



TESIS - SS14 2501

**PEMODELAN ARIMAX DENGAN SIMETRIK
DAN ASIMETRIK GARCH
(Studi Kasus: Data Inflasi Nasional)**

**SRI ARYANI
NRP 1314 201 715**

**DOSEN PEMBIMBING
Dr.rer.pol. Heri Kuswanto, M.Si
Dr. Suhartono, M.Sc**

**PROGRAM MAGISTER
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2016**



THESIS - SS14 2501

**ARIMAX MODELING WITH SYMMETRIC
AND ASYMMETRIC GARCH
(Case Study: National Inflation Data)**

**SRI ARYANI
NRP 1314 201 715**

**SUPERVISOR
Dr.rer.pol. Heri Kuswanto, M.Si
Dr. Suhartono, M.Sc**

**PROGRAM OF MAGISTER
STATISTICS DEPARTMENT
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY
SURABAYA
2016**

**PEMODELAN ARIMAX DENGAN SIMETRIK DAN ASIMETRIK
GARCH
(Studi Kasus: Data Inflasi Nasional)**


Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si)
di
Institut Teknologi Sepuluh Nopember
Oleh :

**SRI ARYANI
NRP. 1314201715**

Tanggal Ujian : 22 Januari 2016
Periode Wisuda : Maret 2016


Disetujui Oleh :

1. 
Dr. rer.pol. Heri Kuswanto, M.Si (Pembimbing)
NIP: 19820326 200312 1 004

2. 
Dr. Suhartono, M.Sc (Pembimbing)
NIP: 19710929 199512 1 001

3. 
Dr. Wahyu Wibowo, M.Si (Penguji)
NIP: 19740328 199802 1 001

4. 
Dr. Pudji Ismartini, M.App.Stat (Penguji)
NIP 19710815 199312 2 002


Direktur Program Pascasarjana

Prof. Ir. Djaufar Manfaat, M.Sc, Ph.D
NIP 19601202 198701 1 001

PEMODELAN ARIMAX DENGAN SIMETRIK DAN ASIMETRIK GARCH (Studi Kasus: Data Inflasi Nasional)


Nama mahasiswa : Sri Aryani
NRP : 1314201715

Pembimbing : Dr. rer.pol. Heri Kuswanto, M.Si
Co-Pembimbing : Dr. Suhartono, M.Sc

ABSTRAK

Salah satu pemodelan data *time series* adalah model ARIMA yang mengasumsikan volatilitas konstan, tetapi terdapat banyak kasus data ekonomi dan keuangan memiliki volatilitas tidak konstan. Hal tersebut mengakibatkan terjadinya masalah heteroskedastisitas pada residual sehingga dibutuhkan model *Generalized Autoregressive Conditional Heteroschedasticity* (GARCH). Selain heteroskedastisitas, salah satu permasalahan yang terdapat pada residual adalah adanya efek asimetris atau *leverage effect*. Untuk itu diperlukan pemodelan asimetrik GARCH. Penelitian ini bertujuan untuk membandingkan tingkat keakuratan metode GARCH, Glosten Jagannathan Runkle-GARCH (GJR-GARCH) dan *Asymmetric Power ARCH* (APARCH) dengan menggunakan studi simulasi dan membandingkan kinerja peramalan inflasi menggunakan ARIMAX dengan GARCH, GJR-GARCH, dan APARCH. Data yang digunakan dalam penelitian ini adalah data inflasi Indonesia dan harga minyak dunia bulan Januari 1990-Desember 2015. Untuk membentuk model ramalan, data dibagi menjadi *in-sample* dan *out-sample*. Data *in-sample* terdiri dari data inflasi Indonesia dan harga minyak dunia bulan Januari 1990-Desember 2014 dan data *out-of-sample* bulan Januari 2015-Desember 2015. Penelitian ini memberikan hasil pada simulasi data *in-sample*, GARCH(1,1) dan GJR-GARCH(1,1) lebih konsisten daripada APARCH(1,1) dalam pemodelan. *Power* uji asimetrik kurang dari 50% pada sampel kecil (200) maupun besar (1.000) dalam mendeteksi efek asimetrik. Pemodelan dan peramalan terbaik inflasi adalah menggunakan metode ARIMAX-GARCH(1,1) karena akan memberikan selang kepercayaan pendugaan inflasi yang lebih pendek dibandingkan dengan ARIMAX dan ARIMAX-APARCH(1,1). Rata-rata ramalan *standard error* pada model ARIMAX sebesar 0,99848, lebih besar dibandingkan rata-rata ramalan *standard error* pada model ARIMAX-GARCH(1,1) dan ARIMAX-APARCH(1,1) yang masing-masing sebesar 0,67981 dan 0,75648.

Kata Kunci: ARIMAX, GARCH, GJR-GARCH, APARCH, inflasi




ARIMAX MODELING WITH SYMMETRIC AND ASYMMETRIC GARCH (Case Study: National Inflation Data)

Name : Sri Aryani
NRP : 1314201715
Supervisor : Dr. rer.pol. Heri Kuswanto, M.Si
Co-Supervisor : Dr. Suhartono, M.Sc

ABSTRACT

One modeling of time series data is ARIMA model that assumes constant volatility, but there are many cases of economic and financial data volatility that is not constant. This resulted heteroskedasticity problems in residual that needed Generalized Autoregressive Conditional Heteroschedasticity (GARCH) model. Besides heteroscedasticity, one of the problems contained in the residuals is the asymmetric effect or leverage effect. It is necessary for modeling asymmetric GARCH. This study aimed to compare the accuracy of GARCH, Glosten Jagannathan Runkle-GARCH (GJR-GARCH) and Asymmetric Power ARCH (APARCH) using simulation studies and comparing performance using ARIMAX inflation forecasting with GARCH, GJR-GARCH, and APARCH. The data used in this study are the national inflation data and world oil prices in January 1990-December 2015. To establish the forecast model, the data is divided into in-sample and out-of-sample. In-sample data are consisted of national inflation data and oil prices in January 1990 to Desember 2014 and out-of-sample data is from January 2015 to December 2015. This study shows the results that from data simulation, GARCH(1,1) and GJR-GARCH(1,1) are more consistent than APARCH (1,1) in the modeling. Power test asymmetric less than 50% on a small sample (200) and large (1,000) in detecting the asymmetric effect. The best method of modeling and forecasting inflation is ARIMAX-GARCH (1,1) because it will give confidence interval estimate of inflation which is shorter than the ARIMAX and ARIMAX-APARCH (1,1). The mean of standard error forecasting in ARIMAX model is 0.99848, greater than the mean of standard error forecasting on the model ARIMAX-GARCH (1,1) and ARIMAX-APARCH (1,1) are 0.67981 and 0.75648 respectively.

Keywords: ARIMAX, GARCH, GJR-GARCH, APARCH, inflation



KATA PENGANTAR

Alhamdulillah Robbil ‘Aalamiin, puji syukur atas kehadiran Allah SWT, Dzat Yang Maha Esa, atas segala karunia nikmat, taufik dan hidayah-Nya kepada penulis sehingga tesis yang berjudul **“PEMODELAN ARIMAX DENGAN SIMETRIK DAN ASIMETRIK GARCH, Studi Kasus: Data Inflasi Nasional”** dapat terselesaikan tepat waktu. Dalam penyusunan tesis ini, penulis memperoleh banyak bantuan dari berbagai pihak, baik secara langsung maupun tidak langsung. Untuk itu pada kesempatan ini penulis ingin menyampaikan penghargaan dan ucapan terima kasih yang sebesar-besarnya kepada:

1. Badan Pusat Statistik (BPS) yang telah memberi kesempatan serta beasiswa kepada penulis untuk melanjutkan studi program S2 di ITS.
2. Bapak Dr.rer.pol. Heri Kuswanto, M.Si dan Bapak Dr. Suhartono, M.Sc selaku dosen pembimbing yang telah banyak meluangkan waktu serta dengan penuh kesabaran dan keikhlasannya dalam memberikan bimbingan, saran dan masukan serta motivasi dalam penyusunan tesis ini.
3. Bapak Dr. Suhartono, M.Sc selaku Ketua Jurusan Statistika FMIPA ITS Surabaya yang telah memberikan fasilitas dan pelayanan yang baik selama penulis menyelesaikan pendidikan S2 di kampus tercinta ini.
4. Bapak Dr. Wahyu Wibowo, M.Si dan Ibu Dr. Pudji Ismartini, M.App.Stat yang telah banyak memberikan koreksi, saran, dan masukan dalam penyusunan tesis ini.
5. Ibu Santi Wulan Purnami, M.Si, Ph.D, selaku dosen wali yang telah banyak memberikan bimbingan, masukan, dan arahan selama menempuh pendidikan di Program Studi Magister Jurusan Statistika ITS Surabaya.
6. Bapak dan Ibu dosen Statistika atas pembekalan ilmu dan pengalamannya selama penulis menempuh pendidikan di Program Studi Magister Jurusan Statistika FMIPA ITS Surabaya.
7. Kedua orangtua tercinta, yang telah membesarkan, mendidik dan mendoakan dengan penuh keikhlasan dan kasih sayangnya, kakak-kakak serta semua keluarga yang telah memberikan dukungan, motivasi, semangat dan doanya.

8. Santi Eksiandayani, "*my partner in crime*", atas segala kebaikan, canda tawa, dukungan, motivasi, kekompakan, serta kebersamaannya. Semoga Allah SWT berkenan mempertemukan lagi di masa mendatang.
9. Teman-teman kos ARH48: Mbak Dian, Mpih, Mbak Nike, Mbak Widi, Yanti, dan Mbak Afni, untuk segala bantuan, kerjasama, keceriaan, dan kebersamaannya selama ini. Semoga dapat berjumpa lagi di lain kesempatan.
10. Teman-teman BPS angkatan 8, Vivin, Maul, Mbak Nita, Aan, Mas Arip, Mas Mur, Mas Ali, Fatih, Mas Duto, Bang Rory, Bang Henri, Kak Zablin, terima kasih atas segala bantuannya, kebersamaan dan kekompakannya selama menjalani pendidikan di ITS, senang bisa bertemu dan mengenal teman-teman semua, semoga dapat berjumpa lagi di lain kesempatan.
11. Teman-teman reguler angkatan 2014, teman-teman BPS angkatan 9, Pak Irul, dan Bagian Administarsi Jurusan Statistika FMIPA ITS beserta semua pihak yang tidak bisa disebutkan satu per satu terima kasih atas bantuannya.

Akhir kata, semoga segala kebaikan yang telah diberikan kepada penulis, mendapatkan pahala dari Allah SWT. Penulis menyadari bahwa tesis ini masih jauh dari kesempurnaan, untuk itu kritik dan saran yang bersifat membangun penulis harapkan demi perbaikan pada masa yang akan datang. Penulis berharap semoga tesis ini dapat memberikan manfaat kepada pembaca serta menambah wawasan keilmuan untuk penulis sendiri. Aamiin Yaa Robbal 'Aalamiin.

Surabaya, Januari 2016

Penulis

DAFTAR ISI

HALAMAN JUDUL.....	i
LEMBAR PENGESAHAN	v
ABSTRAK.....	vii
ABSTRACT.....	ix
KATA PENGANTAR	xi
DAFTAR ISI.....	xiii
DAFTAR TABEL.....	xv
DAFTAR GAMBAR.....	xix
DAFTAR LAMPIRAN.....	xxiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	6
1.3 Tujuan Penelitian.....	6
1.4 Manfaat Penelitian.....	6
1.5 Batasan Masalah.....	6
BAB II TINJAUAN PUSTAKA.....	7
2.1 Model <i>Time Series</i>	7
2.1.1 Stasioneritas.....	7
2.1.2 <i>Autocovariance dan Autocorrelation Function (ACF)</i>	8
2.1.3 <i>Partial Autocovariance dan Autocorrelation Function (PACF)</i>	9
2.2 Metode ARIMA Box-Jenkins.....	9
2.2.1 Identifikasi.....	9
2.2.2 Uji Signifikansi Parameter.....	11
2.2.3 Uji Kesesuaian Model.....	12
2.3 Deteksi <i>Outlier</i>	13
2.3.1 <i>Additive Outlier (AO)</i>	13
2.3.2 <i>Innovational Outlier (IO)</i>	14
2.3.3 <i>Level Shift (LS)</i>	15
2.3.4 <i>Temporary Change (TC)</i>	15

2.4	ARIMA with Exogenous Factor (ARIMAX).....	15
2.5	Model Heteroskedastisitas Deret Waktu.....	20
2.5.1	Uji Heteroskedastisitas.....	20
2.5.2	Model Autoregressive Conditional Heteroscedasticity (ARCH)..	21
2.5.3	Penaksiran Model ARCH(1).....	23
2.5.4	Model Generalized ARCH (GARCH)	24
2.5.5	Model Glosten, Jagannathan dan Runkle GARCH	26
2.5.6	Model Asymmetric Power ARCH (APARCH).....	27
2.6	Pemilihan Model Terbaik.....	29
2.7	Inflasi.....	29
BAB III METODOLOGI PENELITIAN.....		33
3.1	Data dan Variabel.....	33
3.1.1	Sumber Data.....	33
3.1.2	Variabel Penelitian.....	33
3.2	Metode Analisis Data.....	33
3.2.1	Studi Simulasi	33
3.2.2	Aplikasi Data Riil	34
BAB IV HASIL DAN PEMBAHASAN.....		39
4.1	Studi Simulasi.....	39
4.1.1	Simulasi Data Bangkitan.....	39
4.1.2	Hasil Simulasi.....	41
4.2	Data Inflasi Nasional.....	76
4.2.1	Gambaran Umum Inflasi	76
4.2.2	Model ARIMA dan ARIMA Fungsi Transfer.....	80
4.2.3	Model GARCH, GJR-GARCH, dan APARCH.....	92
BAB V KESIMPULAN DAN SARAN		111
5.1	Kesimpulan	111
5.2	Saran	112
DAFTAR PUSTAKA		113
LAMPIRAN		117

DAFTAR TABEL

	Halaman
Tabel 4.1 Setting parameter untuk data simulasi.....	40
Tabel 4.2 Setting parameter untuk data simulasi <i>power</i> dan <i>size</i> uji asimetrik	41
Tabel 4.3 Perbandingan AIC model skenario 1 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	42
Tabel 4.4 Perbandingan AIC model skenario 2 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	44
Tabel 4.5 Perbandingan AIC model skenario 3 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	46
Tabel 4.6 Perbandingan AIC model skenario 4 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	48
Tabel 4.7 Perbandingan AIC model skenario 5 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	50
Tabel 4.8 Perbandingan AIC model skenario 6 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	52
Tabel 4.9 Perbandingan AIC model skenario 7 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	54
Tabel 4.10 Perbandingan AIC model skenario 8 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	56
Tabel 4.11 Perbandingan AIC model skenario 9 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	58
Tabel 4.12 Perbandingan AIC model skenario 10 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	60
Tabel 4.13 Perbandingan AIC model skenario 11 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	62
Tabel 4.14 Perbandingan AIC model skenario 12 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	64

Tabel 4.15	Perbandingan AIC model skenario 13 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	65
Tabel 4.16	Perbandingan AIC model skenario 14 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	66
Tabel 4.17	Perbandingan AIC model skenario 15 untuk data <i>in-sample</i> pada model GARCH, GJR-GARCH, dan APARCH.....	69
Tabel 4.18	Ringkasan akurasi hasil simulasi pada jumlah sampel 200.....	70
Tabel 4.19	Ringkasan akurasi hasil simulasi pada jumlah sampel 200.....	71
Tabel 4.20	Pesentase hasil uji asimetrik untuk simulasi model GARCH(1,1).....	72
Tabel 4.21	Pesentase hasil uji asimetrik untuk simulasi model GJR-GARCH(1,1).....	74
Tabel 4.22	Pesentase hasil uji asimetrik untuk simulasi model APARCH(1,1).....	75
Tabel 4.23	Uji signifikansi parameter model ARIMA inflasi nasional.....	81
Tabel 4.24	Uji Residual <i>White Noise</i> Model ARIMA Inflasi nasional.....	81
Tabel 4.25	Identifikasi <i>outlier</i> data inflasi nasional.....	83
Tabel 4.26	Uji signifikansi parameter model ARIMA inflasi nasional.....	83
Tabel 4.27	Uji <i>White Noise</i> residual model ARIMA inflasi nasional.....	84
Tabel 4.28	Perbandingan data <i>out-of-sample</i> dan hasil ramalan model ARIMA Januari-Desember 2015.....	85
Tabel 4.29	Uji signifikansi parameter ARIMA perubahan harga minyak dunia.....	87
Tabel 4.30	Uji <i>white noise</i> model ARIMA perubahan harga minyak dunia.....	87

Tabel 4.31	Uji signifikansi model ARIMA fungsi transfer.....	89
Tabel 4.32	Uji <i>White noise</i> model ARIMA fungsi transfer.....	90
Tabel 4.33	Uji signifikansi model ARIMA fungsi transfer setelah deteksi <i>outlier</i>	90
Tabel 4.34	Uji <i>White noise</i> model ARIMA fungsi transfer dengan <i>outlier</i>	91
Tabel 4.35	<i>Outlier</i> model ARIMA fungsi transfer.....	92
Tabel 4.36	Uji heteroskedastisitas residual model ARIMA inflasi nasional.....	93
Tabel 4.37	Uji signifikansi parameter model ARCH(1).....	94
Tabel 4.38	Uji <i>white noise</i> model ARCH(1).....	95
Tabel 4.39	Uji <i>goodness of fit</i> distribusi residual model ARCH(1).....	95
Tabel 4.40	Uji signifikansi parameter model ARCH(2).....	96
Tabel 4.41	Uji signifikansi parameter model GARCH(0,1).....	96
Tabel 4.42	Uji signifikansi parameter model GARCH(0,2).....	97
Tabel 4.43	Uji signifikansi parameter model GARCH(1,1).....	97
Tabel 4.44	Uji <i>Ljung-Box</i> model GARCH(1,1).....	98
Tabel 4.45	Uji <i>goodness of fit</i> distribusi residual model GARCH(1,1)..	98
Tabel 4.46	Uji ARCH LM residual model GARCH(1,1).....	99
Tabel 4.47	Uji asimterik residual model GARCH(1,1).....	99
Tabel 4.48	Uji signifikansi parameter model GARCH(1,2).....	100
Tabel 4.49	Uji signifikansi parameter model GARCH(2,1).....	100
Tabel 4.50	Uji signifikansi parameter model GARCH(2,2).....	101
Tabel 4.51	Ringkasan hasil uji signifikansi parameter model GARCH.....	101
Tabel 4.52	Uji signifikansi parameter model GJR-GARCH(1,1).....	102
Tabel 4.53	Uji <i>Ljung-Box</i> model GJR-GARCH(1,1).....	103
Tabel 4.54	Uji <i>goodness of fit</i> distribusi residual model GJR GARCH(1,1).....	103
Tabel 4.55	Uji ARCH LM residual model GJR-GARCH(1,1).....	104
Tabel 4.56	Uji signifikansi parameter model APARCH(1,1).....	104

Tabel 4.57	Uji Ljung-Box model APARCH(1,1).....	105
Tabel 4.58	Uji Ljung-Box model APARCH(1,1).....	106
Tabel 4.59	Uji ARCH LM residual model APARCH(1,1).....	106
Tabel 4.60	Perbandingan hasil ramalan sigma pada GARCH(1,1) dan APARCH(1,1).....	108
Tabel 4.61	Perbandingan hasil interval ramalan ARIMAX, ARIMAX- GARCH(1,1), dan ARIMAX-APARCH(1,1).....	109


DAFTAR GAMBAR

Halaman

Gambar 3.1	Diagram alir pemodelan data dengan metode ARIMAX-GARCH.....	38
Gambar 4.1	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 1.....	41
Gambar 4.2	<i>News impact curve</i> pada model skenario 1.....	43
Gambar 4.3	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 2.....	43
Gambar 4.4	<i>News impact curve</i> pada model skenario 2.....	45
Gambar 4.5	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 3.....	45
Gambar 4.6	<i>News impact curve</i> pada model skenario 3.....	47
Gambar 4.7	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 4.....	47
Gambar 4.8	<i>News impact curve</i> pada model skenario 4.....	49
Gambar 4.9	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 5.....	49
Gambar 4.10	<i>News impact curve</i> pada model skenario 5.....	51
Gambar 4.11	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 6.....	51
Gambar 4.12	<i>News impact curve</i> pada model skenario 6.....	53
Gambar 4.13	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 7.....	53
Gambar 4.14	<i>News impact curve</i> pada model skenario 7.....	55
Gambar 4.15	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 8.....	55
Gambar 4.16	<i>News impact curve</i> pada model skenario 8.....	57


Gambar 4.17	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 9.....	57
Gambar 4.18	<i>News impact curve</i> pada model skenario 9.....	59
Gambar 4.19	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 10.....	59
Gambar 4.20	<i>News impact curve</i> pada model skenario 10.....	60
Gambar 4.21	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 11.....	61
Gambar 4.22	<i>News impact curve</i> pada model skenario 11.....	62
Gambar 4.23	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 12.....	63
Gambar 4.24	<i>News impact curve</i> pada model skenario 12.....	64
Gambar 4.25	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 13.....	65
Gambar 4.26	<i>News impact curve</i> pada model skenario 13.....	66
Gambar 4.27	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 14.....	67
Gambar 4.28	<i>News impact curve</i> pada model skenario 13.....	68
Gambar 4.29	Plot ACF observasi, ACF dari kuadrat observasi, <i>time series</i> , dan plot sigma dari model skenario 15.....	68
Gambar 4.30	<i>News impact curve</i> pada model skenario 15.....	69
Gambar 4.31	Plot series data inflasi nasional Januari 1990-Desember 2015.....	77
Gambar 4.32	Deskripsi inflasi bulanan nasional Januari 1990-Desember 2015.....	77
Gambar 4.33	Plot series data perubahan harga minyak dunia Januari 1990- Desember 2015.....	78
Gambar 4.34	Deskripsi persentase perubahan harga minyak dunia Januari 1990-Desember 2015.....	79
Gambar 4.35	Plot ACF (a) dan PACF (b) data inflasi nasional.....	80

Gambar 4.36	Plot ACF (a) dan PACF (b) residual ARIMA inflasi.....	82
Gambar 4.37	<i>Qq</i> -plot residual inflasi.....	82
Gambar 4.38	Plot residual inflasi nasional setelah deteksi <i>outlier</i>	84
Gambar 4.39	Plot ACF dan PACF perubahan harga minyak dunia.....	86
Gambar 4.40	Plot ACF dan PACF residual model ARIMA perubahan harga minyak dunia.....	87
Gambar 4.41	<i>Qq plot</i> residual model ARIMA perubahan harga minyak dunia.....	88
Gambar 4.42	CCF perubahan harga minyak dunia dan inflasi.....	89
Gambar 4.43	Plot residual model ARIMAX setelah deteksi <i>outlier</i>	91
Gambar 4.44	<i>Series</i> residual dan residual kuadrat dari model ARIMA inflasi.....	93
Gambar 4.45	Plot acf dan pacf residual (a) dan plot acf dan pacf residual kuadrat (b) dari model ARIMA inflasi.....	94
Gambar 4.46	<i>News impact curve</i> model GARCH(1,1) dan APARCH(1,1)....	107
Gambar 4.47	Ramalan interval inflasi Januari-Desember 2015.....	109



DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Inflasi Indonesia dan Persentase Perubahan Rata-rata Harga Minyak Dunia Januari 1990 sampai dengan Desember 2015.....	117
Lampiran 2 Sintaks Program R untuk Data Bangkitan GARCH(1,1).....	124
Lampiran 3 Sintaks Program R untuk Data Bangkitan GJR-GARCH(1,1).....	125
Lampiran 4 Sintaks Program R untuk Data Bangkitan APARCH(1,1).....	126
Lampiran 5 Sintaks Program R untuk Menghitung <i>Power</i> Pengujian Asimetrik.....	127
Lampiran 6 Sintaks Program R untuk Pemodelan GARCH(1,1) Inflasi.....	129
Lampiran 7 Sintaks Program R untuk Pemodelan GJR-GARCH(1,1) Inflasi.....	130
Lampiran 8 Sintaks Program R untuk Pemodelan APARCH(1,1) Inflasi.....	131
Lampiran 9 Hasil Uji ADF Data Inflasi	132
Lampiran 10 Hasil Uji ADF Data Persentase Perubahan Rata-rata Harga Minyak Dunia	133
Lampiran 11 Output ARCH(1)	134
Lampiran 12 Output ARCH(2)	135
Lampiran 13 Output GARCH(0,1)	136
Lampiran 14 Output GARCH(0,2)	137
Lampiran 15 Output GARCH(1,1)	138
Lampiran 16 Output GARCH(1,2)	139
Lampiran 17 Output GARCH(2,1)	140
Lampiran 18 Output GARCH(2,2)	141
Lampiran 19 Output GJR-GARCH(1,1)	142
Lampiran 20 Output APARCH(0,1)	143



BAB 1

PENDAHULUAN

1.1 Latar Belakang

Kehidupan perekonomian suatu negara tidak terlepas dari masalah ekonomi makro, antara lain: pertumbuhan ekonomi, inflasi, pengangguran, kestabilan kegiatan ekonomi serta neraca perdagangan dan neraca pembayaran (Sukirno, 2012). Secara sederhana inflasi diartikan sebagai meningkatnya harga-harga secara umum dan terus menerus. Menurut Badan Pusat Statistik (BPS), inflasi merupakan kenaikan harga barang dan jasa secara umum dimana barang dan jasa tersebut merupakan kebutuhan pokok masyarakat atau turunnya daya jual mata uang suatu negara. Jika perkembangan inflasi bergerak tanpa kendali akan mengakibatkan nilai uang akan menjadi rendah. Inflasi yang tinggi sangat penting diperhatikan mengingat dampaknya bagi perekonomian yang dapat menimbulkan ketidakstabilan ekonomi, pertumbuhan ekonomi yang lambat, dan pengangguran yang meningkat.

Dalam perkembangannya, menurut BPS, inflasi di Indonesia dapat dikelompokkan berdasarkan pengaruhnya ke dalam tiga komponen disagregasi inflasi, yaitu inflasi inti (*core inflation*), inflasi komponen bergejolak (*volatile food inflation*), dan inflasi komponen harga yang diatur pemerintah (*administered price inflation*). Disagregasi inflasi tersebut dilakukan untuk menghasilkan suatu indikator inflasi yang lebih menggambarkan pengaruh dari faktor yang bersifat fundamental.

Secara umum, inflasi timbul karena adanya tekanan dari sisi penawaran (*cost push inflation*) dan dari sisi permintaan (*demand pull inflation*). Dalam perkembangannya, faktor lain yang juga dapat memengaruhi tingkat inflasi adalah naiknya gaji pegawai negeri, adanya hari besar keagamaan serta kebijakan pemerintah dalam penyesuaian harga Bahan Bakar Minyak (BBM) dan Tarif Dasar Listrik (TDL). Faktor-faktor terjadinya *cost push inflation* dapat disebabkan oleh depresiasi nilai tukar, dampak inflasi luar negeri terutama negara-negara partner dagang, peningkatan harga-harga komoditi yang diatur pemerintah

(*administered price*), dan terjadi *negative supply shocks* akibat bencana alam dan terganggunya distribusi.

Kenaikan harga minyak mentah di pasar internasional juga menyebabkan meningkatnya inflasi. Harga minyak mentah yang lebih tinggi akan segera diikuti oleh naiknya harga produk-produk minyak, seperti bensin dan minyak bakar yang digunakan konsumen (Cologni dan Manera, 2008). Lebih lanjut, karena ada upaya mensubstitusi minyak dengan energi bentuk lain, harga sumber energi alternatif juga akan meningkat. Nizar (2012) melakukan penelitian mengenai dampak fluktuasi harga minyak dunia terhadap perekonomian Indonesia menggunakan metode *Vector Auto Regressive* (VAR), menunjukkan hasil bahwa fluktuasi harga minyak dunia memberi dampak positif terhadap laju inflasi selama satu tahun. Sementara itu Saleem dan Ahmad (2015) melakukan penelitian serupa di Pakistan dan menunjukkan hasil bahwa fluktuasi harga minyak dunia berdampak positif terhadap inflasi di Pakistan.

Penghitungan inflasi didasarkan pada perubahan indeks harga konsumen (IHK) yang merupakan suatu indeks yang menghitung rata-rata perubahan harga dalam suatu periode, dari suatu kumpulan barang dan jasa yang dikonsumsi oleh penduduk/rumah tangga dalam kurun waktu tertentu. Salah satu metode analisis yang dapat digunakan untuk memodelkan dan meramalkan angka inflasi adalah analisis deret waktu.

Pengamatan-pengamatan dalam deret waktu seringkali dipengaruhi oleh kejadian-kejadian yang tidak biasa, gangguan, krisis politik dan ekonomi, maupun kesalahan-kesalahan dalam pencatatan maupun perekaman data. Kejadian-kejadian tersebut biasanya disebut sebagai *outlier*. Keberadaan *outlier* mempunyai pengaruh substansial terhadap peramalan maupun spesifikasi model. Karena dampak yang begitu besar tersebut, penting untuk melakukan suatu prosedur untuk mendeteksi dan mengatasi *outlier*.

Penelitian terkait peramalan inflasi di Indonesia dengan berbagai metode analisis deret waktu telah banyak dilakukan. Suryono (2009) memodelkan dan meramalkan inflasi nasional dengan metode *Auto Regressive Integrated Moving Average* (ARIMA) dan *ARIMAX-Neural Network* (ARIMAX-NN) dengan hasil bahwa model ARIMAX-NN merupakan model terbaik yang digunakan. Rokimah

(2012) melakukan peramalan inflasi Jawa Timur dengan pendekatan fungsi transfer multi input dan *Artificial Neural Network* (ANN) yang mendapatkan hasil bahwa metode fungsi transfer multi input merupakan metode terbaik untuk meramalkan nilai inflasi umum dua sampai dengan delapan, sepuluh dan sebelas langkah ke depan sedangkan metode ANN merupakan metode terbaik untuk meramalkan nilai inflasi umum satu, sembilan, dan dua belas langkah ke depan. Juwariyanto (2012) menggunakan model *Bayesian Markov Switching Auto Regressive Conditional Heteroskedasticity* (*Bayesian MS-ARCH*) untuk meramalkan inflasi Indonesia dengan hasil bahwa peramalan *conditional mean* dan *conditional variance* dengan menggunakan model *Bayesian MS-ARCH* lebih baik daripada model *Bayesian Generalized ARCH* (*Bayesian GARCH*). Selanjutnya Rukini (2014) memodelkan inflasi kota Denpasar dengan metode ARIMAX dan deteksi GARCH dengan hasil bahwa tidak terdapat heteroskedastisitas pada model ARIMAX yang terbentuk. Affandi (2014) melakukan pemodelan dengan *Vector Auto Regressive* (VAR) dan *Generalize Space Time Auto Regressive* (GSTAR) untuk meramalkan inflasi kota Jayapura, Sorong, dan Manokwari yang menunjukkan bahwa model terbaik adalah VAR.

Penelitian di luar negeri mengenai inflasi diantaranya adalah Bidarkota dan McCulloch (1998) yang melakukan peramalan inflasi Amerika Serikat menggunakan model univariat *state space* dengan *symmetric stable shocks* dengan hasil bahwa model *stable shocks* untuk *level shift outlier* memberikan hasil estimasi yang lebih akurat. Hyung *et al.* (2006) melakukan peramalan inflasi menggunakan model *structural breaks* dan *long memory* yang memberikan hasil bahwa model tersebut lebih baik daripada model linier *auto regressive*. Kichian dan Rumler (2014) memodelkan inflasi menggunakan *New Keynesian Phillips Curve* (NKPC) dan menunjukkan bahwa pendekatan semi structural NKPC memberikan hasil peramalan yang lebih baik daripada metode konvensional. Selanjutnya Maheu dan Song (2014) meramalkan inflasi dengan model *structural breaks* dengan hasil bahwa model terbaik untuk peramalan inflasi Kanada adalah model *structural breaks*. Malhotra dan Krishna (2015) menggunakan DCC-GARCH untuk menganalisis dampak fluktuasi harga minyak mentah dunia

terhadap inflasi dan suku bunga di India, dengan hasil bahwa fluktuasi harga minyak mentah dunia memiliki dampak signifikan terhadap inflasi.

