



TESIS - SS142501

MODEL MULTILEVEL KOMBINASI ARIMAX-ANFIS-GARCH UNTUK PERAMALAN NILAI *OUTFLOW* DAN *INFLOW* UANG KARTAL DI BANK INDONESIA PROVINSI PAPUA

BOBI FRANS KUDDI
NRP 1314201043

DOSEN PEMBIMBING
Dr. Suhartono, M.Sc.
Santi Puteri Rahayu, M.Si., Ph.D.

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



THESIS - SS142501

HYBRID MULTILEVEL MODEL OF ARIMAX-ANFIS-GARCH FOR FORECASTING CURRENCY OUTFLOW AND INFLOW IN BANK INDONESIA AT PAPUA PROVINCE

BOBI FRANS KUDDI
NRP 1314201043

SUPERVISOR
Dr. Suhartono, M.Sc.
Santi Puteri Rahayu, M.Si., Ph.D.

MAGISTER PROGRAM
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2016

**MODEL MULTILEVEL KOMBINASI ARIMAX-ANFIS-GARCH UNTUK
PERAMALAN NILAI OUTFLOW DAN INFLOW UANG KARTAL
DI BANK INDONESIA PROVINSI PAPUA**

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

Oleh:
BOBI FRANS KUDDI
NRP.1314201043

Tanggal Ujian
Periode Wisuda

: 18 Juli 2016
: September 2016

Disetujui Oleh:

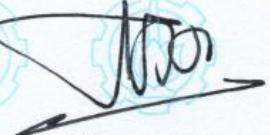
1. **Dr. Suhartono, M.Sc.**
NIP. 19710929 199512 1 001


(Pembimbing I)

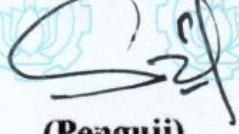
2. **Santi Puteri Rahayu, M.Si., Ph.D.**
NIP. 19750115 199903 2 003


(Pembimbing II)

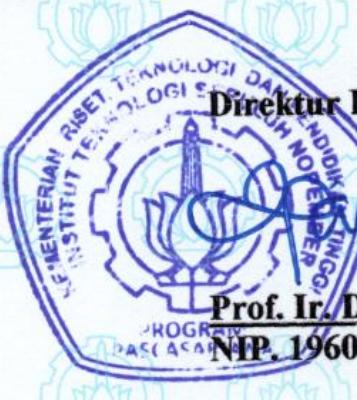
3. **Dr. Agus Suharsono, MS.**
NIP. 19580823 198403 1 003


(Pengaji)

4. **Santi Wulan Purnami, M.Si., Ph.D.**
NIP. 19720923 199803 2 001


(Pengaji)

Direktur Pascasarjana ITS




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

MODEL MULTILEVEL KOMBINASI ARIMAX-ANFIS-GARCH UNTUK PERAMALAN NILAI *OUTFLOW* DAN *INFLOW* UANG KARTAL DI BANK INDONESIA PROVINSI PAPUA

Nama Mahasiswa : Bobi Frans Kuddi
NRP : 1314201043
Pembimbing : Dr. Suhartono, M.Sc.
Co-Pembimbing : Santi Puteri Rahayu, M.Si., Ph.D.

ABSTRAK

Bank Indonesia (BI) merupakan bank sentral Republik Indonesia yang mempunyai tujuan tunggal yakni mencapai dan memelihara kestabilan nilai rupiah. Salah satu hal yang dilakukan untuk memenuhi tujuan tersebut adalah dengan pemantauan *outflow-inflow* uang kartal. Pemantauan *outflow-inflow* uang kartal salah satunya dengan melakukan peramalan *outflow-inflow* uang kartal. Secara umum peramalan *outflow-inflow* dapat dilakukan dengan pendekatan *time series*, pendekatan kausal, dan gabungan antara pendekatan *time series* dan kausal. Model dengan pendekatan gabungan yang banyak digunakan untuk peramalan *outflow-inflow* adalah ARIMAX. Selain itu, pendekatan *Autoregressive Conditional Heteroscedasticity* (ARCH) untuk model varians residual juga pernah diaplikasikan pada peramalan *outflow-inflow*. Penelitian ini bertujuan mendapatkan metode terbaik untuk meramalkan *outflow-inflow* di BI Provinsi Papua. Metode-metode yang akan digunakan yaitu ARIMAX dua level, ANFIS dan gabungan ARIMAX dua level dengan ANFIS serta deteksi GARCH. Proses GARCH untuk peramalan data *outflow* hanya terdapat pada model ANFIS sendangkan pada peramalan data *inflow* hanya terdapat pada model ARIMAX. Hasil yang diperoleh menunjukkan bahwa ANFIS merupakan model dengan peramalan *outflow* uang kartal yang terbaik, sedangkan model yang terbaik untuk peramalan *inflow* uang kartal di BI Provinsi Papua adalah metode gabungan ARIMAX-ANFIS.

