m_k P_{ik} = m_k \quad (3.38)$$

**Aturan 3.18.3:** Jika FLRG  $A_j$  adalah satu ke banyak ( $A_j \rightarrow A_1, A_2, \dots, A_n, j = 1, 2, \dots, n$ ), jika kumpulan data  $Y_{(t-1)}$  pada saat  $t-1$  yang berrada pada *state*  $A_j$ , maka hasil peramalan  $F(t)$  adalah sebagai berikut:

$$F(t) = m_1 P_{j1} + m_2 P_{j2} + \dots + m_{j-1} P_{j(j-1)} + Y_{(t-1)} P_j + m_{j+1} P_{j(j+1)} + \dots + m_n P_{jn} \quad (3.39)$$

Dengan  $m_1, m_2, \dots, m_{j-1}, m_{j+1}, m_n$  merupakan titik tengah dari  $u_1, u_2, \dots, u_{j-1}, u_{j+1}, \dots, u_n$  dan  $m_j$  disubstitusikan ke  $Y_{(t-1)}$  agar diperoleh informasi *state*  $A_j$  saat  $t - 1$ .

## Langkah 7

Menyelesaikan kecenderungan nilai peramalan. Analisis *time series* membutuhkan sampel berukuran besar. Oleh karena itu, ketika menggunakan ukuran sampel yang kecil maka model *fuzzy time series markov chain* yang diperoleh adalah matriks *markov chain* yang bias, dan beberapa penyesuaian disarankan untuk meninjau kesalahan peramalan. Aturan penyesuaian untuk nilai peramalan adalah sebagai berikut:

**Aturan 3.18.4:** Jika *state*  $A_1$  berkomunikasi dengan  $A_1$  dimulai dari *state*  $A_1$  pada saat  $t - 1$  sebagaimana  $F(t - 1) = A_i$  dan terjadi perpindahan transisi naik ke *state*  $A_j$  pada saat  $t$ , ( $i < j$ ) maka nilai penyesuaian  $D_t$  ditentukan sebagai berikut:

$$D_{t1} = \left(\frac{1}{2}\right) \quad (3.40)$$

**Aturan 3.18.5:** Jika *state*  $A_1$  berkomunikasi dengan  $A_1$  dimulai dari *state*  $A_1$  pada saat  $t - 1$  sebagaimana  $F(t - 1) = A_i$  dan terjadi perpindahan transisi turun ke *state*  $A_j$  pada saat  $t$ , ( $i > j$ ) maka nilai penyesuaian  $D_t$  ditentukan sebagai berikut:

$$D_{t1} = -\left(\frac{1}{2}\right) \quad (3.41)$$

**Aturan 3.18.6:** Jika *state*  $A_i$  pada saat  $t - 1$  sebagaimana  $F(t - 1) = A_i$  dan terjadi perpindahan transisi maju ke *state*  $A_{i+s}$  pada saat  $t$ ,  $1 \leq s \leq n - 1$  maka nilai penyesuaian  $D_t$  ditentukan sebagai berikut:

$$D_{t2} = \left(\frac{1}{2}\right) s, (i \leq s \leq n - 1) \quad (3.42)$$

Dengan  $s$  adalah banyak perpindahan transisi maju.

**Aturan 3.18.7:** Jika *state*  $A_i$  pada saat  $t - 1$  sebagaimana  $F(t - 1) = A_i$  dan terjadi perpindahan transisi maju ke *state*  $A_{i+v}$  pada saat  $t$ ,  $1 \leq v \leq n - 1$  maka nilai penyesuaian  $D_t$  ditentukan sebagai berikut:

$$D_{t2} = -\left(\frac{1}{2}\right) v, (i \leq v \leq n - 1) \quad (3.43)$$

Dengan  $s$  adalah banyak perpindahan transisi mundur.



### Langkah 8

Menentukan hasil peramalan akhir. Ketika FLRG dari  $A_1$  adalah satu ke banyak dengan  $state A_{i+1}$  dapat diperoleh dari  $state A_i$  dimana  $state A_i$  berkomunikasi dengan  $A_i$ , penyesuaian hasil peramalan  $F'(t)$  dapat diperoleh sebagai berikut:

$$F'(t) = F(t) + D_{t1} + D_{t2} = F + \frac{l}{2} + \frac{l}{2} \quad (3.44)$$

Ketika FLRG dari  $A_1$  adalah satu ke banyak dengan  $state A_{i+1}$  dapat diperoleh dari  $state A_i$  tetapi  $state A_i$  tidak berkomunikasi dengan  $A_i$ , penyesuaian hasil peramalan  $F'(t)$  dapat diperoleh sebagai berikut:

$$F'(t) = F(t) + \frac{l}{2} \quad (3.45)$$

Ketika FLRG dari  $A_1$  adalah satu ke banyak dan  $state A_{i+2}$  dapat diperoleh dari  $state A_i$  tetapi  $state A_i$  tidak berkomunikasi dengan  $A_i$ , penyesuaian hasil peramalan  $F'(t)$  dapat diperoleh sebagai berikut:

$$F'(t) = F(t) - D_{t1} = F(t) - \left(\frac{l}{2}\right) \times 2 = F(t) - l \quad (3.46)$$

Sehingga diperoleh bentuk umum sebagai berikut:

$$F'(t) = F(t) \pm D_{t1} \pm D_{t2} = F(t) \pm \frac{l}{2} \pm \left(\frac{l}{2}\right) v \quad (3.47)$$

Dengan  $l$  merupakan rata-rata dari selisih interval yang berurutan dan  $v$  adalah perpindahan transisi. (Tsaur, 2012)

### 3.19 Pengukuran Kesalahan Peramalan

Pengukuran kesalahan peramalan dilakukan dengan membandingkan hasil peramalan dengan kenyataan yang terjadi. Teknik peramalan yang paling baik digunakan yaitu teknik peramalan yang menghasilkan penyimpangan terkecil. Berikut adalah ukuran kesalahan yang digunakan dalam penelitian ini sebagai berikut:

**Mean Absolute Error (MAE)** adalah rata-rata mutlak dari kesalahan meramal, tanpa menghiraukan tanda positif dan negatif dengan persamaan sebagai berikut:

$$MAE = \frac{\sum X_t - F_t}{n} \quad (3.48)$$

Dengan:

$X_t$  = Data aktual

$F_t$  = Data peramalan

$n$  = Jumlah data

Selain MAPE terdapat metode lain yaitu **Root Mean Squared Error (RMSE)** dengan persamaan sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (X_t - F_t)^2}{n}} \quad (3.49)$$

Dengan:

$X_t$  = Data aktual

$F_t$  = Data peramalan

$n$  = Jumlah data

**Mean Absolute Percentage Error (MAPE)** adalah rata-rata dari keseluruhan persentase kesalahan antara data aktual dengan data peramalan. Berikut adalah persamaan dari MAPE:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|X(t) - F(t)|}{X(t)} \times 100\% \quad (3.50)$$

Dengan:

$X_t$  = Data aktual

$F_t$  = Data peramalan

$n$  = Jumlah data

## BAB IV

### METODOLOGI PENELITIAN

#### 4.1 Populasi dan Sampel Penelitian

Populasi yang peneliti gunakan dalam penelitian adalah seluruh data harga minyak mentah dunia yang tercatat di harga saham. Sampel yang digunakan dalam penelitian ini adalah data bulanan harga minyak mentah perbarell dalam US\$ tahun 2001 sampai dengan tahun 2017.

#### 4.2 Jenis dan Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari data harga saham.

#### 4.3 Variabel Penelitian

Pada penelitian ini menggunakan variabel harga minyak mentah perbarell pada tahun 2001 sampai dengan 2017. Sehingga dapat dikatakan bahwa variabel yang digunakan yaitu:

**Tabel 4.1.** Nama Variabel dan Definisi Operasional Variabel

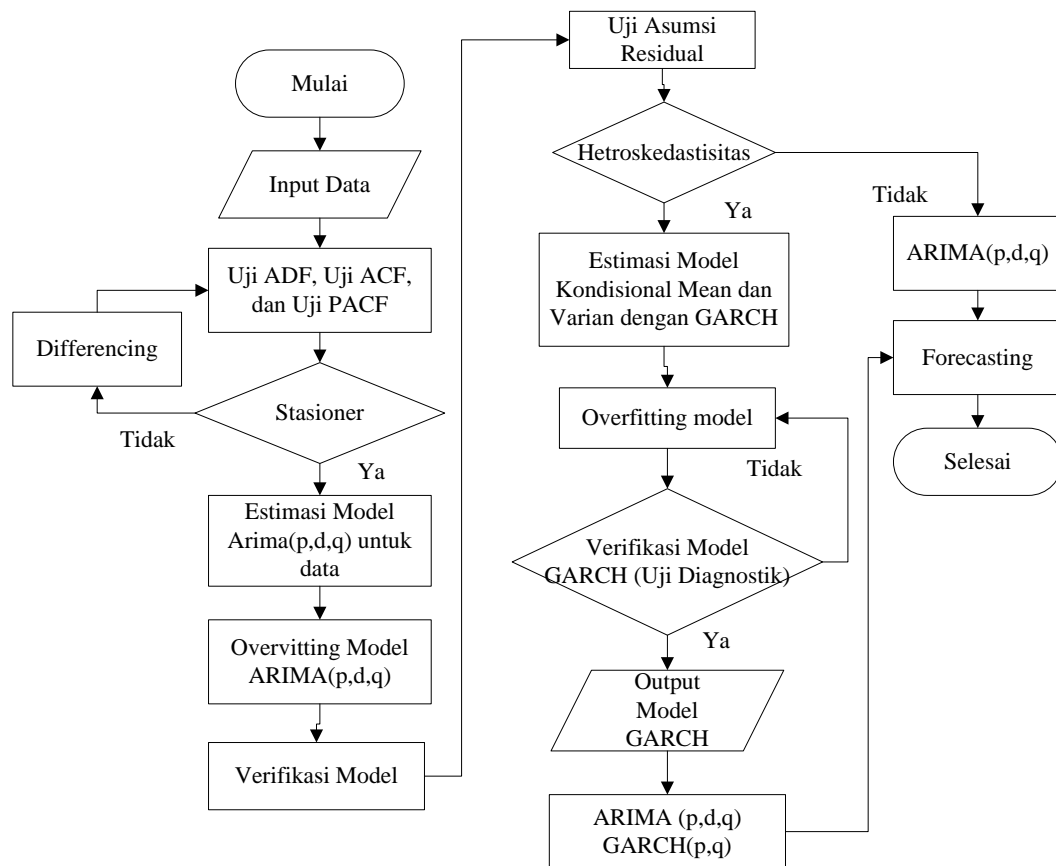
Variabel	Definisi Operasional Variabel
Harga Minyak Mentah	Harga minyak mentah merupakan harga rata-rata dari tiga harga spot yaitu: <i>Dated Brent</i> , <i>West Texas Intermediate</i> , dan <i>Dubai Fatch</i> yang dinyatakan dalam US\$ perbarell dan disajikan dalam data harga bulanan

#### 4.4 Metode Analisis Data

Metode analisis yang digunakan dalam penelitian ini yaitu analisis deskriptif yang berfungsi untuk melihat gambaran umum dari data bulanan harga minyak mentah dunia tahun 2001 sampai 2017 menggunakan *Microsoft Excel 2013*. Kemudian analisis peramalan ARIMA-GARCH dan *Fuzzy Time Series Markov*

Chain yang berfungsi untuk mengetahui peramalan harga minyak mentah dunia tahun 2018 yang disajikan dalam peramalan bulanan menggunakan data tahun 2001 sampai dengan 2017.

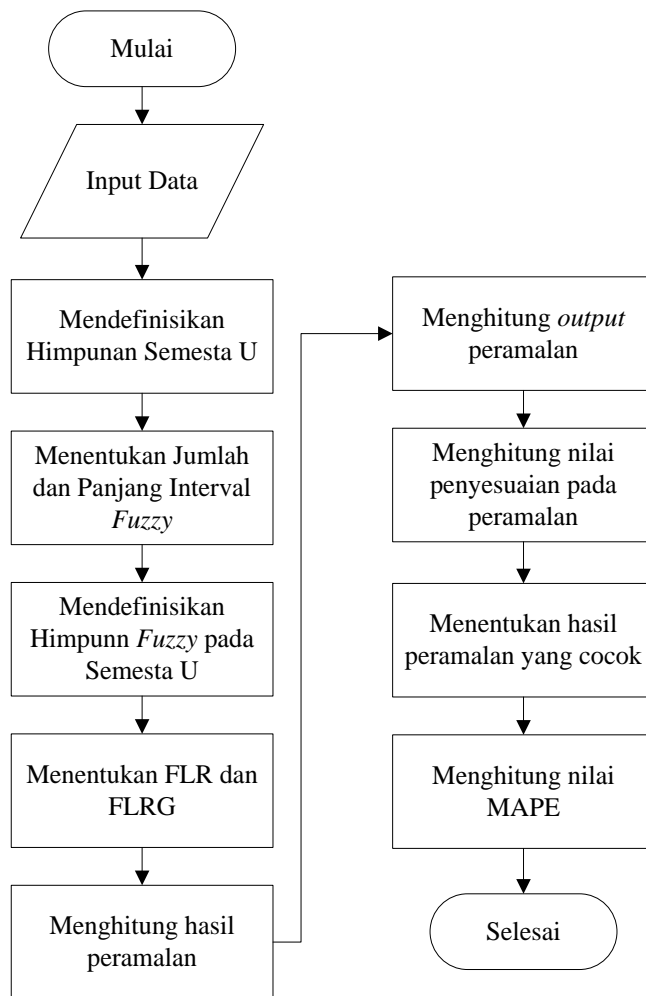
#### 4.5 Tahapan Penelitian



**Gambar 4.1.** Tahapan Penelitian ARIMA-GARCH

Langkah awal penelitian ini adalah memasukkan data bulanan harga minyak mentah dunia tahun 2001 sampai 2017 kedalam *software* R. Melakukan peramalan yang diawali dengan identifikasi masalah yaitu uji ADF, uji ACF, dan uji PACF untuk menstasionerkan data. Setelah data stasioner dilakukan estimasi model ARIMA(p,d,q) kemudian dilakukan *overfitting* model. Melakukan uji diagnostik model ARIMA(p,d,q) yang signifikan diantaranya uji normalitas, uji no autokorelasi, dan uji homoskedastisitas. Ketika terjadi heteroskedastisitas maka dilanjutkan dengan model ARCH-GARCH. Melakukan estimasi model

GARCH(p,q) kemudian dilakukan overfitting model dan uji diagnostik. Didapatkan model ARIMA(p,d,q)-GARCH(p,q) kemudian melakukan peramalan menggunakan model yang diperoleh. Selanjutnya tahapan penelitian dari metode *Fuzzy Time Series Markov-Chain* adalah sebagai berikut:



**Gambar 4.2.** Tahapan Penelitian *Fuzzy Time Series Markov-Chain*

Melakukan analisis peramalan menggunakan metode *Fuzzy Time Series Markov-Chain* dengan langkah awal yaitu mendefinisikan himpunan semesta  $U$  dan menentukan jumlah dan panjang interval *fuzzy*. Selanjutnya mendefinisikan himpunan *fuzzy* pada semesta  $U$  dan melakukan *fuzzyfikasi* data historis. Membentuk *Fuzzy Logical Relation* (FLR) kemudian dikelompokkan menjadi *Fuzzy Logical Relation Group* (FLRG). Melakukan peramalan dan menghitung nilai kesalahan peramalan.