Salah satu asumsi dalam deret waktu adalah adanya autokorelasi, misalnya korelasi antara kejadian waktu sekarang dengan waktu sebelumnya. Terdapat berbagai model yang biasa digunakan dalam analisis deret waktu, baik model univariat maupun multivariat. Model univariat yang sering digunakan diantaranya ARIMA, *Exponential Smoothing*, dan GARCH, sedangkan model multivariat yang sering digunakan adalah VAR. Asumsi lain dalam membentuk ARIMA maupun VAR adalah stasioner baik dari rata-rata ataupun variansinya. Menstasionerkan rata-rata bisa didapatkan dengan mendiferensikan data deret waktu. Akan tetapi untuk menstasionerkan variansi sulit didapatkan karena ketika data deret waktu didiferensi dan diperoleh stasioner pada rata-rata, data tersebut menjadi lebih tidak stasioner pada variansi seperti data deret waktu finansial (indeks harga saham, tingkat suku bunga, inflasi, atau kurs mata uang) yang umumnya memiliki variansi yang tidak konstan (heteroskedastisitas).

Untuk menanggulangi masalah heteroskedastisitas ini, digunakan ARCH yang diperkenalkan oleh Engle pada tahun 1982. Menurut Engle, penggunaan metode ARCH pada data deret waktu yang mengalami heteroskedastisitas berperan penting dalam meningkatkan efisiensi. Pada model ini, variansi *error* data deret waktu sekarang hanya dipengaruhi oleh *error* dari variabel yang diteliti pada waktu sebelumnya. Kemudian pada tahun 1986, Tim Bollerslev mengembangkan metode ARCH dengan metode yang disebut *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH). Model ini dianggap memberikan hasil yang lebih singkat dan efektif daripada model ARCH karena dapat mengurangi ketergantungan sejumlah besar *Lag error* masa lalu.

Dalam perkembangannya, model GARCH memiliki banyak jenis diantaranya Glosten Jagannathan Runkle-GARCH (GJR-GARCH), *Threshold* GARCH (TGARCH), *Exponential* GARCH (EGARCH), Nonlinear GARCH (NGARCH), Asymmetric Power ARCH (APARCH), *Constant Conditional Correlation-GARCH* (CCC-GARCH), *Dynamic Conditional Correlation-GARCH* (DCC-GARCH), dan lain-lain. Ding *et al.* (1993) menyatakan bahwa tidak cukup beralasan hanya menggunakan fungsi linier saja untuk varians residual. Pada

banyak kasus finansial, model nonlinier ternyata memiliki hasil yang lebih baik dibandingkan model linier. Hal itu terbukti pada penelitian yang dilakukan Rizvi *et al.* (2013) yang memodelkan inflasi beberapa negara di Asia termasuk Indonesia dengan membandingkan model simetrik dan asimetrik GARCH.

Salah satu model asimetrik GARCH yang banyak digunakan adalah GJR-GARCH. Model ini merupakan pengembangan GARCH yang digagas oleh Glosten *et al.* (1993). Hentschel (1994) meneliti tentang model simetrik dan asimetrik GARCH pada deret waktu harga saham harian Amerika Serikat. Dalam penelitian tersebut, Hentschel membandingkan GARCH, GJR-GARCH, TGARCH, AGARCH, NGARCH, EGARCH, dan APGARCH dalam melakukan peramalan. Selanjutnya Forte dan Manera (2006) melakukan penelitian volatilitas harga saham di Asia dan Eropa dengan beberapa model asimetrik GARCH salah satunya adalah GJR-GARCH. Akurasi peramalan pada setiap model tersebut berbeda-beda bergantung pada negara yang menjadi domain penelitian. Selanjutnya Labuschagne (2015) menyimpulkan dari hasil penelitiannya tentang peramalan indeks nilai tukar sekuritas BRICS bahwa model asimetrik GARCH (GJR-GARCH dan EGARCH) lebih akurat dalam hasil pemodelan dibandingkan dengan *Risk Neutral Historic Distribution* (RNHD).

Model APARCH yang dikembangkan Ding *et al.* pada tahun 1993 merupakan model yang komprehensif dan mencakup tujuh model GARCH lainnya. Sanjaya (2015) menggunakan APARCH, NGARCH, GJR-GARCH, GARCH, EGARCH, dan TGARCH untuk memodelkan volatilitas nilai tukar rupiah terhadap dollar Amerika, dengan hasil bahwa APARCH merupakan model terbaik diantara model-model tersebut. Sementara itu Tully dan Lucey (2007) menggunakan GARCH dan APARCH untuk menganalisis dampak indikator makro ekonomi terhadap harga emas dan menunjukkan hasil bahwa metode APARCH tepat digunakan untuk memodelkan harga emas. Lin dan Fei (2012) memodelkan fluktuasi saham di China menggunakan berbagai modifikasi GARCH dan APARCH, dengan hasil bahwa APARCH lebih baik dalam menggambarkan *long memory* pada saham. Selanjutnya penelitian yang dilakukan oleh Hickey *et al.* (2012) menggunakan ARMAX-GARCH model dengan simetrik dan asimetrik GARCH model untuk meramalkan harga listrik di Amerika

Serikat. Hasil yang diperoleh bahwa APARCH merupakan model terbaik untuk menggambarkan volatilitas harga listrik.

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah diuraikan sebelumnya, dapat diidentifikasi beberapa permasalahan sebagai berikut: Bagaimana membandingkan tingkat keakuratan metode GARCH, GJR-GARCH dan APARCH menggunakan studi simulasi? Bagaimana kinerja peramalan pada data inflasi menggunakan ARIMAX dengan GARCH, GJR-GARCH, dan APARCH?

1.3 Tujuan Penelitian

Berdasarkan permasalahan yang telah dirumuskan, tujuan dari penelitian ini adalah sebagai berikut:

1. Membandingkan tingkat keakuratan metode GARCH, GJR-GARCH dan APARCH dengan menggunakan studi simulasi.
2. Membandingkan kinerja peramalan pada data inflasi menggunakan ARIMAX dengan GARCH, GJR-GARCH, dan APARCH.

1.4 Manfaat Penelitian

Penelitian ini diharapkan memiliki manfaat:

1. Dapat dijadikan sebagai masukan bagi pemerintah khususnya BPS dalam memodelkan data deret waktu seperti inflasi, PDRB, dan data yang terdapat masalah heteroskedastisitas dan terindikasi mengandung *outlier*.
2. Dapat menambah wawasan dan pengetahuan mengenai metode ARIMAX maupun pengembangan model-model GARCH.

1.5 Batasan Masalah

Dalam penelitian ini, digunakan data inflasi nasional dan perubahan rata-rata harga minyak dari ketiga jenis penghasil minyak dunia yaitu Brent, *West Texas Intermediate* (WTI), dan Dubai. Selanjutnya variabel yang digunakan sebagai variabel eksogen yaitu harga minyak dunia dan deteksi *outlier*. Pada pemodelan simetrik dan asimetrik GARCH, dibatasi pada model GARCH yang berdistribusi normal.

BAB 2

TINJAUAN PUSTAKA

Pada bagian ini akan dijelaskan teori-teori yang berkaitan dengan analisis yang digunakan dalam penelitian ini, yang meliputi konsep dasar *time series*, model ARIMA, model ARIMAX, model GARCH, model GJR-GARCH, model APARCH, dan penjelasan mengenai inflasi di Indonesia.

2.1 Model Time Series

Model *time series* merupakan suatu model yang mempelajari pola gerakan nilai-nilai variabel pada satu interval waktu yang teratur. Dari model *time series* ini akan diperoleh ukuran-ukuran yang dapat digunakan untuk membuat keputusan pada saat ini, untuk peramalan dan perencanaan masa depan. Model *time series* ini banyak digunakan untuk analisis data-data ekonomi dan bisnis baik model univariat maupun multivariat. Model univariat yang sering digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA).

2.1.1 Stasioneritas

Asumsi dasar yang harus dipenuhi dalam penggunaan analisis deret waktu adalah stasioneritas data. Syarat-syarat yang harus dipenuhi dalam stasioneritas adalah sebagai berikut:

1. Stasioner dalam varians (varians konstan)

$$Var(Z_t) = Var(Z_{t+k}), \text{ dimana } Z_t \text{ adalah variabel dependen pada waktu } t.$$

2. Stasioner dalam *mean* (rata-rata konstan)

$$E(Z_t) = E(Z_{t+k}).$$

Kestasioneran varians dapat dideteksi dari nilai varians data yang bersifat konstan atau dinotasikan dengan $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$. Untuk mengatasi data dengan varians tidak homogen dapat dilakukan dengan transformasi. Metode transformasi yang sering digunakan adalah model transformasi yang diperkenalkan oleh Box dan Cox pada tahun 1964, yaitu:

$$T(Z_t) = Z_t^{(\lambda)} = \frac{Z_t^{\lambda-1}}{\lambda}, \quad (2.1)$$

dengan λ adalah parameter transformasi (Wei, 2006).

Stasioneritas dalam *mean* akan tercapai apabila nilai *mean* dari data deret waktu yang sedang dianalisis tidak dipengaruhi oleh deret waktu. Data dikatakan stasioner dalam *mean* bila berfluktuasi disekitar garis sejajar dengan sumbu waktu (t) atau di sekitar suatu nilai *mean* yang konstan. Data yang tidak stasioner dalam *mean* perlu dilakukan proses pembedaan (*differencing*). *Differencing* pertama (Makridakis, 1999):

$$Z'_t = Z_t - Z_{t-1} \quad (2.2)$$

Deret baru Z'_t akan mempunyai $n-1$ buah nilai dan akan stasioner apabila trend dari data awal Z_t adalah linier (pada orde pertama). Apabila autokorelasi dari data yang dibedakan pertama tidak mendekati nol sesudah *Lag* kedua atau ketiga, ini menunjukkan kestasioneran belum tercapai, sehingga pembedaan pertama dari data yang telah dibedakan dapat dilakukan dengan *differencing* orde kedua. Proses *differencing* orde ke- d dapat ditulis sebagai $(1 - B)^d Z_t$.

2.1.2 Autocovariance dan Autocorrelation Function (ACF)

Suatu proses yang stasioner $\{Z_t\}$ mempunyai nilai *mean* $\mu_t = E(Z_t)$ dan $Var(Z_t) = E(Z_t - \mu_t)^2 = \sigma^2$ yang konstan serta kovarians (Z_t, Z_s) yang fungsinya hanya berbeda dalam waktu $|t - s|$ saja. Kovarians diantara Z_t dan Z_{t+k} adalah (Wei, 2006):

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.3)$$

dengan $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$

Sebagai fungsi dari k , maka γ_k disebut fungsi autokovarians dan ρ_k disebut sebagai fungsi autokorelasi (ACF) dalam analisis deret waktu karena merepresentasikan kovarian dan korelasi antara Y_t dan Y_{t+k} dari proses yang sama. Suatu proses stasioner jika dari fungsi autokovarian dan fungsi autokorelasi memiliki sifat-sifat sebagai berikut:

1. $\gamma_0 = Var(Z_t); \rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0; |\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$ untuk semua k .

2.1.3 Partial Autocorrelation Function (PACF)

PACF digunakan sebagai alat untuk mengukur tingkat keamatan antara Z_t dan Z_{t+k} setelah mengeliminasi dependensi $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$. Nilai PACF dalam analisis deret waktu $\hat{\phi}_{kk}$ dimulai dengan menghitung $\hat{\phi}_{11} = \hat{\rho}_1$, sedangkan untuk menghitung $\hat{\phi}_{kk}$ sendiri digunakan formula sebagai berikut (Wei, 2006):

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.4)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, \text{ dengan } j = 1, 2, \dots, k$$

2.2 Metode ARIMA Box-Jenkins

Pemilihan model ARIMA yang sesuai untuk suatu data deret waktu dapat dilakukan dengan menggunakan prosedur Box-Jenkins. Prosedur pembentukan model ARIMA meliputi beberapa tahapan yaitu identifikasi, estimasi, cek diagnosa dan peramalan. Tahap identifikasi dilakukan dengan mengamati plot ACF dan PACF dari data yang selanjutnya digunakan untuk mendapatkan dugaan sementara model ARIMA yang sesuai. Tahap selanjutnya melakukan estimasi dan uji signifikansi parameter apakah model dugaan sementara yang telah diestimasi cukup sesuai dengan data deret waktunya.

2.2.1 Identifikasi

Identifikasi model ARIMA(p, d, q) dilakukan setelah data stasioner. Jika data tidak mengalami *differencing*, maka d bernilai 0 dan jika data menjadi stasioner setelah *differencing* ke-1 maka d bernilai 1 dan seterusnya. Model Box Jenkins (ARIMA) mempunyai bentuk antara lain:

a. Autoregressive (AR)

Suatu persamaan linier dikatakan sebagai *autoregressive model* jika model tersebut menunjukkan Z_t sebagai fungsi linier dari sejumlah Z_t aktual kurun waktu sebelumnya bersama dengan kesalahan sekarang. Bentuk model ini dengan orde p atau AR(p) atau model ARIMA($p, 0, 0$) secara umum adalah:

$$\hat{Z}_t = \phi_1 \hat{Z}_{t-1} + \phi_2 \hat{Z}_{t-2} + \dots + \phi_p \hat{Z}_{t-p} + a_t \quad (2.5)$$

atau

$$\phi_p(B)\dot{Z}_t = a_t$$

dimana

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

dan

$$\dot{Z}_t = Z_t - \mu$$

dengan:

$\dot{Z}_t$ = data deret waktu sebagai variabel respon pada waktu ke- t

$\dot{Z}_{t-1}, \dot{Z}_{t-2}, \dots, \dot{Z}_{t-p}$ = data deret waktu ke $t-1, \dots, t-p$

$\phi_1, \phi_2, \dots, \phi_p$ = parameter-parameter *autoregressive*

a_t = nilai kesalahan pada waktu ke- t

b. *Moving Average (MA)*

Berbeda dengan model AR yang menunjukkan Z_t sebagai fungsi linier dari sejumlah Z_t aktual kurun waktu sebelumnya, *moving average model* menunjukkan nilai Z_t berdasarkan kombinasi kesalahan linier masa lalu (*Lag*). Bentuk model ini dengan orde q atau $MA(q)$ atau model $ARIMA(0, 0, q)$ secara umum adalah:

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.6)$$

atau

$$\dot{Z}_t = \theta_q(B)a_t$$

dimana

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

dengan

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

$a_1, a_2, \dots, a_{t-q}$ = nilai kesalahan pada kurun waktu ke- $t, t-1, \dots, t-q$

Terlihat dari model bahwa Z_t merupakan rata-rata tertimbang kesalahan sebanyak q periode lalu yang digunakan untuk model MA. Jika pada suatu model digunakan dua kesalahan masa lalu maka dinamakan MA orde 2 atau $MA(2)$.

c. *Autoregressive Moving Average (ARMA)*

Untuk mendapatkan model yang secara tepat meramalkan data deret waktu, seringkali melibatkan perpaduan antara proses AR dan MA dalam satu model. Perpaduan atau kombinasi kedua proses ini biasa dikenal dengan ARMA. Bentuk model ini dengan orde (p, q) atau $ARMA(p, q)$ atau model $ARIMA(p, 0, q)$ secara umum adalah:

$$\phi_p(B)\dot{Z}_t = \theta_q(B)a_t$$

d. *Autoregressive Integrated Moving Average (ARIMA)*

Model deret waktu dengan data yang stasioner melalui proses *differencing* disebut sebagai model ARIMA. Dengan demikian, jika data stasioner pada proses *differencing* d kali, dengan model dasar $ARMA(p, q)$, maka model yang terbentuk menjadi $ARIMA(p, 0, q)$ dimana p adalah menunjukkan orde AR, d adalah tingkat proses *differencing* dan q menunjukkan orde MA. Model ARIMA merupakan gabungan dari model AR dan model MA. Model $ARIMA(p, d, q)$ secara umum dapat ditulis sebagai berikut (Wei, 2006):

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t \quad (2.7)$$

dengan:

$$\theta_0 = \text{konstanta}$$

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

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

$$B = \text{backward shift operator, } BZ_t = Z_{t-1}$$

2.2.2 Uji Signifikansi Parameter

Uji signifikansi parameter bertujuan untuk menguji kelayakan parameter model. Tahapan dari uji signifikansi parameter adalah sebagai berikut:

1. Hipotesis

$$H_0: \beta = 0 \text{ (}\beta \text{ tidak signifikan)}$$

$$H_1: \beta \neq 0 \text{ (}\beta \text{ signifikan)}$$

dengan β adalah estimasi parameter model

2. Statistik Uji

$$t_{hit} = \frac{\hat{\beta}}{s.e.(\hat{\beta})}$$

3. Daerah penolakan

Daerah penolakan H_0 adalah $|t_{hit}| > t_{(\frac{\alpha}{2}; n-n_p)}$, dimana n_p adalah jumlah parameter dalam model.

2.2.3 Uji Kesesuaian Model

Uji kesesuaian model dilakukan terhadap residual dari model. Pengujian asumsi normal dilakukan dengan menggunakan uji Kolmogorov-Smirnov.

a. Residual (α_t) bersifat *white noise*

White noise artinya tidak terdapat korelasi antar residual dengan *mean* nol dan varians konstan ($\sigma_{\alpha_t}^2$). Tahapan dari uji kesesuaian model untuk residual (α_t) bersifat *white noise* adalah sebagai berikut:

1. Hipotesis:

$H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0$ (tidak ada korelasi antar residual)

H_1 : minimal ada satu $\rho_k \neq 0$; $i=1,2,\dots,K$.

2. Statistik Uji

$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)}$, dimana $\hat{\rho}_k^2$ adalah estimasi taksiran ACF residual dan n adalah banyaknya observasi.

3. Daerah penolakan

Daerah penolakan H_0 adalah $Q > \chi_{\alpha; k-p-q}^2$

b. Residual (ε_t) berdistribusi normal

Uji kenormalan terhadap residual model dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Tahapan uji kenormalan adalah sebagai berikut.

1. Hipotesis:

$H_0: F(\varepsilon_t) = F_0(\varepsilon_t)$, untuk semua ε_t

$H_1: F(\varepsilon_t) \neq F_0(\varepsilon_t)$, untuk semua ε_t

2. Statistik Uji

$$D = \sup |S(\varepsilon_t) - F_0(\varepsilon_t)|,$$

dengan

$F(\varepsilon_t)$ = fungsi distribusi data residual yang belum diketahui

$S(\varepsilon_t)$ = fungsi distribusi kumulatif dari data asal residual

3. Daerah penolakan

Tolak H_0 jika $D_{hit} \geq D_{(\alpha,n)}$ atau jika $p\text{-value} < \alpha$.

2.3 Deteksi Outlier

Suatu data runtun waktu seringkali mengandung pengamatan yang dipengaruhi oleh kejadian-kejadian luar biasa yang tidak terduga dan tanpa disadari seperti pemogokan, wabah perang, krisis politik atau ekonomi yang berkejolak yang mengakibatkan pengamatan tersebut tidak konsisten pada data deret waktunya. Pengamatan seperti ini disebut *outlier* (Wei, 2006). Jika waktu dan penyebab dari gangguan ini diketahui, maka efek dari gangguan ini dapat dianalisis dengan menggunakan analisis intervensi. Tetapi kenyataannya tidak diketahui waktu kejadiannya. *Outlier* dapat menyebabkan hasil analisis data menjadi tidak *reliable* dan tidak valid, sehingga deteksi *outlier* perlu dilakukan untuk menghilangkan efek *outlier* tersebut.

Deteksi *outlier* pertama kali diperkenalkan oleh Fox (1972) dalam Wei (2006). *Outlier* terdiri dari beberapa tipe, yaitu *additive outlier* (AO), *innovational outlier* (IO), *level shift* (LS) dan *temporary change* (TC). Cara mengatasi *outlier* dengan memasukkan *outlier* dalam model sampai mendapatkan model yang memenuhi asumsi *white noise* dan kenormalan.

2.3.1 Additive Outlier (AO)

Additive outlier (AO) merupakan kejadian yang mempengaruhi suatu deret runtun waktu pada satu waktu saja. Wei (2006) mendefinisikan model *additive outlier* sebagai berikut:

$$Z_t = \begin{cases} X_t, & t \neq T \\ X_t + \omega, & t = T \end{cases} \quad (2.8)$$

$$= X_t + \omega I_t^{(T)} \quad (2.9)$$

$$= \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)} \quad (2.10)$$

dengan

$$I_t^{(T)} = \begin{cases} 1, & t = T \\ 0, & t \neq T \end{cases} \quad (2.11)$$

X_t adalah model ARIMA sebelum deteksi *outlier*

$I_t^{(T)}$ adalah variabel indikator keberadaan *outlier* pada waktu T .

2.3.2 *Innovational Outlier (IO)*

Efek dari *innovational outlier* pada suatu deret waktu adalah lebih rumit jika dibandingkan ketiga tipe *outlier* lainnya. Wei (2006) mendefinisikan model IO sebagai berikut :

$$Z_t = X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \quad (2.12)$$

$$= \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)}) \quad (2.13)$$

Efek AO hanya terjadi pada T observasi saja, sedangkan pada IO mempengaruhi seluruh observasi $Z_t, Z_{t+1}, \dots$ melewati waktu T sepanjang memori dari sistem yang diberikan oleh $\frac{\theta(B)}{\phi(B)}$.

Secara umum dalam data runtun waktu dapat mengandung beberapa *outlier* dengan tipe yang berbeda-beda, sehingga dapat dituliskan model *outliernya* secara umum sebagai berikut (Wei, 2006):

$$Z_t = \sum_{j=1}^k \omega_j v_j(B) I_t^{(T_j)} + X_t \quad (2.14)$$

dengan

$$X_t = \frac{\theta(B)}{\phi(B)} a_t$$

$$v_j(B) = \begin{cases} 1, & \text{untuk AO} \\ \frac{\theta(B)}{\phi(B)}, & \text{untuk IO} \end{cases}$$

$I_t^{(T)}$ adalah variabel indikator keberadaan *outlier* pada waktu T seperti pada persamaan (2.11).

2.3.3 Level Shift (LS)

Level Shift adalah kejadian yang mempengaruhi deret pada satu waktu tertentu dan efek yang diberikan memberikan suatu perubahan yang tiba-tiba dan permanen. Model LS dapat dinyatakan sebagai berikut (Wei, 2006):

$$Z_t = X_t + \frac{1}{(1 - B)} \omega_L I_t^{(T)} \quad (2.15)$$

2.3.4 Temporary Change (TC)

Temporary Change adalah suatu kejadian dimana *outlier* menghasilkan efek awal pada waktu ke t sebesar ω_c dan kemudian efek tersebut berkurang secara perlahan sesuai dengan besarnya δ . Model TC dinyatakan sebagai berikut:

$$Z_t = X_t + \frac{1}{(1 - \delta B)} \omega_c I_t^{(T)} \quad (2.16)$$

Pada saat $\delta = 0$ maka TC akan menjadi kasus AO sedangkan pada saat $\delta = 1$ maka TC akan menjadi kasus LS.

2.4 ARIMA with Exogenous Factor (ARIMAX)

ARIMAX merupakan model ARIMA dengan faktor eksogen. Pada penelitian ini model ARIMAX yang akan digunakan adalah ARIMA dengan deteksi *outlier* yaitu model ARIMA dengan faktor eksogen *dummy* dari *outlier*. Selain itu juga digunakan ARIMA dengan model fungsi transfer.

Metode fungsi transfer merupakan pengembangan dari metode Box Jenkins yang modelnya terdiri dari dua variabel (bivariat) tetapi masing-masing variabel mempunyai model ARIMA tertentu. Model fungsi transfer terbentuk melalui fungsi autokorelasi dan korelasi silang sehingga dapat digunakan untuk meramal suatu variabel berdasarkan informasi dari variabel lainnya.

Model fungsi transfer adalah suatu model yang menggambarkan bahwa nilai prediksi masa depan dari suatu deret waktu (disebut output *series* atau y_t) adalah berdasarkan pada nilai-nilai masa lalu dari deret waktu itu sendiri dan

berdasarkan pula pada satu atau lebih deret waktu yang berhubungan (disebut input *series* atau x_t) dengan output *series* tersebut.

Untuk membentuk model fungsi transfer, deret input dan deret output masing-masing harus berautokorelasi dan memiliki korelasi silang yang signifikan. Bentuk umum model fungsi transfer untuk input tunggal (x_t) dan output tunggal (y_t) adalah (Wei, 2006):

$$y_t = v_0 x_t + v_1 x_{t-1} + \dots + n_t \quad (2.17)$$

$$y_t = v(B)x_t + n_t$$

dengan

y_t = representasi dari deret output yang stasioner

x_t = representasi dari deret input yang stasioner

n_t = representasi dari komponen *error* (deret *noise*) yang mengikuti suatu model

ARIMA tertentu

$v(B) = v_0 + v_1 B + \dots + v_k B^k$ yang merupakan koefisien model fungsi transfer atau bobot respon impuls, yaitu susunan bobot pengaruh x_t terhadap y_t dalam sistem dinamis terhadap seluruh periode waktu yang akan datang. Bobot respon impuls dapat dinyatakan sebagai berikut (Wei, 2006):

$$v(B) = \frac{\omega(B)B^b}{\delta(B)} \quad (2.18)$$

sehingga

$$y_t = \frac{\omega(B)B^b}{\delta(B)} x_t + \frac{\theta(B)}{\phi(B)} \alpha_t \quad (2.19)$$

dengan

b adalah banyaknya periode sebelum x_t mulai berpengaruh terhadap y_t .

$\omega(B) = \omega_0 - \omega_1 B - \dots - \omega_s B^s$ adalah operator dari order s , yang merepresentasikan banyaknya pengamatan masa lalu x_t yang berpengaruh terhadap y_t .

$\delta(B) = \delta_0 - \delta_1 B - \dots - \delta_r B^r$ adalah operator dari order r , yang merepresentasikan banyaknya pengamatan masa lalu dari deret output itu sendiri yang berpengaruh terhadap y_t .

Tahapan-tahapan pembentukan model fungsi transfer identik dengan tahapan pada pembentukan model ARIMA dengan ilustrasi seperti yang dilakukan oleh Wei (2006) yaitu:

Tahap I: Identifikasi Bentuk Model

1) Mempersiapkan deret input dan output

Seperti halnya pada pemodelan dengan ARIMA, deret input dan deret output pada pemodelan dengan fungsi transfer mensyaratkan data yang stasioner. Jika data tersebut belum stasioner maka perlu dilakukan *differencing* atau transformasi.

2) Pemutihan deret input (x_t)

Jika deret input berautokorelasi, fungsi *cross-correlation* langsung antara deret input dan deret output dapat memberikan indikasi yang menyesatkan tentang hubungan antara deret input dan deret output. Salah satu solusi untuk mengatasi masalah ini disebut *prewhitening*. Diasumsikan deret input mengikuti proses ARMA:

$$\phi_x(B)x_t = \theta_x(B)\alpha_t \quad (2.20)$$

Dimana α_t adalah *white noise* dengan rata-rata nol dan varians σ_a^2 . Deret α_t yaitu:

$$\alpha_t = \frac{\phi_x(B)}{\theta_x(B)} x_t \quad (2.21)$$

3) Penghitungan deret output (y_t)

Hal tersebut dilakukan dengan mentransformasi deret output y_t menggunakan model deret input yang telah dilakukan *prewhitening* untuk membentuk deret output:

$$\beta_t = \frac{\phi_x(B)}{\theta_x(B)} y_t \quad (2.22)$$

4) Penghitungan korelasi silang dan autokorelasi untuk deret input dan output yang terbentuk

Penghitungan sampel korelasi silang atau *Cross Correlations Function* (CCF), $\hat{\rho}_{\alpha\beta}(k)$ antara α_t dan β_t untuk mengestimasi bobot respon impuls (v_k):

$$\hat{v}_k = \frac{\hat{\sigma}_\beta}{\hat{\sigma}_\alpha} \hat{\rho}_{\alpha\beta}(k) \quad (2.23)$$

Signifikansi dari CCF dan $\hat{v}_k$ dapat diuji dengan membandingkannya dengan *standard error* $(n-1)^{-1/2}$.

5) Penetapan nilai r , s , dan b untuk model fungsi transfer

Tiga nilai penting dalam sebuah model fungsi transfer adalah (b, r, s) . Nilai b menunjukkan periode deret input mulai berpengaruh terhadap deret output sedangkan nilai s mengindikasikan berapa lama deret output dipengaruhi oleh deret input dan r merupakan indikasi lamanya deret output memiliki hubungan dengan nilai periode sebelumnya dari deret output itu sendiri.

Setelah nilai (b, r, s) ditentukan, maka dapat diperoleh estimasi fungsi transfer $v(B)$ sebagai berikut:

$$\hat{v}(B) = \frac{\hat{\omega}(B)}{\hat{\delta}(B)} B^b \quad (2.24)$$

6) Penaksiran awal deret gangguan (n_t)

Setelah diketahui $\hat{v}(B)$, maka dapat dihitung nilai estimasi deret *noise* sebagai berikut:

$$\hat{n}_t = y_t - \hat{v}(B)x_t \quad (2.25)$$

$$\hat{n}_t = y_t - \frac{\hat{\omega}(B)}{\hat{\delta}(B)} B^b x_t \quad (2.26)$$

7) Penetapan (p_n, q_n) untuk model ARIMA $(p_n, 0, q_n)$ dari deret gangguan n_t .

Kemudian dari deret n_t dapat ditentukan model ARIMA yang tepat dengan mengamati pola ACF dan PACF nya, sehingga diperoleh model ARIMA sebagai berikut:

$$\phi(B)n_t = \theta(B)a_t \quad (2.27)$$

dimana:

$\phi(B)$ = operator *autoregressive* orde ke- p dari n_t

$\theta(B)$ = operator *moving average* orde ke- q dari n_t

a_t = residual dari deret n_t

Setelah deret n_t diperoleh dari prosedur di atas, langkah selanjutnya adalah memperoleh model fungsi transfer sebagai berikut:

$$y_t = \frac{\omega(B)}{\delta(B)} B^b x_t + \frac{\theta(B)}{\phi(B)} a_t \quad (2.28)$$

Tahap II: Estimasi Parameter Model Fungsi Transfer

Setelah mengidentifikasi bentuk model fungsi transfer tahapan berikutnya adalah mengestimasi parameter-parameter model fungsi transfer, yaitu parameter:

$$\boldsymbol{\delta} = (\delta_1, \dots, \delta_r)', \boldsymbol{\omega} = (\omega_0, \omega_1, \dots, \omega_s)', \boldsymbol{\phi} = (\phi_1, \dots, \phi_p)', \boldsymbol{\theta} = (\theta_1, \dots, \theta_q)', \text{ dan } \sigma_a^2.$$

diperoleh

$$\alpha_t = y_t - c_1 y_{t-1} - \dots - c_{p+r} y_{t-p-r} - d_0 x_{t-b} + d_1 x_{t-b-1} + \dots + d_{p+s} x_{t-b-p-s} + e_1 \alpha_{t-1} + \dots + e_{r+q} \alpha_{t-r-q}$$

dengan c_i, d_j, e_k adalah fungsi transfer dari $\delta_i, \omega_j, \phi_k$, dan θ_l . Metode estimasi yang digunakan adalah *Conditional Maximum Likelihood*, dengan asumsi α_t adalah *White Noise* dengan berdistribusi $N(0, \sigma_a^2)$.