Kata kunci : ARIMAX, ANFIS, kombinasi ARIMAX-ANFIS, GARCH, *Inflow*, *Outflow*

(Halaman ini sengaja dikosongkan)

HYBRID MULTILEVEL MODEL OF ARIMAX-ANFIS-GARCH FOR FORECASTING CURRENCY OUTFLOW AND INFLOW IN BANK INDONESIA AT PAPUA PROVINCE

Student Name : Bobi Frans Kuddi
Student ID : 1314201043
Supervisor : Dr. Suhartono, M.Sc.
Co-Supervisor : Santi Puteri Rahayu, M.Si., Ph.D.

ABSTRACT

Bank Indonesia (BI) is the central bank of Republic of Indonesia, which has the sole purpose to achieve and maintain stability in the rupiah. One of the things to do to meet these goals is monitoring the inflow-outflow of currency by forecasting the outflow-inflow of currency. Forecasting outflow-inflow can be generally done with time series approach, causal approach, and the combination. Models with a combined approach that is widely used for forecasting outflow-inflow is ARIMAX. In addition, the approach Autoregressive Conditional Heteroscedasticity (ARCH) to model the residual variance has also been applied to the forecasting of outflow-inflow. This study aims to obtain the best method for predicting outflow-inflow in BI at Papua Province. The methods that will be used is ARIMAX two levels, ANFIS and combined ARIMAX two levels with ANFIS and GARCH detection. GARCH processes for forecasting the data outflow only in ANFIS, models in forecasting inflow data is only available on models ARIMAX. The results obtained showed that the ANFIS method is the best forecasting model for outflow of currency, while the best model for forecasting currency inflow in BI at Papua province is hybrid ARIMAX-ANFIS method.

Keywords: ARIMAX, ANFIS, hybrid ARIMAX-ANFIS, GARCH Outflow, Inflow

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa, atas kasih dan penyertaan-Nya sehingga penulis dapat menyelesaikan tesis dengan judul: **“Model Multilevel Kombinasi ARIMAX-ANFIS-GARCH untuk Peramalan Nilai *Outflow* dan *Inflow* Uang Kartal di Bank Indonesia Provinsi Papua”**

Tesis ini disusun sebagai salah satu syarat untuk menyelesaikan pendidikan pada Program Magister Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember (ITS) Surabaya. Keberhasilan penulisan tesis ini tidak lepas dari bimbingan dan bantuan dari berbagai pihak, baik berupa doa, pikiran, motivasi, mupun tenaga. Oleh karena itu penulis ingin mengucapkan terima kasih sebesar-besarnya kepada:

1. Ayah, Ibu, Nenek, Kakek, Adik-adik dan Keluarga besar penulis atas segala doa, dukungan materi, motivasi, kepercayaan dan kasih sayang.
2. Dr. Suhartono, M.Sc. selaku Ketua Jurusan Statistika FMIPA ITS sekaligus pembimbing dan Santi Puteri Rahayu, M.Si., Ph.D. selaku co-pembimbing yang telah banyak memberikan bimbingan dan saran selama pengerjaan tesis ini.
3. Dr. Agus Suharsono, MS., dan Santi Wulan Purnami, M.Si., Ph.D. selaku dosen penguji yang telah memberikan tambahan ilmu selama proses perbaikan tesis ini.
4. Dr. Ismaini Zain, M.Si. selaku dosen wali yang telah membimbing dan mengarahkan sejak awal perkuliahan.
5. Dr. rer.pol. Heri Kuswanto, M.Si. selaku Ketua Program Pascasarjana S2 Statistika FMIPA ITS.
6. Teman-teman yang mengambil tesis dengan topik analisis *time series*, yang berperan serta dalam penyelesaian tesis ini.
7. Teman-teman S2 Statistika Angkatan 2014 yang telah berjuang bersama-sama menyelesaikan perkuliahan di Jurusan Statistika FMIPA ITS
8. Pihak-pihak lain yang telah mendukung dan membantu penyusunan tesis ini yang tidak mungkin penulis sebutkan satu per satu. Terima kasih.