## BAB V

### PEMBAHASAN

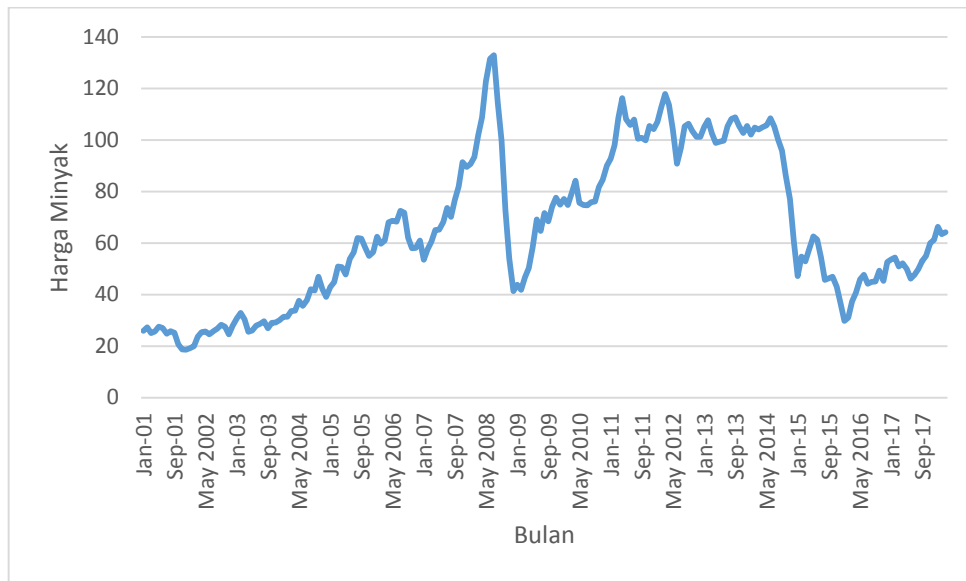
#### 5.1 Analisis Deskriptif

Pada penelitian ini, analisis deskriptif dilakukan untuk melihat gambaran umum dari data harga minyak mentah tahun 2001 hingga 2017 dalam satuan US\$ per barel. Hasil dari analisis deskriptif harga minyak mentah dapat dilihat pada tabel berikut:

**Tabel 5.1.** Analisis Deskriptif Harga Minyak Mentah

<b>Minimal</b>	18,52
<b>Kuartil Pertama</b>	41,78
<b>Median</b>	59,81
<b>Mean</b>	64,60
<b>Kuartil Ketiga</b>	92,86
<b>Maksimal</b>	132,83

Pada analisis deskriptif, peneliti menggunakan 204 data bulanan harga minyak mentah dari bulan Januari 2001 sampai Desember 2017. Berdasarkan **Tabel 5.1.** dapat dilihat bahwa harga bulanan minyak mentah memiliki nilai minimal 18,52 dan nilai maksimal 132,83 selama periode 2001 hingga 2017. Harga bulanan minyak mentah memiliki nilai rata-rata 64,60. Hal tersebut menandakan bahwa terdapat jangkauan nilai yang cukup jauh sehingga dapat dikatakan bahwa terjadi naik turun harga harga minyak mentah bulanan. Untuk lebih jelasnya plot dari harga minyak mentah dapat dilihat pada grafik berikut:




**Gambar 5.1** Grafik Harga Minyak Mentah

Berdasarkan **Gambar 5.1** dapat dilihat bahwa terdapat pola fuktuatif pada data bulanan harga minyak mentah. Harga bulanan minyak mentah mulai terjadi kenaikan pada awal tahun 2003 hingga puncaknya yaitu bulan Juni 2008 dan turun drastis hingga tahun 2009. Harga minyak mentah naik kembali hingga bulan April 2011, turun lagi hingga Februari 2016, dan naik lagi hingga tahun 2017. Harga bulanan minyak mentah yang naik turun menyebabkan ketidakstabilan perekonomian disuatu negara khususnya Indonesia. Selain itu juga dapat menyebabkan harga yang sering berubah-ubah sehingga pemerintah melakukan revisi terhadap APBN setiap terjadi kenaikan harga minyak mentah agar tetap dapat menyediakan subsidi untuk rakyat.


## 5.2 Peramalan ARIMA-GARCH

Langkah awal untuk melakukan peramalan yaitu dengan melihat plot data yang digunakan untuk melihat bentuk grafik serta kestasioneran data harga bulanan minyak mentah. Jika plot dari harga minyak mentah belum stasioner maka dapat dilakukan transformasi. Plot data bulanan harga minyak mentah adalah sebagai berikut:



**Gambar 5.2.** Plot Data Runtun Waktu

Berdasarkan **Gambar 5.2.** terlihat bahwa data belum stasioner, masih terlihat naik turunnya (fluktuatif) dari data harga minyak mentah. Jika dilihat, grafik tersebut menunjukkan adanya *trend* sehingga harus distasionerkan baik dalam *mean* ataupun *varians* sebelum dilakukan estimasi model ataupun peramalan. Selain dengan melihat plot data dapat juga dilihat melalui plot ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*) sebagai berikut:



**Gambar 5.3.** ACF dan PACF Data



Berdasarkan **Gambar 5.3.** plot ACF menunjukkan bahwa grafik cenderung turun secara melambat atau secara linear. Sehingga dapat dikatakan bahwa data minyak mentah tidak stasioner dalam *mean* ataupun *varian*. Sedangkan pada plot PACF menunjukkan bahwa terdapat *lag* atau data yang keluar dari batas stasioner sehingga dapat disimpulkan bahwa data tidak stasioner. Untuk lebih jelasnya dapat dilakukan uji ADF (*Augmented Dickey-Fuller*) dari data bulanan harga minyak mentah sebagai berikut:

**Tabel 5.2.** Hasil Uji ADF Sebelum Transformasi

<i>Dickey-Fuller</i>	-1,9204
<i>Lag Order</i>	5
<i>P-value</i>	0,6094

Berdasarkan **Tabel 5.2.** dapat dilihat uji hipotesis sebagai berikut:

i. Hipotesis

$H_0$ : Data mengandung akar unit (data tidak stasioner)

$H_1$ : Data tidak mengandung akar unit (data stasioner)

ii. Tingkat Signifikansi

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

iii. Statistika Uji

$P\text{-value} = 0,6094$

iv. Daerah Kritis

$P\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai  $P\text{-value} > \alpha$  ( $0,6094 > 0,05$ ) maka gagal tolak  $H_0$

vi. Kesimpulan

Data mengandung *unit root* (data tidak stasioner)

Berdasarkan uji hipotesis untuk uji ADF tersebut didapatkan kesimpulan bahwa data tidak stasioner, sehingga dilakukan transformasi data yaitu *differencing* data untuk data tidak stasioner dalam *mean* dan *logaritma natural* untuk data tidak stasioner dalam *varians*. Untuk meyakinkan bahwa data sudah stasioner dalam

*mean* ataupun *varian*, maka dilakukan uji ADF kembali dari data yang sudah dilakukan transformasi. Hasil dari uji ADF data setelah ditransformasi dapat dilihat sebagai berikut:

**Tabel 5.3.** Hasil Uji ADF Setelah Transformasi

<i>Dickey-Fuller</i>	-6,449
<i>Lag Order</i>	5
<i>P-value</i>	0,01

Berdasarkan **Tabel 5.3.** dapat dilihat uji hipotesis sebagai berikut:

i. Hipotesis

$H_0$ : Data mengandung akar unit (data tidak stasioner)

$H_1$ : Data tidak mengandung akar unit (data stasioner)

ii. Tingkat Signifikansi

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

iii. Statistika Uji

$P\text{-value} = 0,01$

iv. Daerah Kritis

$P\text{-value} < \alpha$  maka gagal tolak  $H_0$


v. Keputusan

Karena nilai  $P\text{-value} < \alpha$  ( $0,01 < 0,05$ ) maka tolak  $H_0$

vi. Kesimpulan

Data tidak mengandung *unit root* (data stasioner)

Berdasarkan uji hipotesis untuk uji ADF tersebut didapatkan kesimpulan bahwa data stasioner sehingga dapat dilakukan estimasi model. Estimasi model dapat dilakukan dengan melihat plot ACF dan PACF sebagai berikut.



**Gambar 5.4.** ACF dan PACF Data Stasioner

Berdasarkan **Gambar 5.4.** plot ACF menunjukkan bahwa terdapat 2 lag yang keluar yang berarti mengandung *moving average* atau MA(2). Sedangkan untuk plot PACF menunjukkan terdapat 1 lag yang keluar yang berarti mengandung *autoregressive* atau AR(1). Sehingga didapatkan model utama yaitu ARIMA (1,1,2). Untuk mengetahui model yang terbaik maka dilakukan *overfitting* model disekitar model utama. Peneliti melakukan uji kecocokan model ARIMA (1,1,2) dapat dilihat sebagai berikut:

**Tabel 5.4.** Hasil Uji Kecocokan Model ARIMA (1,1,2)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>T</i>	<i>p-value</i>
AR(1)	-0,0886	0,3312	-0,2675	0,7893
MA(1)	0,4068	0,3244	1,2540	0,2113
MA(2)	0,2096	0,1234	1,6985	0,0909

Berdasarkan **Tabel 5.4.** dapat dilihat uji hipotesis dari uji kecocokan model ARIMA (1,1,2) sebagai berikut:

i. Hipotesis

$H_0$ : Data tidak berpengaruh secara signifikan terhadap model

$H_1$ : Data berpengaruh secara signifikan terhadap model

ii. Tingkat Signifikansi

$$\alpha = 5\% \text{ atau } 0,05$$

iii. Statistika Uji

$$p\text{-value AR}(1) = 0,7893$$

$$p\text{-value MA}(1) = 0,2113$$

$$p\text{-value MA}(2) = 0,0909$$

iv. Daerah Kritis

$$P\text{-value} < \alpha \text{ maka tolak } H_0$$

v. Keputusan

Karena nilai  $p\text{-value AR}(1)$ ,  $MA(1)$ , dan  $MA(2) > \alpha$  maka gagal tolak  $H_0$

vi. Kesimpulan

Data tidak berpengaruh secara signifikan terhadap model

Berdasarkan uji kecocokan model ARIMA (1,1,2) diperoleh kesimpulan bahwa data tidak berpengaruh secara signifikan terhadap model. Selanjutnya peneliti melakukan uji kecocokan model ARIMA (1,1,1) sebagai berikut:

**Tabel 5.5.** Hasil Uji Kecocokan Model ARIMA (1,1,1)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>T</i>	<i>p-value</i>
AR(1)	0,3812	0,1610	2,3677	0,0188
MA(1)	-0,0617	0,1688	-0,3655	0,7151

Berdasarkan **Tabel 5.5.** dapat dilihat uji hipotesis dari uji kecocokan model ARIMA (1,1,1) sebagai berikut:

i. Hipotesis

$H_0$ : Data tidak berpengaruh secara signifikan terhadap model

$H_1$ : Data berpengaruh secara signifikan terhadap model

ii. Tingkat Signifikansi

$$\alpha = 5\% \text{ atau } 0,05$$

iii. Statistika Uji

$$p\text{-value AR}(1) = 0,0188$$

$$p\text{-value MA}(1) = 0,7151$$

iv. Daerah Kritis

$P\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai  $p\text{-value}$  AR(1)  $< \alpha$  maka tolak  $H_0$

Karena nilai  $p\text{-value}$  MA(1)  $> \alpha$  maka gagal tolak  $H_0$

vi. Kesimpulan

Karena terdapat nilai  $p\text{-value}$  yang lebih besar dari nilai  $\alpha$  maka data tidak berpengaruh secara signifikan terhadap model

Berdasarkan uji hipotesis untuk uji kecocokan model ARIMA (1,1,1) maka didapatkan kesimpulan bahwa data tidak berpengaruh secara signifikan terhadap model. Selanjutnya peneliti melakukan uji kecocokan model ARIMA (1,1,0) sebagai berikut:

**Tabel 5.6.** Hasil Uji Kecocokan Model ARIMA (1,1,0)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>T</i>	<i>p-value</i>
AR(1)	0,3258	0,0662	4,9215	0,0000

Berdasarkan **Tabel 5.6.** dapat dilihat uji hipotesis dari uji kecocokan model ARIMA (1,1,0) sebagai berikut:

i. Hipotesis

$H_0$ : Data tidak berpengaruh secara signifikan terhadap model

$H_1$ : Data berpengaruh secara signifikan terhadap model

ii. Tingkat Signifikansi

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

iii. Statistika Uji

$p\text{-value}$  AR(1)= 0,0000

iv. Daerah Kritis

$P\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai  $p\text{-value}$  AR(1)  $< \alpha$  maka tolak  $H_0$

vi. Kesimpulan

Data berpengaruh secara signifikan terhadap model

Berdasarkan uji hipotesis untuk uji kecocokan model ARIMA (1,1,0) maka didapatkan kesimpulan bahwa data berpengaruh secara signifikan terhadap model. Selanjutnya peneliti melakukan uji kecocokan model ARIMA (0,1,2) sebagai berikut:

**Tabel 5.7.** Hasil Uji Kecocokan Model ARIMA (0,1,2)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>T</i>	<i>p-value</i>
MA(1)	0,3213	0,0694	4,6297	0,0000
MA(2)	0,1821	0,0730	2,4945	0,0134

Berdasarkan **Tabel 5.7.** dapat dilihat uji hipotesis dari uji kecocokan model ARIMA (0,1,2) sebagai berikut:

i. Hipotesis

$H_0$ : Data tidak berpengaruh secara signifikan terhadap model

$H_1$ : Data berpengaruh secara signifikan terhadap model

ii. Tingkat Signifikansi

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

iii. Statistika Uji

*p-value* MA(1)= 0,0000

*p-value* MA(2)= 0,0134

iv. Daerah Kritis

$P\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai *p-value* MA(1) dan MA(2)  $< \alpha$  maka tolak  $H_0$

vi. Kesimpulan

Data berpengaruh secara signifikan terhadap model

Berdasarkan uji hipotesis untuk uji kecocokan model ARIMA (0,1,2) maka didapatkan kesimpulan bahwa data berpengaruh secara signifikan terhadap model. Selanjutnya peneliti melakukan uji kecocokan model ARIMA (0,1,1) sebagai berikut:

**Tabel 5.8.** Hasil Uji Kecocokan Model ARIMA (0,1,1)

<i>Variable</i>	<i>Coefficient</i>	<i>s.e</i>	<i>t</i>	<i>p-value</i>
MA(1)	0,3213	0,0694	4,6297	0,0000

Berdasarkan **Tabel 5.8.** dapat dilihat uji hipotesis dari uji kecocokan model ARIMA (0,1,2) sebagai berikut:

i. Hipotesis

$H_0$ : Data tidak berpengaruh secara signifikan terhadap model

$H_1$ : Data berpengaruh secara signifikan terhadap model

ii. Tingkat Signifikansi

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

iii. Statistika Uji

*p-value* MA(1)= 0,0000

iv. Daerah Kritis

*P-value* <  $\alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai *p-value* MA(1) <  $\alpha$  maka tolak  $H_0$

vi. Kesimpulan

Data berpengaruh secara signifikan terhadap model

Berdasarkan uji hipotesis untuk uji kecocokan model ARIMA (0,1,1) maka didapatkan kesimpulan bahwa data berpengaruh secara signifikan terhadap model.

Untuk melihat hasil uji kecocokan model secara keseluruhan maka disajikan pada tabel berikut:

**Tabel 5.9.** Hasil Estimasi Parameter ARIMA

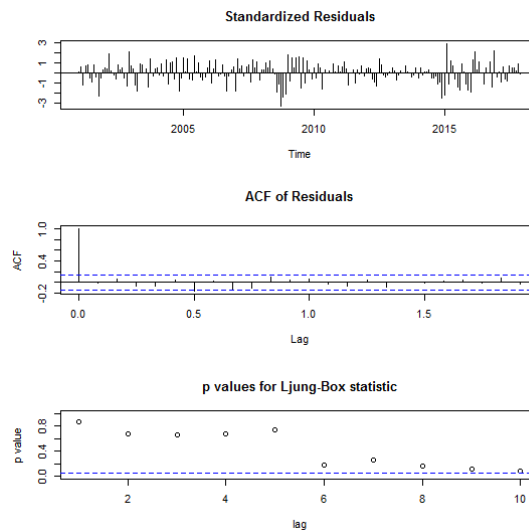
No.	Model	Parameter		Signifikan	
		AR(p)	MA(q)		
		1	1 2		
1.	ARIMA (1,1,2)	-0,0886	0,4068	0,2096	Tidak
	s.e.	0,3312	0,3244	0,1234	

	<i>p-value</i>	0,7893	0,2113	0,0909	
2.	ARIMA	0,3812	-0,0617		Tidak
	(1,1,1)				
	s.e.	0,1610	0,1688		
	<i>p-value</i>	0,0188	0,7151		
3.	ARIMA	0,3258			Ya
	(1,1,0)				
	s.e.	0,0662			
	<i>p-value</i>	0,0000			
4.	ARIMA		0,3213	0,1821	Ya
	(0,1,2)				
	s.e.		0,0694	0,0730	
	<i>p-value</i>		0,0000	0,0134	
5.	ARIMA			0,3213	Ya
	(0,1,1)				
	s.e.			0,0694	
	<i>p-value</i>			0,0000	

Berdasarkan **Tabel 5.9.** dapat diketahui bahwa terdapat tiga model yang signifikan yaitu ARIMA (1,1,0), ARIMA (0,1,2), dan ARIMA (0,1,1). Untuk mengetahui model terbaik yang akan digunakan untuk peramalan maka dilakukan uji diagnostik residual data. Terdapat tiga uji diagnostik residual data yaitu uji normalitas, uji homoskedastisitas, dan uji no autokorelasi. Hasil dari uji diagnostik residual model yang signifikan ARIMA (1,1,0) sebagai berikut:

1. Uji no autokorelasi





**Gambar 5.5.** ACF dan PACF Residual ARIMA (1,1,0)

Berdasarkan **Gambar 5.5.** dapat dilihat pada plot ACF residual data merupakan model *white noise* ditandai dengan tidak adanya *lag* yang keluar dari garis batas interval. Dengan kata lain, residual dari model ARIMA (1,1,0) merupakan data yang baik untuk data harga minyak mentah. Sedangkan nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

**Tabel 5.10.** Nilai Statistik *Ljung-Box* ARIMA (1,1,0)

Orde	ACF	PACF	Q-Stats	Orde	ACF	PACF	Q-Stats
0	1	1		19	0.02558	0.05284	0.29321
1	-0.0107	-0.0107	0.87716	20	0.05379	0.03119	0.3149
2	0.05917	0.05907	0.68648	21	-0.0026	0.00215	0.37208
3	-0.063	-0.062	0.66362	22	0.07792	0.02227	0.35322
4	-0.06	-0.065	0.67399	23	-0.0215	-0.0197	0.40416
5	0.04302	0.04989	0.74181	24	-0.0874	-0.0893	0.36451
6	-0.1684	-0.1663	0.18814	25	0.11499	0.13434	0.26886
7	0.02947	0.01531	0.25734	26	-0.0232	0.00771	0.31066
8	-0.1148	-0.0967	0.16227	27	-0.0049	-0.0344	0.36018
9	-0.1041	-0.1304	0.11895	28	-0.0965	-0.0496	0.30665
10	0.10941	0.10827	0.08154	29	-0.0387	-0.0315	0.33784

Orde	ACF	PACF	Q-Stats	Orde	ACF	PACF	Q-Stats
11	0.04608	0.06199	0.10348	30	0.09704	0.06537	0.286
12	0.06179	-0.0089	0.11609	31	-0.0285	0.01085	0.32216
13	-0.038	-0.0224	0.14629	32	-0.0025	-0.0818	0.36828
14	-0.0746	-0.0931	0.14553	33	0.03037	0.06579	0.40536
15	0.04984	0.02318	0.16864	34	-0.0276	0.00538	0.44459
16	-0.0809	-0.0506	0.15835	35	0.00373	-0.0361	0.49266
17	0.01045	-0.0276	0.20166	36	-0.0429	-0.0289	0.51849
18	-0.021	0.00419	0.24681				

Berdasarkan **Tabel 5.10**, maka dapat dilihat uji hipotesis dari uji no autokorelasi sebagai berikut:

i. Hipotesis

$H_0$ : Tidak terdapat autokorelasi pada data ( $\rho_k = 0$ )

$H_1$ : Terdapat autokorelasi pada data ( $\exists \rho_k \neq 0$ )

ii. Tingkat Signifikansi

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

iii. Statistika Uji

Semua nilai *p-value* lebih dari 0,05

iv. Daerah Kritis

*p-value* <  $\alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai *p-value* >  $\alpha$  maka gagal tolak  $H_0$

vi. Kesimpulan

Tidak terdapat autokorelasi pada data ( $\rho_k = 0$ )

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat autokorelasi pada data sehingga asumsi no autokorelasi terpenuhi.

## 2. Uji normalitas

**Tabel 5.11.** Nilai *Jarque Bera Test* ARIMA (1,1,0)

<i>X-squared</i>	5,19
<i>Df</i>	2
<i>p-value</i>	0,07465

Berdasarkan **Tabel 5.11.** dapat dilihat uji hipotesis dari uji normalitas sebagai berikut:

### i. Hipotesis

$H_0$ : Residual data mengikuti distribusi normal

$H_1$ : Residual data tidak mengikuti distribusi normal

### ii. Tingkat Signifikansi

$\alpha = 5\%$

### iii. Statistika Uji

$p\text{-value} = 0,07465$

### iv. Daerah Kritis

$p\text{-value} < \alpha$  maka tolak  $H_0$

### v. Keputusan

Karena nilai  $p\text{-value} > \alpha$  maka gagal tolak  $H_0$

### vi. Kesimpulan


Residual data mengikuti distribusi normal

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data berdistribusi normal sehingga asumsi normalitas terpenuhi.

## 3. Uji homoskedastisitas

Uji homoskedastisitas dilihat dari plot ACF dan PACF kuadrat residual.

Hasil dari plot ACF dan PACF kuadrat residual dapat dilihat sebagai berikut:

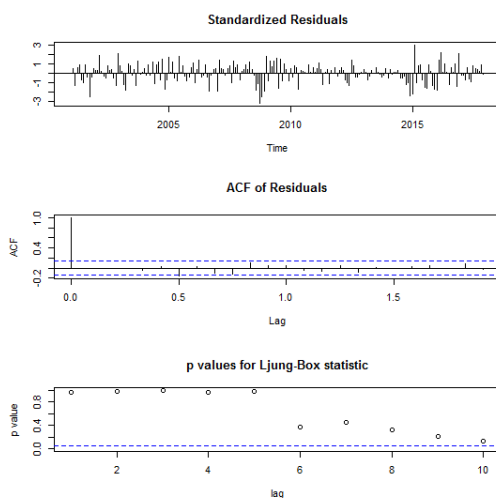


**Gambar 5.6.** ACF dan PACF *Squared* Residual ARIMA (1,1,0)

Berdasarkan **Gambar 5.6.** dapat dilihat bahwa terdapat *lag* yang keluar dari garis batas interval. Dapat dikatakan bahwa residual data pada model ARIMA (1,1,0) tersebut variansinya tidak konstan atau dengan kata lain masih terdapat volatilitas atau heteroskedastisitas. Sehingga asumsi homoskedastisitas tidak terpenuhi.

Peneliti melakukan uji diagnostik model yang signifikan kedua yaitu ARIMA (0,1,2). Hasil dari uji diagnostik residual model yang signifikan ARIMA (0,1,2) sebagai berikut:

1. Uji no autokorelasi



**Gambar 5.7.** ACF dan PACF Residual ARIMA (0,1,2)

Berdasarkan **Gambar 5.7.** dapat dilihat pada plot ACF residual data adalah model *white noise* ditandai dengan tidak adanya *lag* yang keluar dari garis batas interval. Dengan kata lain, residual dari model ARIMA (0,1,2) merupakan data yang baik untuk data harga minyak mentah. Sedangkan nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

**Tabel 5.12.** Nilai Statistik *Ljung-Box* ARIMA (0,1,2)

Orde	ACF	PACF	Q-Stats	Orde	ACF	PACF	Q-Stats
0	1	1		19	0,0276	0,0562	0,4127
1	-0,0033	-0,0033	0,9626	20	0,0471	0,0282	0,4450
2	-0,0126	-0,0126	0,9826	21	-0,0080	0,0033	0,5072
3	-0,0169	-0,0170	0,9925	22	0,0902	0,0362	0,4538
4	-0,0441	-0,0444	0,9731	23	-0,0281	-0,0319	0,5031
5	0,0325	0,0318	0,9815	24	-0,0947	-0,0892	0,4400
6	-0,1640	-0,1658	0,3762	25	0,1167	0,1297	0,3278
7	0,0370	0,0374	0,4578	26	-0,0109	0,0040	0,3782
8	-0,1066	-0,1170	0,3288	27	-0,0110	-0,0117	0,4301
9	-0,1168	-0,1215	0,2075	28	-0,0993	-0,0618	0,3638
10	0,1119	0,0977	0,1388	29	-0,0372	-0,0396	0,3982
11	0,0499	0,0541	0,1666	30	0,1065	0,0730	0,3201
12	0,0549	0,0154	0,1904	31	-0,0345	0,0063	0,3538
13	-0,0433	-0,0288	0,2266	32	-0,0108	-0,0761	0,4003
14	-0,0710	-0,0955	0,2283	33	0,0366	0,0630	0,4332
15	0,0548	0,0246	0,2517	34	-0,0235	-0,0008	0,4754
16	-0,0750	-0,0537	0,2451	35	-0,0009	-0,0214	0,5240
17	0,0020	-0,0224	0,3023	36	-0,0441	-0,0351	0,5483
18	-0,0163	-0,0032	0,3600				

Berdasarkan **Tabel 5.12.** maka dapat dilihat uji hipotesis dari uji no autokorelasi sebagai berikut:

i. Hipotesis

$H_0$ : Tidak terdapat autokorelasi pada data ( $\rho_k = 0$ )

$H_1$ : Terdapat autokorelasi pada data ( $\exists \rho_k \neq 0$ )

ii. Tingkat Signifikansi

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

iii. Statistika Uji

Semua nilai *p-value* lebih dari 0,05

iv. Daerah Kritis

$p\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai  $p\text{-value} > \alpha$  maka gagal tolak  $H_0$

vi. Kesimpulan

Tidak terdapat autokorelasi pada data ( $\rho_k = 0$ )

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa tidak terdapat autokorelasi pada data sehingga asumsi no autokorelasi terpenuhi.