Tahap III: Diagnosa Model Fungsi Transfer

1. Uji korelasi silang antara x_t dengan a_t

Model fungsi transfer yang layak mensyaratkan antara x_t dengan a_t bersifat independen satu sama lain. Kondisi ini merupakan hal yang penting untuk validitas model fungsi transfer. Korelasi silang antara x_t dan a_t dapat dideteksi dengan melihat pola *cross correlation* antara $e_{x,t}$ dengan a_t yang berada di dalam interval dua *standard error*nya atau tidak munculnya *spike*. Pendeteksiannya dapat dilakukan dengan menggunakan salah satu dari empat statistik portmanteau test, yaitu:

$$Q_0 = m(m+2) \sum_{j=0}^k (m-j)^{-1} \hat{\rho}_{\alpha\hat{a}}^2(j) \quad (2.29)$$

Q_0 berdistribusi χ^2 dengan derajat bebas $(k+1)-m$ dimana $m = n - t_0 + 1$ dan m adalah jumlah parameter δ_i dan ω_j yang diestimasi dalam fungsi transfer $v(B) = \omega(B)/\delta(B)$.

2. Uji autokorelasi

Untuk model yang baik, sampel ACF dari $\hat{a}_t$ harus menunjukkan tidak ada yang signifikan, sehingga dapat dihitung nilai sebagai berikut:

$$Q_0 = m(m+2) \sum_{j=1}^k (m-j)^{-1} \hat{\rho}_{\hat{a}}^2(j) \quad (2.30)$$

Aproksimasi statistik Q_1 berdistribusi χ^2 dengan derajat bebas $(k-p-q)$ hanya dependen pada jumlah parameter model *noise*.

Tahap IV: Peramalan dengan Fungsi Transfer

Setelah lolos pada tahap diagnosa, maka model fungsi transfer siap digunakan untuk peramalan. Peramalan dilakukan dengan menggunakan model yang telah dihasilkan melalui tahapan-tahapan tersebut di atas. Peramalan dengan model fungsi transfer juga mirip dengan peramalan pada model ARIMA.

2.5 Model Heteroskedastisitas Deret Waktu

Variansi bersyarat $Var(X_t|X_{t-1}, X_{t-2}, \dots)$ tidak konstan dari waktu ke waktu dan proses X_t bersifat heteroskedastisitas, dimana dalam ekonometrik biasa disebut *volatility* yaitu $\sigma_t = \sqrt{Var(X_t|X_{t-1}, X_{t-2}, \dots)}$ berubah dari waktu ke waktu (Posedel, 2005). Pemahaman sifat data deret waktu sangat penting untuk aplikasi dalam ekonomi makro atau finansial seperti indeks harga saham, tingkat suku bunga, inflasi atau kurs mata uang dan lain-lain. Model heteroskedastisitas bersyarat untuk deret waktu memiliki peranan sangat penting dalam manajemen resiko keuangan dan digunakan untuk membuat keputusan finansial berdasarkan data yang diamati.

2.5.1 Uji Heteroskedastisitas

Untuk mengidentifikasi apakah suatu model tersebut mengandung ARCH/GARCH maka dapat dilakukan dengan cara menghitung nilai ACF dan PACF dari kuadrat residual yang dihasilkan oleh model *mean* (ARIMA) dan dapat juga memakai uji *Lagrange Multiplier (LM)*. Jika terdapat *conditional heteroscedasticity*, disarankan menggambarkan *correlogram* kuadrat residual dengan langkah-langkah sebagai berikut:

1. Melakukan pemilihan model terbaik dengan menggunakan model ARIMA sehingga diperoleh nilai residualnya dan setelah itu masing-masing residual dikuadratkan. Nilai tersebut digunakan untuk menghitung variansi sampel residual sebagai berikut :

$$\hat{\sigma}^2 = \sum_{t=1}^T \frac{\varepsilon_t^2}{T} \quad (2.31)$$

dengan t adalah banyaknya residual.

2. Menghitung dan membuat plot autokorelasi sampel dari kuadrat residual dengan formula:

$$\rho(i) = \frac{\sum_{t=j+1}^T (\hat{\varepsilon}_t^2 - \hat{\sigma}^2)(\hat{\varepsilon}_{t-1}^2 - \hat{\sigma}^2)}{\sum_{t=1}^T (\hat{\varepsilon}_t^2 - \hat{\sigma}^2)} \quad (2.32)$$

Nilai $\rho(i)$ yang secara individu mempunyai nilai lebih besar dari standard deviasi, mengindikasikan adanya proses ARCH.

Tahapan uji LM yang diusulkan oleh Engle (1982) untuk menguji adanya proses ARCH yaitu:

1. Menggunakan metode kuadrat terkecil untuk mendapatkan AR (n):

$$X_t = \alpha_0 + \alpha_1 X_{t-1} + \dots + \alpha_n X_{t-n} + \varepsilon_t \quad (2.33)$$

2. Menghitung besarnya kuadrat residual, kemudian meregresikan nilai tersebut sehingga diperoleh taksiran sebagai berikut:

$$\hat{\varepsilon}_t^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{\varepsilon}_{t-1}^2 + \dots + \hat{\alpha}_n \hat{\varepsilon}_{t-n}^2 \quad (2.34)$$

3. Melakukan pengujian parameter:

$$H_0 : \alpha_1 = \dots = \alpha_n = 0$$

$$H_1 : \text{minimal ada satu } \alpha_i \neq 0, i = 1, 2, \dots, n$$

Statistik Uji:

$T'R^2$ dengan $T' = T - n$, dimana T adalah jumlah residual dibawah H_0 .

Daerah penolakan:

Tolak H_0 jika $T'R^2 > \chi_n$, yang berarti bahwa terdapat efek ARCH dalam model.

2.5.2 Model Autoregressive Conditional Heteroscedasticity (ARCH)

Sebelum mendefinisikan proses ARCH pada data deret waktu, pertama perlu diketahui perbedaan antara variansi bersyarat dengan variansi tidak bersyarat. Dimisalkan model AR(1), rata-rata bersyarat dari Y_t adalah $\phi_1 Y_{t-1}$ sedangkan rata-rata tidak bersyarat adalah nol (Engle, 1982).

Sebagaimana diasumsikan bahwa $Var(\varepsilon_t) = \sigma_\varepsilon^2$ yang juga merupakan variansi bersyarat terhadap Y_{t-1} . Artinya Y_{t-1} konstan dan sumber variasi dari Y_t adalah ε_t . Dapat ditunjukkan sebagai berikut:

$$\begin{aligned}
Var(Y_t|Y_{t-1}) &= Var[(\phi_1 Y_{t-1} + \varepsilon_t)|Y_{t-1}] \\
&= Var(\phi_1 Y_{t-1}|Y_{t-1}) + Var(\varepsilon_t|Y_{t-1}) \\
&= 0 + Var(\varepsilon_t|Y_{t-1}) \\
&= \sigma_\varepsilon^2
\end{aligned}$$

dengan asumsi variansi bersyarat ε_t konstan. Jika variansi bersyarat tidak konstan, maka variansi bersyarat terhadap Y_{t-1} adalah

$$Var(\varepsilon_t|) = \sigma_t^2 \quad (2.35)$$

Sedangkan untuk variansi tidak bersyarat adalah:

$$\begin{aligned}
Var(Y_t) &= Var(\phi_1 Y_{t-1} + \varepsilon_t) \\
&= \phi_1^2 Var(Y_{t-1}) + Var(\varepsilon_t) \\
\sigma_x^2 &= \phi_1^2 \sigma_x^2 + \sigma_\varepsilon^2 \\
\sigma_x^2(1 - \phi_1^2) &= \sigma_\varepsilon^2 \\
\sigma_x^2 &= \frac{\sigma_\varepsilon^2}{(1 - \phi_1^2)}
\end{aligned}$$

dengan $Var(Y_t) = Var(Y_{t-1}) = \sigma_y^2$ dan $Var(\varepsilon_t) = \sigma_\varepsilon^2$.

Variansi tidak bersyarat adalah σ_y^2 . Jika dibandingkan variansi bersyarat dengan variansi tidak bersyarat terhadap Y_{t-1} , didapatkan bahwa variansi tidak bersyarat kemungkinan konstan, sedangkan variansi bersyarat kemungkinan bervariasi dari waktu ke waktu (tidak konstan).

Untuk itu, Engle (1982) mengusulkan suatu model untuk variansi tidak konstan yang tergantung pada nilai-nilai masa lalu Y_t atau dikenal sebagai model *Autoregressive Conditional Heteroscedasticity* (ARCH), yang didefinisikan sebagai

$$Y_t = \varepsilon \sigma_t \quad (2.36)$$

$$Y_t | \psi_{t-1} \sim N(0, h_t) \quad (2.37)$$

$$h_t = \alpha_0 + \alpha_1 Y_{t-1}^2 \quad (2.38)$$

dengan $\varepsilon_t \sim (0,1)$ atau *white noise*, dan σ_t positif. Model diatas disebut sebagai model ARCH(1). Fungsi untuk variansi waktu adalah $\psi_{t-1} = (Y_{t-1}, Y_{t-2}, \dots)$, yang merupakan himpunan informasi yang tersedia pada waktu $t - 1$.

Fungsi variansi pada persamaan (2.38) dapat digeneralisasi untuk orde lebih dari satu, sehingga diperoleh persamaan

$$h_t = \alpha_0 + \alpha_1 Y_{t-1}^2 + \alpha_p Y_{t-p}^2 \quad (2.39)$$

Persamaan (2.39) dikenal sebagai model ARCH dengan orde p , dan $\alpha_0, \alpha_1, \dots, \alpha_p$ adalah parameter yang tidak diketahui.

Untuk mendapatkan model regresi ARCH, rata-rata dari Y_t diasumsikan sebagai kombinasi linier dari *lag*, termasuk himpunan informasi pada waktu $t-1$ yaitu $E(Y_t) = X_t \beta$ (Engle, 1982), sehingga secara formal model regresi ARCH dapat dituliskan sebagai

$$Y_t | \sim N(X_t \beta, h_t)$$

$$Y_t = X_t \beta + \varepsilon_t \text{ atau } \varepsilon_t = Y_t - X_t \beta$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$$

secara kusus, Engle (1982) mengemukakan bahwa salah satu cara parameterisasi h_t adalah

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \quad (2.40)$$

dengan $\alpha_0 > 0$ dan $\alpha_i \geq 0$. Persamaan (2.40) menunjukkan σ_t^2 sebagai fungsi linier dari proses nilai kuadrat p masa lalu, yang merupakan alasan proses ini dikenal sebagai model ARCH(p) linier.

Berdasarkan bentuk model regresi ARCH di atas, misal model rata-rata dari X_t merupakan model AR, maka diperoleh model AR(1)-ARCH(1), yaitu:

$$Y_t = \phi Y_{t-1} + \varepsilon_t$$

$$\varepsilon_t = Z_t \sigma_t$$

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

dengan $\alpha_0 > 0$ dan $\alpha_1 \geq 0$

2.5.3 Penaksiran Model ARCH(1)

Untuk penyederhanaan, dimisalkan model ARCH(1) yang dinyatakan dengan:

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t)$$

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \quad (2.41)$$

dan parameter α_0 dan α_1 dapat ditaksir sebagai berikut. Kepadatan gabungan dari $\varepsilon_1, \dots, \varepsilon_T$ adalah (Engle, 1982):

$$f_{E_1, \dots, E_T}(\varepsilon_t, \dots, \varepsilon_T) = \left\{ \prod_{j=2}^T f_{E_j \setminus E_1, \dots, E_{j-1}}(\varepsilon_j \setminus \varepsilon_1, \dots, \varepsilon_{j-1}) \right\} \times f_{E_1}(\varepsilon_1)$$

kepadatan marginal ε_1 dapat diabaikan. Untuk $t = 2, \dots, T$ kepadatan bersyarat ε_t , dengan syarat $\varepsilon_1, \dots, \varepsilon_{t-1}$ adalah

$$f_{E_t \setminus E_1, \dots, E_{t-1}}(\varepsilon_t \setminus \varepsilon_1, \dots, \varepsilon_{t-1}) = \frac{1}{\sqrt{2\pi h_t}} \exp \left\{ -\frac{\varepsilon_t^2}{2h_t} \right\}$$

Dengan h_t diberikan pada persamaan (2.41) dan menghasilkan fungsi *likelihood* menjadi

$$L(\alpha_0, \alpha_1) = \prod_{t=2}^T \frac{1}{\sqrt{2\pi h_t}} \exp \left\{ -\frac{\varepsilon_t^2}{2h_t} \right\}$$

dan fungsi *log-likelihood* dengan mengabaikan konstanta adalah

$$l(\alpha_0, \alpha_1) = -\frac{1}{2} \sum_{t=2}^T \left\{ \log h_t + \frac{\varepsilon_t^2}{h_t} \right\}$$

dan taksiran parameternya $(\hat{\alpha}_0, \hat{\alpha}_1)$ diperoleh dengan memaksimalkan fungsi *log-likelihood* di atas.

2.5.4 Model *Generalized ARCH* (GARCH)

Pada dasarnya model ARCH dengan GARCH adalah sama, yang membedakan adalah model GARCH tidak hanya tergantung pada kuadrat *error* waktu sebelumnya tetapi juga tergantung pada variansi waktu sebelumnya. Sedangkan model ARCH hanya tergantung pada kuadrat *error* waktu sebelumnya. Model GARCH(p, q) dinyatakan sebagai (Bollerslev, 1986):

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t)$$

dengan

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \beta_1 h_{t-1} + \beta_2 h_{t-2} + \dots \quad (2.42)$$

$$= \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^q \beta_i h_{t-i}$$

di mana, $\alpha_0 > 0$, $\alpha_i \geq 0$ untuk $i = 1, \dots, p$ dan $\beta_i \geq 0$ untuk $i = 1, \dots, q$.

Untuk lebih sederhana dimisalkan proses GARCH(1, 1)

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t)$$

dengan

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \quad (2.43)$$

Dimana $\alpha_0 > 0$, $\alpha_1 \geq 0$ dan $\beta_1 \geq 0$.

$$\frac{\varepsilon_t}{\sqrt{h_t}} | \psi_{t-1} \sim N(0,1)$$

Urutan $Z_1, \dots, Z_T$ didefinisikan dengan $Z_t = \frac{\varepsilon_t}{\sqrt{h_t}}$ maka Z_t menjadi *independent and identically distributed* (iid) $N(0, 1)$.

Solusi stasioner untuk GARCH(1,1) diperoleh dengan asumsi bahwa proses bermula pada jarak tak terbatas di masa lalu, sehingga h_t dapat dinyatakan sebagai (Lo, M.S., 2003):

$$\begin{aligned} h_t &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \\ &= \alpha_0 + \alpha_1 (Z_{t-1}^2 h_{t-1}) + \beta_1 h_{t-1} \\ &= \alpha_0 + (\alpha_1 Z_{t-1}^2 + \beta_1) h_{t-1} \\ &= \alpha_0 + (\alpha_1 Z_{t-1}^2 + \beta_1) \{ \alpha_0 + (\alpha_1 Z_{t-2}^2 + \beta_1) h_{t-2} \} \\ &\text{dst.} \end{aligned}$$

$$= \alpha_0 + \alpha_0 \sum_{k=1}^{\infty} \left\{ \prod_{j=1}^k (\alpha_1 Z_{t-j}^2 + \beta_1) \right\}$$

maka ekspektasi varians dari

$$\begin{aligned} h_t &= \alpha_0 + \alpha_0 \sum_{k=1}^{\infty} \left\{ \prod_{j=1}^k (\alpha_1 E(Z_{t-j}^2) + \beta_1) \right\} \\ h_t &= \alpha_0 + \alpha_0 \sum_{k=1}^{\infty} (\alpha_1 + \beta_1)^k \quad (2.44) \end{aligned}$$

$$= \frac{\alpha_0}{1 - \alpha_1 - \beta_1} \quad (2.45)$$

Jika digeneralisasi untuk GARCH(p, q) maka syarat stasioner adalah $\sum_{i=1}^p \alpha_i + \sum_{i=1}^q \beta_i < 1$.

Engle dan Ng (1993) mengusulkan tiga tes yang dapat digunakan untuk mengetahui pengaruh asimetris, yaitu *Sign Bias Test* (SBT), *the Negative Sign Bias Test* (NSBT), dan *the Positive Sign Bias Test* (PSBT). Ketiga persamaan tersebut dapat dihitung dengan persamaan berikut:

$$v_t^2 = a + bS_{t-1}^- + \underline{\beta}' \underline{z}_{at}^* + e_t \quad (2.46)$$

$$v_t^2 = a + bS_{t-1}^- \varepsilon_{t-1} + \underline{\beta}' \underline{z}_{at}^* + e_t \quad (2.47)$$

$$v_t^2 = a + bS_{t-1}^+ \varepsilon_{t-1} + \underline{\beta}' \underline{z}_{at}^* + e_t \quad (2.48)$$

dimana a dan b adalah parameter konstan, $\underline{\beta}'$ adalah vektor parameter konstan, dan e_t adalah residual. Ketiga tes tersebut juga dapat dilakukan secara bersama-sama menggunakan rumus:

$$v_t^2 = a + b_1 S_{t-1}^- + b_2 S_{t-1}^- \varepsilon_{t-1} + b_3 S_{t-1}^+ \varepsilon_{t-1} + \underline{\beta}' \underline{z}_{at}^* + e_t \quad (2.49)$$

di mana:

ε_{t-1} : nilai duga residual,

S_{t-1}^- : variabel *dummy* dengan nilai 1 jika $\varepsilon_{t-1} < 0$ dan nilai 0 jika $\varepsilon_{t-1} \geq 0$,

S_{t-1}^+ : variabel *dummy* dengan nilai 0 jika $\varepsilon_{t-1} < 0$ dan nilai 1 jika $\varepsilon_{t-1} \geq 0$,

Semua tes tersebut digunakan untuk mengetahui nyata atau tidaknya nilai b pada setiap tes. Tes dilakukan dengan meregresikan setiap persamaan dengan statistik uji t .

2.5.5 Model Glosten, Jannathan and Runkle GARCH (GJR-GARCH)

Model GARCH ini dikembangkan oleh Glosten, Jagannathan, dan Runkle pada tahun 1993. Model tersebut merupakan modifikasi dari penghitungan varians bersyarat dari GARCH(1,1) yang mengasumsikan parameter ε_{t-1}^2 bergantung pada tanda dari nilai *shock* atau volatilitasnya. Model GJR-GARCH(1,1) dapat dituliskan sebagai berikut:

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \gamma \varepsilon_{t-1}^2 I(\varepsilon_{t-1} < 0) + \beta h_{t-1} \quad (2.50)$$

dengan $I[\cdot]$ merupakan fungsi indikator. Model ini sering pula disebut sebagai *Sign-GARCH* model. Formula GJR berhubungan dengan *Threshold GARCH* (TGARCH) yang merupakan model yang dikembangkan oleh Zakoian (1994) dan *Asymmetric GARCH* (AGARCH) oleh Engle (1990). Ketika mengestimasi model GJR dengan ekuitas *index returns* (Glosten *et al.*, 1993), γ didapatkan bernilai positif, sehingga volatilitas meningkat secara proporsional mengikuti *negative shocks* daripada *positive shocks*. Model asimetri tersebut berdasarkan beberapa literatur disebut sebagai *leverage effect*.

2.5.6 Model Asymmetric Power ARCH (APARCH)

Model APARCH dikembangkan oleh Ding, Granger, dan Engle pada tahun 1993. Studi Monte-Carlo yang dilakukan Ding *et al.* (1993) menunjukkan bahwa model ARCH umumnya menangkap pola khusus dari autokorelasi. Model GARCH oleh Bollerslev maupun Taylor/Schwert dalam nilai absolut model dapat menghasilkan properti tersebut. Tampaknya tidak ada alasan yang jelas mengapa harus mengasumsikan varians bersyarat adalah fungsi linier dari kuadrat residual seperti dalam GARCH Bollerslev atau fungsi linier standar deviasi bersyarat adalah fungsi linier dari residual absolut seperti dalam Model Taylor/Schwert.

Studi empiris yang dilakukan oleh Nelson (1991), Glosten *et al.* (1989) dan Engle dan Ng (1992) menunjukkan bahwa sangat penting untuk memasukkan unsur asimetrik dalam model finansial *time series*. Model APARCH yang dibentuk oleh Ding *et al.* (1993) ini merupakan modifikasi dari model GARCH dan mencakup tujuh model lain dari ARCH.

Jika diasumsikan distribusi dari *series* data (r_t) adalah normal, dari model GARCH yang telah diformulasi maka Es_t^δ dari model APARCH adalah:

$$\sum_{i=1}^p \alpha_i E(|e_{t-1}| - \gamma_i e_{t-1})^\delta + \sum_{j=1}^q \beta_j < 1, \quad (2.51)$$

dimana

$$E(|e_{t-1}| - \gamma_i e_{t-1})^\delta = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} (|x| - \gamma_i x)^\delta e^{-\frac{x^2}{2}} dx$$

$$= \frac{1}{\sqrt{2\pi}} [(1 + \gamma_i)^\delta + (1 - \gamma_i)^\delta] 2^{\frac{\delta-1}{2}} \Gamma\left(\frac{\delta+1}{2}\right)$$

sehingga menjadi

$$\frac{1}{\sqrt{2\pi}} \sum_{i=1}^p \alpha_i [(1 + \gamma_i)^\delta + (1 - \gamma_i)^\delta] 2^{\frac{\delta-1}{2}} \Gamma\left(\frac{\delta+1}{2}\right) + \sum_{j=1}^q \beta_j < 1,$$

maka

$$\begin{aligned} E|\varepsilon_t|^\delta &= E|e_t|^\delta E s_t^\delta \\ &= \frac{1}{\sqrt{\pi}} 2^{\frac{\delta}{2}} \Gamma\left(\frac{\delta+1}{2}\right) E s_t^\delta \end{aligned} \quad (2.52)$$

Ketika kondisi terpenuhi, maka ekspektasi tidak bersyarat dari s_t^δ sebagai berikut:

$$E s_t^\delta = \alpha_0 / (1 - \sum_{i=1}^p \alpha_i E(|e_{t-1}| - \gamma_i e_{t-1})^\delta + \sum_{j=1}^q \beta_j) = \omega^\delta$$

dan

$$\begin{aligned} E|\varepsilon_t|^\delta &= \frac{1}{\sqrt{\pi}} 2^{\frac{\delta}{2}} \Gamma\left(\frac{\delta+1}{2}\right) E s_t^\delta \\ &= \frac{1}{\sqrt{\pi}} 2^{\frac{\delta}{2}} \Gamma\left(\frac{\delta+1}{2}\right) \omega^\delta \end{aligned}$$

Pada kasus tertentu, ketika $\delta = 2$ dan $\gamma_i = 0$, maka kovarians yang stasioner untuk ε^t adalah

$$\begin{aligned} \frac{1}{\sqrt{2\pi}} \sum_{i=1}^p \alpha_i 2 \left(2^{\frac{2-1}{2}}\right) \Gamma\left(\frac{2+1}{2}\right) + \sum_{j=1}^q \beta_j &= \frac{1}{\sqrt{\pi}} \sum_{i=1}^p \alpha_i 2 \left(\frac{1}{2}\right) \Gamma\left(\frac{1}{2}\right) + \sum_{j=1}^q \beta_j \\ &= \sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j < 1 \end{aligned}$$

Dibawah asumsi tersebut, yaitu moment ke- δ dari s_t dan $|\varepsilon_t|$ ada, maka ε_t stasioner dalam kovarians jika $\delta \geq 2$. Model APARCH(p, q) dapat dituliskan:

$$\sigma_t^\delta = \alpha_0 + \sum_{i=1}^p \alpha_i (|\varepsilon_{t-1}| - \gamma_i \varepsilon_{t-1})^\delta + \sum_{j=1}^q \beta_j \sigma_{t-1}^\delta \quad (2.53)$$

2.6 Pemilihan Model Terbaik

Untuk memilih model yang sesuai, maka dilakukan pemilihan model berdasarkan kriteria *in-sample* (data *training*) dan *out-of-sample* (data *testing*). Kriteria *in-sample* yaitu menggunakan AIC (Wei, 2006):

$$AIC(M) = -2 \ln[\text{maximum likelihood}] + 2M \quad (2.54)$$

dimana M adalah jumlah parameter dalam model. Untuk model ARMA dan n adalah jumlah efektif dari observasi, maka fungsi *log-likelihood* yaitu:

$$\ln L = -\frac{n}{2} \ln 2\pi\sigma_a^2 - \frac{1}{2\sigma_a^2} S(\phi, \mu, \theta) \quad (2.55)$$

$$\ln \hat{L} = -\frac{n}{2} \ln \sigma_a^2 - \frac{n}{2} (1 + \ln 2\pi) \quad (2.56)$$

$$AIC(M) = n \ln \sigma_a^2 + 2M \quad (2.57)$$

Order optimal dari order dipilih berdasarkan nilai M , yang merupakan fungsi p dan q , sehingga $AIC(M)$ adalah minimum.

2.7 Inflasi

Kehidupan perekonomian suatu negara tidak terlepas dari masalah ekonomi makro, antara lain: pertumbuhan ekonomi, inflasi, pengangguran, kestabilan kegiatan ekonomi serta neraca perdagangan dan neraca pembayaran (Sukirno, 2012). Dalam perjalanannya, inflasi bisa menjadi momok bagi masyarakat namun juga bisa menjadi pemicu bagi perkembangan perekonomian. Secara sederhana inflasi diartikan sebagai meningkatnya harga-harga secara umum dan terus menerus. Kenaikan harga dari satu atau dua barang saja tidak dapat disebut inflasi kecuali bila kenaikan itu meluas (atau mengakibatkan kenaikan harga) pada barang lainnya. Jika perkembangan inflasi bergerak tanpa kendali akan mengakibatkan nilai uang akan menjadi rendah. Hal ini berpengaruh terhadap pola konsumsi masyarakat yang dampaknya akan dirasakan langsung khususnya oleh golongan masyarakat berpenghasilan menengah ke bawah serta yang berpenghasilan tetap. Inflasi yang tinggi sangat penting diperhatikan mengingat dampaknya bagi perekonomian yang dapat menimbulkan ketidakstabilan ekonomi, pertumbuhan ekonomi yang lambat, dan

pengangguran yang meningkat. Oleh karena itu perlu adanya pengendalian kestabilan pergerakan inflasi.

Perkembangan inflasi dapat dikatakan ideal jika bergerak naik namun terkendali. Kondisi ini memungkinkan dunia usaha untuk berkembang dan dapat meningkatkan produksinya, sementara masyarakat selaku konsumen tidak dikejutkan oleh kenaikan harga barang yang relatif kecil, sehingga tidak menimbulkan gejolak di masyarakat.

Secara umum, inflasi timbul karena adanya tekanan dari sisi supply (*cost push inflation*), dari sisi permintaan (*demand pull inflation*), dan dari ekspektasi inflasi. Namun dalam perkembangannya faktor lain yang juga dapat mempengaruhi tingkat inflasi adalah naiknya gaji pegawai negeri, adanya hari besar keagamaan serta kebijakan pemerintah dalam penyesuaian harga Bahan Bakar Minyak (BBM) dan Tarif Dasar Listrik (TDL) terhambatnya jalur distribusi yang mengakibatkan berkurangnya persediaan barang dipasaran juga menjadi penentu naiknya harga barang. Dalam hal ini, Bank Indonesia (BI) selaku pemegang otoritas moneter di Indonesia hanya memiliki kemampuan untuk mempengaruhi tekanan inflasi yang berasal dari *demand pull inflation*, sedangkan tekanan inflasi dari *cost push inflation* berada di luar pengendalian Bank Indonesia. Faktor-faktor terjadinya *cost push inflation* dapat disebabkan oleh depresiasi nilai tukar, dampak inflasi luar negeri terutama negara-negara partner dagang, peningkatan harga-harga komoditi yang diatur pemerintah (*administered price*), dan terjadi *negative supply shocks* akibat bencana alam dan terganggunya distribusi.

Indikator yang sering digunakan untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK). Perubahan IHK dari waktu ke waktu menunjukkan pergerakan harga dari paket barang dan jasa yang dikonsumsi masyarakat. Sejak Juli 2008, paket barang dan jasa dalam keranjang IHK telah dilakukan atas dasar Survei Biaya Hidup (SBH) Tahun 2007 yang dilaksanakan oleh Badan Pusat Statistik (BPS). Kemudian, BPS akan memonitor perkembangan harga dari barang dan jasa tersebut secara bulanan di beberapa kota, di pasar tradisional dan modern terhadap beberapa jenis barang/jasa di setiap kota.

Indikator inflasi lainnya menurut BPS berdasarkan *international best practice* antara lain:

- a) Indeks Harga Perdagangan Besar (IHPB). Harga Perdagangan Besar dari suatu komoditas ialah harga transaksi yang terjadi antara penjual/pedagang besar pertama dengan pembeli/pedagang besar berikutnya dalam jumlah besar pada pasar pertama atas suatu komoditas.
- b) Deflator Produk Domestik Bruto (PDB) menggambarkan pengukuran level harga barang akhir (final goods) dan jasa yang diproduksi di dalam suatu ekonomi (negeri). Deflator PDB dihasilkan dengan membagi PDB atas dasar harga nominal dengan PDB atas dasar harga konstan.

Selanjutnya inflasi dikelompokkan ke dalam 7 kelompok pengeluaran (berdasarkan *the Classification of individual consumption by purpose* - COICOP), yaitu :

- a) Kelompok Bahan Makanan
- b) Kelompok Makanan Jadi, Minuman, dan Tembakau
- c) Kelompok Perumahan
- d) Kelompok Sandang
- e) Kelompok Kesehatan
- f) Kelompok Pendidikan dan Olah Raga
- g) Kelompok Transportasi dan Komunikasi.

Disamping pengelompokan berdasarkan COICOP tersebut, BPS saat ini juga mempublikasikan inflasi berdasarkan pengelompokan yang lainnya yang dinamakan disagregasi inflasi. Disagregasi inflasi tersebut dilakukan untuk menghasilkan suatu indikator inflasi yang lebih menggambarkan pengaruh dari faktor yang bersifat fundamental.

Di Indonesia, disagregasi inflasi IHK tersebut dikelompokkan menjadi:

- a) Inflasi Inti, yaitu komponen inflasi yang cenderung menetap atau persisten (persistent component) di dalam pergerakan inflasi dan dipengaruhi oleh faktor fundamental, seperti:
 - Interaksi permintaan-penawaran,

- Lingkungan eksternal: nilai tukar, harga komoditi internasional, inflasi mitra dagang,
- Ekspektasi Inflasi dari pedagang dan konsumen.

b) Inflasi non Inti, yaitu komponen inflasi yang cenderung tinggi volatilitasnya karena dipengaruhi oleh selain faktor fundamental.

Komponen inflasi non inti terdiri dari :

- Inflasi Komponen Bergejolak (*Volatile Food*) :

Inflasi yang dominan dipengaruhi oleh shocks (kejutan) dalam kelompok bahan makanan seperti panen, gangguan alam, atau faktor perkembangan harga komoditas pangan domestik maupun perkembangan harga komoditas pangan internasional.

- Inflasi Komponen Harga yang diatur Pemerintah (*Administered Prices*) :

Inflasi yang dominan dipengaruhi oleh shocks (kejutan) berupa kebijakan harga Pemerintah, seperti harga BBM bersubsidi, tarif listrik, tarif angkutan, dan lain-lain.