Penulis menyadari bahwa penyusunan Tesis ini masih jauh dari sempurna, maka kritik dan saran yang membangun akan senantiasa penulis harapkan demi kesempurnaan di masa mendatang. Semoga tesis ini dapat memberikan sumbangan yang bermanfaat bagi pihak yang membutuhkan dan dapat menambah pengetahuan.

Surabaya, Juli 2016

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN	xix
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan Penelitian	7
1.4 Manfaat Penelitian	7
1.5 Batasan Masalah	7
BAB 2 TINJAUAN PUSTAKA	9
2.1 Analisis <i>Time Series</i>	9
2.2 Model ARIMA	9
2.2.1 Stasioneritas	11
2.2.2 Autocorrelation Function (ACF)	12
2.2.3 Partial Autocorrelation Function (PACF)	12
2.2.4 Identifikasi Model ARIMA	12
2.2.5 Estimasi Parameter	13
2.2.6 Cek Diagnostik	14
2.3 Model ARIMAX	15
2.4 Adative Neuro-Fuzzy Inference System (ANFIS)	17

2.5 Model Peramalan Gabungan	21
2.6 Model ARCH dan GARCH.....	23
2.7 Pemilihan Model Terbaik	25
2.8 Tujuan dan Tugas Bank Indonesia	26
BAB 3 METODOLOGI PENELITIAN	27
3.1 Sumber Data	27
3.2 Metode Analisis Data	27
BAB 4 ANALISIS DAN PEMBAHASAN	35
4.1 Karakteristik <i>Outflow</i> dan <i>Inflow</i> Uang Kartal periode tahun 2003-2014..	35
4.2 Model ARIMAX <i>Outflow</i> dan <i>Inflow</i> Uang Kartal	39
4.2.1 Model ARIMAX untuk Data <i>Outflow</i>	41
4.2.2 Model ARIMAX untuk Data <i>Inflow</i>	51
4.3 Peramalan <i>Outflow</i> dan <i>Inflow</i> dengan Menggunakan ANFIS	65
4.3.1 Peramalan Data <i>Outflow</i> Menggunakan Metode ANFIS	65
4.3.2 Peramalan Data <i>Inflow</i> Menggunakan Metode ANFIS	72
4.4 Peramalan Gabungan	77
4.4.1 Peramalan Gabungan untuk Data <i>Outflow</i>	78
4.4.2 Peremalan Gabungan untuk Data <i>Inflow</i>	83
4.5 Pemilihan Model Terbaik	87
BAB 5 KESIMPULAN DAN SARAN	93
5.1 Kesimpulan.....	93
5.2 Saran	94
DAFTAR PUSTAKA	97
LAMPIRAN	101