2. Uji normalitas

**Tabel 5.13.** Nilai *Jarque Bera Test* ARIMA (0,1,2)

<i>X-squared</i>	4,482
<i>Df</i>	2
<i>p-value</i>	0,1064

Berdasarkan **Tabel 5.13.** dapat dilihat uji hipotesis dari uji normalitas sebagai berikut:

i. Hipotesis

$H_0$ : Residual data mengikuti distribusi normal

$H_1$ : Residual data tidak mengikuti distribusi normal

ii. Tingkat Signifikansi

$\alpha = 5\%$

iii. Statistika Uji

$p\text{-value} = 0,1064$

iv. Daerah Kritis

$p\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena nilai  $p\text{-value} > \alpha$  maka gagal tolak  $H_0$

vi. Kesimpulan


Residual data mengikuti distribusi normal

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data berdistribusi normal sehingga asumsi normalitas terpenuhi.

3. Uji homoskedastisitas

Uji homoskedastisitas dilihat dari plot ACF dan PACF kuadrat residual.

Hasil dari plot ACF dan PACF kuadrat residual dapat dilihat sebagai berikut:

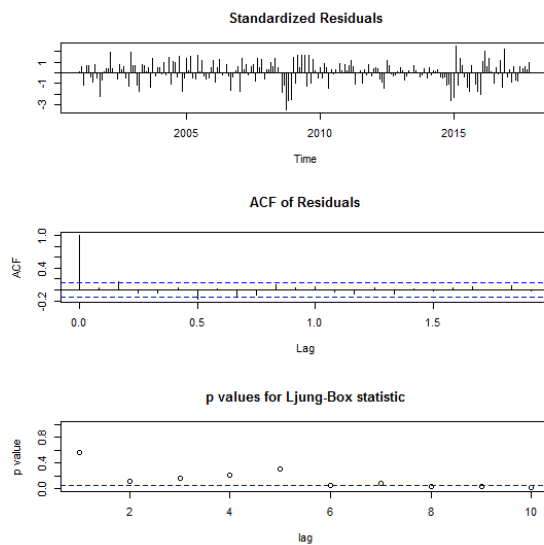


**Gambar 5.8.** ACF dan PACF *Squared* Residual ARIMA (0,1,2)

Berdasarkan **Gambar 5.8.** dapat dilihat bahwa terdapat *lag* yang keluar dari garis batas interval. Dapat dikatakan bahwa residual data pada model ARIMA (0,1,2) tersebut variansinya tidak konstan atau dengan kata lain masih terdapat volatilitas atau heteroskedastisitas. Sehingga asumsi homoskedastisitas tidak terpenuhi.

Peneliti melakukan uji diagnostik model yang signifikan ketiga yaitu ARIMA (0,1,1). Hasil dari uji diagnostik residual model yang signifikan ARIMA (0,1,1) sebagai berikut:

1. Uji no autokorelasi



**Gambar 5.9.** ACF dan PACF Residual ARIMA (0,1,1)

Berdasarkan **Gambar 5.9.** dapat dilihat pada plot ACF residual data bukan model *white noise* ditandai dengan adanya *lag* yang keluar dari garis batas interval. Dengan kata lain, residual dari model ARIMA (0,1,1) merupakan data yang kurang cocok untuk data harga minyak mentah. Sedangkan nilai *p-value* dari *Ljung-Box* dapat dilihat sebagai berikut:

**Tabel 5.14.** Nilai Statistik *Ljung-Box* ARIMA (0,1,1)

Orde	ACF	PACF	Q-Stats	Orde	ACF	PACF	Q-Stats
0	1	1		19	0,0279	0,0558	0,1594
1	0,0397	0,0397	0,5683	20	0,0578	0,0283	0,1726
2	0,1401	0,1387	0,1104	21	0,0048	-0,0051	0,2141
3	-0,0519	-0,0635	0,1741	22	0,0730	0,0106	0,2099
4	-0,0631	-0,0801	0,2141	23	-0,0117	-0,0133	0,2532
5	0,0270	0,0505	0,3100	24	-0,0764	-0,0820	0,2424
6	-0,1788	-0,1698	0,0473	25	0,1059	0,1366	0,1871
7	0,0090	0,0053	0,0782	26	-0,0325	0,0025	0,2170
8	-0,1224	-0,0772	0,0427	27	-0,0044	-0,0508	0,2585
9	-0,0980	-0,1155	0,0347	28	-0,0915	-0,0445	0,2245



Orde	ACF	PACF	Q-Stats	Orde	ACF	PACF	Q-Stats
10	0,0989	0,1240	0,0278	29	-0,0398	-0,0213	0,2507
11	0,0405	0,0638	0,0387	30	0,0839	0,0653	0,2287
12	0,0630	-0,0315	0,0450	31	-0,0248	0,0120	0,2629
13	-0,0311	-0,0307	0,0619	32	0,0024	-0,0842	0,3050
14	-0,0734	-0,0930	0,0637	33	0,0261	0,0651	0,3422
15	0,0390	0,0253	0,0814	34	-0,0283	0,0059	0,3792
16	-0,0846	-0,0430	0,0747	35	0,0044	-0,0446	0,4256
17	0,0112	-0,0215	0,1002	36	-0,0403	-0,0235	0,4539
18	-0,0205	0,0160	0,1289				

Berdasarkan **Tabel 5.14.** maka dapat dilihat uji hipotesis dari uji no autokorelasi sebagai berikut:

i. Hipotesis

$H_0$ : Tidak terdapat autokorelasi pada data ( $\rho_k = 0$ )

$H_1$ : Terdapat autokorelasi pada data ( $\exists \rho_k \neq 0$ )

ii. Tingkat Signifikansi

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

iii. Statistika Uji

Terdapat nilai *p-value* kurang dari 0,05

iv. Daerah Kritis

$p\text{-value} < \alpha$  maka tolak  $H_0$

v. Keputusan

Karena terdapat nilai  $p\text{-value} < \alpha$  maka tolak  $H_0$

vi. Kesimpulan

Terdapat autokorelasi pada data ( $\exists \rho_k \neq 0$ )

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa terdapat autokorelasi pada data sehingga asumsi no autokorelasi tidak terpenuhi.

## 2. Uji normalitas

**Tabel 5.15.** Nilai *Jarque Bera Test* ARIMA (0,1,1)

<i>X-squared</i>	11,955
<i>Df</i>	2
<i>p-value</i>	0,002535

Berdasarkan **Tabel 5.15.** dapat dilihat uji hipotesis dari uji normalitas sebagai berikut:

### i. Hipotesis

$H_0$ : Residual data mengikuti distribusi normal

$H_1$ : Residual data tidak mengikuti distribusi normal

### ii. Tingkat Signifikansi

$\alpha = 5\%$

### iii. Statistika Uji

$p\text{-value} = 0,002535$

### iv. Daerah Kritis

$p\text{-value} < \alpha$  maka tolak  $H_0$

### v. Keputusan

Karena nilai  $p\text{-value} < \alpha$  maka tolak  $H_0$

### vi. Kesimpulan

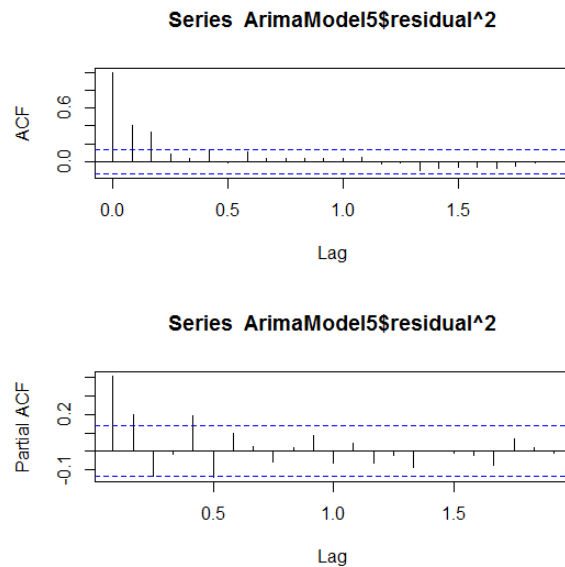
Residual data tidak mengikuti distribusi normal

Berdasarkan uji hipotesis tersebut didapatkan kesimpulan bahwa residual data tidak berdistribusi normal sehingga asumsi normalitas tidak terpenuhi.

## 3. Uji homoskedastisitas

Uji homoskedastisitas dilihat dari plot ACF dan PACF kuadrat residual.

Hasil dari plot ACF dan PACF kuadrat residual dapat dilihat sebagai berikut:



**Gambar 5.10.** ACF dan PACF *Squared* Residual ARIMA (0,1,1)

Berdasarkan **Gambar 5.10.** dapat dilihat bahwa terdapat *lag* yang keluar dari garis batas interval. Dapat dikatakan bahwa residual data pada model ARIMA (0,1,1) tersebut variansinya tidak konstan atau dengan kata lain masih terdapat volatilitas atau heteroskedastisitas. Sehingga asumsi no homoskedastisitas tidak terpenuhi.

Berdasarkan uji diagnostik pada model yang signifikan maka dapat disajikan dalam tabel seperti berikut:

**Tabel 5.16.** Hasil Uji Diagnostik

Model	Normalitas	Homoskedastisitas	No autokorelasi
ARIMA (1,1,0)	Ya	Tidak	Ya
ARIMA (0,1,2)	Ya	Tidak	Ya
ARIMA (0,1,1)	Tidak	Tidak	Tidak

Berdasarkan hasil uji diagnostik pada **Tabel 5.14.** terdapat dua model (ARIMA (1,1,0) dan ARIMA (0,1,2)) yang memiliki asumsi yang sama yaitu memenuhi asumsi normalitas, no autokorelasi, dan tidak memenuhi homoskedastisitas. Dengan kata lain, kedua model tersebut bersifat heteroskedastisitas. Oleh karena itu perlu dilanjutkan analisis ARCH-GARCH.

Namun, peneliti terlebih dahulu menentukan model yang terbaik dengan membandingkan nilai *Akaike Info Criterion* dan *Schwarz Bayesian Criterion* seperti pada tabel berikut:

**Tabel 5.17.** *AIC* dan *BIC*

<b>Model</b>	<b><i>AIC</i></b>	<b><i>BIC</i></b>	<b><math>s^2e</math></b>	<b><i>Log likelihood</i></b>
ARIMA (1,1,0)	-441,9	-435,28	0,006538	222,95
ARIMA (0,1,2)	-441,82	-431,88	0,006508	223,91

Berdasarkan **Tabel 5.17.** diperoleh model terbaik dengan nilai *Akaike Info Criterion (AIC)*/ *Bayesian Information Criterion (BIC)* terkecil yaitu ARIMA (1,1,0). Berdasarkan plot ACF kuadrat residual pada **Gambar 5.5.** dapat dilihat terdapat *lag* keluar batas interval sampai pada orde ke 2. Oleh sebab itu, ditentukan model GARCH untuk estimasi yaitu model GARCH (p,q) dengan p= 0,1,2 dan q= 0,1,2. Berdasarkan model tersebut, praktikan akan melakukan estimasi dari model GARCH. Estimasi pertama dilakukan pada model GARCH (2,1). Hasil dari estimasi moel GARCH (2,1) dapat dilihat sebagai berikut:

**Tabel 5.18.** Hasil Estimasi GARCH (2,1)

<b><i>Variabel</i></b>	<b><i>Estimate</i></b>	<b><i>Std. Error</i></b>	<b><i>t value</i></b>	<b><i>Pr( &gt;  t  )</i></b>
$\mu$	1,058e-02	5,967e-03	1,773	0,07615
$\omega$	1,156e-03	9,524e-04	1,214	0,22465
$\alpha_1$	3,193e-01	1,200e-01	2,662	0,00778
$\alpha_2$	1,024e-08	2,752e-01	0,000	1,00000
$\beta_1$	5,262e-01	2,865e-01	1,837	0,06625

Berdasarkan **Tabel 5.18.** dapat dilihat pada nilai *p-value (Pr( >| t |))* bahwa komponen konstanta dalam model  $\sigma_2$  tidak signifikan karena memiliki nilai *p-value* 1,000 lebih dari nilai  $\sigma$  0,05. Sehingga model tereduksi menjadi model GARCH(1,1). Hasil dari estimasi model GARCH (1,1) dapat dilihat sebagai berikut:

**Tabel 5.19.** Hasil Estimasi GARCH (1,1)

<i>Variabel</i>	<i>Estimate</i>	<i>Std. Error</i>	<i>t value</i>	<i>Pr( &gt;  t  )</i>
$\mu$	0,0104637	0,0051273	2,041	0,04127
$\omega$	0,0011561	0,0008275	1,397	0,16240
$\alpha_1$	0,3189891	0,1019329	3,129	0,00175
$\beta_1$	0,5273278	0,1717190	3,071	0,00213

Berdasarkan **Tabel 5.19.** dapat dilihat pada nilai *p-value* ( $Pr( >| t |)$ ) bahwa komponen omega karena memiliki nilai *p-value* 0,16240 (lebih dari nilai  $\alpha$  0,05) yang berarti tidak signifikan. Sehingga dapat dikatakan bahwa model GARCH (1,1) tidak signifikan terhadap model. Peneliti mengestimasi model GARCH (1,0). Hasil dari estimasi model GARCH (1,0) dapat dilihat sebagai berikut:

**Tabel 5.20.** Hasil Estimasi GARCH (1,0)

<i>Variabel</i>	<i>Estimate</i>	<i>Std. Error</i>	<i>t value</i>	<i>Pr( &gt;  t  )</i>
$\mu$	0,0145821	0,0049495	2,946	0,003217
$\omega$	0,0039575	0,0005892	6,717	1,86e-11
$\alpha_1$	0,4224031	0,1215136	3,476	0,000509

Berdasarkan **Tabel 5.20.** dapat dilihat pada nilai *p-value* ( $Pr( >| t |)$ ) bahwa semua komponen ( $\mu, \omega, \alpha_2$ ) signifikan karena memiliki nilai *p-value* kurang dari nilai alfa 0,05. Sehingga dapat dikatakan bahwa model GARCH (1,0) signifikan terhadap model.