BAB 3 METODOLOGI PENELITIAN

3.1 Data dan Variabel

3.1.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Publikasi Statistik Harga Badan Pusat Statistik (BPS). Data yang digunakan merupakan data deret waktu (*time series*) inflasi Indonesia, mulai dari Januari 1990 sampai dengan Desember 2015. Jumlah *series* data yang digunakan adalah 312 *series*. Dari bulan Januari 1990 sampai dengan Desember 2014 digunakan sebagai data *in-sample* dan data Januari 2015 sampai dengan Desember 2015 digunakan sebagai data *out-of-sample*.

3.1.2 Variabel Penelitian

Berdasarkan latar belakang dan tujuan penelitian, maka variabel penelitian yang akan digunakan adalah inflasi nasional sebagai *series output*. Selanjutnya variabel input eksogen yang digunakan adalah variabel perubahan harga minyak dunia harga minyak dunia. Data perubahan rata-rata harga minyak dunia per bulan yang digunakan merupakan perubahan rata-rata dari tiga jenis penghasil minyak dunia yaitu Brent, West Texas Intermediate (WTI), dan Dubai. Selanjutnya dilakukan deteksi *outlier* dalam membentuk model ARIMAX.

3.2 Metode Analisis Data

Berdasarkan tujuan penelitian, langkah-langkah yang akan dilakukan dalam mendapatkan suatu model inflasi yang baik dan dapat digunakan untuk memprediksi nilai inflasi di waktu yang akan datang adalah sebagai berikut.

3.2.1 Studi Simulasi

Untuk menjawab tujuan pertama dari penelitian maka disusun langkah-langkah analisis sebagai berikut:

1. Membangkitkan data residual simulasi model yang mengandung heteroskedastisitas (ARCH/GARCH) yaitu GARCH(1,1) dengan

pertimbangan bahwa GARCH(1,1) merupakan model GARCH paling sederhana yang bisa digunakan untuk membandingkannya dengan metode GARCH asimetrik. Jumlah sampel menggunakan tiga macam kondisi, yaitu sampel kecil $n = 200$ dan sampel besar $n = 1.000$. Data dibangkitkan dengan menentukan kombinasi beberapa parameter (α dan β) tertentu.

2. Melakukan pemodelan dan estimasi parameter menggunakan metode GARCH, GJR-GARCH, dan APARCH.
3. Menghitung nilai AIC pada data *in-sample*
4. Mengulangi langkah 1 dan 2 sebanyak 100 kali.
5. Menghitung rata-rata nilai AIC.
6. Menghitung persentase hasil replikasi yang tolak H_0 pada uji asimetrik.
7. Membandingkan hasil pemodelan terbaik dengan melihat rata-rata nilai AIC.
8. Membangkitkan data GJR-GARCH(1,1) dengan parameter yang ditetapkan.
9. Melakukan langkah 2 s.d. 7.
10. Membangkitkan data APARCH(1,1) dengan parameter yang sudah ditetapkan.
11. Melakukan langkah 2 s.d. 7.

3.2.2 Aplikasi Data Riil

Tahapan pembentukan model ARIMA dengan deteksi *outlier*:

- a. Melakukan identifikasi model ARIMA.
- b. Melakukan estimasi parameter model ARIMA.
- c. Melakukan uji signifikansi parameter.
- d. Melakukan cek diagnosa residual model ARIMA.
- e. Mendeteksi data *outlier* pada model ARIMA.
- f. Menetapkan identifikasi model ARIMA dengan deteksi *outlier*.
- g. Melakukan estimasi parameter dengan deteksi *outlier* sebagai faktor eksogen.
- h. Melakukan uji signifikansi parameter dengan deteksi *outlier* sebagai faktor eksogen.
- i. Melakukan cek diagnosa residual model ARIMA dengan deteksi *outlier* sebagai faktor eksogen.
- j. Melakukan peramalan model ARIMA dengan deteksi *outlier*.
- k. Menghitung MSE data *in-sample* dan *out-of-sample*.

Tahapan pembentukan model ARIMA fungsi transfer:

1. Identifikasi bentuk model:
 - a. Mempersiapkan deret input (harga minyak dunia) dan deret output (inflasi).
 - b. *Prewhitening* deret input dan penghitungan deret output.
 - c. Penghitungan *crosscorrelation* dan autokorelasi untuk deret input dan deret output yang telah dilakukan *prewhitening*.
 - d. Penaksiran bobot respon impuls.
 - e. Penetapan (b, r, s) untuk model fungsi transfer.
 - f. Penaksiran awal deret gangguan (noise series).
 - g. Penentuan model ARIMA dari deret gangguan n_t .
2. Estimasi parameter model fungsi transfer.
3. Diagnosa model residual fungsi transfer.
4. Melakukan penanganan dengan deteksi *outlier* bila terjadi residual yang tidak berdistribusi normal.


Tahapan pembentukan model ARIMAX dengan fungsi transfer dan deteksi *outlier*:

- a. Melakukan tahapan proses ARIMA dengan fungsi transfer.
- b. Mendeteksi data *outlier* pada model ARIMAX fungsi transfer.
- c. Menetapkan identifikasi model ARIMAX fungsi transfer dengan deteksi *outlier*.
- d. Melakukan estimasi parameter dengan deteksi *outlier* sebagai faktor eksogen.
- e. Melakukan cek diagnosa residual model ARIMA fungsi transfer dengan deteksi *outlier* sebagai faktor eksogen.
- f. Melakukan peramalan model ARIMAX fungsi transfer dengan deteksi *outlier*.
- g. Menghitung MSE data *in-sample* dan *out-of-sample*.


Dari model ARIMAX yang terbentuk baik dengan fungsi transfer maupun deteksi *outlier*, kemudian residual yang terbentuk dari model, dilanjutkan dengan proses pemodelan dengan GARCH.

Tahapan pembentukan model ARIMAX-GARCH simetrik dan asimetrik:

- a. Melakukan tahapan proses ARIMA, fungsi transfer dan deteksi *outlier* seperti yang dijelaskan sebelumnya.
- b. Residual yang didapatkan dari proses *a*, dipersiapkan untuk model GARCH.
- c. Eksplorasi data residual yang terbentuk.
- d. Melakukan identifikasi apakah data residual mengandung unsur ARCH. Identifikasi ini dilakukan dengan uji LM.
- e. Identifikasi dugaan model ARCH.
- f. Melakukan estimasi parameter.
- g. Melakukan uji signifikansi parameter.
- h. Melakukan cek diagnosa residual dan residual kuadrat dari model-model GARCH yang terbentuk.
- i. Melakukan pemilihan model terbaik ARCH/GARCH.
- j. Melakukan pengujian efek asimetris pada model GARCH pada ordo minimal GARCH(1,1).
- k. Melakukan estimasi parameter GJR-GARCH dan APARCH.
- l. Melakukan uji signifikansi parameter GJR-GARCH dan APARCH.
- m. Melakukan cek diagnosa residual dan residual kuadrat dari model-model GARCH yang terbentuk.
- n. Melakukan peramalan sigma.
- o. Melakukan peramalan interval pada model ARIMAX dengan simetrik dan asimetrik GARCH.
- p. Validasi dan pengecekan performa masing-masing model.



Gambar 3.1 Diagram alir pemodelan data dengan metode ARIMAX-GARCH



BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini akan dilakukan analisis dan pembahasan tentang GARCH, GJR-GARCH, dan APARCH dengan menggunakan data simulasi serta data inflasi Indonesia. Analisis dan pembahasan data simulasi meliputi pemodelan GARCH, GJR-GARCH, dan APARCH serta menganalisis performa masing-masing model. Analisis dan pembahasan data inflasi meliputi karakteristik dari data, model GARCH, GJR-GARCH, dan APARCH, meramalkan data inflasi Indonesia, serta menganalisis performa masing-masing model.

4.1 Studi Simulasi

Simulasi data *time series* bertujuan untuk membuktikan bahwa suatu metode memang layak untuk digunakan dan hasil estimasi yang diperoleh dari metode tersebut tidak semata-mata karena faktor kebetulan. Pada penelitian ini data yang akan disimulasi adalah data GARCH.

4.1.1 Simulasi Data Bangkitan

Model GARCH merupakan model yang dapat mengakomodasi masalah heteroskedastisitas data. Tahap awal dari membangkitkan data GARCH untuk tujuan simulasi adalah membangkitkan data yang berdistribusi normal dengan parameter GARCH yang ditentukan terlebih dahulu. GARCH yang dibangkitkan merupakan model GARCH(1,1) dengan pertimbangan bahwa GARCH(1,1) merupakan model GARCH paling sederhana yang bisa digunakan untuk membandingkannya dengan metode GARCH asimetrik. Selanjutnya dibangkitkan pula data GARCH asimetrik yaitu GJR-GARCH(1,1) dan APARCH(1,1). Pada setiap skenario digunakan 100 kali pengulangan dengan masing-masing jumlah sampel adalah 200 dan 1.000. Pemilihan jumlah sampel berdasarkan pertimbangan jumlah sampel kecil = 200 dan jumlah sampel besar = 1.000. Ada tiga parameter yang digunakan dalam pembentukan model GARCH(1,1) yaitu α_0 , α_1 , dan β_1 . Sementara itu ada empat parameter yang digunakan dalam pembentukan model GJR-GARCH(1,1) yaitu α_0 , α_1 , β_1 dan γ_1 . Untuk

pembentukan model APARCH(1,1) digunakan 5 parameter yaitu α_0 , α_1 , β_1 , γ_1 , dan δ . *Setting* parameter yang digunakan adalah sebanyak 15 skenario. Skenario 1-9 merupakan skenario model GARCH(1,1) dengan α_0 yang dibuat konsisten pada tiap skenario dan mempertahankan nilai $\alpha_1 + \beta_1 = 0,9$.

Tabel 4.1 *Setting* parameter untuk data simulasi


Skenario	Parameter				
	α_0	α_1	β_1	γ_1	δ
1	0,01	0,1	0,8	-	-
2	0,01	0,2	0,7	-	-
3	0,01	0,3	0,6	-	-
4	0,01	0,4	0,5	-	-
5	0,01	0,45	0,45	-	-
6	0,01	0,5	0,4	-	-
7	0,01	0,6	0,3	-	-
8	0,01	0,7	0,2	-	-
9	0,01	0,8	0,1	-	-
10	0,005	0,28	0,5	0,23	-
11	0,005	0,18	0,6	0,23	-
12	0,005	0,38	0,4	0,23	-
13	0,005	0,28	0,5	0,23	2
14	0,005	0,18	0,6	0,23	2
15	0,005	0,38	0,4	0,23	2

Simulasi data seperti pada Tabel 4.1 digunakan untuk membandingkan performa masing-masing model GARCH. Selanjutnya dibangkitkan pula data GARCH simetrik dan asimetrik untuk mengetahui *power* dan *size* dari pengujian asimetrik GARCH. *Setting* parameter yang digunakan ada 9 skenario seperti yang disajikan pada tabel 4.2. *Setting* parameter simulasi pada Tabel 4.2 didasarkan pada simulasi yang dilakukan Engle dan Ng (1993).

Tabel 4.2 *Setting parameter untuk data simulasi power dan size uji asimetrik*

Skenario	Parameter				
	α_0	α_1	β_1	γ_1	δ
1	0,01	0,09	0,9	-	-
2	0,05	0,05	0,9	-	-
3	0,2	0,05	0,75	-	-
4	0,005	0,28	0,5	0,23	-
5	0,005	0,18	0,6	0,23	-
6	0,005	0,38	0,4	0,23	-
7	0,005	0,28	0,5	0,23	2
8	0,005	0,18	0,6	0,23	2
9	0,005	0,38	0,4	0,23	2

4.1.2 Hasil Simulasi



Gambar 4.1 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 1

Pada Gambar 4.1 disajikan plot ACF observasi, plot ACF kuadrat observasi, plot *time series*, plot *standard error* dari data yang mengikuti model GARCH(1,1) dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,1$, dan $\beta_1 = 0,8$ dengan jumlah sampel 1.000.


Tabel 4.3 Perbandingan AIC model skenario 1 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	0,5120054
	1.000	0,4907642
GJR-GARCH(1,1)	200	0,5109466
	1.000	0,4920505
APARCH(1,1)	200	0,5188978
	1.000	0,4928501

Model persamaan dari simulasi pada tabel 4.3 adalah sebagai berikut:


$$\sigma_t^2 = 0,01 + 0,1\varepsilon_{t-1}^2 + 0,8\sigma_{t-1}^2 \quad (4.1)$$

Pada ketiga model GARCH hasil estimasi dari data simulasi, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH, memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada jumlah sampel 200, model dengan nilai AIC terkecil adalah GJR-GARCH(1,1). Sementara itu pada jumlah sampel 1.000, model GARCH(1,1) memiliki nilai AIC terkecil dibandingkan dengan kedua model GARCH lainnya. Bila kedua model GARCH asimetrik dibandingkan, baik dalam sampel kecil maupun sampel besar, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Hal tersebut mengindikasikan model GJR-GARCH(1,1) lebih baik dibandingkan APARCH(1,1). Pada model skenario 1 terlihat bahwa seiring peningkatan jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hasil tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik.



Gambar 4.2 *News impact curve* pada model skenario 1

Untuk melihat hubungan simetrik pada data yang dibangkitkan melalui model skenario 1, dapat dilihat pada Gambar 4.2. Pada gambar tersebut tampak bahwa nilai yang sama namun bertanda positif ataupun negatif dari *shock* (ε_{t-1}) memberikan dampak yang sama terhadap nilai varians, sehingga hubungan tersebut disebut simetrik.



Gambar 4.3 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 2

Selanjutnya pada gambar 4.3 disajikan plot ACF observasi, plot ACF kuadrat observasi, plot *time series*, plot *standard error* dari data yang mengikuti model GARCH(1,1) dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,2$, dan $\beta_1 = 0,7$ dengan jumlah sampel 1.000. Hasil penghitungan akurasi berdasarkan estimasi parameter pada data bangkitan dijabarkan dalam tabel berikut.

Tabel 4.4 Perbandingan AIC model skenario 2 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH


Model	Jumlah Sampel	AIC
GARCH(1,1)	200	0,4407345
	1.000	0,3821103
GJR-GARCH(1,1)	200	0,4426322
	1.000	0,3830722
APARCH(1,1)	200	1,540991
	1.000	0,3840547

Model persamaan dari simulasi pada tabel 4.4 adalah sebagai berikut:

$$\sigma_t^2 = 0,01 + 0,2\varepsilon_{t-1}^2 + 0,7\sigma_{t-1}^2 \quad (4.2)$$


Pada ketiga model GARCH hasil estimasi dari data simulasi, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH, memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Pada Tabel 4.4, Bila kedua model GARCH asimetrik dibandingkan, baik dalam sampel kecil maupun sampel besar, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Hal tersebut mengindikasikan model GJR-GARCH(1,1) lebih baik dibandingkan APARCH(1,1). Pada model skenario 2 terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut

mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.4.



Gambar 4.4 *News impact curve* pada model skenario 2

Berikutnya model skenario ketiga menggunakan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,3$, dan $\beta_1 = 0,6$. Plot data bangkitan dapat dilihat pada Gambar 4.5.



Gambar 4.5 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 3

Hasil penghitungan akurasi berdasarkan estimasi parameter pada data bangkitan dijabarkan dalam Tabel 4.5.


Tabel 4.5 Perbandingan AIC model skenario 3 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	0,2548288
	1.000	0,2192589
GJR-GARCH(1,1)	200	0,2591613
	1.000	0,2202762
APARCH(1,1)	200	0,2622997
	1.000	0,2212801

Model persamaan dari simulasi pada Tabel 4.5 adalah sebagai berikut:


$$\sigma_t^2 = 0,01 + 0,3\varepsilon_{t-1}^2 + 0,6\sigma_{t-1}^2 \quad (4.3)$$

Pada ketiga model GARCH hasil estimasi dari data simulasi, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH, memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Seperti halnya pada skenario 2, baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Bila kedua model GARCH asimetrik dibandingkan, baik dalam sampel kecil maupun sampel besar, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Hal tersebut mengindikasikan model GJR-GARCH(1,1) lebih baik dibandingkan APARCH(1,1). Pada model skenario 3 terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.6.



Gambar 4.6 *News impact curve* pada model skenario 3

Model skenario berikutnya adalah model skenario 5 melalui data yang dibangkitkan dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,4$, dan $\beta = 0,5$. Plot data bangkitan dengan skenario 5 disajikan pada Gambar 4.7.



Gambar 4.7 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 4


Model persamaan dari simulasi pada Tabel 4.6 adalah sebagai berikut:

$$\sigma_t^2 = 0,01 + 0,4\varepsilon_{t-1}^2 + 0,5\sigma_{t-1}^2 \quad (4.4)$$

Tabel 4.6 Perbandingan AIC model skenario 4 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH


Model	Jumlah Sampel	(AIC)
GARCH(1,1)	200	0,08110778
	1.000	0,08364749
GJR-GARCH(1,1)	200	0,08770618
	1.000	0,08465974
APARCH(1,1)	200	0,08896112
	1.000	0,08564994

Pada ketiga model GARCH hasil estimasi dari data simulasi, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH, memberikan akurasi yang tinggi, dengan nilai berkisar antara 0,08 sampai dengan 0,10. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Seperti halnya pada skenario sebelumnya, baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Bila kedua model GARCH asimetrik dibandingkan, baik dalam sampel kecil maupun sampel besar, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Hal tersebut mengindikasikan model GJR-GARCH(1,1) lebih baik dibandingkan APARCH(1,1). Pada model skenario 4 terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.8.



Gambar 4.8 *News impact curve* pada model skenario 4

Model skenario berikutnya adalah model skenario 5 melalui data yang dibangkitkan dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,45$, dan $\beta = 0,45$. Plot *series* maupun sigma dapat dilihat pada Gambar 4.9. Sementara itu hasil penghitungan akurasi berdasarkan estimasi parameter pada data bangkitan disajikan dalam Tabel 4.7.



Gambar 4.9 Plot ACF observasi 9 (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 5


Tabel 4.7 Perbandingan AIC model skenario 5 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	0,009184111
	1.000	-0,01416541
GJR-GARCH(1,1)	200	0,01701766
	1.000	-0,01327129
APARCH(1,1)	200	0,01685195
	1.000	-0,01228112

Model persamaan dari simulasi pada Tabel 4.7 adalah sebagai berikut:


$$\sigma_t^2 = 0,01 + 0,45\varepsilon_{t-1}^2 + 0,45\sigma_{t-1}^2 \quad (4.5)$$

Pada ketiga model GARCH hasil estimasi dari data simulasi, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH, memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Seperti halnya pada skenario sebelumnya, baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Bila kedua model GARCH asimetrik dibandingkan, pada sampel 1.000, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Akan tetapi pada sampel 200 APARCH(1,1) memiliki AIC yang paling kecil. Pada model skenario 5 terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.10.



Gambar 4.10 *News impact curve* pada model skenario 5

Model skenario selanjutnya adalah model skenario 6 dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,5$, dan $\beta = 0,4$, dengan plot sebagai berikut:



Gambar 4.11 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 6

Pada Tabel 4.8 berikut menyajikan hasil perhitungan akurasi dari ketiga model GARCH pada masing-masing dua besaran sampel.


Tabel 4.8 Perbandingan AIC model skenario 6 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	(AIC)
GARCH(1,1)	200	-0,1280882
	1.000	-0,1023247
GJR-GARCH(1,1)	200	-0,1188232
	1.000	-0,101349
APARCH(1,1)	200	-0,1180307
	1.000	-0,1002242

Model persamaan dari simulasi pada Tabel 4.8 adalah sebagai berikut:


$$\sigma_t^2 = 0,01 + 0,5\varepsilon_{t-1}^2 + 0,4\sigma_{t-1}^2 \quad (4.6)$$

Dari ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Seperti halnya pada skenario sebelumnya, baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Bila kedua model GARCH asimetrik dibandingkan, baik dalam sampel kecil maupun sampel besar, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Hal tersebut mengindikasikan model GJR-GARCH(1,1) lebih baik dibandingkan APARCH(1,1). Pada model skenario 6 terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.12.



Gambar 4.12 *News impact curve* pada model skenario 6

Selanjutnya model skenario 7 menggunakan parameter yang seperti model skenario sebelumnya yakni yang memiliki persistensi tinggi. Adapun nilai parameter yang ditentukan adalah $\alpha_0 = 0,01$, $\alpha_1 = 0,6$, dan $\beta = 0,3$. Berikut disajikan gambar plot *series* maupun plot *standard error* dari model dengan parameter tersebut.



Gambar 4.13 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 7


Model persamaan dari simulasi pada Tabel 4.9 adalah sebagai berikut:

$$\sigma_t^2 = 0,01 + 0,6\varepsilon_{t-1}^2 + 0,3\sigma_{t-1}^2 \quad (4.7)$$

Tabel 4.9 Perbandingan AIC model skenario 7 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH


Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-0,2265736
	1.000	-0,2551862
GJR-GARCH(1,1)	200	-0,2182287
	1.000	-0,2541444
APARCH(1,1)	200	-0,2180928
	1.000	-0,2531143

Dari ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Seperti halnya pada skenario sebelumnya, baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Bila kedua model GARCH asimetrik dibandingkan, baik dalam sampel kecil maupun sampel besar, GJR-GARCH(1,1) memiliki nilai AIC yang paling kecil. Hal tersebut mengindikasikan model GJR-GARCH(1,1) lebih baik dibandingkan APARCH(1,1). Pada model skenario 7, seperti pada skenario-skenario sebelumnya terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.14.



Gambar 4.14 *News impact curve* pada model skenario 7

Model skenario selanjutnya adalah model skenario 8 dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,7$, dan $\beta = 0,2$. Berikut disajikan plot series dari data yang dibangkitkan berdasarkan parameter tersebut.



Gambar 4.15 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 8


Model persamaan dari simulasi pada Tabel 4.10 adalah sebagai berikut:

$$\sigma_t^2 = 0,01 + 0,7\varepsilon_{t-1}^2 + 0,2\sigma_{t-1}^2 \quad (4.8)$$

Tabel 4.10 Perbandingan AIC model skenario 8 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH


Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-0,4379149
	1.000	-0,4726064
GJR-GARCH(1,1)	200	-0,4318631
	1.000	-0,4716019
APARCH(1,1)	200	-0,4320058
	1.000	-0,4707529

Berdasarkan ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada jumlah sampel 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Namun pada sampel 200, GJR-GARCH(1,1) memiliki AIC terkecil. Pada model skenario 8, seperti pada skenario sebelumnya terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.16.



Gambar 4.16 *News impact curve* pada model skenario 8

Model skenario selanjutnya adalah model skenario 9 dengan parameter $\alpha_0 = 0,01$, $\alpha_1 = 0,8$, dan $\beta = 0,1$. Plot *series* data ditunjukkan oleh gambar 4.15. Adapun hasil penghitungan akurasi berdasarkan estimasi parameter pada data bangkitan dijabarkan dalam Tabel 4.11.



Gambar 4.17 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 9


Tabel 4.11 Perbandingan AIC model skenario 9 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-0,6110365
	1.000	-0,635689
GJR-GARCH(1,1)	200	-0,6046982
	1.000	-0,6347591
APARCH(1,1)	200	-0,6056782
	1.000	-0,6335522

Model persamaan dari simulasi pada Tabel 4.11 adalah sebagai berikut:


$$\sigma_t^2 = 0,01 + 0,8\varepsilon_{t-1}^2 + 0,1\sigma_{t-1}^2 \quad (4.9)$$

Dari ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Seperti halnya pada skenario sebelumnya, baik pada jumlah sampel 200 maupun 1.000, model GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GARCH(1,1) merupakan model terbaik pada data tersebut. Bila kedua model GARCH asimetrik dibandingkan, dalam sampel kecil, APARCH(1,1) memiliki nilai AIC yang paling kecil. Namun pada jumlah sampel 1.000, model GJR-GARCH(1,1) memiliki AIC yang lebih kecil dibandingkan dengan model APARCH(1,1). Pada model skenario 9, seperti pada skenario-skenario sebelumnya terlihat bahwa semakin besar jumlah sampel yang digunakan pada masing-masing model GARCH, maka nilai AIC pada data *in-sample* atau data *training* semakin kecil. Hal tersebut mengindikasikan semakin besar sampel, model yang dihasilkan akan semakin baik. Hubungan simetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.18.



Gambar 4.18 *News impact curve* pada model skenario 9

Model skenario selanjutnya adalah model skenario 10 yang merupakan model GJR-GARCH(1,1) dengan parameter $\alpha_0 = 0,005$, $\alpha_1 = 0,28$, $\beta_1 = 0,5$, dan $\gamma_1 = 0,23$. Plot *series* data ditunjukkan oleh Gambar 4.19.



Gambar 4.19 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 10


Model persamaan dari simulasi pada Tabel 4.12 adalah sebagai berikut:

$$\sigma_t^2 = 0,005 + 0,28\varepsilon_{t-1}^2 + 0,23\varepsilon_{t-1}^2\mathbf{I}(\varepsilon_{t-1} < 0) + 0,5\sigma_{t-1}^2 \quad (4.10)$$

Tabel 4.12 Perbandingan AIC model skenario 10 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-0,4978889
	1.000	-0,5116037
GJR-GARCH(1,1)	200	-0,5046406
	1.000	-0,5233587
APARCH(1,1)	200	-0,4993939
	1.000	-0,5224259


Berdasarkan ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada skenario 10, baik pada jumlah sampel 200 maupun 1.000, model GJR-GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GJR-GARCH(1,1) merupakan model terbaik. Sementara itu, model GARCH(1,1) memiliki AIC yang paling besar diantara ketiga model tersebut. Hubungan asimetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.20.



Gambar 4.20 *News impact curve* pada model skenario 10

Dari Gambar 4.20 tampak bahwa kurva tidak asimetrik. Hal tersebut disebabkan kontribusi ε_{t-1} (*shock*) terhadap σ_t^2 (varians) lebih besar pada saat terjadi *shock* negatif.

Model skenario selanjutnya adalah model skenario 11 yang merupakan model GJR-GARCH(1,1) dengan parameter $\alpha_0 = 0,005$, $\alpha_1 = 0,18$, $\beta_1 = 0,6$, dan $\gamma_1 = 0,23$. Plot *series* data ditunjukkan oleh Gambar 4.21.



Gambar 4.21 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 11

Model persamaan dari simulasi pada Tabel 4.13 adalah sebagai berikut:

$$\sigma_t^2 = 0,005 + 0,18\varepsilon_{t-1}^2 + 0,23\varepsilon_{t-1}^2I + 0,6\sigma_{t-1}^2 \quad (4.11)$$


Berdasarkan ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada skenario 11, baik pada jumlah sampel 200 maupun 1.000, model GJR-GARCH(1,1) memiliki nilai AIC

terkecil diantara ketiga model GARCH. Dengan demikian, GJR-GARCH(1,1) merupakan model terbaik. Sementara itu, model APARCH(1,1) memiliki AIC yang paling besar diantara ketiga model tersebut.

Tabel 4.13 Perbandingan AIC model skenario 11 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH


Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-0,3887445
	1.000	-0,3832586
GJR-GARCH(1,1)	200	-0,4029811
	1.000	-0,4004037
APARCH(1,1)	200	1,725783
	1.000	-0,3996801

Hubungan asimetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.22.



Gambar 4.22 *News impact curve* pada model skenario 11

Selanjutnya model skenario yang digunakan adalah model skenario 12 yang merupakan model GJR-GARCH(1,1) dengan parameter $\alpha_0 = 0,005$, $\alpha_1 = 0,38$, $\beta_1 = 0,4$, dan $\gamma_1 = 0,23$. Plot *series* data ditunjukkan oleh Gambar 4.23.



Gambar 4.23 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 12

Model persamaan dari simulasi pada tabel 4.14 adalah sebagai berikut:


$$\sigma_t^2 = 0,005 + 0,8\varepsilon_{t-1}^2 + 0,23\varepsilon_{t-1}^2I + 0,4\sigma_{t-1}^2 \quad (4.12)$$

Berdasarkan ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada skenario 12, baik pada jumlah sampel 200 maupun 1.000, model GJR-GARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, GJR-GARCH(1,1) merupakan model terbaik. Sementara itu, model GARCH(1,1) memiliki AIC yang paling besar diantara ketiga model tersebut.

Tabel 4.14 Perbandingan AIC model skenario 12 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH


Model	Jumlah Sampel	AIC
GARCH (1,1)	200	-0.8489826
	1.000	-0.8140379
GJR-GARCH (1,1)	200	-0.8544596
	1.000	-0.8182837
APARCH (1,1)	200	-0.8491909
	1.000	-0.8169714

Hubungan asimetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.24.



Gambar 4.24 *News impact curve* pada model skenario 12

Model skenario selanjutnya adalah model skenario 13 yang merupakan model APARCH(1,1) dengan parameter $\alpha_0 = 0,005$, $\alpha_1 = 0,28$, $\beta_1 = 0,5$, $\gamma_1 = 0,23$ dan $\delta = 2$. Plot *series* data ditunjukkan oleh Gambar 4.25.



Gambar 4.25 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 13


Model persamaan dari simulasi pada Tabel 4.15 adalah sebagai berikut:

$$\sigma_t^2 = 0,005 + 0,28(|\varepsilon_{t-1}| + 0,23\varepsilon_{t-1})^2 + 0,5\sigma_{t-1}^2 \quad (4.13)$$

Tabel 4.15 Perbandingan AIC model skenario 13 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-1,022623
	1.000	-1,053847
GJR-GARCH(1,1)	200	-1,033129
	1.000	-1,065450
APARCH(1,1)	200	-1,034789
	1.000	-1,064376

Berdasarkan ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH memberikan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada skenario 13, baik pada jumlah sampel 200 maupun 1.000, model APARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Dengan demikian, APARCH(1,1) merupakan model terbaik. Sementara itu, model GARCH(1,1) memiliki AIC yang paling besar diantara ketiga model tersebut.




Gambar 4.26 *News impact curve* pada model skenario 13

Model skenario ke 14 merupakan model APARCH(1,1) dengan parameter $\alpha_0 = 0,005$, $\alpha_1 = 0,18$, $\beta_1 = 0,6$, $\gamma_1 = 0,23$ dan $\delta = 2$. Plot *series* data ditunjukkan oleh Gambar 4.27.

Tabel 4.16 Perbandingan AIC model skenario 14 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-0,9459639
	1.000	-0,9650935
GJR-GARCH(1,1)	200	-0,9506350
	1.000	-0,9730412
APARCH(1,1)	200	-0,9485872
	1.000	-0,9733059




Gambar 4.27 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 14

Model persamaan dari simulasi pada Tabel 4.16 adalah sebagai berikut:

$$\sigma_t^2 = 0,005 + 0,18(|\varepsilon_{t-1}| + 0,23\varepsilon_{t-1})^2 + 0,6\sigma_{t-1}^2 \quad (4.14)$$


Pada ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH menunjukkan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada skenario 14, pada jumlah sampel 200 AIC terkecil dimiliki oleh GJR-GARCH(1,1). Namun pada sampel 1.000, model APARCH(1,1) memiliki nilai AIC terkecil diantara ketiga model GARCH. Sementara itu, model GARCH(1,1) memiliki AIC yang paling besar diantara ketiga model tersebut.

Hubungan asimetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.28.



Gambar 4.28 *News impact curve* pada model skenario 14

Model skenario ke 14 merupakan model APARCH(1,1) dengan parameter $\alpha_0 = 0,005$, $\alpha_1 = 0,38$, $\beta_1 = 0,4$, $\gamma_1 = 0,23$ dan $\delta = 2$. Plot *series* data ditunjukkan oleh Gambar 4.29.