DAFTAR TABEL

	Halaman
Tabel 2.1 Transformasi Box-Cox	11
Tabel 2.2 Pola ACF dan PACF dari Model ARMA	12
Tabel 3.1 Tanggal Terjadinya Hari Raya Idul Fitri Tahun 2003-2014.....	28
Tabel 3.2 Perubahan Kebijakan Bank Indonesia	28
Tabel 4.1 Statistik Deskriptif Data <i>Outflow</i> dan <i>Inflow</i> Uang Kartal BI Papua Berdasarkan <i>In-Sample</i> dan <i>Out-Sample</i>	36
Tabel 4.2 Statistik Deskriptif Data <i>Outflow</i> dan <i>Inflow</i> Uang Kartal Tiap Tahun.....	36
Tabel 4.3 Notasi dari Variabel <i>Dummy</i> Efek Variasi Kalender yang Digunakan.....	39
Tabel 4.4 Variabel <i>Dummy</i> untuk Tiga Periode Kebijakan	41
Tabel 4.5 Hasil Estimasi Parameter Regresi <i>Time Series Outflow</i>	43
Tabel 4.6 Hasil Uji Asumsi Independen Residual Regresi <i>Time Series Outflow</i>	44
Tabel 4.7 Hasil Estimasi Parameter dan Uji Signifikansi Parameter <i>Outflow</i>	45
Tabel 4.8 Hasil Uji Asumsi Independen Residual Regresi <i>Time Series Outflow</i>	45
Tabel 4.9 Hasil Deteksi Data <i>Outlier Outflow</i>	46
Tabel 4.10 Hasil Estimasi Parameter ARIMAX yang Telah Signifikan Data <i>Outflow</i>	48
Tabel 4.11 Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data <i>Outflow</i>	49
Tabel 4.12 Nilai Ramalan <i>Out-sample</i> Model ARIMAX untuk Data <i>Outflow</i>	50
Tabel 4.13 Perbandingan Hasil Ramalan Model ARIMAX Data <i>Outflow</i> ..	50

Tabel 4.14	Uji Heteroskedastisitas Model ARIMAX Data <i>Outflow</i>	51
Tabel 4.15	Hasil Estimasi Parameter Regresi <i>Time Series Inflow</i>	52
Tabel 4.16	Hasil Uji Independen Residual Regresi <i>Time Series</i>	53
Tabel 4.17	Estimasi Parameter dan Uji Signifikansi Parameter <i>Inflow</i>	55
Tabel 4.18	Hasil Uji Asumsi Independen Residual Regresi <i>Time Series Inflow</i>	55
Tabel 4.19	Hasil Deteksi Data <i>Outlier Inflow</i>	56
Tabel 4.20	Hasil Uji Asumsi Independen Residual ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender	56
Tabel 4.21	Hasil Uji Asumsi Independen Residual ARIMAX Data <i>Inflow</i>	58
Tabel 4.22	Hasil Estimasi Parameter ARIMAX yang Telah Signifikan Data <i>Inflow</i>	59
Tabel 4.23	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data <i>Inflow</i>	60
Tabel 4.24	Nilai Ramalan <i>Out-sample</i> Model ARIMAX untuk Data <i>Inflow</i>	61
Tabel 4.25	Perbandingan Hasil Ramalan Model ARIMAX Data <i>Inflow</i>	61
Tabel 4.26	Uji Heteroskedastisitas Model ARIMAX Data <i>Inflow</i>	62
Tabel 4.27	Hasil Estimasi Parameter GARCH Data <i>Inflow</i>	63
Tabel 4.28	Hasil Peramalan Interval <i>Out-sample</i> Uang Kartal Menggunakan Model ARIMAX dengan Efek Variasi Kalender dan GARCH Data <i>Inflow</i>	63
Tabel 4.29	Hasil Peramalan Interval <i>Out-sample</i> Uang Kartal Menggunakan Model ARIMAX dengan Efek Variasi Kalender Data <i>Inflow</i>	64
Tabel 4.30	Parameter <i>Premise</i> Akhir Pada Model ANFIS untuk Data <i>Outflow</i>	67