Berdasarkan pengujian model GARCH (p,q) maka dapat disajikan dalam tabel seperti berikut:

**Tabel 5.21.** Hasil Estimasi Model GARCH (p,q)

<b>Model</b>	<b>Pasca Analisis</b>	<b>Log likelihood</b>	<b>AIC</b>	<b>BIC</b>
GARCH (2,1)	Konstanta, $\omega$ , $\alpha_2$ tidak signifikan	-	-	-

<b>Model</b>	<b>Pasca Analisis</b>	<b>Log likelihood</b>	<b>AIC</b>	<b>BIC</b>
GARCH (1,1)	$\omega$ tidak signifikan	-	-	-
GARCH (1,0)	Melewati semua pasca analisis	231,8316	-2,254499	-2,205535

Berdasarkan **Tabel 5.21.** diperoleh model GARCH terbaik yaitu GARCH (1,0) sehingga model yang diperoleh yaitu ARIMA (1,1,0)-GARCH(1,0). Selanjutnya dilakukan uji diagnostik yang meliputi uji normalitas, uji autokorelasi, dan uji heteroskedastik. Hasil dari uji diagnostik model ARIMA (1,1,0)-GARCH (1,0) sebagai berikut:

**Tabel 5.22.** Uji Diagnostik Model ARIMA (1,1,0)-GARCH (1,0)

<b>Pengujian</b>		<b>Simbol</b>	<b>Statistic</b>	<b>p-value</b>
<i>Jarque-Bera Test</i>	R	$X^2$	5,055049	0,07985647
<i>Shapiro-Wilk Test</i>	R	W	0,9868014	0,5592119
<i>Ljung-Box Test</i>	R	Q(10)	24,05556	0,00745428
<i>Ljung-Box Test</i>	R	Q(15)	30,92497	0,008990182
<i>Ljung-Box Test</i>	R	Q(20)	34,10611	0,02541578
<i>Ljung-Box Test</i>	$R^2$	Q(10)	12,8367	0,2329461
<i>Ljung-Box Test</i>	$R^2$	Q(15)	14,81721	0,4646622
<i>Ljung-Box Test</i>	$R^2$	Q(20)	19,29265	0,5028831

Pengujian		Simbol	Statistic	p-value
LM Arch Test	R	$TR^2$	17,23317	0,1410349

Berdasarkan **Tabel 5.22.** dapat diketahui bahwa pada nilai *p-value* Jarque Bera Test, Ljung Box  $R^2$  lebih dari nilai  $\alpha$  0,05 sehingga residual model ARIMA (1,1,0)-GARCH (1,0) memenuhi asumsi normalitas dan tidak ada gejala heteroskedastisik. Nilai *p-value* pada Ljung Box R kurang dari nilai  $\alpha$  0,05 sehingga residual model ARIMA(1,1,0)-GARCH(1,0) tidak memenuhi asumsi no autokorelasi. Uji ARCH-LM memiliki nilai *p-value* berada di atas batas signifikansi  $\alpha$  0,05, maka dapat disimpulkan model tersebut tidak mengandung efek ARCH atau dapat dikatakan tidak terdapat gejala heteroskedastik pada residual kuadrat. Meskipun gejala heteroskedastik teratasi namun terdapat asumsi yang dilanggar yaitu asumsi no autokorelasi. Sehingga model ARIMA(1,1,0)-GARCH(1,1) tidak dapat digunakan untuk peramalan harga minyak mentah.

### 5.3 Fuzzy Time Series Markov-Chain

Langkah pertama dalam peramalan harga minyak mentah menggunakan metode *Fuzzy Time Series Markov-Chain* adalah menentukan himpunan semesta  $U$  dengan  $U$  adalah data historis dari harga minyak mentah. Berdasarkan data minyak mentah tersebut didapatkan data nilai minimum ( $D_{min}$ ) sebesar 18,52 US\$ dan nilai maksimum ( $D_{maks}$ ) sebesar 132,83 US\$. Berdasarkan nilai  $D_{min}$  dan  $D_{maks}$  maka dapat ditentukan nilai  $D_1$  dan  $D_2$  yang merupakan bilangan positif, nilai  $D_1 = 0,52$  dan  $D_2 = 0,17$ . Dapat didefinisikan semesta  $U$  sebagai berikut:

$$\begin{aligned}
 U &= [D_{min} - D_1; D_{maks} + D_2] \\
 &= [18,52 - 0,52; 132,83 + 0,17] \\
 &= [18; 133]
 \end{aligned}$$

Setelah didapatkan nilai  $U$ , maka selanjutnya membagi himpunan data  $U$  kedalam beberapa bagian dengan interval ( $n$ ) menggunakan persamaan sebagai berikut:

$$\begin{aligned}
 n &= 1 + 3,3 \log N \\
 n &= 1 + 3,3 \log 204 \\
 n &= 1 + 3,3 (2,30963)
 \end{aligned}$$

$$n = 1 + 7,62178$$

$$n = 8,62178 \approx 9$$

Berdasarkan perhitungan tersebut maka didapatkan interval ( $n$ ) yaitu 9 interval. Himpunan semesta  $U$  yang sudah ditentukan sebelumnya dibagi ke dalam 9 interval yang sama panjang. Hasil dari perhitungan pembagian kedalam 9 interval dapat dilihat sebagai berikut:

$$\begin{aligned} l &= \frac{[(D_{maks} + D_2) - (D_{min} - D_1)]}{n} \\ &= \frac{[(132,83 + 0,17) - (18,52 - 0,52)]}{9} \\ &= \frac{[133 - 18]}{9} \\ &= \frac{115}{9} \\ &= 12,78 \end{aligned}$$

Berdasarkan perhitungan tersebut didapatkan nilai  $l$  atau panjang interval sebesar 12,78. Selanjutnya, dapat dibentuk tabel pembagian data kedalam sembilan kelas data sebagai berikut:

**Tabel 5.23.** Pembagian Semesta

Interval	Batas Bawah	Batas Atas	Nilai Tengah
$U_1$	18	30,78	24,39
$U_2$	30,78	43,56	37,17
$U_3$	43,56	56,33	49,94
$U_4$	56,33	69,11	62,72
$U_5$	69,11	81,89	75,5
$U_6$	81,89	94,67	88,28
$U_7$	94,67	107,44	101,06
$U_8$	107,44	120,22	113,83
$U_9$	120,22	133	126,61

Berdasarkan **Tabel 5.23.** dapat diketahui batas bawah, batas atas, dan nilai tengah dari sembilan kelas interval. Selanjutnya peneliti menentukan himpunan *fuzzy*



pada semesta pembicaraan U. Terdapat sembilan himpunan *fuzzy* yang terbentuk berdasarkan jumlah interval u. Hasil dari himpunan *fuzzy* adalah sebagai berikut:

$$\begin{aligned}
 A_1 &= \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} + \frac{0}{u_9} \\
 A_2 &= \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} + \frac{0}{u_9} \\
 A_3 &= \frac{0}{u_1} + \frac{0,5}{u_2} + \frac{1}{u_3} + \frac{0,5}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} + \frac{0}{u_9} \\
 A_4 &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0,5}{u_3} + \frac{1}{u_4} + \frac{0,5}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} + \frac{0}{u_9} \\
 A_5 &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0,5}{u_4} + \frac{1}{u_5} + \frac{0,5}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} + \frac{0}{u_9} \\
 A_6 &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0,5}{u_5} + \frac{1}{u_6} + \frac{0,5}{u_7} + \frac{0}{u_8} + \frac{0}{u_9} \\
 A_7 &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0,5}{u_6} + \frac{1}{u_7} + \frac{0,5}{u_8} + \frac{0}{u_9} \\
 A_8 &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0,5}{u_7} + \frac{1}{u_8} + \frac{0,5}{u_9} \\
 A_9 &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0,5}{u_8} + \frac{1}{u_9}
 \end{aligned}$$

Setelah mengetahui himpunan *fuzzy* maka selanjutnya melakukan *fuzzyfikasi* pada data historis. Pada tahap *fuzzyfikasi* bertujuan untuk menubah data harga minyak mentah ke dalam bentuk nilai linguistik yang merupakan bentuk interval. Sebagai contoh, data bulan Januari 2001 sebesar 25,96 masuk kedalam interval  $U_1 = [18; 30,84]$ . Setelah menentukan data tersebut termasuk kedalam interval  $U_1$  maka data tersebut difuzzyfikasi kedalam  $A_1$ . Hasil *fuzzyfikasi* data harga minyak mentah sebagai berikut:

**Tabel 5.24.** Data *Fuzzyfikasi*

t	Data	Data Fuzzy	t	Data	Data Fuzzy	t	Data	Data Fuzzy
1	25,96	$A_1$	69	62,12	$A_4$	137	104,09	$A_7$
2	27,24	$A_1$	70	57,91	$A_4$	138	90,73	$A_6$

<b>t</b>	<b>Data</b>	<b>Data Fuzzy</b>	<b>t</b>	<b>Data</b>	<b>Data Fuzzy</b>	<b>t</b>	<b>Data</b>	<b>Data Fuzzy</b>
3	25,02	$A_1$	71	58,14	$A_4$	139	96,75	$A_7$
4	25,72	$A_1$	72	60,99	$A_4$	140	105,27	$A_7$
5	27,55	$A_1$	73	53,52	$A_3$	141	106,28	$A_7$
6	26,97	$A_1$	74	57,56	$A_4$	142	103,41	$A_7$
7	24,8	$A_1$	75	60,6	$A_4$	143	101,17	$A_7$
8	25,82	$A_1$	76	65,06	$A_4$	144	101,19	$A_7$
9	25,21	$A_1$	77	65,16	$A_4$	145	105,1	$A_7$
10	20,73	$A_1$	78	68,19	$A_4$	146	107,64	$A_8$
11	18,69	$A_1$	79	73,6	$A_5$	147	102,52	$A_7$
12	18,52	$A_1$	80	70,13	$A_5$	148	98,85	$A_7$
13	19,15	$A_1$	81	76,76	$A_5$	149	99,37	$A_7$
14	19,98	$A_1$	82	81,97	$A_6$	150	99,74	$A_7$
15	23,64	$A_1$	83	91,34	$A_6$	151	105,26	$A_7$
16	25,43	$A_1$	84	89,52	$A_6$	152	108,16	$A_8$
17	25,67	$A_1$	85	90,69	$A_6$	153	108,76	$A_8$
18	24,49	$A_1$	86	93,39	$A_6$	154	105,43	$A_7$
19	25,75	$A_1$	87	101,84	$A_7$	155	102,63	$A_7$
20	26,78	$A_1$	88	108,76	$A_8$	156	105,48	$A_7$
21	28,28	$A_1$	89	122,63	$A_9$	157	102,1	$A_7$
22	27,53	$A_1$	90	131,52	$A_9$	158	104,83	$A_7$
23	24,54	$A_1$	91	132,83	$A_9$	159	104,04	$A_7$
24	27,89	$A_1$	92	114,57	$A_8$	160	104,87	$A_7$
25	30,75	$A_1$	93	99,66	$A_7$	161	105,71	$A_7$
26	32,88	$A_2$	94	72,69	$A_5$	162	108,37	$A_8$
27	30,36	$A_1$	95	53,97	$A_3$	163	105,23	$A_7$
28	25,56	$A_1$	96	41,34	$A_2$	164	100,05	$A_7$
29	26,06	$A_1$	97	43,86	$A_3$	165	95,85	$A_7$