Gambar 4.29 Plot ACF observasi (a), ACF dari kuadrat observasi (b), *time series* (c), dan plot *standard error* (d) dari model skenario 15

Model persamaan dari simulasi pada tabel 4.17 adalah sebagai berikut:


$$\sigma_t^2 = 0,005 + 0,38(|\varepsilon_{t-1}| + 0,23\varepsilon_{t-1})^2 + 0,4\sigma_{t-1}^2 \quad (4.15)$$

Tabel 4.17 Perbandingan AIC model skenario 15 untuk data *in-sample* pada model GARCH, GJR-GARCH, dan APARCH

Model	Jumlah Sampel	AIC
GARCH(1,1)	200	-1,128787
	1.000	-1,13268
GJR-GARCH(1,1)	200	-1,143002
	1.000	-1,149443
APARCH(1,1)	200	0,8207347
	1.000	-1,148395

Pada ketiga model GARCH hasil estimasi dari data simulasi, seperti halnya pada skenario sebelumnya, terlihat bahwa nilai AIC yang dihasilkan pada masing-masing model GARCH menunjukkan akurasi yang tinggi. Nilai AIC pada masing-masing jumlah sampel dan model GARCH sekilas memberikan nilai yang tidak berbeda signifikan. Pada skenario 15, pada jumlah sampel 200 maupun 1.000, AIC terkecil dimiliki oleh GJR-GARCH(1,1). Hal tersebut mengindikasikan pada model tersebut, model GJR-GARCH(1,1) paling baik digunakan.

Hubungan asimetrik antara *shock* (ε_{t-1}) dengan varians (σ_t^2) disajikan pada Gambar 4.30.



Gambar 4.30 *News impact curve* pada model skenario 15

Tabel 4.18 Ringkasan akurasi hasil simulasi pada jumlah sampel 200

Skenario	AIC		
	GARCH(1,1)	GJR-GARCH(1,1)	APARCH(1,1)
1	0,5120054	0,5109466	0,5188978
2	0,4407345	0,4426322	1,5409910
3	0,2548288	0,2591613	0,2622997
4	0,0811078	0,0877062	0,0889611
5	0,0091841	0,0170177	0,0168519
6	-0,1280882	-0,1188232	-0,1180307
7	-0,2265736	-0,2182287	-0,2180928
8	-0,4379149	-0,4318631	-0,4320058
9	-0,6110365	-0,6046982	-0,6056782
10	-0,4978889	-0,5046406	-0,4993939
11	-0,3887445	-0,4029811	1,7257830
12	-0,8489826	-0,8544596	-0,8491909
13	-1,0226230	-1,0331290	-1,0347890
14	-0,9459639	-0,9506350	-0,9485872
15	-1,1287870	-1,1430020	0,8207347

Tabel 4.18 merupakan ringkasan hasil studi simulasi untuk sampel berjumlah 200. Untuk data *in-sample*, pada data yang dibangkitkan melalui model GARCH(1,1), hampir seluruh model skenarionya, menunjukkan bahwa GARCH simetrik (GARCH(1,1)) lebih baik dalam hal akurasi dibandingkan dengan GARCH asimetrik (GJR-GARCH(1,1) dan APARCH(1,1)) kecuali pada model skenario 1 yang menunjukkan bahwa GJR-GARCH(1,1) merupakan model yang paling baik dibandingkan kedua model GARCH lainnya. Untuk data yang dibangkitkan melalui model GJR-GARCH(1,1), semuanya menunjukkan bahwa GJR-GARCH(1,1) merupakan model terbaik. Selanjutnya untuk data yang dibangkitkan melalui model APARCH(1,1), hanya pada model skenario 13 yang menunjukkan APARCH(1,1) merupakan model terbaik. Skenario model 14 dan 15 menunjukkan bahwa model GJR-GARCH merupakan model terbaik.

Tabel 4.19 Ringkasan akurasi hasil simulasi pada jumlah sampel 1.000

Skenario	AIC		
	GARCH(1,1)	GJR-GARCH(1,1)	APARCH(1,1)
1	0,4907642	0,4920505	0,4928501
2	0,3821103	0,3830722	0,3840547
3	0,2192589	0,2202762	0,2212801
4	0,0836475	0,0846597	0,0856499
5	-0,0141654	-0,0132713	-0,0122811
6	-0,1023247	-0,1013490	-0,1002242
7	-0,2551862	-0,2541444	-0,2531143
8	-0,4726064	-0,4716019	-0,4707529
9	-0,6356890	-0,6347591	-0,6335522
10	-0,5116037	-0,5233587	-0,5224259
11	-0,3832586	-0,4004037	-0,3996801
12	-0,8140379	-0,8182837	-0,8169714
13	-1,0538470	-1,0654500	-1,0643760
14	-0,9650935	-0,9730412	-0,9733059
15	-1,1326800	-1,1494430	-1,1483950

Selanjutnya Tabel 4.19 merupakan ringkasan hasil studi simulasi untuk sampel berjumlah 1.000. Untuk data *in-sample*, pada data yang dibangkitkan melalui model GARCH(1,1), seluruh model skenarionya menunjukkan bahwa GARCH simetrik lebih baik dalam hal akurasi dibandingkan dengan GARCH asimetrik. Untuk data yang dibangkitkan melalui model GJR-GARCH(1,1), semuanya menunjukkan bahwa GJR-GARCH(1,1) merupakan model terbaik. Selanjutnya untuk data yang dibangkitkan melalui model APARCH(1,1), hanya pada model skenario 14 yang menunjukkan APARCH(1,1) merupakan model terbaik. Skenario model 13 dan 15 menunjukkan bahwa model GJR-GARCH merupakan model terbaik. Dengan demikian, GARCH(1,1) dan GJR-GARCH(1,1) menunjukkan performa akurasi yang konsisten, sedangkan APARCH(1,1) tidak konsisten.

Untuk mengetahui *power* dan *size* dari masing-masing uji asimetrik, dilakukan suatu simulasi Monte Carlo dengan data bangkitan 100 replikasi. Berdasarkan Tabel 4.2 yang disajikan di awal bab ini, diketahui ada 9 model skenario yang digunakan. Model skenario 1-3 merupakan model skenario data yang dibangkitkan dengan model GARCH(1,1). Selanjutnya model skenario 4-6 merupakan model skenario data yang dibangkitkan dengan model GJR-GARCH(1,1). Kemudian model skenario 7-9 merupakan model skenario data yang dibangkitkan dengan model APARCH(1,1).

Untuk melakukan pengecekan *size* dari uji asimetrik, dilakukan setting parameter berdasarkan skenario 1-3. Pada Tabel 4.20 disajikan hasil uji asimetrik untuk data yang dibangkitkan melalui 3 skenario model GARCH(1,1). dengan persamaan:

$$1. \text{ Model 1 GARCH(1,1): } \sigma_t^2 = 0,01 + 0,09\varepsilon_{t-1}^2 + 0,9\sigma_{t-1}^2 \quad (4.16)$$

$$2. \text{ Model 2 GARCH(1,1): } \sigma_t^2 = 0,05 + 0,05\varepsilon_{t-1}^2 + 0,9\sigma_{t-1}^2 \quad (4.17)$$

$$3. \text{ Model 3 GARCH(1,1): } \sigma_t^2 = 0,2 + 0,05\varepsilon_{t-1}^2 + 0,75\sigma_{t-1}^2 \quad (4.18)$$

Tabel 4.20 Persentase hasil uji asimetrik untuk simulasi model GARCH(1,1)

Uji	Model 1		Model 2		Model 3	
	200	1.000	200	1.000	200	1.000
<i>Sign Bias</i>						
1%	2	1	1	0	0	1
5%	6	5	8	5	6	5
10%	11	9	13	7	8	11
<i>Negative Sign Bias</i>						
1%	0	0	1	1	2	3
5%	2	5	4	5	8	9
10%	5	10	12	11	13	13
<i>Positive Sign Bias</i>						
1%	2	0	0	1	1	3
5%	4	1	5	2	9	11
10%	7	6	7	4	14	14
<i>Joint Effect</i>						
1%	1	0	0	1	3	1
5%	7	1	5	1	6	18
10%	11	8	13	8	16	18

Dari masing-masing data bangkitan pada model skenario GARCH(1,1), kemudian diestimasi berdasarkan GARCH(1,1) dan masing-masing dilakukan 4 pengujian asimetrik yaitu uji *sign bias*, *negative sign bias*, *positive sign bias*, dan *joint effect*. Berdasarkan Tabel 4.20, ukuran simulasi dari uji mendekati ukuran level signifikansi pada kedua jumlah sampel. Pada sampel yang besar, persentase data asimetrik cenderung lebih besar daripada level signifikansinya. Pada level signifikansi 1%, pada kedua jenis sampel, persentase data bersifat asimetrik berada antara 0 hingga 3 persen. Pada level signifikansi 5% dan 10%, *range* persentasenya lebih besar, namun nilai persentase maksimum tidak lebih dari 18 persen. Sehingga, dapat dikatakan keempat uji tersebut memberikan hasil uji yang lebih tepat pada level signifikansi 1%.

Berdasarkan Tabel 4.20, dengan kombinasi nilai α dan β pada model 1-3, tidak memberikan perbedaan signifikan mengenai *size* dari pengujian asimetrik tersebut. Masing-masing model tidak memberikan ukuran yang tepat dari ukuran empiris terhadap ukuran teoritisnya, karena persentase tolak H_0 atau hasil deteksi asimetrik tidak sama dengan level signifikansinya. Akan tetapi ketiga model menunjukkan ukuran yang mendekati level signifikansinya. Sehingga dapat dikatakan *size* dari keempat pengujian asimetrik cukup baik.

Berikutnya dilakukan simulasi data yang dibangkitkan pada model asimetrik. Data yang dibangkitkan mengikuti model GJR-GARCH sebagai berikut:

1. Model 1 GJR-GARCH(1,1):

$$\sigma_t^2 = 0,005 + 0,28\varepsilon_{t-1}^2 + 0,23\varepsilon_{t-1}^2 I + 0,5\sigma_{t-1}^2 \quad (4.19)$$

2. Model 2 GJR-GARCH(1,1):

$$\sigma_t^2 = 0,005 + 0,18\varepsilon_{t-1}^2 + 0,23\varepsilon_{t-1}^2 I + 0,6\sigma_{t-1}^2 \quad (4.20)$$

3. Model 3 GJR-GARCH(1,1):

$$\sigma_t^2 = 0,005 + 0,38\varepsilon_{t-1}^2 + 0,23\varepsilon_{t-1}^2 I + 0,4\sigma_{t-1}^2 \quad (4.21)$$

Tabel 4.21 Persentase hasil uji asimetrik simulasi model GJR-GARCH(1,1)

Uji	Model 1		Model 2		Model 3	
	200	1.000	200	1.000	200	1.000
<i>Sign Bias</i>						
1%	0	1	1	1	1	0
5%	1	6	5	6	7	6
10%	4	10	10	9	17	12
<i>Negative Sign Bias</i>						
1%	1	1	1	5	3	2
5%	6	7	5	12	4	4
10%	10	11	12	26	6	8
<i>Positive Sign Bias</i>						
1%	0	0	0	1	2	0
5%	3	4	4	12	3	2
10%	5	11	10	23	5	5
<i>Joint Effect</i>						
1%	1	13	3	25	5	7
5%	6	27	7	47	9	20
10%	11	31	13	62	11	27

Pada Tabel 4.21 dapat diketahui bahwa pada ketiga model asimetrik, *power* dari uji *joint effect* lebih baik pada sampel yang lebih besar yaitu 1.000. Berdasarkan level signifikansi 5%, pada GJR-GARCH mampu mengidentifikasi efek asimetrik pada model GARCH(1,1) sebesar 27%, 47%, dan 20%. Berarti bahwa uji tersebut memiliki *power* yang tidak terlalu baik, karena hanya mampu mendeteksi efek asimetrik pada GARCH(1,1) kurang dari 50%. Pada penelitian yang dilakukan oleh Engle dan Ng (1993) menyatakan bahwa *power* dari sampel kecil lebih lemah pada uji *joint effect* dan berdasarkan level signifikansi 5% pada GJR-GARCH mampu mengidentifikasi efek asimetrik sebesar 41,5 %. Sementara itu pada seluruh uji, *power* dari sampel yang besar cenderung lebih baik daripada sampel kecil. Hal tersebut berarti bahwa semakin panjang series data atau semakin besar jumlah sampel, semakin memberikan variasi data yang lebih baik sehingga mampu mengidentifikasi apakah data bersifat simetrik atau tidak, dengan lebih baik. Dengan demikian kemampuan uji asimetrik untuk mendeteksi data asimetrik akan lebih baik pada jumlah sampel yang besar (1.000).

Selanjutnya dibangkitkan data dengan mengikuti model APARCH(1,1):

1. Model 1 APARCH(1,1):

$$\sigma_t^2 = 0,005 + 0,28(|\varepsilon_{t-1}| + 0,23\varepsilon_{t-1})^2 + 0,5\sigma_{t-1}^2 \quad (4.22)$$

2. Model 2 APARCH(1,1):

$$\sigma_t^2 = 0,005 + 0,18(|\varepsilon_{t-1}| + 0,23\varepsilon_{t-1})^2 + 0,6\sigma_{t-1}^2 \quad (4.23)$$

3. Model 3 APARCH(1,1):

$$\sigma_t^2 = 0,005 + 0,38(|\varepsilon_{t-1}| + 0,23\varepsilon_{t-1})^2 + 0,4\sigma_{t-1}^2 \quad (4.24)$$

Tabel 4.22 Persentase hasil uji asimetrik untuk simulasi model APARCH(1,1)

Uji	Model 1		Model 2		Model 3	
	200	1000	200	1000	200	1000
<i>Sign Bias</i>						
1%	1	0	1	0	1	1
5%	5	6	4	3	3	7
10%	10	11	7	11	8	12
<i>Negative Sign Bias</i>						
1%	12	2	6	6	11	8
5%	19	14	11	14	18	22
10%	21	27	14	22	23	32
<i>Positive Sign Bias</i>						
1%	0	1	0	5	4	5
5%	4	13	1	13	7	15
10%	8	23	8	21	9	35
<i>Joint Effect</i>						
1%	13	28	5	16	13	54
5%	19	50	10	33	21	75
10%	26	60	15	39	26	81

Seperti halnya pada tabel 4.21, pada tabel 4.22 dapat diketahui bahwa pada ketiga model asimetrik, *power* dari uji *joint effect* lebih baik pada sampel yang lebih besar yaitu 1.000. Demikian halnya dengan ketiga uji lainnya. Berdasarkan level signifikansi 5%, pada jumlah sampel 1.000, model APARCH mampu mengidentifikasi efek asimetrik pada model GARCH(1,1) sebesar 50%, 33%, dan 75%. Berarti bahwa uji tersebut memiliki *power* yang baik, karena mampu mendeteksi efek asimetrik pada GARCH(1,1) sebesar 50% bahkan lebih. Sementara itu pada seluruh uji, *power* dari sampel yang besar cenderung lebih


baik daripada sampel kecil. Hal tersebut berarti bahwa semakin panjang *series* data atau semakin besar jumlah sampel, semakin memberikan variasi data yang lebih baik sehingga mampu mengidentifikasi apakah data bersifat simetrik atau tidak dengan lebih baik. Dengan demikian kemampuan uji asimetrik untuk mendeteksi data asimetrik akan lebih baik pada jumlah sampel yang besar (1.000).

4.2 Data Inflasi Nasional


BPS dalam melakukan penghitungan nilai inflasi didasarkan pada perubahan Indeks Harga Konsumen (IHK) yang dianggap mewakili seluruh barang dan jasa yang dijual di pasar antara suatu periode tertentu dengan periode sebelumnya. Fenomena inflasi di Indonesia menarik untuk diteliti karena nilai inflasi terkait erat dengan stabilitas ekonomi maupun kebijakan pemerintah. Data yang digunakan dalam penelitian ini merupakan data sekunder yang berasal dari data inflasi Indonesia yang dirilis setiap bulan oleh BPS. Periode data yang digunakan adalah Januari 1990 sampai dengan Desember 2015, dimana data *in-sample* adalah data bulan Januari 1990 sampai dengan Desember 2014, sedangkan data bulan Januari sampai dengan Desember 2015 digunakan sebagai data *out-of-sample*.

4.2.1 Gambaran Umum Inflasi

Nilai inflasi nasional di Indonesia cenderung berfluktuasi dengan nilai inflasi tertinggi 12,76 persen terdapat pada bulan Februari 1998. Selama kurun waktu tahun 1990 sampai dengan tahun 2015, tercatat ada beberapa bulan yang mengalami deflasi namun angkanya tidak signifikan. Inflasi mencapai nilai deflasi terendah 1.05 persen (inflasi sebesar -1.05) pada bulan Juli 1999.



Gambar 4.31 Plot series data inflasi nasional Januari 1990-Desember 2015




Gambar 4.32 Deskripsi inflasi bulanan nasional Januari 1990-Desember 2015

Berdasarkan Gambar 4.32 terlihat bahwa nilai inflasi kurun waktu Januari 1990 hingga Desember 2015 berada dalam rentang -1,05 dan 12,76. Bila melihat mediannya, nilai inflasi nasional berada pada kisaran 0.53. Hal ini menunjukkan

bahwa kondisi perekonomian Indonesia cukup stabil terhadap berbagai guncangan baik dari sisi sosial, politik dan ekonomi lainnya. Dilihat dari rata-rata inflasi nasional bernilai 0,79 atau diatas nilai median. Hal tersebut disebabkan adanya beberapa *outlier* yang membuat distribusi data menjadi menceng. Namun data inflasi tidak terdistribusi secara normal dilihat dari *p-value normality test* yang kurang dari 0.05. Data cenderung untuk menceng kanan dengan nilai *skewness* sebesar 4,7025. Data inflasi juga memiliki kurtosis yang cukup tinggi yakni sebesar 31,3678.

Inflasi dipengaruhi oleh berbagai faktor baik internal maupun eksternal seperti yang telah dijelaskan pada bab 2 sebelumnya. Salah satu faktor yang diduga merupakan faktor eksternal inflasi adalah harga minyak dunia. Harga minyak dunia cenderung berubah dari waktu ke waktu. Untuk itu dalam mengukur keterkaitannya dengan inflasi, digunakan perubahan harga minyak dunia setiap bulannya. Berikut disajikan plot *series* data untuk perubahan harga minyak dunia setiap bulan:




Gambar 4.33 Plot series data perubahan harga minyak dunia Januari 1990-Desember 2015

Nilai perubahan harga minyak dunia cenderung lebih berfluktuasi dibandingkan dengan nilai inflasi, dimana nilai perubahan harga tertinggi sebesar 57,88 persen terdapat pada bulan Agustus 1990. Selama kurun waktu tahun 1990

sampai dengan tahun 2015, tercatat ada beberapa bulan yang mengalami perubahan yang negatif. Perubahan yang terendah terjadi pada bulan Oktober 1999 yaitu sebesar -26,79 persen.

Selanjutnya disajikan gambar deskripsi data perubahan harga minyak dunia pada gambar 4.34. Berdasarkan Gambar 4.34 terlihat bahwa nilai perubahan harga minyak dunia kurun waktu Januari 1990 hingga Desember 2015 berada dalam rentang -26,79 dan 57,88. Bila melihat mediannya, perubahan harga minyak dunia berada pada kisaran 0.99 dengan rata-rata sebesar 0,6257. Hal ini menunjukkan bahwa kondisi perubahan harga minyak dunia cukup stabil. Namun demikian data perubahan harga minyak dunia tidak terdistribusi secara normal dilihat dari *p-value normality test* yang kurang dari 0.05. Hal tersebut disebabkan ada beberapa *outlier* data yakni data yang nilainya jauh diluar sebaran nilai-nilainya.




Gambar 4.34 Deskripsi persentase perubahan harga minyak dunia Januari 1990-Desember 2015

4.2.2 Model ARIMA dan ARIMA Fungsi Transfer

a. ARIMA Inflasi

Tahap awal dari pemodelan ARIMA adalah stasioneritas data. Berdasarkan pada plot *time series*, data inflasi nasional cenderung stasioner dengan adanya beberapa *outlier*. Untuk melihat stasioneritas data inflasi nasional pada rata-rata dapat dilihat melalui plot ACF dan PACF seperti terlihat pada Gambar 4.35.



Gambar 4.35 Plot (a) ACF dan (b) PACF data inflasi nasional

Pada plot ACF dan PCF tersebut terlihat pola *cut off* pada kedua plot. Hal ini menunjukkan bahwa data inflasi nasional telah stasioner pada rata-rata, sehingga tidak diperlukan *differencing*. Untuk memperkuat dugaan dilakukan unit *root test* menggunakan uji ADF. Dimana nilai *p-value* lebih kecil dari 0,05, sehingga tolak H_0 . Untuk itu dapat disimpulkan bahwa data telah stasioner dalam rata-rata.

Berdasarkan Gambar 4.35, dapat dilakukan identifikasi model ARIMA. Identifikasi model ARIMA ditentukan dari pola plot ACF dan PACF pada data inflasi nasional yang telah stasioner. Dari pola plot ACF yang terbentuk menurun secara eksponensial, dan pada plot PACF *cut off*. Pada *Lag* PACF, tampak signifikan pada *Lag* 1, 3, 5, dan 8. Berdasarkan hal tersebut, dugaan model ARIMA yang mungkin terbentuk adalah ARIMA ([1,3,5,8],0,0).

Tabel 4.23 Uji signifikansi parameter model ARIMA([1,3,5,8],0,0) inflasi nasional


Parameter	Nilai Estimasi	StandardError	t-hitung	p-value
μ	0,81	0,15511	5,24	<0,0001
ϕ_1	0,52	0,04888	10,66	<0,0001
ϕ_3	0,13	0,05166	2,57	0,0102
ϕ_5	0,18	0,05041	3,64	0,0003
ϕ_8	-0,21	0,04832	-4,47	<0,0001

Dari tabel 4.23 diketahui bahwa uji signifikansi parameter memberikan hasil yang signifikan pada semua parameter. Langkah selanjutnya adalah melakukan cek diagnosa dari residual model. Berdasarkan hasil uji Ljung-Box untuk mengetahui terpenuhinya kondisi *white noise*, diperoleh hasil sebagai berikut.


Tabel 4.24 Uji Residual *White Noise* Model ARIMA Inflasi nasional

Hingga Lag	Chi-Square	DF	p-value
6	0,84	2	0,6587
12	6,96	8	0,5407
18	10,37	14	0,7349
24	15,01	20	0,7756
30	18,37	26	0,8620
36	22,71	32	0,8874
42	25,45	38	0,9405
48	31,79	44	0,9152

Berdasarkan hasil uji *White Noise*, seluruh *Lag* telah memenuhi asumsi *White Noise* karena seluruh nilai *p-value* lebih dari 0,05. Plot residual dapat dilihat pada uji Gambar 4.36. Berdasarkan plot residual, terlihat tidak ada *Lagi Lag* yang signifikan pada plot ACF. Selanjutnya dilakukan uji asumsi normalitas pada residual.



Berdasarkan plot normalitas *qq-plot residual* tampak bahwa data belum berdistribusi normal. Berdasarkan hasil uji normalitas menggunakan uji Kolmogorov Smirnov menunjukkan *p-value* kurang dari 0,05, sehingga dapat disimpulkan bahwa residual tidak berdistribusi normal. Hal tersebut diidentifikasi disebabkan oleh adanya data *outlier*. Untuk itu perlu dilakukan deteksi *outlier* dan memasukkan input *outlier* kedalam model ARIMA agar residual berdistribusi normal.



Gambar 4.37 *Qq-plot* residual inflasi

Dari hasil deteksi *outlier* yang dilakukan, dapat diidentifikasi keseluruhan *outlier* merupakan *additive outlier* seperti yang tampak pada tabel 4.25.

Tabel 4.25 Identifikasi *outlier* data inflasi nasional

Waktu	Keterangan
Januari 1998	Krisis ekonomi dimana nilai tukar rupiah terhadap dollar terdepresiasi 80%
Februari 1998	Krisis ekonomi
Juli 1998	Krisis ekonomi dimana SBI 70,8%, SBPU 60%, IHSG anjlok
Oktober 1998	Krisis ekonomi
Oktober 2005	Kenaikan BBM 125%
Juli 2013	Kenaikan BBM 33,33%

Outlier yang terdeteksi dimasukkan ke dalam model ARIMA inflasi satu per-satu dengan memasukkan *outlier* yang paling signifikan. *Outlier* paling signifikan pada deteksi *outlier* ada pada data ke 190 yaitu kenaikan BBM Oktober 2005. Selanjutnya dilakukan uji signifikansi dari estimasi parameter dengan memasukkan *outlier* tersebut. Hal tersebut dilakukan hingga didapatkan parameter yang signifikan seluruhnya dan memenuhi uji asumsi pada residual.

Tabel 4.26 Uji signifikansi parameter model ARIMA inflasi nasional dengan deteksi *outlier*


Parameter	Nilai Estimasi	Standard Error	t-hitung	p-value
μ	0,74772	0,14684	5,09	<0,0001
θ_{10}	-0,17216	0,05911	-2,91	0,0036
θ_{12}	-0,37120	0,05915	-6,28	<0,0001
ϕ_1	0,66582	0,04689	14,20	<0,0001
ϕ_3	0,16870	0,04943	3,41	0,0006
ϕ_8	-0,18997	0,04369	-4,35	<0,0001
ω_{190}	7,26172	0,44866	16,19	<0,0001
ω_{98}	8,22766	0,52358	15,71	<0,0001
ω_{103}	4,23731	0,45331	9,35	<0,0001
ω_{97}	3,19870	0,52370	6,11	<0,0001
ω_{106}	-2,65681	0,47013	-5,65	<0,0001
ω_{283}	2,08955	0,45795	4,56	<0,0001

Dari hasil uji signifikansi parameter, pada model ARIMA inflasi ada enam *outlier* yang dimasukkan yang bersifat *additive outlier*. Selanjutnya dilakukan cek diagnosa residual model ARIMA. Pada Gambar 4.38, plot ACF residual model ARIMA menunjukkan tidak ada *Lagi Lag* yang signifikan. Sehingga dapat diindikasikan bahwa residual telah *white noise*. Pada tabel 4.27 berdasarkan hasil uji *Ljung-Box* bahwa pada semua *Lag* telah memiliki nilai *p-value* lebih dari 0,05. Dari uji tersebut dapat disimpulkan bahwa residual model ARIMA dengan deteksi *outlier* telah memenuhi asumsi *white noise*.

Tabel 4.27 Uji *White Noise* residual model ARIMA inflasi nasional

Hingga Lag	Chi-Square	DF	p-value
6	1,85	1	0,1739
12	5,63	7	0,5841
18	13,63	13	0,4002
24	25,59	19	0,1421
30	29,55	25	0,2417
36	36,92	31	0,2140
42	47,27	37	0,1202
48	53,76	43	0,1259

Pada residual selanjutnya dilakukan uji normalitas. Sebelumnya bila dilihat dari plot residual model ARIMA dengan deteksi *outlier*, pada Gambar 4.38 tampak bahwa data cenderung berdistribusi normal.



Gambar 4.38 Plot residual inflasi nasional setelah deteksi *outlier*

Untuk memperkuat dugaan normalitas pada residual, selanjutnya dilakukan uji normalitas dengan uji Kolmogorov Smirnov. Dari hasil pengujian normalitas model, pada uji Kolmogorov Smirnov, residual data memiliki *p-value* lebih besar dari 0,05 yaitu 0,0567 sehingga dapat disimpulkan bahwa residual telah berdistribusi normal.

Persamaan model peramalan ARIMA ([1,3,8],0,[10,12]) dengan deteksi *outlier* adalah sebagai berikut:

$$y_t = 0,75 + \omega_1 I_t^{(190)} + \omega_2 I_t^{(98)} + \omega_3 I_t^{(103)} + \omega_4 I_t^{(97)} - \omega_5 I_t^{(106)} + \omega_6 I_t^{(283)} + \frac{(1 + \theta_{10} B^{10} + \theta_{12} B^{12})}{(1 - \phi_1 B - \phi_3 B^3 + \phi_8 B^8)} a_t +$$

$$y_t = 0,75 + 7,26 I_t^{(190)} + 8,23 I_t^{(98)} + 4,24 I_t^{(103)} + 3,2 I_t^{(97)} - 2,66 I_t^{(106)} + 2,09 I_t^{(283)} \frac{(1 + 0,17 B^{10} + 0,37 B^{12})}{(1 - 0,67 B - 0,18 B^3 + 0,23 B^8)} a_t$$

Dari persamaan model ARIMA yang terbentuk, dapat diketahui bahwa inflasi nasional pada bulan ke-*t* berkaitan dengan inflasi nasional satu bulan sebelumnya, inflasi nasional tiga bulan sebelumnya, inflasi nasional delapan bulan sebelumnya serta *outlier* yang diidentifikasi. Berdasarkan model yang terbentuk, selanjutnya dapat dilakukan peramalan data inflasi.

Tabel 4.28 Perbandingan data *out-of-sample* dan hasil ramalan model ARIMA Januari-Desember 2015


Bulan	Data <i>Out-of-sample</i>	Ramalan Inflasi	Residual
Januari	-0,24	2,00	-2,24
Februari	-0,36	1,56	-1,92
Maret	0,17	1,43	-1,26
April	0,36	1,36	-1
Mei	0,5	1,34	-0,84
Juni	0,54	1,12	-0,58
Juli	0,93	1,10	-0,17
Agustus	0,39	0,55	-0,16
September	-0,05	0,57	-0,62
Oktober	-0,08	0,57	-0,65
November	0,21	0,65	-0,44
Desember	0,96	0,81	0,15

Hasil ramalan untuk data *out-of-sample* (Januari s.d. Desember 2015) disajikan dalam Tabel 4.28. Dari Tabel 4.28 diketahui bahwa hasil ramalan ARIMA inflasi memiliki MSE sebesar 1,11756. Sementara itu MSE untuk data *in-sample* sebesar 0.617389, sehingga akurasi data *in-sample* lebih baik daripada data *out-sample*.

b. ARIMA Fungsi Transfer Inflasi

Tahap awal dari pemodelan fungsi transfer multi input adalah proses *prewhitening* deret input, yaitu deret perubahan harga minyak dunia. Asumsi dasar yang harus dipenuhi dalam analisis time series dan pembentukan model ARIMA adalah stasioneritas data. Uji stasioneritas data dalam rata-rata dilakukan dengan uji *Augmented Dicky-Fuller*. Dari hasil uji ADF, diperoleh bahwa kedua deret input (perubahan harga minyak dunia) dan deret output (inflasi) masing-masing memiliki *p-value* kurang dari 0,05 sehingga dapat dikatakan bahwa kedua deret telah stasioner dalam rata-rata. Karena telah stasioner, maka berarti tidak perlu dilakukan differencing pada data.

Langkah selanjutnya adalah dengan memodelkan deret input. Dalam pemodelan deret input terlebih dahulu dilakukan identifikasi model ARIMA input. Identifikasi dapat dilakukan melalui pengamatan pada plot ACF dan PACF data deret input. Plot data perubahan harga minyak dunia disajikan pada Gambar 4.39.



Gambar 4.39 Plot (a) ACF dan (b) PACF perubahan harga minyak dunia


Berdasarkan Gambar 4.39, dapat dilakukan identifikasi model ARIMA. Identifikasi model ARIMA ditentukan dari pola plot ACF dan PACF pada data perubahan harga minyak dunia yang telah stasioner. Dari pola plot ACF dan PACF yang terbentuk, pada *Lag* PACF, tampak signifikan pada *Lag* 1 sedangkan

pada plot ACF tampak signifikan pada *Lag* 1 dan 6. Berdasarkan hal tersebut, dugaan model ARIMA yang mungkin terbentuk adalah ARIMA (1,0,6).

Tabel 4.29 Uji signifikansi parameter ARIMA perubahan harga minyak dunia

Parameter	Estimasi	Standard Error	t-hitung	p-value
θ_6	0,12546	0,05828	2,15	0,0313
ϕ_1	0,31707	0,05562	5,70	<0,0001

Dari Tabel 4.29 diketahui bahwa uji signifikansi parameter memberikan hasil yang signifikan pada semua parameter. Langkah selanjutnya adalah melakukan cek diagnosa dari residual model. Gambar 4.40 menyajikan plot residual dari model ARIMA perubahan harga minyak dunia yang terbentuk.