Tabel 4.31	Parameter <i>consequent</i> Akhir Pada Model ANFIS untuk Data <i>Outflow</i>	68
Tabel 4.32	Nilai Ramalan <i>Out-sample</i> Model ANFIS untuk Data <i>Outflow</i>	69
Tabel 4.33	Perbandingan Hasil Ramalan Model ANFIS Data <i>Outflow</i>	69
Tabel 4.34	Uji Heteroskedastisitas Model ANFIS Data <i>Outflow</i>	70
Tabel 4.35	Hasil Estimasi Parameter Model ARCH Data <i>Outflow</i>	71
Tabel 4.36	Hasil Peramalan Interval <i>Out-sample</i> Uang Kartal menggunakan model ANFIS Data <i>Outflow</i>	71
Tabel 4.37	Parameter <i>Premise</i> Akhir Pada Model ANFIS untuk Data <i>Inflow</i>	74
Tabel 4.38	Parameter <i>consequent</i> Akhir Pada Model ANFIS untuk Data <i>Inflow</i>	75
Tabel 4.39	Nilai Ramalan <i>Out-sample</i> Model ANFIS untuk Data <i>Inflow</i>	76
Tabel 4.40	Perbandingan Hasil Ramalan Model ANFIS Data <i>Inflow</i>	76
Tabel 4.41	Uji Heteroskedastisitas Model ANFIS Data <i>Inflow</i>	77
Tabel 4.42	Parameter <i>Premise</i> Akhir Pada Model ANFIS untuk Residual <i>Outflow</i>	80
Tabel 4.43	Parameter <i>Consequent</i> Akhir Pada Model ANFIS untuk Residual <i>Outflow</i>	80
Tabel 4.44	Nilai Ramalan <i>Out-sample</i> Model Gabungan ARIMAX-ANFIS untuk Data <i>Outflow</i>	81
Tabel 4.45	Perbandingan Hasil Ramalan Model Gabungan ARIMAX-ANFIS Data <i>Outflow</i>	82
Tabel 4.46	Uji Heteroskedastisitas Model Gabungan ARIMAX-ANFIS <i>Outflow</i>	82
Tabel 4.47	Parameter <i>Premise</i> Akhir Pada Model ANFIS untuk Residual <i>Inflow</i>	85
Tabel 4.48	Parameter <i>Consequent</i> Akhir Model ANFIS untuk Residual <i>Inflow</i>	85

Tabel 4.49	Nilai Ramalan <i>Out-sample</i> Model Gabungan ARIMAX-ANFIS untuk Data <i>Inflow</i>	86
Tabel 4.50	Perbandingan Hasil Ramalan Model Gabungan ARIMAX-ANFIS Data <i>Inflow</i>	86
Tabel 4.51	Uji Heteroskedastisitas Model Gabungan ARIMAX-ANFIS Data <i>Inflow</i>	87
Tabel 4.52	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual <i>Outflow</i>	89
Tabel 4.53	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual <i>Inflow</i>	91

DAFTAR GAMBAR

	Halaman
Gambar 2.1	Framework dari ANFIS untuk Peramalan <i>Time Series</i>
Gambar 3.1	Diagram Alir Model ARIMAX
Gambar 3.2	Diagram Alir Model ANFIS
Gambar 3.3	Diagram Alir Model Kombinasi ARIMAX-ANFIS
Gambar 3.4	Tahapan Penelitian
Gambar 4.1	<i>Time Series Plot</i> (a) <i>Outflow</i> (b) <i>Inflow</i> Uang Kartal
Gambar 4.2	<i>Time Series Plot</i> (a) <i>Outflow</i> (b) <i>Inflow</i> Uang Kartal dengan Tanggal Terjadinya Idul Fitri
Gambar 4.3	<i>Time Series Plot</i> (a) <i>Outflow</i> dan (b) <i>Inflow</i> Uang Kartal dengan Tiga <i>Trend</i>
Gambar 4.4	Box-Cox Data <i>Outflow</i> Uang Kartal.....
Gambar 4.5	Plot ACF dan PACF dari Residual Regresi Time Series <i>Outflow</i> Uang Kartal.....
Gambar 4.6	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data <i>Outflow</i>
Gambar 4.7	Box-Cox Data <i>Inflow</i> Uang Kartal
Gambar 4.8	Plot ACF dan PACF dari Residual Model Regresi Time Series <i>Inflow</i> Uang Kartal.....
Gambar 4.9	Plot ACF dan PACF dari Residual ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender <i>Inflow</i> Uang Kartal
Gambar 4.10	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX yang Memuat Parameter Signifikan dengan Parameter yang Tidak Signifikan Data <i>Inflow</i>