<b>t</b>	<b>Data</b>	<b>Data Fuzzy</b>	<b>t</b>	<b>Data</b>	<b>Data Fuzzy</b>	<b>t</b>	<b>Data</b>	<b>Data Fuzzy</b>
30	27,92	$A_1$	98	41,84	$A_2$	166	86,08	$A_6$
31	28,59	$A_1$	99	46,65	$A_3$	167	76,99	$A_5$
32	29,68	$A_1$	100	50,28	$A_3$	168	60,7	$A_4$
33	26,88	$A_1$	101	58,15	$A_4$	169	47,11	$A_3$
34	29,01	$A_1$	102	69,15	$A_5$	170	54,79	$A_3$
35	29,12	$A_1$	103	64,67	$A_4$	171	52,83	$A_3$
36	29,97	$A_1$	104	71,63	$A_5$	172	57,54	$A_4$
37	31,37	$A_2$	105	68,35	$A_4$	173	62,51	$A_4$
38	31,33	$A_2$	106	74,08	$A_5$	174	61,31	$A_4$
39	33,67	$A_2$	107	77,55	$A_5$	175	54,34	$A_3$
40	33,71	$A_2$	108	74,88	$A_5$	176	45,69	$A_3$
41	37,56	$A_2$	109	77,12	$A_5$	177	46,28	$A_3$
42	35,54	$A_2$	110	74,76	$A_5$	178	46,96	$A_3$
43	37,89	$A_2$	111	79,3	$A_5$	179	43,11	$A_2$
44	42,08	$A_2$	112	84,18	$A_6$	180	36,57	$A_2$
45	41,6	$A_2$	113	75,62	$A_5$	181	29,78	$A_1$
46	46,88	$A_3$	114	74,73	$A_5$	182	31,03	$A_2$
47	42,13	$A_2$	115	74,58	$A_5$	183	37,34	$A_2$
48	39,04	$A_2$	116	75,83	$A_5$	184	40,75	$A_2$
49	42,97	$A_2$	117	76,12	$A_5$	185	45,94	$A_3$
50	44,82	$A_3$	118	81,72	$A_5$	186	47,69	$A_3$
51	50,94	$A_3$	119	84,53	$A_6$	187	44,13	$A_3$
52	50,64	$A_3$	120	90,01	$A_6$	188	44,87	$A_3$
53	47,83	$A_3$	121	92,69	$A_6$	189	45,04	$A_3$
54	53,89	$A_3$	122	97,91	$A_7$	190	49,29	$A_3$
55	56,37	$A_4$	123	108,65	$A_8$	191	45,26	$A_3$
56	61,89	$A_4$	124	116,24	$A_8$	192	52,62	$A_3$

t	Data	Data Fuzzy	t	Data	Data Fuzzy	t	Data	Data Fuzzy
57	61,69	$A_4$	125	108,07	$A_8$	193	53,59	$A_3$
58	58,19	$A_4$	126	105,85	$A_7$	194	54,35	$A_3$
59	55,04	$A_3$	127	107,92	$A_8$	195	50,9	$A_3$
60	56,43	$A_4$	128	100,49	$A_7$	196	52,16	$A_3$
61	62,46	$A_4$	129	100,82	$A_7$	197	49,89	$A_3$
62	59,7	$A_4$	130	99,85	$A_7$	198	46,17	$A_3$
63	60,93	$A_4$	131	105,41	$A_7$	199	47,66	$A_3$
64	67,97	$A_4$	132	104,23	$A_7$	200	49,94	$A_3$
65	68,68	$A_4$	133	107,07	$A_7$	201	52,95	$A_3$
66	68,29	$A_4$	134	112,69	$A_8$	202	54,92	$A_3$
67	72,45	$A_5$	135	117,79	$A_8$	203	59,93	$A_4$
68	71,81	$A_5$	136	113,67	$A_8$	204	61,19	$A_4$

Setelah melakukan *fuzzyfikasi* maka selanjutnya menentukan *fuzzy logical relation* (FLR) dan *fuzzy logical relation group* (FLRG). *Fuzzy logical relation* adalah hubungan antara setiap urutan data terhadap data berikutnya dalam bentuk himpunan *fuzzy*. Sebagai contoh, data ke-1 yaitu  $A_1$  dan data ke-2 yaitu  $A_1$  maka *fuzzy logical relation* yang didapatkan yaitu  $A_1 \rightarrow A_1$ . Hasil dari *fuzzy logical relation* dapat dilihat sebagai berikut:

**Tabel 5.25.** *Fuzzy Logical Relation (FLR)*

Urutan Data	FLR	Urutan Data	FLR	Urutan Data	FLR
1-2	$A_1 \rightarrow A_1$	69-70	$A_4 \rightarrow A_4$	137-138	$A_6 \rightarrow A_7$
2-3	$A_1 \rightarrow A_1$	70-71	$A_4 \rightarrow A_4$	138-139	$A_7 \rightarrow A_7$
3-4	$A_1 \rightarrow A_1$	71-72	$A_4 \rightarrow A_3$	139-140	$A_7 \rightarrow A_7$
4-5	$A_1 \rightarrow A_1$	72-73	$A_4 \rightarrow A_3$	140-141	$A_7 \rightarrow A_7$
5-6	$A_1 \rightarrow A_1$	73-74	$A_4 \rightarrow A_4$	141-142	$A_7 \rightarrow A_7$

<b>Urutan Data</b>	<b>FLR</b>	<b>Urutan Data</b>	<b>FLR</b>	<b>Urutan Data</b>	<b>FLR</b>
6-7	$A_1 \rightarrow A_1$	74-75	$A_4 \rightarrow A_4$	142-143	$A_7 \rightarrow A_7$
7-8	$A_1 \rightarrow A_1$	75-76	$A_4 \rightarrow A_4$	143-144	$A_7 \rightarrow A_7$
8-9	$A_1 \rightarrow A_1$	76-77	$A_4 \rightarrow A_4$	144-145	$A_7 \rightarrow A_8$
9-10	$A_1 \rightarrow A_1$	77-78	$A_4 \rightarrow A_5$	145-146	$A_8 \rightarrow A_7$
10-11	$A_1 \rightarrow A_1$	78-79	$A_5 \rightarrow A_5$	146-147	$A_7 \rightarrow A_7$
11-12	$A_1 \rightarrow A_1$	79-80	$A_5 \rightarrow A_5$	147-148	$A_7 \rightarrow A_7$
12-13	$A_1 \rightarrow A_1$	80-81	$A_5 \rightarrow A_6$	148-149	$A_7 \rightarrow A_7$
13-14	$A_1 \rightarrow A_1$	81-82	$A_6 \rightarrow A_6$	149-150	$A_7 \rightarrow A_7$
14-15	$A_1 \rightarrow A_1$	82-83	$A_6 \rightarrow A_6$	150-151	$A_7 \rightarrow A_8$
15-16	$A_1 \rightarrow A_1$	83-84	$A_6 \rightarrow A_6$	151-152	$A_8 \rightarrow A_8$
16-17	$A_1 \rightarrow A_1$	84-85	$A_6 \rightarrow A_6$	152-153	$A_8 \rightarrow A_7$
17-18	$A_1 \rightarrow A_1$	85-86	$A_6 \rightarrow A_7$	153-154	$A_7 \rightarrow A_7$
18-19	$A_1 \rightarrow A_1$	86-87	$A_7 \rightarrow A_8$	154-155	$A_7 \rightarrow A_7$
19-20	$A_1 \rightarrow A_1$	87-88	$A_8 \rightarrow A_9$	155-156	$A_7 \rightarrow A_7$
20--21	$A_1 \rightarrow A_1$	88-89	$A_9 \rightarrow A_9$	156-157	$A_7 \rightarrow A_7$
21-22	$A_1 \rightarrow A_1$	89-90	$A_9 \rightarrow A_9$	157-158	$A_7 \rightarrow A_7$
22-23	$A_1 \rightarrow A_1$	90-91	$A_9 \rightarrow A_8$	158-159	$A_7 \rightarrow A_7$
23-24	$A_1 \rightarrow A_1$	91-92	$A_8 \rightarrow A_7$	159-160	$A_7 \rightarrow A_7$
24-25	$A_1 \rightarrow A_2$	92-93	$A_7 \rightarrow A_5$	160-161	$A_7 \rightarrow A_8$
25-26	$A_2 \rightarrow A_1$	93-94	$A_5 \rightarrow A_3$	161=162	$A_8 \rightarrow A_7$
26-27	$A_1 \rightarrow A_1$	94-95	$A_3 \rightarrow A_2$	162-163	$A_7 \rightarrow A_7$
27-28	$A_1 \rightarrow A_1$	95-96	$A_2 \rightarrow A_3$	163-164	$A_7 \rightarrow A_7$
28-29	$A_1 \rightarrow A_1$	96-97	$A_3 \rightarrow A_2$	164-165	$A_7 \rightarrow A_6$
29-30	$A_1 \rightarrow A_1$	97-98	$A_2 \rightarrow A_3$	165-166	$A_6 \rightarrow A_5$
30-31	$A_1 \rightarrow A_1$	98-99	$A_3 \rightarrow A_3$	166-167	$A_5 \rightarrow A_4$
31-32	$A_1 \rightarrow A_1$	99-100	$A_3 \rightarrow A_4$	167-168	$A_4 \rightarrow A_3$
32-33	$A_1 \rightarrow A_1$	100-101	$A_4 \rightarrow A_5$	168-169	$A_3 \rightarrow A_3$

<b>Urutan Data</b>	<b>FLR</b>	<b>Urutan Data</b>	<b>FLR</b>	<b>Urutan Data</b>	<b>FLR</b>
33-34	$A_1 \rightarrow A_1$	101-102	$A_5 \rightarrow A_4$	169-170	$A_3 \rightarrow A_3$
34-35	$A_1 \rightarrow A_1$	102-103	$A_4 \rightarrow A_5$	170-171	$A_3 \rightarrow A_4$
35-36	$A_1 \rightarrow A_2$	103-104	$A_5 \rightarrow A_4$	171-172	$A_4 \rightarrow A_4$
36-37	$A_2 \rightarrow A_2$	104-105	$A_4 \rightarrow A_5$	172-173	$A_4 \rightarrow A_4$
37-38	$A_2 \rightarrow A_2$	105-106	$A_5 \rightarrow A_5$	173-174	$A_4 \rightarrow A_3$
38-39	$A_2 \rightarrow A_2$	106-107	$A_5 \rightarrow A_5$	174-175	$A_3 \rightarrow A_3$
39-40	$A_2 \rightarrow A_2$	107-108	$A_5 \rightarrow A_5$	175-176	$A_3 \rightarrow A_3$
40-41	$A_2 \rightarrow A_2$	108-109	$A_5 \rightarrow A_5$	176-177	$A_3 \rightarrow A_3$
41-42	$A_2 \rightarrow A_2$	109-110	$A_5 \rightarrow A_5$	177-178	$A_3 \rightarrow A_2$
42-43	$A_2 \rightarrow A_2$	110-111	$A_5 \rightarrow A_6$	178-179	$A_2 \rightarrow A_2$
43-44	$A_2 \rightarrow A_2$	111-112	$A_6 \rightarrow A_5$	179-180	$A_2 \rightarrow A_1$
44-45	$A_2 \rightarrow A_3$	112-113	$A_5 \rightarrow A_5$	180-181	$A_1 \rightarrow A_2$
45-46	$A_3 \rightarrow A_2$	113-114	$A_5 \rightarrow A_5$	181-182	$A_2 \rightarrow A_2$
46-47	$A_2 \rightarrow A_2$	114-115	$A_5 \rightarrow A_5$	182-183	$A_2 \rightarrow A_2$
47-48	$A_2 \rightarrow A_2$	115-116	$A_5 \rightarrow A_5$	183-184	$A_2 \rightarrow A_3$
48-49	$A_2 \rightarrow A_3$	116-117	$A_5 \rightarrow A_5$	184-185	$A_3 \rightarrow A_3$
49-50	$A_3 \rightarrow A_3$	117-118	$A_5 \rightarrow A_6$	185-186	$A_3 \rightarrow A_3$
50-51	$A_3 \rightarrow A_3$	118-119	$A_6 \rightarrow A_6$	186-187	$A_3 \rightarrow A_3$
51-52	$A_3 \rightarrow A_3$	119-120	$A_6 \rightarrow A_6$	187-188	$A_3 \rightarrow A_3$
52-53	$A_3 \rightarrow A_3$	120-121	$A_6 \rightarrow A_7$	188-189	$A_3 \rightarrow A_3$
53-54	$A_3 \rightarrow A_4$	121-122	$A_7 \rightarrow A_8$	189-190	$A_3 \rightarrow A_3$
54-55	$A_4 \rightarrow A_4$	122-123	$A_8 \rightarrow A_8$	190-191	$A_3 \rightarrow A_3$
55-56	$A_4 \rightarrow A_4$	123-124	$A_8 \rightarrow A_8$	191-192	$A_3 \rightarrow A_3$
56-57	$A_4 \rightarrow A_4$	124-125	$A_8 \rightarrow A_7$	192-193	$A_3 \rightarrow A_3$
57-58	$A_4 \rightarrow A_3$	125-126	$A_7 \rightarrow A_8$	193-194	$A_3 \rightarrow A_3$
58-59	$A_3 \rightarrow A_4$	126-127	$A_8 \rightarrow A_7$	194-195	$A_3 \rightarrow A_3$
59-60	$A_4 \rightarrow A_4$	127-128	$A_7 \rightarrow A_7$	195-196	$A_3 \rightarrow A_3$

Urutan Data	FLR	Urutan Data	FLR	Urutan Data	FLR
60-61	$A_4 \rightarrow A_4$	128-129	$A_7 \rightarrow A_7$	196-197	$A_3 \rightarrow A_3$
61-62	$A_4 \rightarrow A_4$	129-130	$A_7 \rightarrow A_7$	197-198	$A_3 \rightarrow A_3$
62-63	$A_4 \rightarrow A_4$	130-131	$A_7 \rightarrow A_7$	198-199	$A_3 \rightarrow A_3$
63-64	$A_4 \rightarrow A_4$	131-132	$A_7 \rightarrow A_7$	199-200	$A_3 \rightarrow A_3$
64-65	$A_4 \rightarrow A_4$	132-133	$A_7 \rightarrow A_8$	200-201	$A_3 \rightarrow A_3$
65-66	$A_4 \rightarrow A_5$	133-134	$A_8 \rightarrow A_8$	201-202	$A_3 \rightarrow A_3$
66-67	$A_5 \rightarrow A_5$	134-135	$A_8 \rightarrow A_8$	202-203	$A_3 \rightarrow A_4$
67-68	$A_5 \rightarrow A_4$	135-136	$A_8 \rightarrow A_7$	203-204	$A_4 \rightarrow A_4$
68-69	$A_4 \rightarrow A_4$	136-137	$A_7 \rightarrow A_6$		