Gambar 4.40 Plot ACF dan PACF residual model ARIMA perubahan harga minyak dunia

Pada Gambar 4.40, plot ACF residual memberikan indikasi bahwa data residual telah memenuhi asumsi *white noise*. Untuk itu dilakukan uji Ljung-Box. Hasil uji Ljung-Box disajikan pada tabel 4.30.

Tabel 4.30 Uji *white noise* model ARIMA perubahan harga minyak dunia

Lag	Chi-Square	DF	p-value
6	3,11	4	0,5401
12	9,86	10	0,4529
18	15,78	16	0,4684
24	19,89	22	0,5897
30	34,56	28	0,1831
36	41,21	34	0,1844
42	46,88	40	0,2111
48	51,42	46	0,2700

Pada Tabel 4.30, semua *lag* telah memiliki *p-value* lebih dari 0,05 sehingga dapat disimpulkan bahwa residual model ARIMA perubahan harga minyak dunia telah *white noise*. Selanjutnya pada Gambar 4.41 terlihat bahwa residual mengikuti distribusi normal.



Gambar 4.41 *Qq plot* residual model ARIMA perubahan harga minyak dunia

Berdasarkan nilai estimasi parameter pada Tabel 4.29, model ARIMA yang terbentuk untuk perubahan harga minyak dunia adalah:

$$x_t = 0,31707x_{t-1} + \alpha_t - 0,12546\alpha_{t-6}$$

Sehingga deret perubahan harga minyak dunia yang telah di-*prewhitening* adalah:


$$\alpha_t = \frac{(1 - 0,31707B)}{(1 - 0,12546B^6)} x_t$$

Prewhitening deret output (inflasi nasional) mengikuti *prewhitening* deret input.

Sehingga deret output inflasi nasional yang telah di-*prewhitening* adalah:

$$\beta_t = \frac{(1 - 0,31707B)}{(1 - 0,12546B^6)} y_t$$

Identifikasi model dugaan awal fungsi transfer didasarkan pada nilai korelasi silang antara deret input dan deret output yang telah di-*prewhitening*. Korelasi silang digunakan untuk menentukan nilai orde (*b*, *r*, *s*).



Gambar 4.42 CCF perubahan harga minyak dunia dan inflasi

Berdasarkan hasil korelasi silang sebagaimana terlihat pada Gambar 4.42, diperoleh kemungkinan nilai orde (b, r, s) yaitu $(b=1, r=0, \text{ dan } s=0)$. Hasil estimasi parameter model awal fungsi transfer disajikan pada tabel 4.31.

Tabel 4.31 Uji signifikansi model ARIMA fungsi transfer

Parameter	Estimasi	Standard Error	<i>t</i> -hitung	<i>p</i> -value
ϕ_1	0,61170	0,04871	12,56	<0,0001
ϕ_3	0,23488	0,05182	4,53	<0,0001
ϕ_8	-0,09890	0,04687	-2,11	0,0348
ω_1	-0,01391	0,0070604	-1,97	0,0488

Model fungsi transfer untuk orde $(b=1, r=0, s=0)$ sebagaimana disajikan pada Tabel 4.31 nilai *p*-value kurang dari 0,05 sehingga model tersebut memenuhi uji signifikansi parameter. Orde $b=1$ menunjukkan bahwa perubahan harga minyak dunia pada bulan ke- t mempengaruhi inflasi nasional secara langsung pada bulan $t+1$.

Pengujian residual model dugaan awal perubahan harga minyak dunia terhadap inflasi umum sebagaimana disajikan pada Tabel 4.24 orde $(b=1, r=0, s=0)$ tidak memenuhi asumsi *white noise* karena nilai *p*-value di semua *lag* kurang dari 0,05.


Tabel 4.32 Uji *White noise* model ARIMA fungsi transfer

Hingga Lag	Chi-Square	DF	p-value
6	11,16	3	0,0109
12	31,02	9	0,0003
18	33,74	15	0,0037
24	41,45	21	0,0049
30	44,57	27	0,0180
36	52,97	33	0,0152
42	58,21	39	0,0245
48	67,96	45	0,0151

Pada pengujian normalitas residual berdasarkan uji Kolmogorov Smirnov, diketahui bahwa *p-value* lebih kecil dari 0,01, sehingga dapat disimpulkan model arima fungsi transfer tersebut memiliki residual yang tidak berdistribusi normal. Untuk itu dilakukan deteksi *outlier*. Dengan memasukkan variabel *outlier*, diperoleh estimasi parameter seperti yang ditunjukkan pada Tabel 4.33.

Tabel 4.33 Uji signifikansi model ARIMA fungsi transfer setelah deteksi *outlier*

Parameter	Estimasi	Standar Error	t-hitung	p-value
θ_{10}	-0,17558	0,05852	-3,00	0,0027
θ_{12}	-0,34821	0,05878	-5,92	<,0001
θ_{13}	0,13391	0,05822	2,30	0,0215
ϕ_1	0,67783	0,04657	14,56	<,0001
ϕ_3	0,18711	0,04948	3,78	0,0002
ϕ_8	-0,19259	0,04272	-4,51	<,0001
ω_0	-0,0014690	0,0038680	-0,38	0,7041
ω_1	7,15180	0,42792	16,71	<,0001
ω_2	8,23921	0,51353	16,04	<,0001
ω_3	4,12209	0,43484	9,48	<,0001
ω_4	3,17054	0,51738	6,13	<,0001
ω_5	-2,56027	0,44966	-5,69	<,0001
ω_6	2,07183	0,44415	4,66	<,0001
ω_7	0,84833	0,15398	5,51	<,0001



Gambar 4.43 Plot residual model ARIMAX setelah deteksi *outlier*

Pengujian residual model perubahan harga minyak dunia terhadap inflasi nasional sebagaimana disajikan pada Tabel 4.34 memenuhi asumsi *white noise* karena nilai *p-value* di semua *lag* lebih besar dari 0,05. Begitu pula dengan uji normalitas menggunakan Kolmogorov Smirnov, diperoleh *p-value* sebesar 0,0995, sehingga dapat disimpulkan bahwa residual fungsi transfer setelah dimasukkan *outlier* menjadi berdistribusi normal.

Tabel 4.34 Uji *White noise* model ARIMA fungsi transfer dengan *outlier*

<i>Hingga Lag</i>	<i>Chi-Square</i>	<i>DF</i>	<i>p-value</i>
12	4,93	6	0,5527
18	7,02	12	0,8560
24	19,59	18	0,3566
30	23,10	24	0,5137
36	31,08	30	0,4114
42	42,43	36	0,2135
48	47,87	42	0,2466

Setelah dimasukkan deteksi *outlier* kedalam model ARIMA fungsi transfer, residual telah berdistribusi normal dan memenuhi asumsi normalitas dan *white noise*. Namun demikian, seperti yang disajikan pada Tabel 4.33, parameter input yaitu perubahan harga minyak dunia menjadi tidak signifikan. Hal tersebut disebabkan terdapat *outlier* yang disajikan dalam Tabel 4.35.

Tabel 4.35 *Outlier* model ARIMA fungsi transfer

Waktu	Perubahan Harga Minyak Dunia	Inflasi	Inflasi $t+1$
Januari 1993	-3,85	2,92	2,03
Januari 1998	-5,61	8,7	1,31
Februari 1998	-5,91	12,76	5,49
Juli 1998	1,92	8,56	4,48
Oktober 1998	-12,59	6,88	12,76
Oktober 2005	-3,91	-0,27	0,48
Juli 2013	5,48	3,29	1,12

Meskipun asumsi-asumsi pada residual terpenuhi, namun karena parameter perubahan harga minyak dunia tidak signifikan, maka untuk selanjutnya tidak dilakukan peramalan inflasi menggunakan ARIMA fungsi transfer dengan input harga minyak dunia. Pemodelan selanjutnya hanya dilakukan dengan menggunakan ARIMA dengan deteksi *outlier* (ARIMAX) inflasi.


4.2.3 Model GARCH, GJR-GARCH, dan APARCH

Asumsi *white noise* dan normalitas pada data inflasi nasional telah terpenuhi. Selanjutnya ingin diketahui apakah dari model yang terbentuk, ada unsur heteroskedastisitas didalamnya. Untuk itu dilakukan uji LM dari residual dengan hasil seperti yang dijabarkan pada Tabel 4.36.

Tabel 4.36 Uji heteroskedastisitas residual model ARIMAX inflasi nasional


Variabel	Chi-square	DF	p-value
Residual ARIMA	27,8467	12	0,005825

Dari tabel 4.36 diketahui bahwa hasil uji heteroskedastisitas pada residual ARIMAX inflasi memiliki $p\text{-value} < 0,05$ sehingga tolak H_0 . Hal tersebut berarti ada unsur heteroskedastikas pada kuadrat residual. Untuk itu, residual pada model ARIMAX dilanjutkan dengan pemodelan GARCH untuk mengatasi masalah tersebut. Pada gambar 4.44 disajikan *series* residual dan residual kuadrat dari model ARIMAX inflasi.




Gambar 4.44 *Series* residual dan residual kuadrat dari model ARIMAX inflasi

Setelah diketahui bahwa data residual inflasi nasional memiliki efek ARCH, kemudian dimodelkan kedalam bentuk GARCH. Untuk itu terlebih dahulu dilakukan identifikasi terhadap model GARCH. Identifikasi GARCH dapat dilakukan melalui pengamatan terhadap plot acf dan pacf residual kuadrat. Gambar 4.27 menyajikan plot acf dan pacf dari residual dan residual kuadrat.



(a)



(b)

Gambar 4.45 (a) Plot acf dan pacf residual dan (b) plot acf dan pacf residual kuadrat dari model ARIMA inflasi

Dari gambar 4.45 (a) dapat diidentifikasi bahwa residual bersifat *white noise* karena tidak ada *Lag* yang signifikan pada plot acf. Pada gambar 4.45 (b) dapat diketahui bahwa masing-masing plot signifikan pada *Lag* 2. Dengan demikian model dugaan GARCH adalah ARCH(1), ARCH(2), GARCH(0,1), GARCH(0,2), GARCH(1,1), GARCH(2,1), GARCH(1,2), dan GARCH(2,2). Masing-masing model akan diestimasi dan dilakukan pengujian-pengujian untuk menentukan model terbaik.

Setelah tahap identifikasi model, kemudian dilakukan estimasi parameter masing-masing model dugaan. Model dugaan yang pertama adalah model ARCH(1).

Tabel 4.37 Uji signifikansi parameter model ARCH(1)

Parameter	Estimasi	Standar Error	<i>t</i> -hitung	<i>p</i> -value
α_0	0,27900	0,032131	8,6833	0,000000
α_1	0,26222	0,099404	2,6379	0,008341

Dari model diketahui bahwa parameter α_0 dan α_1 memiliki nilai *p*-value yang kurang dari 0,05 sehingga dapat disimpulkan parameter-parameter tersebut signifikan. Setelah estimasi parameter dilakukan, langkah selanjutnya adalah melakukan cek diagnosa residual model. Dalam hal ini dilakukan uji asumsi

residual. Untuk melihat ada tidaknya serial korelasi didalam kuadrat residual, maka dilakukan uji *Weighted* Ljung-Box.

Tabel 4.38 Uji *white noise* model ARCH(1)

<i>Lag</i>	Statistik Uji	<i>p-value</i>
<i>Lag</i> [1]	0,4241	0,51492
<i>Lag</i> [2*(p+q)+(p+q)-1][2]	1,860064	0,21644
<i>Lag</i> [4*(p+q)+(p+q)-1][5]	7,8709	0,03172

Dari tabel 4.38 dapat diketahui bahwa pada *Lag* ke-5, *p-value* kurang dari 0,05. Hal tersebut berarti bahwa masih terdapat korelasi antarkuadrat residual dari model ARCH(1). Model ARCH(1) dikatakan residualnya tidak *white noise*. Selanjutnya dilakukan pengujian atas terpenuhinya asumsi normalitas pada residualnya. Hasil ujinya disajikan dalam Tabel 4.39.

Tabel 4.39 Uji *goodness of fit* distribusi residual model ARCH(1)

Grup	Statistik Uji	<i>p-value</i>
20	29,87	0,05352
30	48,20	0,01401
40	42,20	0,30637
50	55,33	0,24799

Berdasarkan Tabel 4.39, pada grup 30 nilai *p-value* kurang dari 0,05. Hal tersebut berarti bahwa asumsi distribusi normal ditolak. Dengan demikian maka distribusi dari residual dapat dikatakan tidak mengikuti asumsi kenormalan. Karena asumsi-asumsi pada residual tidak terpenuhi, maka tidak dilanjutkan dengan peramalan terhadap nilai sigma.

Model selanjutnya yang diduga adalah model ARCH(2). Seperti pada ARCH(1), terlebih dahulu dilakukan estimasi parameter. Hasil estimasi parameter oleh model ARCH(1) disajikan dalam Tabel 4.40.

Tabel 4.40 Uji signifikansi parameter model ARCH(2)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,23969	0,033268	7,2047	0,000000
α_1	0,24070	0,101683	2,3672	0,017925
α_2	0,13061	0,069452	1,8806	0,060029

Pada hasil estimasi parameter dalam tabel 4.40 diketahui bahwa tidak semua parameter memiliki *p-value* kurang dari 0,05. Parameter α_2 memiliki *p-value* = 0,060029 yang berarti bahwa parameter tersebut tidak signifikan pada level signifikansi 5%. Akan tetapi parameter tersebut dapat menjadi signifikan pada level signifikansi 10%. Namun demikian pada penelitian ini ditetapkan tingkat signifikansi sebesar 5%. Sehingga dengan demikian, parameter α_2 dikatakan tidak signifikan. Karena berdasarkan estimasi parameternya yang tidak signifikan, maka tidak perlu dilakukan pengujian asumsi pada residual.

Model dugaan ketiga adalah model GARCH(0,1). Model tersebut memiliki dua parameter yaitu α_0 dan β_1 . Untuk itu dilakukan estimasi parameter dan uji signifikansi parameter yang terbentuk. Hasil uji signifikansi parameter disajikan pada Tabel 4.41

Tabel 4.41 Uji signifikansi parameter model GARCH(0,1)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,00000	0,000103	6,0000e-06	0,99999
β_1	0,99889	0,000783	1,2762e+03	0,00000

Pada Tabel 4.41, diketahui bahwa parameter α_0 memiliki *p-value* lebih dari 0,05. Sehingga dapat disimpulkan pada level signifikansi 5%, parameter tersebut tidak signifikan. Seperti pada model sebelumnya, model ini tidak dilanjutkan dengan pengujian terhadap pemenuhan asumsi residual.

Selanjutnya dilakukan pemodelan GARCH(0,2). Hasil estimasi parameter oleh model GARCH(0,2) disajikan dalam Tabel 4.42.

Tabel 4.42 Uji signifikansi parameter model GARCH(0,2)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,00000	0,000135	0,00	1
β_1	0,45754	0,000809	565,40	0,00000
β_2	0,54074	0,000802	674,58	0,00000

Seperti halnya pada GARCH(0,1), pada model GARCH(0,2) dapat diketahui bahwa parameter α_0 memiliki $p\text{-value} > 0,05$. Sehingga dapat disimpulkan pada level signifikansi 5%, parameter tersebut tidak signifikan.

Model dugaan berikutnya adalah model GARCH(1,1). Model GARCH tersebut dilakukan estimasi parameter dan uji signifikansi parameter pada level signifikansi 5%. Hasil uji signifikansi disajikan dalam Tabel 4.43.

Tabel 4.43 Uji signifikansi parameter model GARCH(1,1)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,10862	0,036863	2,9465	0,003214
α_1	0,27375	0,090499	3,0249	0,002487
β_1	0,44621	0,127648	3,4956	0,000473

Dari Tabel 4.43, dapat diketahui hasil estimasi parameter dimana semua parameter bernilai positif. Persistensi dari model GARCH(1,1) atau $(\alpha_1 + \beta_1)$ dapat diketahui yaitu sebesar 0,71996 (persistensi bersifat moderat). Dari hasil estimasi parameter, kemudian diuji signifikansinya pada level signifikansi 5%. Semua parameter memiliki $p\text{-value}$ kurang dari 0,05. Hal tersebut berarti bahwa parameter-parameter dalam model GARCH(1,1) signifikan pada tingkat signifikansi 5%.

Setelah uji signifikansi parameter dilakukan, kemudian dilakukan cek diagnosa asumsi residual. Pada Tabel 4.44 disajikan uji *weighted* Ljung-Box.

Tabel 4.44 Uji *Ljung-Box* model GARCH(1,1)

<i>Lag</i>	Statistik Uji	<i>p-value</i>
<i>Lag</i> [1]	0,05186	0,8199
<i>Lag</i> [2*(p+q)+(p+q)-1][5]	1,24583	0,8020
<i>Lag</i> [4*(p+q)+(p+q)-1][9]	3,19320	0,7267

Berdasarkan tabel 4.44, pada *Lag-Lag* yang diuji, seluruhnya memiliki *p-value* > 0,05. Hal tersebut menjelaskan bahwa tidak cukup bukti untuk menyatakan bahwa terdapat serial korelasi pada kuadrat residual model GARCH(1,1).

Pengujian asumsi selanjutnya adalah asumsi normalitas residual. Pengujian ini dapat dilakukan melalui *goodness of fit* seperti yang disajikan dalam tabel 4.45.

Tabel 4.45 Uji *goodness of fit* distribusi residual model GARCH(1,1)

Grup	Statistik Uji	<i>p-value</i>
20	30,00	0,0518
30	34,00	0,2393
40	41,07	0,3801
50	47,33	0,5409

Tabel 4.45 merupakan tabel yang menguji kelayakan dari distribusi. Dalam hal ini dalam estimasi telah diasumsikan residual berdistribusi normal. Untuk itu, berdasarkan tabel tersebut menunjukkan bahwa dari setiap grup memiliki *p-value* > 0,05. Hal tersebut berarti bahwa tidak cukup bukti untuk menyatakan bahwa residual dari model GARCH(1,1) tidak berdistribusi normal.

Selanjutnya dilakukan pengujian ARCH LM untuk mengetahui apakah residual model GARCH(1,1) masih mengandung efek ARCH atau tidak. Hasil pengujian efek ARCH dinyatakan dalam Tabel 4.47.

Tabel 4.46 Uji ARCH LM residual model GARCH(1,1)

<i>Lag</i>	Statistik Uji	<i>p-value</i>
ARCH <i>Lag</i> [3]	1,849	0,1738
ARCH <i>Lag</i> [5]	1,989	0,4736
ARCH <i>Lag</i> [7]	3,890	0,3627

Dari Tabel 4.46 diketahui bahwa seluruh *p-value* memiliki nilai lebih besar daripada 0,05. Hal tersebut berarti residual dari GARCH(1,1) sudah tidak mengandung heteroskedastisitas atau tidak ada efek ARCH *Lagi*. Untuk itu tidak perlu dilakukan estimasi parameter model untuk orde yang lebih tinggi. Akan tetapi, sesuai dengan model dugaan awal, maka dalam penelitian ini, selanjutnya tetap akan dilakukan estimasi pada orde yang lebih tinggi.

Tabel 4.47 Uji asimetrik residual model GARCH(1,1)

Uji	Statistik Uji	<i>p-value</i>
<i>Sign Bias</i>	0,4394	0,6607
<i>Negative Sign Bias</i>	1,5076	0,1327
<i>Positive Sign Bias</i>	0,9940	0,3210
<i>Joint Effect</i>	5,4765	0,1401

Berdasarkan Tabel 4.47, diketahui bahwa semua *p-value* memiliki nilai lebih besar dari 0,05. Dengan demikian dapat disimpulkan bahwa tidak cukup bukti untuk menyatakan bahwa terdapat efek asimetrik pada residual model GARCH(1,1). Sehingga dapat dikatakan bahwa pemodelan penanganan heteroskedastisitas ARIMAX inflasi ini cukup dilakukan dengan GARCH simetrik. Model GARCH(1,1) berdasarkan hasil estimasi diatas, dituliskan:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

atau

$$\sigma_t^2 = 0,10862 + 0,27375 \varepsilon_{t-1}^2 + 0,44621 \sigma_{t-1}^2$$

Selanjutnya dilakukan estimasi parameter model dugaan GARCH(1,2). Hasil estimasi parameter dan uji signifikansi parameter dapat dilihat pada Tabel 4.48.

Tabel 4.48 Uji signifikansi parameter model GARCH(1,2)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,10446	0,034985	2,9858	0,002828
α_1	0,27846	0,082258	3,3852	0,000711
β_1	0,45149	0,362670	1,2449	0,213166
β_2	0,00000	0,346573	0,0000	1,000000

Pada tabel 4.48, diketahui bahwa parameter β_1 dan β_2 memiliki *p-value* lebih dari 0,05. Sehingga dapat disimpulkan pada level signifikansi 5%, parameter tersebut tidak signifikan. Seperti pada model GARCH sebelumnya yang parameternya tidak signifikan, model ini tidak dilanjutkan dengan pengujian terhadap pemenuhan asumsi residual.

Model dugaan berikutnya adalah GARCH(2,1). Hasil estimasi parameter dan uji signifikansi parameter dapat dilihat pada Tabel 4.49.

Tabel 4.49 Uji signifikansi parameter model GARCH(2,1)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,111738	0,055167	2,02544	0,042822
α_1	0,270019	0,103427	2,61073	0,009035
α_2	0,022228	0,129961	0,17104	0,864194
β_1	0,418352	0,225591	1,85447	0,063671

Berdasarkan Tabel 4.49, diketahui bahwa parameter β_1 dan α_2 memiliki *p-value* lebih dari 0,05. Sehingga dapat disimpulkan pada level signifikansi 5%, parameter tersebut tidak signifikan. Seperti pada model GARCH sebelumnya yang parameternya tidak signifikan, model ini tidak dilanjutkan dengan pengujian terhadap pemenuhan asumsi residual. Model dugaan selanjutnya adalah GARCH(2,2). Hasil estimasi parameternya dapat dilihat pada Tabel 4.50.

Tabel 4.50 Uji signifikansi parameter model GARCH(2,2)

Parameter	Estimasi	Standar Error	t-hitung	p-value
α_0	0,111739	0,051965	2,15026	0,031535
α_1	0,270021	0,101273	2,66627	0,007670
α_2	0,022232	0,119966	0,18532	0,852980
β_1	0,418347	0,354933	1,17866	0,238532
β_2	0,000000	0,303517	0,00000	1,000000

Pada Tabel 4.50, diketahui bahwa parameter α_2 , β_1 , dan β_2 memiliki *p-value* lebih dari 0,05. Sehingga dapat disimpulkan pada level signifikansi 5%, parameter tersebut tidak signifikan. Hal tersebut konsisten dengan pengujian ARCH LM pada model GARCH(1,1) yang menyatakan residual model sudah tidak mengandung efek ARCH. Sehingga orde selanjutnya tidak perlu diestimasi. Seperti pada model GARCH sebelumnya yang parameternya tidak signifikan, model ini tidak dilanjutkan dengan pengujian terhadap pemenuhan asumsi residual. Dari seluruh model dugaan, dapat ditentukan model terbaik yang digunakan untuk peramalan volatilitas.

Tabel 4.51 Ringkasan hasil uji signifikansi parameter model GARCH

Model	Signifikansi Parameter
ARCH(1)	Signifikan
ARCH(2)	Tidak Signifikan
GARCH(0,1)	Tidak Signifikan
GARCH(0,2)	Tidak Signifikan
GARCH(1,1)	Signifikan
GARCH(1,2)	Tidak Signifikan
GARCH(2,1)	Tidak Signifikan
GARCH(2,2)	Tidak Signifikan

Dari delapan model ARCH/GARCH simetrik yang diuji signifikansinya, hanya dua model yang parameternya signifikan yaitu ARCH(1) dan GARCH(1,1). Namun dari hasil uji asumsi residual, hanya GARCH(1,1) yang merupakan model yang layak digunakan untuk peramalan. Sehingga dalam penelitian ini GARCH(1,1) merupakan model GARCH simetrik terbaik.

Selanjutnya model GARCH(1,1) akan dibandingkan dengan dua model GARCH asimetrik yaitu GJR-GARCH(1,1) dan APARCH(1,1). Dari hasil uji asimetrik sebelumnya, diketahui bahwa residual GARCH(1,1) tidak memiliki efek asimetris. Hal tersebut berarti bahwa residual ARIMAX inflasi nasional cukup dimodelkan dengan GARCH(1,1). Akan tetapi, melihat hasil yang diperoleh dari simulasi untuk mengetahui *power* uji asimetrik, bahwa *power* uji asimetrik tidak terlalu baik yakni kurang dari 50% mampu mendeteksi efek asimetrik, maka dalam penelitian ini tetap akan dilakukan estimasi model GJR-GARCH(1,1) dan APARCH(1,1) untuk melihat performa GARCH asimetrik dibandingkan dengan GARCH simetrik.

Tabel 4.52 Uji signifikansi parameter model GJR-GARCH(1,1)

Parameter	Estimasi	Standar Error	<i>t</i> -hitung	<i>p</i> -value
α_0	0,008039	0,001822	4,4123	0,00001
α_1	0,059929	0,002537	23,6252	0,00000
β_1	0,983048	0,000049	19932,2919	0,00000
γ_1	-0,137499	0,004378	-31,4047	0,00000

Dari tabel 4.52, dapat diketahui hasil estimasi parameter dimana tidak semua parameter bernilai positif. Parameter γ_1 memiliki nilai estimasi negatif. Parameter γ_1 merupakan *leverage effect* atau parameter asimetrik dari model GARCH. Hal tersebut sejalan dengan penelitian dari Rizvi *et al.* (2014) yang meneliti tentang inflasi di Asia. Rizvi *et al.* (2014) menyatakan bahwa efek *leverage* oleh inflasi di Indonesia bernilai negatif. Hal tersebut mengindikasikan bahwa *shocks* inflasi yang negatif (*good news*) pada waktu ke-*t* mampu menurunkan inflasi pada periode berikutnya. Jadi, dapat dikatakan bahwa *shock*

negatif dari inflasi lebih berpengaruh terhadap volatilitas inflasi daripada *shock* yang positif dari inflasi (*bad news*). Seperti halnya yang terjadi di negara Pakistan, China, Thailand dan India (Rizvi *et al.*, 2014).

Dari hasil estimasi parameter, kemudian diuji signifikansinya pada level signifikansi 5%. Semua parameter memiliki *p-value* kurang dari 0,05. Hal tersebut berarti bahwa parameter-parameter dalam model GJR-GARCH(1,1) signifikan pada tingkat signifikansi 5%.

Setelah uji signifikansi parameter dilakukan, kemudian dilakukan cek diagnosa asumsi residual. Pada Tabel 4.54 disajikan uji Ljung-Box.

Tabel 4.53 Uji Ljung-Box model GJR-GARCH(1,1)

<i>Lag</i>	Statistik Uji	<i>p-value</i>
<i>Lag</i> [1]	7,586	0,005883
<i>Lag</i> [2*(p+q)+(p+q)-1][5]	9,047	0,016102
<i>Lag</i> [4*(p+q)+(p+q)-1][9]	11,600	0,022346

Berdasarkan Tabel 4.53, pada *Lag-Lag* yang diuji, seluruhnya memiliki *p-value* kurang dari 0,05. Hal tersebut menjelaskan bahwa terdapat serial korelasi pada kuadrat residual model GJR-GARCH(1,1). Pengujian asumsi selanjutnya adalah asumsi normalitas residual. Pengujian ini dapat dilakukan melalui *goodness of fit* seperti yang disajikan dalam Tabel 4.54.

Tabel 4.54 Uji *goodness of fit* distribusi residual model GJR-GARCH(1,1)

Grup	Statistik Uji	<i>p-value</i>
20	22,40	0,26480
30	28,20	0,50724
40	54,40	0,05163
50	80,33	0,00316

Tabel 4.54 menunjukkan bahwa terdapat satu grup memiliki *p-value* kurang dari 0,05. Hal tersebut berarti bahwa residual dari model GJR-GARCH(1,1) tidak berdistribusi normal.

Selanjutnya dilakukan pengujian ARCH LM untuk mengetahui apakah residual model GJR-GARCH(1,1) masih mengandung efek ARCH atau tidak. hasil pengujian efek ARCH dinyatakan dalam Tabel 4.55.

Tabel 4.55 Uji ARCH LM residual model GJR-GARCH(1,1)

<i>Lag</i>	Statistik Uji	<i>p-value</i>
ARCH <i>Lag</i> [3]	1,474	0,2247
ARCH <i>Lag</i> [5]	1,730	0,5340
ARCH <i>Lag</i> [7]	4,377	0,2954

Dari Tabel 4.55 diketahui bahwa seluruh *p-value* memiliki nilai lebih besar daripada 0,05. Hal tersebut berarti residual dari GJR-GARCH(1,1) sudah tidak mengandung heteroskedastisitas atau tidak ada efek ARCH *Lagi*. Untuk itu tidak perlu dilakukan estimasi parameter model untuk orde yang lebih tinggi.

Model asimetrik lainnya adalah model APARCH(1,1). Model tersebut terdiri dari lima parameter yang akan diestimasi. Hasil estimasi parameter maupun uji signifikansi model APARCH(1,1) disajikan dalam Tabel 4.56.

Tabel 4.56 Uji signifikansi parameter model APARCH(1,1)

Parameter	Estimasi	Standar Error	<i>t</i> -hitung	<i>p-value</i>
α_0	0,11997	0,043026	2,7882	0,005300
α_1	0,18556	0,041502	4,4711	0,000008
β_1	0,65268	0,118712	5,4980	0,000000
γ_1	-1,00000	0,002159	-463,1767	0,000000
δ_1	0,98428	0,432467	2,2760	0,022848

Seperti halnya pada model GJR-GARCH, dari Tabel 4.57 dapat diketahui hasil estimasi parameter dimana tidak semua parameter bernilai positif. Parameter γ_1 memiliki nilai estimasi negatif. Parameter γ_1 merupakan *leverage effect* atau

parameter asimetrik dari model GARCH. Seperti yang dikemukakan sebelumnya, hal tersebut sejalan dengan penelitian dari Rizvi *et al.* (2014) yang meneliti tentang inflasi di Asia. Rizvi *et al.* (2014) menyatakan bahwa efek *leverage* oleh inflasi di Indonesia bernilai negatif. Hal tersebut mengindikasikan bahwa *shocks* inflasi yang negatif (*good news*) pada waktu ke-*t* mampu menurunkan inflasi pada periode berikutnya. Jadi, dapat dikatakan bahwa *shock* negatif dari inflasi lebih berpengaruh terhadap volatilitas inflasi daripada *shock* yang positif dari inflasi (*bad news*). Meskipun kedua model asimetrik memberikan tanda koefisien estimasi yang sama, namun nilainya berbeda. Nilai estimasi efek asimetrik APARCH(1,1) lebih besar yaitu -1,00 sedangkan pada GJR-GARCH(1,1) -0.14.

Dari hasil estimasi parameter, kemudian diuji signifikansinya pada level signifikansi 5%. Semua parameter memiliki *p-value* kurang dari 0,05. Hal tersebut berarti bahwa parameter-parameter dalam model APARCH(1,1) signifikan pada tingkat signifikansi 5%.

Setelah uji signifikansi parameter dilakukan, kemudian dilakukan cek diagnosa asumsi residual. Pada Tabel 4.57 disajikan uji Ljung-Box.