Gambar 4.11	Plot ACF dan PACF Residual Kuadrat pada Model ARIMAX <i>Inflow</i> Uang Kartal.....	62
Gambar 4.12	Ramalan Interval <i>Out-sample</i> Uang Kartal dengan Menggunakan Model ARIMAX Data <i>Inflow</i>	64
Gambar 4.13	Plot PACF untuk Data <i>Outflow</i> yang Sudah Stasioner	66
Gambar 4.14	Arsitektur ANFIS untuk Data <i>Outflow</i>	66
Gambar 4.15	Plot ACF dan PACF Residual Kuadrat pada Model ANFIS <i>Outflow</i> Uang Kartal	70
Gambar 4.16	Ramalan Interval <i>Out-sample</i> Uang Kartal dengan Menggunakan Metode ANFIS <i>Outflow</i>	72
Gambar 4.17	Plot PACF untuk Data <i>Inflow</i> yang Sudah Stasioner.....	72
Gambar 4.18	Arsitektur ANFIS untuk Data <i>Inflow</i>	73
Gambar 4.19	Plot PACF Residual ARIMAX $([2],0,1)(1,0,0)^{12}$ dengan Efek Variasi Kalender untuk Data <i>Outflow</i>	79
Gambar 4.20	Arsitektur ANFIS dari Data Residual <i>Outflow</i>	79
Gambar 4.21	Plot PACF Residual ARIMAX $([1,13,14],0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender untuk <i>Inflow</i>	83
Gambar 4.22	Arsitektur ANFIS dari Data Residual <i>Inflow</i>	84
Gambar 4.23	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual <i>Outflow</i>	88
Gambar 4.24	Perbandingan Hasil Ramalan <i>Out-sample</i> Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual <i>Inflow</i>	90

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data <i>Outflow</i> Uang Kartal di Bank Indonesia Provinsi Papua.....	101
Lampiran 2 Data <i>Inflow</i> Uang Kartal di Bank Indonesia Provinsi Papua.....	102
Lampiran 3 <i>Syntax</i> MATLAB Model ANFIS	103
Lampiran 4 <i>Syntax</i> SAS Regresi <i>Time Series</i>	104
Lampiran 5 <i>Syntax</i> SAS Model ARIMA.....	105
Lampiran 6 <i>Syntax</i> SAS Model ARIMAX.....	106
Lampiran 7 Hasil Estimasi Parameter, Independen dan Kenormalan Residual Regresi <i>Time Series</i> untuk Data <i>Outflow</i> Uang Kartal.....	107
Lampiran 8 Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMA $(2,0,0)(1,0,0)^{12}$ untuk Data <i>Outflow</i> Uang Kartal	108
Lampiran 9 Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMA $(1,0,[2])(1,0,0)^{12}$ untuk Data <i>Outflow</i> Uang Kartal.....	109
Lampiran 10 Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMA $([2],0,1)(1,0,0)^{12}$ untuk Data <i>Outflow</i> Uang Kartal.....	110
Lampiran 11 Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMAX $([2],0,1)(1,0,0)^{12}$ dengan Efek Variasi Kalender untuk Data <i>Outflow</i> Uang Kartal...	111
Lampiran 12 Hasil Estimasi Parameter yang Telah Signifikan, Independen dan Kenormalan Residual Model ARIMAX $(0,0,1)(1,0,0)^{12}$ dengan Efek Variasi Kalender untuk Data <i>Outflow</i> Uang Kartal	112

Lampiran 13	Hasil Estimasi Parameter, Independen dan Kenormalan Residual Regresi <i>Time Series</i> untuk Data <i>Inflow</i> Uang Kartal	113
Lampiran 14	Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMA $(1,0,0)(1,0,0)^{48}$ untuk Data <i>Inflow</i> Uang Kartal	114
Lampiran 15	Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMA $(0,0,1)(1,0,0)^{48}$ untuk Data <i>Inflow</i> Uang Kartal	115
Lampiran 16	Hasil Estimasi Parameter, Independen dan Kenormalan Residual Model ARIMAX $([1,13,14],0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender untuk Data <i>Inflow</i> Uang Kartal	116
Lampiran 17	Hasil Estimasi Parameter yang Telah Signifikan, Independen dan Kenormalan Residual Model ARIMAX $([1,13,14],0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender untuk Data <i>Inflow</i> Uang Kartal	117

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Time series atau deret waktu merupakan suatu deretan observasi yang diambil secara berurutan berdasarkan waktu dengan interval yang sama, bisa harian, mingguan, bulanan, tahunan atau yang lainnya (Montgomery, Jennings dan Kulahci 2008:2). Analisis *time series* adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilistik suatu keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan (Box, Jenkins dan Reinsel, 1994:19). Berdasarkan jumlah variabel yang diteliti, *time series* dapat dikelompokkan menjadi dua bagian yaitu *time series* secara *univariate* dan *time series* secara *multivariate*. Selain itu *time series* juga dapat dikelompokkan berdasarkan linieritas data yaitu linier dan non linier (Terasvirta, Tjostheim, & Granger, 1992).