Berdasarkan **Tabel 5.25**, selanjutnya dapat ditentukan *Fuzzy Logical relation Group* (FLRG) yang merupakan pengelompokan dari setiap perpindahan *state*, yaitu *state* saat ini (*current state*) dan *state* selanjutnya (*next state*). Pada setiap FLRG terdapat hubungan antara dua *state* yang disebut *current state* dan *next state*. *Current state* adalah nilai yang akan dihitung sebagai nilai peramalan. Sedangkan *next state* merupakan data yang digunakan sebagai syarat untuk memperoleh nilai pada *current state*. FLRG dibentuk untuk mempermudah perhitungan dari FLR yang sudah ada. Hubungan yang terdapat dalam FLRG antara *current state* dan *next state* ini sejalan dengan prinsip dasar rantai *markov*. Hasil dari FLRG yang ada untuk eluruh data dapat dilihat sebagai berikut:

**Tabel 5.26.** *Fuzzy Logical Relation Group* (FLRG)

<i>Current State</i>	<i>Next State</i>
$A_1$	$33(A_1), 3(A_2)$
$A_2$	$2(A_1), 13(A_2), 5(A_3)$
$A_3$	$4(A_2), 27(A_3), 6(A_4)$
$A_4$	$4(A_3), 19(A_4), 5(A_5)$
$A_5$	$(A_3), 4(A_4), 13(A_5), 3(A_6)$
$A_6$	$2(A_5), 6(A_6), 3(A_7)$

<i>Current State</i>	<i>Next State</i>
$A_7$	$(A_5), 2(A_6), 24(A_7), 7(A_8)$
$A_8$	$7(A_7), 5(A_8), 1(A_9)$
$A_9$	$(A_8), 2(A_9)$

Berdasarkan **Tabel 5.26.** yaitu *Fuzzy Logical Relation Group* (FLRG) yang sudah dikelompokkan selanjutnya digunakan untuk membentuk proses transisi peramalan yang menggambarkan hubungan antara setiap *state* dengan *state* lainnya. Hasil dari proses transisi peramalan sebagai berikut:



**Gambar 5.11.** Proses Transisi Peramalan Berdasarkan FLRG

Berdasarkan **Gambar 5.12.** proses transisi menunjukkan hubungan antara *state-state*. Tanda panah yang menunjukkan ke arah dirinya sendiri berarti bahwa *state* tersebut bertransisi terhadap dirinya, *state-state* tersebut adalah  $A_1, A_2, A_3, A_4, A_5, A_6, A_7, A_8,$  dan  $A_9$ . Panah satu menunjukkan bahwa *state* bertransisi dari satu *state* ke *state* berikutnya tetapi tidak berlaku sebaliknya, *state-state* tersebut adalah  $A_5$  dan  $A_7$ . Sedangkan tanda panah dua arah menunjukkan bahwa *state* bertransisi dari satu *state* ke *state* berikutnya dan berlaku hubungan sebaliknya antar *state* tersebut, *state-state* tersebut adalah  $A_1$  dan  $A_2, A_2$  dan  $A_3, A_3$  dan  $A_4, A_4$  dan  $A_5, A_5$  dan  $A_6, A_6$  dan  $A_7, A_7$  dan  $A_8, A_8$  dan  $A_9$ .

Tahap selanjutnya yaitu menghitung hasil peramalan awal. Pada tahap ini dibentuk matriks probabilitas transisi *markov* berorde  $9 \times 9$  dari *fuzzy logical relation*



group yang sudah ditentukan pada tahap sebelumnya yaitu pada **Tabel 5.28.** Hasil dari matriks transisi *markov* adalah sebagai berikut:

$$R = \begin{bmatrix} 0,917 & 0,083 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 \\ 0,100 & 0,650 & 0,250 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 \\ 0,000 & 0,108 & 0,730 & 0,162 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 \\ 0,000 & 0,000 & 0,143 & 0,679 & 0,179 & 0,000 & 0,000 & 0,000 & 0,000 \\ 0,000 & 0,000 & 0,048 & 0,190 & 0,619 & 0,143 & 0,000 & 0,000 & 0,000 \\ 0,000 & 0,000 & 0,000 & 0,000 & 0,182 & 0,545 & 0,273 & 0,000 & 0,000 \\ 0,000 & 0,000 & 0,000 & 0,000 & 0,029 & 0,059 & 0,706 & 0,206 & 0,000 \\ 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,538 & 0,385 & 0,077 \\ 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,000 & 0,333 & 0,667 \end{bmatrix}$$

Setelah mendapatkan matriks probabilitas transisi markov selanjutnya akan dilakukan peramalan dari bulan Februari 2001 dengan melihat data bulan sebelumnya (Januari 2001) dengan *state* bertransisi dari  $A_1 \rightarrow A_1$ . Hasil dari perhitungan peramalan adalah sebagai berikut:

$$\begin{aligned} F(2) &= Y_{(t-1)}P_{11} + m_2P_{12} + m_3P_{13} + m_4P_{14} + m_5P_{15} + m_6P_{16} + m_7P_{17} + \\ &\quad m_8P_{18} + m_9P_{19} \\ &= 25,96 * (0,917) + 37,17*(0,083) \\ &= 26,89 \end{aligned}$$

Dengan menggunakan cara yang sama maka hasil dari peramaan awal seluruhnya adalah sebagai berikut:

**Tabel 5.27.** Hasil Peramalan Awal

t	Peramalan	t	Peramalan	t	Peramalan	t	Peramalan
1	26,89	52	51,14	103	64,50	154	105,27
2	28,07	53	49,09	104	71,28	155	103,29
3	26,03	54	53,51	105	67,00	156	105,31
4	26,67	55	58,87	106	72,80	157	102,92
5	28,35	56	62,61	107	74,94	158	104,85
6	27,82	57	62,48	108	73,29	159	104,29
7	25,83	58	60,10	109	74,68	160	104,88
8	26,77	59	54,35	110	73,22	161	105,47
9	26,21	60	58,91	111	76,03	162	105,83

<b>t</b>	<b>Peramalan</b>	<b>t</b>	<b>Peramalan</b>	<b>t</b>	<b>Peramalan</b>	<b>t</b>	<b>Peramalan</b>
10	22,10	61	63,00	112	87,20	163	105,13
11	20,23	62	61,13	113	73,75	164	101,47
12	20,07	63	61,96	114	73,20	165	98,51
13	20,65	64	66,74	115	73,11	166	88,24
14	21,41	65	67,22	116	73,88	167	74,60
15	24,77	66	66,96	117	74,06	168	61,81
16	26,41	67	71,79	118	77,53	169	48,57
17	26,63	68	71,39	119	87,40	170	54,17
18	25,55	69	62,77	120	90,38	171	52,74
19	26,70	70	59,91	121	91,85	172	59,66
20	27,65	71	60,07	122	99,96	173	63,03
21	29,02	72	62,00	123	105,94	174	62,22
22	28,33	73	53,24	124	108,86	175	53,84
23	25,59	74	59,68	125	105,72	176	47,53
24	28,66	75	61,74	126	105,57	177	47,96
25	31,28	76	64,76	127	105,66	178	48,46
26	36,30	77	64,83	128	101,78	179	42,95
27	30,93	78	66,89	129	102,02	180	38,70
28	26,53	79	72,50	130	101,33	181	30,40
29	26,99	80	70,35	131	105,26	182	35,09
30	28,69	81	74,45	132	104,42	183	39,20
31	29,30	82	86,00	133	106,43	184	41,41
32	30,30	83	91,11	134	107,50	185	47,71
33	27,74	84	90,12	135	109,46	186	48,99
34	29,69	85	90,76	136	107,87	187	46,39
35	29,79	86	92,23	137	104,32	188	46,93
36	30,57	87	102,74	138	90,78	189	47,06
37	35,32	88	105,98	139	99,14	190	50,16
38	35,29	89	119,70	140	105,16	191	47,22

t	Peramalan	t	Peramalan	t	Peramalan	t	Peramalan
39	36,81	90	125,62	141	105,87	192	52,59
40	36,84	91	126,50	142	103,84	193	53,30
41	39,34	92	108,22	143	102,26	194	53,85
42	38,03	93	101,20	144	102,28	195	51,33
43	39,55	94	71,94	145	105,04	196	52,25
44	42,28	95	53,57	146	105,55	197	50,60
45	41,97	96	41,80	147	103,22	198	47,88
46	48,40	97	46,20	148	100,63	199	48,97
47	42,31	98	42,12	149	100,99	200	50,63
48	40,30	99	48,23	150	101,25	201	52,83
49	42,86	100	50,88	151	105,15	202	54,27
50	46,90	101	60,08	152	105,75	203	61,28
51	51,36	102	69,74	153	105,98		

Setelah mendapatkan hasil peramalan awal dalam satuan US\$ maka selanjutnya menghitung nilai penyesuaian pada peramalan (*Ajusted Value*). Tahap ini merupakan tahapan untuk mengurangi besarnya penyimpangan pada hasil peramalan. Sebagai contoh, perhitungan bulan Februari 2010 diketahui mempunyai *fuzzy logical relation* yaitu  $A_1 \rightarrow A_1$ . Keadaan tersebut membuat transisi pada bulan Februari 2001 tidak berubah dan memperoleh nilai penyesuaian sebagai berikut:

$$D_{t1} = 0$$

Setelah mendapatkan nilai *adjusted value* maka langkah selanjutnya adalah menentukan hasil ramalanan yang cocok (*adjusted forecasting value*). Pada tahap ini disebut dengan peramalan akhir karena hasil peramalan awal dijumlahkan dengan nilai penyesuaian yang ada. Sebagai contoh perhitungannya adalah sebagai berikut:

$$\begin{aligned} F'(2) &= F(2) + D_{t1} \\ &= 26,89 \end{aligned}$$

Hasil peramalan akhir harga minyak mentah menggunakan metode *fuzzy time series markov chain* adalah sebagai berikut:


**Tabel 5.28.** Hasil Peramalan Akhir

<b>t</b>	<b>Peramalan</b>	<b>t</b>	<b>Peramalan</b>	<b>t</b>	<b>Peramalan</b>	<b>t</b>	<b>Peramalan</b>
1	26,89	52	51,14	103	77,28	154	105,27
2	28,07	53	49,09	104	58,50	155	103,29
3	26,03	54	66,29	105	79,78	156	105,31
4	26,67	55	58,87	106	72,80	157	102,92
5	28,35	56	62,61	107	74,94	158	104,85
6	27,82	57	62,48	108	73,29	159	104,29
7	25,83	58	47,33	109	74,68	160	104,88
8	26,77	59	67,13	110	73,22	161	118,25
9	26,21	60	58,91	111	88,80	162	93,06
10	22,10	61	63,00	112	74,43	163	105,13
11	20,23	62	61,13	113	73,75	164	101,47
12	20,07	63	61,96	114	73,20	165	85,73
13	20,65	64	66,74	115	73,11	166	75,46
14	21,41	65	67,22	116	73,88	167	61,82
15	24,77	66	79,73	117	74,06	168	49,03
16	26,41	67	71,79	118	90,30	169	48,57
17	26,63	68	58,61	119	87,40	170	54,17
18	25,55	69	62,77	120	90,38	171	65,52
19	26,70	70	59,91	121	104,62	172	59,66
20	27,65	71	60,07	122	112,74	173	63,03
21	29,02	72	49,23	123	105,94	174	49,44
22	28,33	73	66,02	124	108,86	175	53,84
23	25,59	74	59,68	125	92,94	176	47,53
24	28,66	75	61,74	126	118,35	177	47,96
25	44,06	76	64,76	127	92,88	178	35,68
26	23,52	77	64,83	128	101,78	179	42,95

t	Peramalan	t	Peramalan	t	Peramalan	t	Peramalan
27	30,93	78	79,67	129	102,02	180	25,92
28	26,53	79	72,50	130	101,33	181	43,17
29	26,99	80	70,35	131	105,26	182	35,09
30	28,69	81	87,23	132	104,42	183	39,20
31	29,30	82	86,00	133	119,21	184	54,19
32	30,30	83	91,11	134	107,50	185	47,71
33	27,74	84	90,12	135	109,46	186	48,99
34	29,69	85	90,76	136	95,10	187	46,39
35	29,79	86	105,01	137	91,55	188	46,93
36	43,35	87	115,51	138	103,55	189	47,06
37	35,32	88	118,76	139	99,14	190	50,16
38	35,29	89	119,70	140	105,16	191	47,22
39	36,81	90	125,62	141	105,87	192	52,59
40	36,84	91	113,72	142	103,84	193	53,30
41	39,34	92	95,44	143	102,26	194	53,85
42	38,03	93	88,42	144	102,28	195	51,33
43	39,55	94	59,16	145	117,82	196	52,25
44	42,28	95	40,79	146	92,78	197	50,60
45	54,74	96	54,57	147	103,22	198	47,88
46	35,62	97	33,42	148	100,63	199	48,97
47	42,31	98	54,90	149	100,99	200	50,63
48	40,30	99	48,23	150	101,25	201	52,83
49	55,63	100	63,66	151	117,93	202	67,04
50	46,90	101	72,85	152	105,75	203	61,28
51	51,36	102	56,97	153	93,21	204	62,14

Berdasarkan **Tabel 5.28.** dapat diketahui nilai peramalan harga minyak mentah dalam satuan US\$ untuk satu periode kedepan (Januari 2018) adalah sebesar 62,14 US\$. Setelah didapatkan nilai peramalan maka dilanjutkan dengan

mencari nilai akurasi. Nilai MAE yang idadaptkan yaitu 0,39, nilai RMSE yaitu 5,58, dan MAPE yaitu 6,74. Berikut adalah grafik perbandingan antara nilai aktual dengan nilai peramalan minyak mentah:



**Gambar 5.12.** Plot Nilai Aktual dengan Hasil Peramalan

Berdasarkan **Gambar 5.12.** terlihat bahwa grafik hasil peramalan mengikuti pola nilai aktual. Dapat dikatakan bahwa hasil peramalan tersebut baik untuk digunakan.