Tabel 4.57 Uji Ljung-Box model APARCH(1,1)

<i>Lag</i>	Statistik Uji	<i>p-value</i>
<i>Lag</i> [1]	0,5966	0,4399
<i>Lag</i> [2*(<i>p</i> + <i>q</i>)+(<i>p</i> + <i>q</i>)-1][5]	1,3997	0,7645
<i>Lag</i> [4*(<i>p</i> + <i>q</i>)+(<i>p</i> + <i>q</i>)-1][9]	2,7676	0,7966

Berdasarkan Tabel 4.57, pada *Lag-Lag* yang diuji, seluruhnya memiliki *p-value* kurang dari 0,05. Hal tersebut menjelaskan bahwa tidak cukup bukti untuk mengatakan bahwa terdapat serial korelasi pada kuadrat residual model APARCH(1,1).

Pengujian asumsi selanjutnya adalah asumsi normalitas residual. Pengujian ini dapat dilakukan melalui *goodness of fit* seperti yang disajikan dalam Tabel 4.58.

Tabel 4.58 Uji Ljung-Box model APARCH(1,1)

Grup	Statistik Uji	<i>p-value</i>
20	14,80	0,7352
30	22,40	0,8033
40	26,67	0,9333
50	35,67	0,9228

Tabel 4.58 merupakan tabel yang menguji kelayakan dari distribusi. Dalam hal ini dalam estimasi telah diasumsikan residual berdistribusi normal. Untuk itu, berdasarkan tabel tersebut menunjukkan bahwa dari setiap grup memiliki *p-value* kurang dari 0,05. Hal tersebut berarti bahwa tidak cukup bukti untuk menyatakan bahwa residual dari model APARCH(1,1) tidak berdistribusi normal.

Selanjutnya dilakukan pengujian ARCH LM untuk mengetahui apakah residual model APARCH(1,1) masih mengandung efek ARCH atau tidak. hasil pengujian efek ARCH dinyatakan dalam Tabel 4.59.

Tabel 4.59 Uji ARCH LM residual model APARCH(1,1)


<i>Lag</i>	Statistik Uji	<i>p-value</i>
ARCH <i>Lag</i> [3]	0,2145	0,6433
ARCH <i>Lag</i> [5]	0,5550	0,8673
ARCH <i>Lag</i> [7]	1,8639	0,7461

Pada Tabel 4.59 diketahui bahwa seluruh *p-value* memiliki nilai lebih besar daripada 0,05. Hal tersebut berarti residual dari APARCH(1,1) sudah tidak mengandung heteroskedastisitas atau tidak ada efek ARCH *Lagi*. Untuk itu tidak perlu dilakukan estimasi parameter model untuk orde yang lebih tinggi. Model APARCH(1,1) berdasarkan hasil estimasi diatas adalah sebagai berikut:

$$\sigma_t^\delta = \alpha_0 + \sum_{i=1}^p \alpha_i (|\varepsilon_{t-1}| - \gamma_i \varepsilon_{t-1})^\delta + \sum_{j=1}^q \beta_j \sigma_{t-1}^\delta$$

$$\sigma_t = 0.11997 + 0.18556(|\varepsilon_{t-1}| + \varepsilon_{t-1}) + 0.65268 \sigma_{t-1}$$

Dari hasil pemodelan GARCH(1,1) dan APARCH(1,1), dapat dilihat hubungan antara *shock* dan varians yaitu sebagai berikut:



Gambar 4.46 *News impact curve* model (a) GARCH(1,1) dan (b) APARCH(1,1) ARIMAX inflasi

Dari Gambar 4.46, dapat dilihat bahwa model GARCH(1,1) pada data inflasi menunjukkan kurva yang simetrik antara ε_{t-1} dan σ_t^2 . Sementara itu pada kurva model APARCH(1,1), tampak tidak asimetrik, dimana ε_{t-1} (*shock*) positif cenderung lebih besar dampaknya terhadap volatilitas varians daripada (*shock*) negatif.

Berdasarkan hasil estimasi GARCH(1,1) menggunakan data *in-sample*, diperoleh nilai AIC sebesar 1,7813. Sementara itu, AIC dari estimasi APARCH(1,1) diperoleh sebesar 1,7142. Bila dibandingkan kedua model tersebut menggunakan data *in-sample*, maka model APARCH(1,1) lebih baik dibandingkan dengan GARCH(1,1) karena memiliki nilai AIC yang lebih kecil.

Dari hasil pemodelan GARCH dengan simetrik maupun asimetrik, diketahui bahwa hanya GARCH(1,1) dan APARCH(1,1) yang memenuhi syarat untuk dilakukan peramalan *standard error*. Peramalan *standard error* dalam hal ini akan digunakan untuk peramalan inflasi melalui *confidence interval*.


Tabel 4.60 Perbandingan hasil ramalan standar deviasi pada GARCH(1,1) dan APARCH(1,1)

Bulan	Ramalan <i>Standard Error Model</i> ARIMAX-GARCH(1,1)	Ramalan <i>Standard Error Model</i> ARIMAX-GARCH(1,1)	Ramalan <i>Standard Error Model</i> ARIMAX-APARCH(1,1)
Januari	0,6354	0,8080	1,0184
Februari	0,7834	0,7607	0,9324
Maret	0,8503	0,7247	0,8638
April	0,9245	0,6977	0,8090
Mei	0,9891	0,6775	0,7653
Juni	1,0391	0,6627	0,7304
Juli	1,0818	0,6517	0,7025
Agustus	1,1189	0,6438	0,6803
September	1,1301	0,6380	0,6625
Oktober	1,1340	0,6337	0,6483
November	1,1459	0,6307	0,6370
Desember	1,1492	0,6285	0,6279

Ramalan data merupakan data Januari s.d. Desember 2015. Rata-rata dari ramalan sigma pada model ARMAX sebesar 0,99848, lebih besar dibandingkan rata-rata ramalan sigma pada model ARMAX-GARCH(1,1) dan ARMAX-APARCH(1,1) yang masing-masing sebesar 0,67981 dan 0,75648. Sigma dari model ARMAX-GARCH(1,1) lebih kecil daripada ARMAX-APARCH(1,1) dan ARMAX. Tentunya pendugaan inflasi melalui selang kepercayaan pada model ARMAX-GARCH(1,1) memiliki interval paling pendek dibandingkan dengan dua model lainnya.

Tabel 4.61 Perbandingan hasil interval ramalan ARIMAX, ARIMAX-GARCH(1,1), dan ARIMAX-APARCH(1,1)

Bulan	Inflasi Aktual	ARIMAX		ARIMAX-GARCH(1,1)		ARIMAX-APARCH(1,1)	
		BB	BA	BB	BA	BB	BA
1	-0,24	0,7588	3,2496	0,42052	3,58788	0,008136	4,000264
2	-0,36	0,02581	3,0968	0,070328	3,052272	-0,266204	3,388804
3	0,17	-0,23228	3,1008	0,013788	2,854612	-0,258848	3,127248
4	0,36	-0,44816	3,1758	-0,003692	2,731292	-0,22184	2,94944
5	0,5	-0,59814	3,2792	0,0126	2,6684	-0,159488	2,840488
6	0,54	-0,91486	3,1584	-0,177092	2,420692	-0,309784	2,553384
7	0,93	-1,02049	3,22	-0,177532	2,377132	-0,2771	2,4767
8	0,39	-1,64419	2,7419	-0,712948	1,810748	-0,784488	1,882288
9	-0,05	-1,64859	2,7813	-0,68418	1,81678	-0,7322	1,8648
10	-0,08	-1,6533	2,7918	-0,672852	1,811252	-0,701468	1,839868
11	0,21	-1,5986	2,8933	-0,588872	1,883472	-0,60122	1,89582
12	0,96	-1,44246	3,0624	-0,42196	2,04176	-0,420784	2,040584



Gambar 4.47 Ramalan interval inflasi Januari-Desember 2015

Pada data *out-sample* digunakan untuk perbandingan nilai ramalan menggunakan *confidence interval*. Dari Tabel 4.62 dapat diketahui bahwa hasil ramalan baik dengan menggunakan ARMAX, ARMAX-GARCH(1,1), maupun ARMAX-APARCH(1,1) menggunakan selang kepercayaan 95%, memberikan ketepatan yang sama dalam ramalan selang kepercayaan yang memuat nilai inflasi

yaitu 83,33 persen. Rata-rata panjang selang interval ramalan inflasi antara ARMAX, ARMAX-GARCH(1,1), dan APARCH-GARCH masing-masing adalah 3,91, 2,66, dan 2,97. Hal tersebut berarti ARMAX-GARCH memberikan selang kepercayaan yang paling pendek dibandingkan dengan ARMAX maupun ARMAX-APARCH(1,1). Demikian pula ARMAX-APARCH(1,1) memberikan selang kepercayaan yang cenderung lebih pendek dibandingkan ramalan dengan menggunakan ARMAX. Jika dibandingkan antara ARMAX-GARCH(1,1) dan ARMAX-APARCH(1,1), ARMAX-GARCH(1,1) memberikan selang kepercayaan yang cenderung lebih pendek. Hal tersebut disebabkan data residual inflasi merupakan data simetrik GARCH, sehingga lebih tepat jika peramalan yang digunakan adalah GARCH(1,1).

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Beberapa kesimpulan yang dapat diambil berdasarkan pembahasan yang telah diuraikan sebelumnya dan merujuk pada tujuan penelitian, yaitu:

1. Berdasarkan skenario studi simulasi, pada data bangkitan GARCH(1,1), baik untuk sampel kecil maupun sampel besar pada data *in-sample*, menghasilkan kesimpulan yang sama, yaitu model GARCH(1,1) lebih baik daripada model GJR-GARCH(1,1) dan APARCH(1,1). Pada data bangkitan GJR-GARCH(1,1), baik untuk sampel kecil maupun sampel besar pada data *in-sample*, menghasilkan kesimpulan yang sama, yaitu model GJR-GARCH(1,1) lebih baik daripada model GARCH(1,1) dan APARCH(1,1). Pada data bangkitan APARCH(1,1), model APARCH(1,1) tidak selalu lebih baik daripada model GARCH lainnya. *Power* uji asimetrik kurang dari 50% pada sampel kecil (200) maupun besar (1.000) dalam mendeteksi efek asimetrik. *Power* akan lebih baik pada jumlah sampel yang besar dibandingkan sampel kecil. Ketiga model GARCH(1,1) menunjukkan *size* yang mendekati level signifikansinya.
2. Data inflasi nasional mengikuti model GARCH. Pada data *in-sample*, berdasarkan nilai AIC, model ARIMAX-APARCH(1,1) lebih baik daripada ARIMAX-GARCH(1,1). Peramalan menggunakan ARIMAX, ARIMAX-GARCH(1,1), dan ARIMAX-APARCH(1,1) memberikan ketepatan yang sama dalam memuat nilai inflasi pada data *out-sample* yaitu sebesar 83,33%. Pemodelan dan peramalan terbaik adalah menggunakan metode ARIMAX-GARCH(1,1) karena akan memberikan selang kepercayaan pendugaan inflasi yang lebih pendek dibandingkan dengan ARIMAX dan ARIMAX-APARCH(1,1). Rata-rata *standard error* pada model ramalan ARIMAX sebesar 0,99848, lebih besar dibandingkan rata-rata *standard error* pada model ramalan ARMAX-GARCH(1,1) dan ARMAX-APARCH(1,1) yang masing-masing sebesar 0,67981 dan 0,75648.

5.2 Saran

Berdasarkan hasil analisis serta kesimpulan tersebut, maka dapat dirumuskan beberapa saran untuk penyempurnaan berkelanjutan dari hasil penelitian ini sebagai berikut:

1. Penelitian berikutnya dapat memfokuskan kepada model GARCH lainnya dengan skenario simulasi yang lebih beragam.
2. Penelitian dapat dilakukan pada GARCH yang tidak berdistribusi normal menggunakan bermacam-macam distribusi statistik.
3. Perlu dilakukan perbandingan dengan metode lainnya, apakah metode GARCH simetrik dan asimetrik ini cukup baik dalam peramalan angka inflasi.
4. Dapat digunakan analisis multivariat GARCH dengan melibatkan variabel-variabel tertentu yang berkaitan dengan inflasi.
5. Untuk melihat akurasi peramalan volatilitas yang lebih baik, maka sebaiknya menggunakan data dengan volatilitas tinggi seperti harga saham, dll.

DAFTAR PUSTAKA

- Affandi, Tricahyo. (2014). *Pemodelan Vector Autoregressive (VAR) dan Generalize Space Time Autoregressive (GSTAR) Data Inflasi di Kota Jayapura, Kota Sorong, dan Kabupaten Manokwari*, Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.
- Badan Pusat Statistik. (2008). *Metode Pengukuran Inflasi di Indonesia*. Direktorat Statistik Keuangan dan Harga, Badan Pusat Statistik, Jakarta.
- Bidarkota, P.V. dan Mcculloh, J.H. (1998). Optimal Univariate Inflation Forecasting with Symmetric Stable Shocks, *Journal of Applied Econometrics*, Vol. 13, hal. 659-670.
- Bollerslev, Tim. (1986). Generalized Autoregressive Conditional Heteroscedasticity, *Journal of Econometrics*, Vol. 31, hal. 307-327.
- Bollerslev, Tim. (2008). *Glosary to ARCH (GARCH)*, CREATES Research Paper 2008-49.
- Box, G.E.P., Jenkins, G.M., dan Reinsel, G.C. (1994). *Time Series Analysis: Forecasting and Control. Third Edition*, Englewood Cliffs: Prentice Hall.
- Brockwell, P.J. dan Davis R.A. (2002). *Introduction to time series and forecasting., 2nd Edition*, New York: Springer, USA.
- Cologni, A dan Manera, M. (2008). Oil prices, inflation and interest rates in a structural cointegrated VAR model for the G-7 countries. *Energy Economics*, Vol. 30, No. 3, hal. 856-888.
- Ding, Z., Granger, C.W.J., dan Engle, R.F. (1993). A Long Memory Property of Stock Market Returns and A New Model, *Journal of Empirical Finance*, Vol. 1, hal. 83-106.
- Engle, R.F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation, *Econometrica*, Vol. 50, No. 4, hal. 987-1008.
- Engle, R.F. (1982). A General Approach to Lagrange Multiplier Model Diagnostics, *Journal of Econometrics*, Vol. 20, hal. 83-104.

- Engle, R.F. dan Ng, V.K. (1993). Measuring and Testing the Impact of News on Volatility, *The Journal of Finance*, Vol. 48, No. 5 hal. 1749-1778.
- Forte, G. dan Manera, M. (2006). Forecasting Volatility in Asian and European Stock Markets with Asymmetric GARCH Models. *Newfin Working Paper at Bocconi University*, Italia.
- Francq, C., dan Zakoian, J.M. (1994). *GARCH Models: Structure, Statistical Inference and Financial Applications*. West Sussex: John Wiley & Sons Ltd., United Kingdom.
- Glosten, L.R., Jagannathan, R., dan Runkle, D.E. (1993). On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks, *The Journal of Finance*, Vol. 68, No. 5, hal. 1779-1801.
- Hentschel, L. (1995). All in the Family Nesting Symmetric and Asymmetric GARCH Model, *Journal of Financial Economics*, Vol. 39, hal. 71-104.
- Hickey, E., Loomis, D.G., Mohammadi, H. (2012). Forecasting Hourly Electricity Prices Using ARMAX-GARCH Models: An Application to MISO Hubs, *Energy Economics*, Vol. 34, hal. 307-315.
- Hyung, N., Franses, P.H., Penm, J. (2006). Structural Breaks and Long Memory in US Inflation Rates: Do they Matter for Forecasting, *International Journal of Business and Finance*, Vol. 20, hal. 95-110.
- Juwariyanto. (2012). *Model Bayesian Markov Switching ARCH (Penerapan pada Inflasi di Indonesia)*, Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.
- Kichian, M. dan Rumler, F. (2014). Forecasting Canadian inflation: A Semi-structural NKPC Approach, *Economic Modelling*, Vol. 43, hal. 183-191.
- Labuschagne, C.C.A., Venter, P., Boetticher, S.T. (2015). A Comparison of Risk Neutral Historic Distribution E-GARCH and GJR-GARCH Model Generated Volatility Skews for BRICS Securities Exchange Indexes Analysis, *Procedia Economics and Finance*, Vol. 4, hal. 344-352.
- Lin, X dan Fei, F. (2013). Long Memory Revisit in Chinese Stock Markets: Based on GARCH-Class Models and Multiscale Analysis, *Economic Modelling*, Vol. 31, hal. 265-275.

Lo, M. S., (2003), Generalized Autoregressive Conditional Heteroscedastic Time Series Models. Thesis, Department of Statistics And Actuarial Science, Simon Fraser University.

Maheu, J.M. dan Song, Y. (2014). A New Structural Break Model, with an Application to Canadian Inflation Forecasting, *International Journal of Forecasting*, Vol. 30, No. 1, hal. 144-160.

Maholtra, A. dan Krishna, S. (2015). *The Effect of Crude Oil Prices on Inflation and Interest Rates in India: Evidence from DCC-GARCH Model*, Paper, Social Science Research Network.

Nizar, M.A. (2012). Dampak Fluktuasi Harga Minyak Dunia terhadap Perekonomian Indonesia. *Buletin Ilmiah Litbang Perdagangan*, Vol. 6, No. 2, hal. 189-209.

Posedel, P. (2005). Properties and Estimation of GARCH(1, 1) Model, *Metodoloski Zvezki*, Vol. 2, No. 2, hal. 243-257.

Rizvi, S.K.A., et al. (2013). Inflation Volatility: An Asian Perspective, *Economic Research*, Vol. 27, hal. 280-303.

Rokhimah, N. (2012). *Pendekatan Fungsi Transfer Multi Input dan Artificial Neural Network untuk Meramalkan Inflasi Jawa Timur*, Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.

Rukini. (2013). Model ARIMAX dan Deteksi GARCH untuk Peramalan Inflasi di Kota Denpasar. *Prosiding Seminar Nasional Matematika dan Pendidikan Matematika*, 9 November 2013, Jurusan Pendidikan Matematika FMIPA UNY, Yogyakarta.

Salim, S. dan Ahmad, K. (2015). Crude Oil Price and Inflation in Pakistan. *Bulletin of Business and Economics*, Vol. 4, No. 1, hal. 10-18.

Sanjaya, M.R. (2015). *Akurasi Prediksi Volatilitas Rupiah*, Gadjah Mada Working Paper in Economics and Business.

Sukirno, S. (2012). *Makroekonomi Teori Pengantar*. Rajawali Pers, Depok.

Suryono, H. (2009). *Pemodelan Auto Regressive Integrated Moving Average with Exogenous Factor-Neural Network (ARIMAX-NN) pada Data Inflasi Indonesia*, Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.

Tully, Edel, dan Lucey, B.M. (2006). A Power GARCH Examination of the Gold Market, *Research in International Business and Finance*, Vol. 21, hal. 316-325.

Wei, W.W.S. (2006). *Time Series Analysis: Univariate and Multivariate Methods, Second Edition*. United State of America: Addison-Wesley Publishing Co., USA.

LAMPIRAN

Lampiran 1 : Data Inflasi Indonesia dan Persentase Perubahan Rata-rata Harga Minyak Dunia Januari 1990 sampai dengan Desember 2015

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
1990	Jan	0.91	6.3	1991	Jan	0.76	-14.28
	Feb	0.99	-4.42		Feb	0.3	-18.76
	Mar	-0.39	-7.93		Mar	0.03	-1.73
	Apr	1.42	-9.93		Apr	1.89	1.54
	Mei	0.58	-0.67		Mei	0.18	1.24
	Jun	1.29	-7.9		Jun	0.44	-5.02
	Jul	2.21	12.59		Jul	1.89	6.97
	Agust	0.59	57.88		Agust	1.9	1.47
	Sept	0.51	26.68		Sept	0.12	3.37
	Okt	1.03	3.66		Okt	0.76	8.07
	Nop	0.33	-9.5		Nop	1.06	-5.33
	Des	0.06	-15.63		Des	0.19	-13.62
1992	Jan	0.44	-0.62	1993	Jan	2.92	-3.85
	Feb	0.26	0.74		Feb	2.03	5.74
	Mar	0.65	-1.7		Mar	1.49	1.48
	Apr	0.92	7.49		Apr	0.15	-0.32
	Mei	0.11	4.66		Mei	0.14	-1.46
	Jun	0.65	6.97		Jun	0.24	-4.4
	Jul	0.23	-3.35		Jul	0.67	-5.76
	Agust	0.16	-2.78		Agust	0.32	0.37
	Sept	0.2	2.91		Sept	0.28	-3.83
	Okt	0.41	-0.74		Okt	0.59	4.05
	Nop	0.25	-5.69		Nop	0.41	-8.21
	Des	0.66	-5.13		Des	0.53	-11.46

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
1994	Jan	1.25	6.06	1995	Jan	1.16	4.65
	Feb	1.76	-2.96		Feb	1.31	3.32
	Mar	0.7	-0.44		Mar	0.57	-0.52
	Apr	0.24	10.66		Apr	1.69	8.18
	Mei	0.52	8.45		Mei	0.49	-1.81
	Jun	0.12	4.87		Jun	0.16	-5.97
	Jul	0.13	4.7		Jul	0.71	-7.33
	Agust	-0.06	-5.88		Agust	-0.16	2.68
	Sept	0.53	-5.01		Sept	0.38	1.7
	Okt	0.89	2.17		Okt	0.64	-3.52
	Nop	0.76	4.37		Nop	0.19	3.96
	Des	0.52	-6.22		Des	0.79	6.6
1996	Jan	2.16	-0.78	1997	Jan	1.03	-0.94
	Feb	1.71	-0.56		Feb	0.19	-11.81
	Mar	-0.61	10.01		Mar	-0.12	-5.45
	Apr	0.78	6.78		Apr	0.56	-7.42
	Mei	0.06	-7.99		Mei	0.19	8.29
	Jun	-0.07	-2.93		Jun	-0.17	-7.45
	Jul	0.68	5.39		Jul	0.66	2.39
	Agust	0.27	3.22		Agust	0.88	1.84
	Sept	-0.04	9.66		Sept	1.29	-0.32
	Okt	0.41	5.83		Okt	1.99	7.42
	Nop	0.57	-5.04		Nop	1.65	-4.77
	Des	0.55	5.66		Des	2.04	-10.02

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
1998	Jan	6.88	-12.59	1999	Jan	2.97	8.74
	Feb	12.76	-5.91		Feb	1.26	-5.04
	Mar	5.49	-6.63		Mar	-0.18	19.63
	Apr	4.7	1.13		Apr	-0.68	22.32
	Mei	5.24	4.33		Mei	-0.28	2.48
	Jun	4.64	-10.67		Jun	-0.34	0.74
	Jul	8.56	1.92		Jul	-1.05	15.46
	Agust	4.48	-1.81		Agust	-0.93	7.79
	Sept	3.75	10.49		Sept	-0.68	10.69
	Okt	-0.27	-3.91		Okt	0.06	-0.8
	Nop	0.48	-10.41		Nop	0.25	9.15
	Des	1.42	-12.37		Des	1.73	3.26
2000	Jan	1.32	0.8	2001	Jan	0.33	2.65
	Feb	0.07	7.7		Feb	0.87	4.97
	Mar	-0.45	1.25		Mar	0.89	-8.15
	Apr	0.56	-14.7		Apr	0.46	2.56
	Mei	0.84	16.12		Mei	1.13	7.37
	Jun	0.5	8.78		Jun	1.67	-2.11
	Jul	1.28	-4.93		Jul	2.12	-8.05
	Agust	0.51	4.44		Agust	-0.21	4.07
	Sept	-0.06	9.08		Sept	0.64	-3.02
	Okt	1.16	-2.12		Okt	0.68	-17.18
	Nop	1.32	2.96		Nop	1.71	-9.84
	Des	1.94	-21.81		Des	1.62	-0.91

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
2002	Jan	1.99	3.4	2003	Jan	0.8	10.33
	Feb	1.5	4.33		Feb	0.2	6.86
	Mar	-0.02	18.32		Mar	-0.23	-7.66
	Apr	-0.24	7.57		Apr	0.15	-16.04
	Mei	0.8	1.02		Mei	0.21	2.24
	Jun	0.36	-4.67		Jun	0.09	7.1
	Jul	0.82	5.14		Jul	0.03	2.44
	Agust	0.29	4		Agust	0.84	3.81
	Sept	0.53	5.6		Sept	0.36	-9.43
	Okt	0.54	-2.65		Okt	0.55	7.92
	Nop	1.85	-9.95		Nop	1.01	0.38
	Des	1.2	12.51		Des	0.94	2.85
2004	Jan	0.57	4.84	2005	Jan	1.43	9.72
	Feb	-0.02	-0.25		Feb	-0.17	3.89
	Mar	0.36	7.5		Mar	1.91	14.3
	Apr	0.97	0.12		Apr	0.34	-0.57
	Mei	0.88	11.63		Mei	0.21	-5.59
	Jun	0.48	-5.55		Jun	0.5	12.72
	Jul	0.39	6.72		Jul	0.78	4.6
	Agust	0.09	10.94		Agust	0.55	9.76
	Sept	0.02	-1.02		Sept	0.69	-0.36
	Okt	0.56	12.53		Okt	8.7	-5.61
	Nop	0.89	-9.9		Nop	1.31	-5.52
	Des	1.04	-7.44		Des	-0.04	2.71

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
2006	Jan	1.36	10.43	2007	Jan	1.04	-12.46
	Feb	0.58	-4.25		Feb	0.62	7.83
	Mar	0.03	2.04		Mar	0.24	5.24
	Apr	0.05	11.6		Apr	-0.16	7.43
	Mei	0.37	0.9		Mei	0.1	0
	Jun	0.45	-0.47		Jun	0.23	4.75
	Jul	0.45	6.18		Jul	0.72	8.04
	Agust	0.33	-0.97		Agust	0.75	-4.81
	Sept	0.38	-13.7		Sept	0.8	9.67
	Okt	0.86	-6.49		Okt	0.79	6.81
	Nop	0.34	0.31		Nop	0.18	11.1
	Des	1.21	4.94		Des	1.1	-2.02
2008	Jan	1.77	1.55	2009	Jan	-0.07	5.73
	Feb	0.65	3.23		Feb	0.21	-4.9
	Mar	0.95	8.63		Mar	0.22	12.43
	Apr	0.57	7.08		Apr	-0.31	7.09
	Mei	1.41	12.58		Mei	0.04	15.55
	Jun	2.46	7.13		Jun	0.11	18.98
	Jul	1.37	0.78		Jul	0.45	-6.48
	Agust	0.51	-13.56		Agust	0.56	10.8
	Sept	0.97	-13.34		Sept	1.05	-4.54
	Okt	0.45	-26.79		Okt	0.19	8.34
	Nop	0.12	-25.66		Nop	-0.03	4.7
	Des	-0.04	-23.15		Des	0.33	-3.46

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
2010	Jan	0.84	2.99	2011	Jan	0.89	2.88
	Feb	0.3	-3.11		Feb	0.13	5.47
	Mar	-0.14	6.13		Mar	-0.32	11.17
	Apr	0.15	6.1		Apr	-0.31	7.06
	Mei	0.29	-10.22		Mei	0.12	-7
	Jun	0.97	-1.07		Jun	0.55	-2.15
	Jul	1.57	-0.28		Jul	0.67	1.92
	Agust	0.76	1.83		Agust	0.93	-6.89
	Sept	0.44	0.3		Sept	0.27	0.38
	Okt	0.06	7.37		Okt	-0.12	-0.9
	Nop	0.6	3.44		Nop	0.34	5.44
	Des	0.92	6.55		Des	0.57	-1.04
2012	Jan	0.76	2.52	2013	Jan	1.03	3.83
	Feb	0.05	5.44		Feb	0.75	2.49
	Mar	0.07	4.52		Mar	0.63	-4.69
	Apr	0.21	-3.43		Apr	-0.1	-3.66
	Mei	0.07	-8.43		Mei	-0.03	0.51
	Jun	0.62	-12.89		Jun	1.03	0.39
	Jul	0.7	6.64		Jul	3.29	5.48
	Agust	0.95	8.82		Agust	1.12	2.71
	Sept	0.01	0.99		Sept	-0.35	0.67
	Okt	0.16	-2.76		Okt	0.09	-3.05
	Nop	0.07	-2.15		Nop	0.12	-2.73
	Des	0.54	0		Des	0.55	2.84

Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia	Tahun	Bulan	Inflasi	% Perubahan Rata-rata Harga Minyak Dunia
2014	Jan	1.07	-3.07	2015	Jan	-0.24	-21.64
	Feb	0.26	2.51		Feb	-0.36	15.76
	Mar	0.08	-0.74		Mar	0.17	-3.82
	Apr	-0.02	0.87		Apr	0.36	8.69
	Mei	0.16	0.75		Mei	0.5	8.85
	Jun	0.43	2.5		Jun	0.54	-1.92
	Jul	0.93	-2.91		Jul	0.93	-11.21
	Agust	0.47	-4.91		Agust	0.39	-16
	Sept	0.27	-4.16		Sept	-0.05	1.25
	Okt	0.47	-10.18		Okt	-0.08	1.45
	Nop	1.5	-10.65		Nop	0.21	-8.16
	Des	2.46	-21.32		Des	0.96	-15.23

Lampiran 2 : Sintaks Program R untuk Data Bangkitan GARCH(1,1)

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

garch111.spec = ugarchspec (variance.model = list(garchOrder = c(1,1)),
mean.model = list(armaOrder = c(0,0)), fixed.pars = list(mu = 0, omega =
0.01, alpha1 = 0.1,beta1 = 0.8), distribution.model="norm")
set.seed(123)
garch111.sim = ugarchpath(garch111.spec, n.sim = 1000)
plot(garch111.sim)
modelfit111=ugarchfit(spec=garch111.spec,data=
garch111.sim@path$seriesSim)
show(modelfit111)
plot(modelfit111)
```

Lampiran 3 : Sintaks Program R untuk Data Bangkitan GJR-GARCH(1,1)

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

gjrgarch1111.spec = ugarchspec(variance.model = list(model = "gjrGARCH",
garchOrder = c(1,1)), mean.model = list(armaOrder = c(0,0)), fixed.pars = list(mu =
0, omega = 0.005, alpha1 = 0.28, beta1 = 0.5, gamma1 = 0.23), distribution.model
= "norm")
set.seed(123)
gjrgarch1111.sim = ugarchpath(gjrgarch1111.spec, n.sim = 1000)
gjrgarch.spec<-ugarchspec(variance.model = list(model = "gjrGARCH",
garchOrder = c(1,1)), mean.model = list(armaOrder = c(0,0), include.mean = T,
archm = F, arfima = F), distribution.model = "norm", fixed.pars = list(mu = 0))
modelfitgjrl1111=ugarchfit(spec=gjrgarch.spec,data=
gjrgarch1111.sim@path$seriesSim)
show(modelfitgjrl1111)
plot(modelfitgjrl1111)
plot(gjrgarch1111.sim)
```

Lampiran 4 : Sintaks Program R untuk Data Bangkitan APARCH(1,1)