Berdasarkan hasil analisis peramalan ARIMA-GARCH dan *Fuzzy Time Series Markov Chain* dilakukan pemilihan metode terbaik. Pada analisis ARIMA-GARCH terdapat asumsi yang harus dipenuhi yaitu normalitas, no autokorelasi dan homoskedastisitas namun pada analisis ARIMA-GARCH tersebut terdapat asumsi yang tidak terpenuhi yaitu asumsi no autokorelasi. Oleh karena itu, metode peramalan terbaik yang diperoleh yaitu *Fuzzy Time Series Markov Chain* walaupun nilai MAE, RMSE dan MAPE yang diperoleh lebih besar dari metode ARIMA-GARCH.

## **BAB VI**

### **PENUTUP**

#### **6.1 Kesimpulan**

Berdasarkan pembahasan pada bab sebelumnya maka dapat diperoleh simpulan sebagai berikut:

1. Berdasarkan analisis deskriptif didapatkan bahwa grafik data harga minyak mentah fluktuatif dan mengalami harga paling tinggi pada bulan Juni 2008.
2. Model peramalan menggunakan metode ARIMA-GARCH diperoleh model terbaik yaitu ARIMA(1,1,0)-GARCH(1,0). Hasil peramalan menggunakan metode *Fuzzy Time Series Markov Chain* menggunakan sembilan himpunan *fuzzy* menghasilkan peramalan pada bulan Januari 2018 sebesar 62,14 US\$ dengan MAPE sebesar 6,7%.
3. Metode terbaik yang digunakan untuk meramalkan data harga minyak mentah yaitu *Fuzzy Time Series Markov Chain* meskipun nilai MAPE yang diperoleh lebih besar. Hal tersebut dikarenakan pada metode ARIMA-GARCH terdapat asumsi yang dilanggar yaitu asumsi no autokorelasi.

#### **6.2 Saran**

1. Metode ARIMA memiliki keterbatasan salah satunya yaitu meramalkan hanya untuk jangka waktu pendek. Oleh karena itu, pada penelitian selanjutnya disarankan menggunakan metode peramalan lainnya yang dapat digunakan untuk meramalkan dalam jangka waktu yang panjang seperti *Generalized Regression Neural Network*.
2. Berdasarkan penelitian menggunakan metode ARIMA-GARCH terdapat asumsi yang tidak terpenuhi yaitu no autokorelasi. Oleh karena itu, pada penelitian selanjutnya disarankan menggunakan metode yang dapat mengatasi no autokorelasi seperti ARIMA-EGARCH.
3. Berdasarkan hasil peramalan yang telah dilakukan didapatkan hasil bahwa nilai peramalan akan naik setiap bulannya sehingga disarankan agar Pemerintah

Indonesia selalu melakukan kajian setiap bulannya untuk menghadapi perubahan harga minyak mentah sehingga dapat menyediakan subsidi yang sesuai untuk rakyat.



## DAFTAR PUSTAKA

- Bain, L. J., & M.Engelhardt. (1992). *Introduction to Probability and Mathematical Statistics 2nd Edition*. California: Duxbury Press.
- Boaisha, S. M., & Amaitik, S. M. (2010). Forecasting Model Based on Fuzzy Time Series Approach. *International Arab Conference on Information Technology (ACIT'2010)*, (pp. 1-6). Libya.
- Box, G. E., & Pierce, D. A. (1970). Distribution of Residual Autocorrelation in Autoregressive-Integrated Moving Average Time Series Model. *American Statistical Association*, 1509-1526.
- Caraka, R. E., & Yasin, H. (2014). Peramalan Harga Minyak Dunia dengan General Regression Neural Network (GRNN) dalam Rangka Mengukur Kestabilan Perekonomian Indonesia. *Statistics Center Undip-Ekonomi*.
- Fanstina, R. S., Agoestanto, A., & Hendikawati, P. (2017). Model Hybrid ARIMA-GARCH Untuk Estimasi Volatilitas Harga Emas Menggunakan Software R. *UNNES Journal of Mathematics*, 11-24.
- Fauzannissa, R. A., Yasin, H., & Ispriyanti, D. (2015). Peramalan Harga Minyak Mentah Dunia Menggunakan Metode Radial Basis Function Neural Network. *Gaussian*, 193-202.
- Gideon, A. (2017, November 04). *Bisnis; Energi & Tambang*. Retrieved from liputan6.com: <https://www.liputan6.com/bisnis/read/3150932/harga-minyak-cetak-rekor-apa-penyebabnya>
- Hanke, J., & Wichern, D. W. (2005). *Bussiness Forecasting, 8 Edition*. New Jersey: Prentice-Hall.
- Haryono, E., Widodo, A., & Abusini, S. (2013). Kajian Model Automatic Clustering-Fuzzy Time Series-Markov Chain dalam Memprediksi Data Historis Jumlah Kecelakaan Lalu Lintas di Kota Malang. *Journal Sains Dasar*, 63-71.

- Herawati, S., & Djunaidy, A. (2014). Peramalan Harga Minyak Mentah Menggunakan Gabungan Metode Ensemble Empirical Mode Decomposition (EEMD) dan Jaringan Syaraf Tiruan. *SimanteC*, 61-69.
- Larasati, E. N., Hendikawati, P., & Zaenuri. (2016). Analisis Volatility Forecasting Sembilan Bahan Pokok Menggunakan Metode GARCH Dengan Program R. *UNNES Journal of Mathematics*, 90-99.
- Makridakis. (1988). *Metode dan Aplikasi Peramalan Jilid I. Edisi ke 2. Terjemahan Untung Sus Andriyanto*. Jakarta: Erlangga.
- May, E. (2017). *Tiga alasan Harga Minyak Dunia Turun*. Jakarta: detikFinance.
- Noh, J., Wijono, & Yudaningtyas, E. (2015). Model Average Based FTS Markov Chain untuk Peramalan Penggunaan Bandwidth Jaringan Komputer. *EECCIS*, 31-36.
- Nurkhasanah, L. A., Suparti, & Sudarno. (2015). Perbandingan Metode Runtun Waktu Fuzzy-Chen dan Fuzzy-Markov Chain Untuk Meramalkan Data Inflasi di Indonesia. *Gaussian*, 917-926.
- Pahlavani, M., & Roshan, R. (2015). The Comparison among ARIMA and Hybrid ARIMA-GARCH Models in Forecasting the Exchange Rate of Iran. *Business and Development Studies*, 31-50.
- Rosadi, D. (2011). *Analisis Ekonometrika & Runtun Waktu Terapan dengan R*. Yogyakarta: Andi.
- Supriharyono. (2000). *Pengelolaan Ekosistem Terumbu Karang*. Jakarta: Djambatan.
- Tsaur, R.-C. (2012). A Fuzzy Time Series Markov Chain Model With an Application to Forecast The Exchange Rate Between The Taiwan and US Dollar. *Inovative Computing Information and Control*, 4931-4942.

## LAMPIRAN

**Lampiran 1.** Data Bulanan Harga Minyak Mentah

<b>t</b>	<b>Bulan</b>	<b>Harga</b>	<b>t</b>	<b>Bulan</b>	<b>Harga</b>	<b>t</b>	<b>Bulan</b>	<b>Harga</b>
1	1-01	25,96	69	9-06	62,12	137	5 -12	104,09
2	2-01	27,24	70	10 -06	57,91	138	6-12	90,73
3	3-01	25,02	71	11-06	58,14	139	7-12	96,75
4	4-01	25,72	72	12 -06	60,99	140	8 -12	105,27
5	5 -01	27,55	73	1-07	53,52	141	9-12	106,28
6	6-01	26,97	74	2-07	57,56	142	10 -12	103,41
7	7-01	24,8	75	3-07	60,6	143	11-12	101,17
8	8 -01	25,82	76	4-07	65,06	144	12 -12	101,19
9	9-01	25,21	77	5 -07	65,16	145	1-13	105,1
10	10 -01	20,73	78	6-07	68,19	146	2-13	107,64
11	11-01	18,69	79	7-07	73,6	147	3-13	102,52
12	12 -01	18,52	80	8 -07	70,13	148	4-13	98,85
13	1-02	19,15	81	9-07	76,76	149	5 -13	99,37
14	2-02	19,98	82	10 -07	81,97	150	6-13	99,74
15	3-02	23,64	83	11-07	91,34	151	7-13	105,26
16	4-02	25,43	84	12 -07	89,52	152	8 -13	108,16
17	5 -02	25,67	85	1-08	90,69	153	9-13	108,76
18	6-02	24,49	86	2-08	93,39	154	10 -13	105,43
19	7-02	25,75	87	3-08	101,84	155	11-13	102,63
20	8 -02	26,78	88	4-08	108,76	156	12 -13	105,48
21	9-02	28,28	89	5 -08	122,63	157	1-14	102,1
22	10 -02	27,53	90	6-08	131,52	158	2-14	104,83
23	11-02	24,54	91	7-08	132,83	159	3-14	104,04
24	12 -02	27,89	92	8 -08	114,57	160	4-14	104,87
25	1-03	30,75	93	9-08	99,66	161	5 -14	105,71

<b>t</b>	<b>Bulan</b>	<b>Harga</b>	<b>t</b>	<b>Bulan</b>	<b>Harga</b>	<b>t</b>	<b>Bulan</b>	<b>Harga</b>
26	2-03	32,88	94	10 -08	72,69	162	6-14	108,37
27	3-03	30,36	95	11-08	53,97	163	7-14	105,23
28	4-03	25,56	96	12 -08	41,34	164	8 -14	100,05
29	5 -03	26,06	97	1-09	43,86	165	9-14	95,85
30	6-03	27,92	98	2-09	41,84	166	10 -14	86,08
31	7-03	28,59	99	3-09	46,65	167	11-14	76,99
32	8 -03	29,68	100	4-09	50,28	168	12 -14	60,7
33	9-03	26,88	101	5 -09	58,15	169	1-15	47,11
34	10 -03	29,01	102	6-09	69,15	170	2-15	54,79
35	11-03	29,12	103	7-09	64,67	171	3-15	52,83
36	12 -03	29,97	104	8 -09	71,63	172	4-15	57,54
37	1-04	31,37	105	9-09	68,35	173	5 -15	62,51
38	2-04	31,33	106	10 -09	74,08	174	6-15	61,31
39	3-04	33,67	107	11-09	77,55	175	7-15	54,34
40	4-04	33,71	108	12 -09	74,88	176	8 -15	45,69
41	5 -04	37,56	109	1-10	77,12	177	9-15	46,28
42	6-04	35,54	110	2-10	74,76	178	10 -15	46,96
43	7-04	37,89	111	3-10	79,3	179	11-15	43,11
44	8 -04	42,08	112	4-10	84,18	180	12 -15	36,57
45	9-04	41,6	113	5 -10	75,62	181	1-16	29,78
46	10 -04	46,88	114	6-10	74,73	182	2-16	31,03
47	11-04	42,13	115	7-10	74,58	183	3-16	37,34
48	12 -04	39,04	116	8 -10	75,83	184	4-16	40,75
49	1-05	42,97	117	9-10	76,12	185	5 -16	45,94
50	2-05	44,82	118	10 -10	81,72	186	6-16	47,69
51	3-05	50,94	119	11-10	84,53	187	7-16	44,13
52	4-05	50,64	120	12 -10	90,01	188	8 -16	44,87
53	5 -05	47,83	121	1-11	92,69	189	9-16	45,04
54	6-05	53,89	122	2-11	97,91	190	10 -16	49,29

<b>t</b>	<b>Bulan</b>	<b>Harga</b>	<b>t</b>	<b>Bulan</b>	<b>Harga</b>	<b>t</b>	<b>Bulan</b>	<b>Harga</b>
55	7-05	56,37	123	3-11	108,65	191	11-16	45,26
56	8 -05	61,89	124	4-11	116,24	192	12 -16	52,62
57	9-05	61,69	125	5 -11	108,07	193	1-17	53,59
58	10 -05	58,19	126	6-11	105,85	194	2-17	54,35
59	11-05	55,04	127	7-11	107,92	195	3-17	50,9
60	12 -05	56,43	128	8 -11	100,49	196	4-17	52,16
61	1-06	62,46	129	9-11	100,82	197	5 -17	49,89
62	2-06	59,7	130	10 -11	99,85	198	6-17	46,17
63	3-06	60,93	131	11-11	105,41	199	7-17	47,66
64	4-06	67,97	132	12 -11	104,23	200	8 -17	49,94
65	5 -06	68,68	133	1-12	107,07	201	9-17	52,95
66	6-06	68,29	134	2-12	112,69	202	10 -17	54,92
67	7-06	72,45	135	3-12	117,79	203	11-17	59,93
68	8 -06	71,81	136	4-12	113,67	204	12 -17	61,19