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

(model="apARCH", garchOrder=c(1,1)), mean.model =list(armaOrder=c(0,0)),
fixed.pars=list(mu = 0, omega=0.005, alpha1=0.28, beta1 = 0.5, gamma1 =0.23,
delta=2), distribution.model="norm")
set.seed(123)
aparch1114.sim = ugarchpath(aparch1114.spec, n.sim=1000)
aparch.spec5<-
ugarchspec(variance.model=list(model="apARCH",garchOrder=c(1,1)),
mean.model=list(armaOrder=c(0,0),include.mean=T,
archm=F,arfima=F),distribution.model="norm",fixed.pars=list(mu = 0))
modelfitaparch1114=ugarchfit(spec=aparch.spec5,data=
aparch1114.sim@path$seriesSim,out.sample=12)
show(modelfitaparch1114)
plot(modelfitaparch1114)
plot(aparch1114.sim)
```

Lampiran 5 : Sintaks Program R untuk Menghitung *Power* Pengujian Asimetrik

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

simulasi = function(replikasi, sampel)
{
  #sim = matrix(nrow=sampel, ncol=replikasi)
  aic1 = matrix(nrow=replikasi, ncol=1)
  aic2 = matrix(nrow=replikasi, ncol=1)
  aic3 = matrix(nrow=replikasi, ncol=1)

  tes1 = matrix(nrow=replikasi, ncol=1)
  tes2 = matrix(nrow=replikasi, ncol=1)
  tes3 = matrix(nrow=replikasi, ncol=1)
  tes4 = matrix(nrow=replikasi, ncol=1)

  for (i in 1 : replikasi)
  {
    spec=ugarchspec(variance.model=list(model="apARCH",
    garchOrder=c(1,1)),mean.model=list(armaOrder=c(0,0)),
    distribution.model="norm", fixed.pars=list(mu=0, omega=0.005, alpha1=0.28,
    beta1=0.5, gamma1=0.23, delta=2))
    path.garch = ugarchpath(spec, n.sim=sampel, n.start=1, m.sim=1)

    garch11=ugarchspec (variance.model = list(model = "sGARCH", garchOrder = c(1,
    1)), mean.model = list(armaOrder = c(0, 0)), distribution.model = "norm",
    fixed.pars=list(mu=0))
    gjrgarch.spec5<-
    ugarchspec(variance.model=list(model="gjrgARCH",garchOrder=c(1,1)),
    mean.model=list(armaOrder=c(0,0),include.mean=T,
    archm=F,arfima=F),distribution.model="norm", fixed.pars=list(mu=0))
    aparch<-ugarchspec(variance.model=list(model="apARCH",garchOrder=c(1,1)),
    mean.model=list(armaOrder=c(0,0),include.mean=T,
    archm=F,arfima=F),distribution.model="norm", fixed.pars=list(mu=0))

    fit1 = ugarchfit(spec=garch11,data=path.garch@path$seriesSim)
    fit2=ugarchfit(spec=gjrgarch.spec5,data=path.garch@path$seriesSim)
    fit3 = ugarchfit(spec=aparch,data=path.garch@path$seriesSim)
```

```

criteria1 = infocriteria(fit1)[1]
criteria2 = infocriteria(fit2)[1]
criteria3 = infocriteria(fit3)[1]

aic1[i] = criteria1 # untuk AIC1
aic2[i] = criteria2
aic3[i] = criteria3

tes1[i] = signbias(fit1)[1,2]
tes2[i] = signbias(fit1)[2,2]
tes3[i] = signbias(fit1)[3,2]
tes4[i] = signbias(fit1)[4,2]
}

mean.aic1 = mean(aic1)
mean.aic2 = mean(aic2)
mean.aic3 = mean(aic3)

power11 = length(which(tes1 < 0.01))
power12 = length(which(tes2 < 0.01))
power13 = length(which(tes3 < 0.01))
power14 = length(which(tes4 < 0.01))

power21 = length(which(tes1 < 0.05))
power22 = length(which(tes2 < 0.05))
power23 = length(which(tes3 < 0.05))
power24 = length(which(tes4 < 0.05))

power31 = length(which(tes1 < 0.10))
power32 = length(which(tes2 < 0.10))
power33 = length(which(tes3 < 0.10))
power34 = length(which(tes4 < 0.10))

list(koef.11=      aic.garch11      =      mean.aic1,      aic.gjrgarch11=mean.aic2,
aic.aparch11=mean.aic3,power.sign11=power11,      power.sign12=power12,
power.sign13=power13,      power.sign14=power14,      power.sign21=power21,
power.sign22=power22,      power.sign23=power23,      power.sign24=power24,
power.sign31=power31,      power.sign32=power32,      power.sign33=power33,
power.sign34=power34)
}

```

Lampiran 6 : Sintaks Program R untuk Pemodelan GARCH(1,1) Inflasi

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

garch11 = ugarchspec (variance.model = list(model = "sGARCH", garchOrder =
c(1, 1)), mean.model = list(armaOrder = c(0, 0)), distribution.model = "norm",
fixed.pars=list(mu=0))
modelfit11=ugarchfit(spec=garch11,data= ResInf,out.sample=12)
show(modelfit11)
modelfor11=ugarchforecast(modelfit11, data = NULL, n.ahead = 12, n.roll=0)
show(modelfor11)
plot(modelfit11)
plot(modelfor11)
```

Lampiran 7 : Sintaks Program R untuk Pemodelan GJR-GARCH(1,1) Inflasi

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

gjrarch11<-
ugarchspec(variance.model=list(model="gjrGARCH",garchOrder=c(1,1)),
mean.model=list(armaOrder=c(0,0),include.mean=T,
archm=F,arfima=F),distribution.model="norm",fixed.pars=list(mu=0))
mod.fit.gjrarch11<-ugarchfit(spec=gjrarch11,data=ResInf,out.sample=12)
show(mod.fit.gjrarch11)
modelfor.gjr11=ugarchforecast(mod.fit.gjrarch11, data = NULL, n.ahead = 12,
n.roll= 0)
show(modelfor.gjr11)
plot(mod.fit.gjrarch11)
plot(modelfor.gjr11)
```

Lampiran 8 : Sintaks Program R untuk Pemodelan APARCH(1,1) Inflasi

```
library(PerformanceAnalytics)
library(quantmod)
library(rugarch)
library(car)
library(FinTS)
library(TSA)

aparch11<-ugarchspec(variance.model=list(model="apARCH",garchOrder=c(1,1)),
mean.model=list(armaOrder=c(0,0),include.mean=T,
archm=F,arfima=F),distribution.model="norm",fixed.pars=list(mu=0))
mod.fit.aparch11<-ugarchfit(spec=aparch11,data=ResInf,out.sample=12)
show(mod.fit.aparch11)
modelfor.aparch11=ugarchforecast(mod.fit.aparch11, data = NULL, n.ahead = 12,
n.roll= 0)
show(modelfor.aparch11)
plot(mod.fit.aparch11)
plot(modelfor.aparch11)
```

Lampiran 9 : Hasil Uji ADF Data Inflasi

Augmented Dickey-Fuller Unit Root Tests							
Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	0	-87.9504	<.0001	-7.12	<.0001		
	1	-70.6531	<.0001	-5.87	<.0001		
	2	-46.1690	<.0001	-4.54	<.0001		
Single Mean	0	-120.397	0.0001	-8.62	<.0001	37.14	0.0010
	1	-109.191	0.0001	-7.32	<.0001	26.76	0.0010
	2	-78.9235	0.0016	-5.84	<.0001	17.09	0.0010
Trend	0	-121.756	0.0001	-8.65	<.0001	37.45	0.0010
	1	-111.037	0.0001	-7.35	<.0001	27.02	0.0010
	2	-80.8692	0.0007	-5.89	<.0001	17.36	0.0010

Lampiran 10 : Hasil Uji ADF Data Persentase Perubahan Rata-rata Harga Minyak Dunia

Augmented Dickey-Fuller Unit Root Tests							
Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	0	-201.035	0.0001	-12.15	<.0001		
	1	-207.863	0.0001	-10.00	<.0001		
	2	-222.999	0.0001	-8.78	<.0001		
Single Mean	0	-202.575	0.0001	-12.19	<.0001	74.32	0.0010
	1	-211.445	0.0001	-10.05	<.0001	50.53	0.0010
	2	-230.502	0.0001	-8.86	<.0001	39.22	0.0010
Trend	0	-202.568	0.0001	-12.17	<.0001	74.07	0.0010
	1	-211.359	0.0001	-10.03	<.0001	50.39	0.0010
	2	-230.168	0.0001	-8.83	<.0001	39.14	0.0010

Lampiran 11 : Output ARCH(1)

```

*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : SGARCH(1,0)
Mean Model       : ARFIMA(0,0,0)
Distribution      : norm

Optimal Parameters
-----
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.27900       0.032131      8.6833  0.000000
alpha1      0.26222       0.099404      2.6379  0.008341

Robust Standard Errors:
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.27900       0.035745      7.8053  0.000000
alpha1      0.26222       0.100702      2.6039  0.009216

LogLikelihood : -269.3349

Information Criteria
-----
Akaike          1.8089
Bayes           1.8336
Shibata         1.8088
Hannan-Quinn    1.8188

Weighted Ljung-Box Test on Standardized Residuals
-----
      statistic   p-value
Lag[1]          0.002454  0.9605
Lag[2*(p+q)+(p+q)-1][2]  1.860064  0.2871
Lag[4*(p+q)+(p+q)-1][5]  3.703219  0.2935
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
      statistic   p-value
Lag[1]          0.4241  0.51492
Lag[2*(p+q)+(p+q)-1][2]  2.3077  0.21644
Lag[4*(p+q)+(p+q)-1][5]  7.8709  0.03172
d.o.f=1

Weighted ARCH LM Tests
-----
      Statistic   Shape   Scale   P-value
ARCH Lag[2]      3.717   0.500   2.000  0.053847
ARCH Lag[4]      9.164   1.397   1.611  0.008086
ARCH Lag[6]     10.535   2.222   1.500  0.010202

Nyblom stability test
-----
Joint Statistic: 1.081
Individual Statistics:
omega  1.0490
alpha1 0.3115

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic:  0.61 0.749 1.07
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value   prob sig
Sign Bias      0.8787  0.3803
Negative Sign Bias 1.5123  0.1315
Positive Sign Bias 1.2838  0.2002
Joint Effect     4.9796  0.1733

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      29.87      0.05352
2      30      48.20      0.01401
3      40      42.93      0.30637
4      50      55.33      0.24799

```

Lampiran 12 : Output ARCH(2)

```

*-----*
*      GARCH Model Fit      *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : SGARCH(2,0)
Mean Model       : ARFIMA(0,0,0)
Distribution      : norm

Optimal Parameters
-----
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.23969        0.033268      7.2047 0.000000
alpha1      0.24070        0.101683      2.3672 0.017925
alpha2      0.13061        0.069452      1.8806 0.060029

Robust Standard Errors:
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.23969        0.035973      6.6629 0.000000
alpha1      0.24070        0.104313      2.3075 0.021028
alpha2      0.13061        0.072444      1.8029 0.071400

LogLikelihood : -266.4199

Information Criteria
-----
Akaike          1.7961
Bayes           1.8332
Shibata         1.7959
Hannan-Quinn   1.8110

Weighted Ljung-Box Test on Standardized Residuals
-----
              statistic p-value
Lag[1]              0.04221 0.8372
Lag[2*(p+q)+(p+q)-1][2] 1.76243 0.3054
Lag[4*(p+q)+(p+q)-1][5] 3.93577 0.2622
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
              statistic p-value
Lag[1]              0.06999 0.79134
Lag[2*(p+q)+(p+q)-1][5] 6.33506 0.07493
Lag[4*(p+q)+(p+q)-1][9] 9.53608 0.06291
d.o.f=2

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-value
ARCH Lag[3]      10.23 0.500 2.000 0.001381
ARCH Lag[5]      10.25 1.440 1.667 0.005713
ARCH Lag[7]      11.88 2.315 1.543 0.006619

Nyblom stability test
-----
Joint Statistic: 1.1283
Individual Statistics:
omega 0.9365
alpha1 0.3179
alpha2 0.2499

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 0.846 1.01 1.35
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
              t-value   prob sig
Sign Bias          0.613 0.5403
Negative Sign Bias 1.345 0.1798
Positive Sign Bias 1.207 0.2286
Joint Effect       4.758 0.1904

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      31.33      0.0371
2      30      32.20      0.3112
3      40      42.93      0.3064
4      50      48.33      0.5001

```

Lampiran 13 : Output GARCH(0,1)

```

*-----*
*      GARCH Model Fit      *
*-----*

Conditional Variance Dynamics
-----
GARCH Model : SGARCH(0,1)
Mean Model  : ARFIMA(0,0,0)
Distribution : norm

Optimal Parameters
-----
      Estimate Std. Error   t value Pr(>|t|)
mu      0.00000      NA         NA         NA
omega   0.00000      0.000103 6.0000e-06 0.99999
beta1   0.99889      0.000783 1.2762e+03 0.00000

Robust Standard Errors:
      Estimate Std. Error   t value Pr(>|t|)
mu      0.00000      NA         NA         NA
omega   0.00000      0.000069 0.000009 0.99999
beta1   0.99889      0.001301 767.733295 0.00000

LogLikelihood : -274.3737

Information Criteria
-----
Akaike      1.8425
Bayes       1.8672
Shibata     1.8424
Hannan-Quinn 1.8524

Weighted Ljung-Box Test on Standardized Residuals
-----
      statistic p-value
Lag[1]      0.0005998 0.9805
Lag[2*(p+q)+(p+q)-1][2] 0.6244081 0.6380
Lag[4*(p+q)+(p+q)-1][5] 1.2285885 0.8061
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
      statistic p-value
Lag[1]      12.42 4.243e-04
Lag[2*(p+q)+(p+q)-1][2] 17.46 2.068e-05
Lag[4*(p+q)+(p+q)-1][5] 22.75 3.380e-06
d.o.f=1

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-value
ARCH Lag[2]      9.943 0.500 2.000 0.001614
ARCH Lag[4]      12.676 1.397 1.611 0.001024
ARCH Lag[6]      14.061 2.222 1.500 0.001330

Nyblom stability test
-----
Joint Statistic: 3.7697
Individual Statistics:
omega 0.8016
beta1 0.8884

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 0.61 0.749 1.07
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value prob sig
Sign Bias      1.1503 2.509e-01
Negative Sign Bias 0.2705 7.870e-01
Positive Sign Bias 4.7864 2.690e-06 ***
Joint Effect    25.4043 1.271e-05 ***

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      30.80      0.04246
2      30      42.60      0.04955
3      40      49.87      0.11397
4      50      69.33      0.02946

```

Lampiran 14 : Output GARCH(0,2)

```

*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : SGARCH(0,2)
Mean Model       : ARFIMA(0,0,0)
Distribution      : norm

Optimal Parameters
-----
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.00000         0.000135      0.00      1
beta1       0.45754         0.000809     565.40     0
beta2       0.54074         0.000802     674.58     0

Robust Standard Errors:
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.00000         0.000009      0.00      1
beta1       0.45754         0.000638     717.02     0
beta2       0.54074         0.000627     862.29     0

LogLikelihood : -274.3574

Information Criteria
-----
Akaike          1.8490
Bayes           1.8861
Shibata         1.8489
Hannan-Quinn    1.8639

Weighted Ljung-Box Test on Standardized Residuals
-----
      statistic   p-value
Lag[1]          0.0006028   0.9804
Lag[2*(p+q)+(p+q)-1][2] 0.6244090   0.6380
Lag[4*(p+q)+(p+q)-1][5] 1.2294893   0.8059
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
      statistic   p-value
Lag[1]          12.43 4.236e-04
Lag[2*(p+q)+(p+q)-1][5] 22.74 3.394e-06
Lag[4*(p+q)+(p+q)-1][9] 26.01 5.246e-06
d.o.f=2

Weighted ARCH LM Tests
-----
      Statistic   Shape   Scale   P-Value
ARCH Lag[3]      3.623   0.500   2.000   0.0570
ARCH Lag[5]      3.752   1.440   1.667   0.1977
ARCH Lag[7]      5.733   2.315   1.543   0.1602

Nyblom stability test
-----
Joint Statistic: 4.1973
Individual Statistics:
omega 0.7987
beta1 0.8839
beta2 0.8839

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 0.846 1.01 1.35
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value   prob sig
Sign Bias      1.150 2.509e-01
Negative Sign Bias 0.270 7.873e-01
Positive Sign Bias 4.786 2.694e-06 ***
Joint Effect    25.401 1.273e-05 ***

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      30.80      0.04246
2      30      42.60      0.04955
3      40      50.93      0.09552
4      50      69.33      0.02946

```

Lampiran 15 : Output GARCH(1,1)

```

*-----*
*      GARCH Model Fit      *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : SGARCH(1,1)
Mean Model       : ARFIMA(0,0,0)
Distribution      : norm

Optimal Parameters
-----
      Estimate Std. Error t value Pr(>|t|)
mu      0.00000      NA      NA      NA
omega    0.10862    0.036863  2.9465 0.003214
alpha1   0.27375    0.090499  3.0249 0.002487
beta1    0.44621    0.127648  3.4956 0.000473

Robust Standard Errors:
      Estimate Std. Error t value Pr(>|t|)
mu      0.00000      NA      NA      NA
omega    0.10862    0.040888  2.6565 0.007896
alpha1   0.27375    0.088645  3.0882 0.002014
beta1    0.44621    0.128655  3.4682 0.000524

LogLikelihood : -264.1982

Information Criteria
-----
Akaike      1.7813
Bayes       1.8184
Shibata     1.7811
Hannan-Quinn 1.7961

Weighted Ljung-Box Test on Standardized Residuals
-----
      statistic p-value
Lag[1]      0.0828 0.7735
Lag[2*(p+q)+(p+q)-1][2] 2.1669 0.2365
Lag[4*(p+q)+(p+q)-1][5] 4.3932 0.2089
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
      statistic p-value
Lag[1]      0.05186 0.8199
Lag[2*(p+q)+(p+q)-1][5] 1.24583 0.8020
Lag[4*(p+q)+(p+q)-1][9] 3.19320 0.7267
d.o.f=2

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-value
ARCH Lag[3]  1.849 0.500 2.000 0.1738
ARCH Lag[5]  1.989 1.440 1.667 0.4736
ARCH Lag[7]  3.890 2.315 1.543 0.3627

Nyblom stability test
-----
Joint Statistic: 0.6956
Individual Statistics:
omega 0.6223
alpha1 0.3754
beta1 0.5631

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 0.846 1.01 1.35
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value prob sig
Sign Bias 0.4394 0.6607
Negative Sign Bias 1.5076 0.1327
Positive Sign Bias 0.9940 0.3210
Joint Effect 5.4765 0.1401

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1 20 30.00 0.0518
2 30 34.00 0.2393
3 40 41.07 0.3801
4 50 47.33 0.5409

```

Lampiran 16 : Output GARCH(1,2)

```

*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : SGARCH(1,2)
Mean Model       : ARFIMA(0,0,0)
Distribution      : norm

Optimal Parameters
-----
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.10446        0.034985      2.9858      0.002828
alpha1      0.27846        0.082258      3.3852      0.000711
beta1       0.45149        0.362670      1.2449      0.213166
beta2       0.00000        0.346573      0.0000      1.000000

Robust Standard Errors:
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA         NA         NA
omega       0.10446        0.038535      2.71074     0.006713
alpha1      0.27846        0.106243      2.62100     0.008767
beta1       0.45149        0.540825      0.83482     0.403820
beta2       0.00000        0.488939      0.00000     1.000000

LogLikelihood : -263.8557

Information Criteria
-----
Akaike          1.7857
Bayes           1.8351
Shibata         1.7854
Hannan-Quinn    1.8055

Weighted Ljung-Box Test on Standardized Residuals
-----
                        statistic p-value
Lag[1]                0.06838   0.7937
Lag[2*(p+q)+(p+q)-1][2] 2.20064   0.2315
Lag[4*(p+q)+(p+q)-1][5] 4.45259   0.2027
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
                        statistic p-value
Lag[1]                0.08378   0.7722
Lag[2*(p+q)+(p+q)-1][8] 2.83141   0.7164
Lag[4*(p+q)+(p+q)-1][14] 5.59956   0.6924
d.o.f=3

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-Value
ARCH Lag[4]    0.1398 0.500 2.000 0.7085
ARCH Lag[6]    2.1215 1.461 1.711 0.4646
ARCH Lag[8]    2.7872 2.368 1.583 0.5840

Nyblom stability test
-----
Joint Statistic: 1.1058
Individual Statistics:
omega 0.5492
alpha1 0.3648
beta1 0.5130
beta2 0.4050

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 1.07 1.24 1.6
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value   prob sig
Sign Bias      0.4752 0.6350
Negative Sign Bias 1.5561 0.1208
Positive Sign Bias 0.9872 0.3243
Joint Effect    5.5659 0.1347

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      28.67      0.07141
2      30      34.20      0.23201
3      40      44.00      0.26815
4      50      48.00      0.51364

```

Lampiran 17 : Output GARCH(2,1)

```

*-----*
*      GARCH Model Fit      *
*-----*

Conditional Variance Dynamics
-----
GARCH Model : SGARCH(2,1)
Mean Model  : ARFIMA(0,0,0)
Distribution : norm

Optimal Parameters
-----
      Estimate Std. Error t value Pr(>|t|)
mu      0.000000      NA      NA      NA
omega   0.111738    0.055167    2.02544 0.042822
alpha1  0.270019    0.103427    2.61073 0.009035
alpha2  0.022228    0.129961    0.17104 0.864194
beta1   0.418352    0.225591    1.85447 0.063671

Robust Standard Errors:
      Estimate Std. Error t value Pr(>|t|)
mu      0.000000      NA      NA      NA
omega   0.111738    0.04822    2.31725 0.020490
alpha1  0.270019    0.10607    2.54559 0.010909
alpha2  0.022228    0.12672    0.17542 0.860752
beta1   0.418352    0.18542    2.25620 0.024058

LogLikelihood : -263.8418

Information Criteria
-----
Akaike      1.7856
Bayes       1.8350
Shibata     1.7853
Hannan-Quinn 1.8054

Weighted Ljung-Box Test on Standardized Residuals
-----
              statistic p-value
Lag[1]              0.07186 0.7887
Lag[2*(p+q)+(p+q)-1][2] 2.17515 0.2353
Lag[4*(p+q)+(p+q)-1][5] 4.40919 0.2072
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
              statistic p-value
Lag[1]              0.0459 0.8304
Lag[2*(p+q)+(p+q)-1][8] 2.7962 0.7228
Lag[4*(p+q)+(p+q)-1][14] 5.5119 0.7039
d.o.f=3

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-value
ARCH Lag[4]    0.1283 0.500 2.000 0.7202
ARCH Lag[6]    2.0613 1.461 1.711 0.4774
ARCH Lag[8]    2.7239 2.368 1.583 0.5963

Nyblom stability test
-----
Joint Statistic: 0.8028
Individual Statistics:
omega 0.5611
alpha1 0.3613
alpha2 0.2835
beta1 0.5344

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 1.07 1.24 1.6
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value prob sig
Sign Bias      0.455 0.6494
Negative Sign Bias 1.510 0.1321
Positive Sign Bias 1.026 0.3056
Joint Effect     5.556 0.1354

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      29.73      0.05529
2      30      34.00      0.23926
3      40      43.47      0.28688
4      50      46.00      0.59550

```

Lampiran 18 : Output GARCH(2,2)

```

*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : SGARCH(2,2)
Mean Model       : ARFIMA(0,0,0)
Distribution      : norm

Optimal Parameters
-----
      Estimate   Std. Error   t value   Pr(>|t|)
mu      0.000000      NA         NA         NA
omega   0.111739      0.051965      2.15026    0.031535
alpha1  0.270021      0.101273      2.66627    0.007670
alpha2  0.022232      0.119966      0.18532    0.852980
beta1   0.418347      0.354933      1.17866    0.238532
beta2   0.000000      0.303517      0.00000    1.000000

Robust Standard Errors:
      Estimate   Std. Error   t value   Pr(>|t|)
mu      0.000000      NA         NA         NA
omega   0.111739      0.058545      1.90860    0.056314
alpha1  0.270021      0.101068      2.67167    0.007547
alpha2  0.022232      0.164200      0.13539    0.892300
beta1   0.418347      0.520521      0.80371    0.421565
beta2   0.000000      0.270228      0.00000    1.000000

LogLikelihood : -263.8418

Information Criteria
-----
Akaike      1.7923
Bayes       1.8540
Shibata     1.7917
Hannan-Quinn 1.8170

Weighted Ljung-Box Test on Standardized Residuals
-----
              statistic p-value
Lag[1]          0.07186  0.7887
Lag[2*(p+q)+(p+q)-1][2]  2.17515  0.2353
Lag[4*(p+q)+(p+q)-1][5]  4.40920  0.2072
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
              statistic p-value
Lag[1]          0.0459  0.8304
Lag[2*(p+q)+(p+q)-1][11]  4.0167  0.7304
Lag[4*(p+q)+(p+q)-1][19]  8.9721  0.5648
d.o.f=4

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-Value
ARCH Lag[5]      0.1082 0.500 2.000 0.7422
ARCH Lag[7]      2.9626 1.473 1.746 0.3261
ARCH Lag[9]      3.2999 2.402 1.619 0.5113

Nyblom stability test
-----
Joint Statistic: 2.5187
Individual Statistics:
omega 0.5611
alpha1 0.3613
alpha2 0.2835
beta1 0.5344
beta2 0.4243

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 1.28 1.47 1.88
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
              t-value   prob sig
Sign Bias      0.455  0.6494
Negative Sign Bias 1.510 0.1321
Positive Sign Bias 1.026 0.3056
Joint Effect    5.556 0.1354

Adjusted Pearson Goodness-of-Fit Test:
-----
group statistic p-value(g-1)
1    20      29.73      0.05529
2    30      34.00      0.23926
3    40      43.47      0.28688
4    50      46.00      0.59550

```

Lampiran 19 : Output GJR-GARCH(1,1)

```

*-----*
*      GARCH Model Fit      *
*-----*

Conditional Variance Dynamics
-----
GARCH Model : gjrGARCH(1,1)
Mean Model  : ARFIMA(0,0,0)
Distribution : norm

Optimal Parameters
-----
      Estimate Std. Error t value Pr(>|t|)
mu      0.000000      NA      NA      NA
omega   0.008039   0.001822   4.4123  1e-05
alpha1  0.059929   0.002537  23.6252 0e+00
beta1   0.983048   0.000049 19932.2919 0e+00
gamma1  -0.137499   0.004378  -31.4047 0e+00

Robust Standard Errors:
      Estimate Std. Error t value Pr(>|t|)
mu      0.000000      NA      NA      NA
omega   0.008039   0.001435   5.6024  0
alpha1  0.059929   0.002004  29.8979  0
beta1   0.983048   0.000009 106285.8678  0
gamma1  -0.137499   0.003413  -40.2866  0

LogLikelihood : -261.8665

Information Criteria
-----
Akaike      1.7724
Bayes       1.8218
Shibata     1.7721
Hannan-Quinn 1.7922

Weighted Ljung-Box Test on Standardized Residuals
-----
      statistic p-value
Lag[1]      0.3146 0.5749
Lag[2*(p+q)+(p+q)-1][2] 0.9845 0.5033
Lag[4*(p+q)+(p+q)-1][5] 2.1150 0.5915
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
      statistic p-value
Lag[1]      7.586 0.005883
Lag[2*(p+q)+(p+q)-1][5] 9.047 0.016102
Lag[4*(p+q)+(p+q)-1][9] 11.600 0.022346
d.o.f=2

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-value
ARCH Lag[3]  1.474 0.500 2.000 0.2247
ARCH Lag[5]  1.730 1.440 1.667 0.5340
ARCH Lag[7]  4.377 2.315 1.543 0.2954

Nyblom stability test
-----
Joint Statistic: 0.9251
Individual Statistics:
omega  0.16963
alpha1 0.09659
beta1  0.10194
gamma1 0.10577

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 1.07 1.24 1.6
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value prob sig
Sign Bias 0.2465 0.805439
Negative Sign Bias 0.5230 0.601391
Positive Sign Bias 2.8942 0.004085 ***
Joint Effect 10.3561 0.015770 **

Adjusted Pearson Goodness-of-Fit Test:
-----
      group statistic p-value(g-1)
1      20      22.40      0.26480
2      30      28.20      0.50724
3      40      54.40      0.05163
4      50      80.33      0.00316

```

Lampiran 20 : Output APARCH(1,1)

```

*-----*
*          GARCH Model Fit          *
*-----*

Conditional Variance Dynamics
-----
GARCH Model      : apARCH(1,1)
Mean Model      : ARFIMA(0,0,0)
Distribution     : norm

Optimal Parameters
-----
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA          NA          NA
omega       0.11997        0.043026      2.7882 0.005300
alpha1      0.18536        0.041502      4.4711 0.000008
beta1       0.65268        0.118712      5.4980 0.000000
gamma1      -1.00000        0.002159    -463.1767 0.000000
delta       0.98428        0.432467      2.2760 0.022848

Robust Standard Errors:
      Estimate   Std. Error   t value   Pr(>|t|)
mu          0.00000         NA          NA          NA
omega       0.11997         NA          NA          NA
alpha1      0.18536         NA          NA          NA
beta1       0.65268         NA          NA          NA
gamma1      -1.00000         NA          NA          NA
delta       0.98428         NA          NA          NA

LogLikelihood : -252.127

Information Criteria
-----
Akaike          1.7142
Bayes           1.7759
Shibata         1.7136
Hannan-Quinn   1.7389

Weighted Ljung-Box Test on Standardized Residuals
-----
                        statistic p-value
Lag[1]                  0.9558 0.32824
Lag[2*(p+q)+(p+q)-1][2] 2.8050 0.15848
Lag[4*(p+q)+(p+q)-1][5] 5.9894 0.09047
d.o.f=0
H0 : No serial correlation

Weighted Ljung-Box Test on Standardized Squared Residuals
-----
                        statistic p-value
Lag[1]                  0.5966 0.4399
Lag[2*(p+q)+(p+q)-1][5] 1.3997 0.7645
Lag[4*(p+q)+(p+q)-1][9] 2.7676 0.7966
d.o.f=2

Weighted ARCH LM Tests
-----
      Statistic Shape Scale P-Value
ARCH Lag[3]    0.2145 0.500 2.000 0.6433
ARCH Lag[5]    0.5550 1.440 1.667 0.8673
ARCH Lag[7]    1.8639 2.315 1.543 0.7461


Nyblom stability test
-----
Joint Statistic: NA
Individual Statistics:
omega 0.5245
alpha1 0.2097
beta1 0.3934
gamma1 NA
delta 0.4622

Asymptotic Critical Values (10% 5% 1%)
Joint Statistic: 1.28 1.47 1.88
Individual Statistic: 0.35 0.47 0.75

Sign Bias Test
-----
      t-value   prob sig
Sign Bias      0.62498 0.5325
Negative Sign Bias 0.05398 0.9570
Positive Sign Bias 0.02341 0.9813
Joint Effect    0.90304 0.8247

Adjusted Pearson Goodness-of-Fit Test:
-----
group statistic p-value(g-1)
1    20      14.80      0.7352
2    30      22.40      0.8033
3    40      26.67      0.9333
4    50      35.67      0.9228

```



BIOGRAFI PENULIS



Penulis dilahirkan di Kendari, Sulawesi Tenggara pada tanggal 15 Oktober 1985. Penulis merupakan putri bungsu dari bapak H. L. Ubo dengan ibu Wd. Ombeli. Penulis telah menempuh pendidikan formal yaitu di SD Negeri 2 Kemaraya (1991-1997), SLTP Negeri 1 Kendari (1997-2000), SMU Negeri 4 Kendari (2000-2003). Kemudian penulis melanjutkan pendidikan ke jenjang D-IV di Sekolah Tinggi Ilmu Statistik (STIS)

Jakarta (2003-2007) jurusan Statistik Sosial dan Kependudukan. Setelah menyelesaikan pendidikan D-IV di STIS, penulis ditugaskan sebagai staf di BPS Kabupaten Kolaka Utara Provinsi Sulawesi Tenggara dan empat tahun berikutnya penulis dipercaya menjadi Kasie Statistik Distribusi di BPS Kota Kendari. Pada tahun 2014 penulis memperoleh kesempatan untuk mendapatkan beasiswa dari BPS untuk melanjutkan jenjang pendidikan S2 di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Institut Teknologi Sepuluh Nopember (ITS) Surabaya. Pembaca yang ingin memberikan kritik, saran dan pertanyaan mengenai penelitian ini, dapat menghubungi penulis melalui email sriaryani@bps.go.id.