Data *time series* seringkali dipengaruhi oleh beberapa kejadian eksternal seperti hari libur, promosi, perubahan kebijakan pemerintah dan sebagainya (Wei, 2006:212). Kejadian-kejadian eksternal tersebut mengakibatkan data *time series* mengalami perubahan pola *mean* yang ekstrem yang dikenal dengan perubahan rezim (Hamilton, 1994:677). Kejadian-kejadian eksternal tersebut dalam analisis *time series* disebut dengan intervensi. Untuk mengetahui pengaruh akibat adanya suatu intervensi terhadap data *time series* metode yang digunakan adalah analisis intervensi.

Seiring dengan perkembangan jaman, *time series* mengalami banyak pengembangan sebagai sebuah gabungan dari teknik matematika dan statistika dalam pemodelan sistem dinamis. Jika suatu sistem terdiri dari satu deret input dan sebuah deret output, maka salah satu cabang dalam metodologi *time series* yang sesuai untuk digunakan adalah model *Autoregressive Integrated Moving Average* (ARIMA). Lee, Suhartono dan Hamzah (2010) menjelaskan bahwa ARIMAX adalah model ARIMA dengan penambahan variabel prediktor. Jika

suatu sistem terdiri dari satu atau lebih deret input dan sebuah deret output, maka salah satu cabang dalam metodologi *time series* yang sesuai untuk digunakan adalah model *Autoregressive Integrated Moving Average* ARIMAX. Model ARIMAX yang digunakan adalah suatu *time series* dengan efek variasi kalender.

Bank Indonesia (BI) merupakan bank sentral Republik Indonesia. Dalam kapasitasnya sebagai bank sentral, BI memiliki tujuan tunggal, yaitu mencapai dan memelihara kestabilan nilai rupiah. Untuk dapat memenuhi tujuan tersebut, maka salah satu segmen yang senantiasa dipantau oleh BI adalah *outflow-inflow* uang kartal. Hal ini dilakukan agar BI dapat mengambil kebijakan terhadap proses pencetakan uang, serta mengatur uang keluar masuk pada BI. Pemantauan *outflow-inflow* uang kartal salah satunya dengan melakukan peramalan *outflow-inflow* uang kartal. BI melalui *Open Market Committee* (OMC) memiliki agenda bulanan untuk melakukan proyeksi *netflow* uang kartal yang diedarkan, sebagai salah satu upaya pengendalian likuiditas perbankan. Permasalahan yang seringkali dihadapi adalah nilai proyeksi yang terlalu jauh dari nilai realisasinya. Untuk memenuhi kebutuhan praktis dalam menghitung peramalan *outflow-inflow*, model linier masih cukup dominan dilakukan. Tetapi ada dugaan bahwa pengaruh hari raya Idul Fitri terhadap *outflow-inflow* di BI Provinsi Papua bersifat nonlinier. Dalam upaya memperoleh hasil peramalan yang sesuai untuk data *outflow-inflow* di BI Provinsi Papua maka diperlukan metode yang dapat digunakan dalam pemodelan linier maupun pemodelan nonlinier.

Penelitian mengenai peramalan *outflow-inflow* pernah dilakukan oleh peneliti-peneliti sebelumnya. Wulansari dan Suhartono (2014) tentang peramalan *netflow* uang kartal dengan metode ARIMAX dan *Radial Basic Function Network*. Peramalan terbaik yang diperolah dari penelitian tersebut adalah ARIMAX dengan efek variasi kalender dan variabel prediktor Indeks Harga Konsumen (IHK). Reganata dan Suhartono (2015) melakukan peramalan *outflow-inflow* uang kartal dengan fungsi transfer multi input dan *hybrid ARIMA-Artificial Neural Network*(ANN). Hasil penelitian menunjukkan bahwa model fungsi transfer multi input yang terbaik untuk deret *inflow* maupun *outflow*, Urusiyah, Suharsono dan Suhartono (2015) melakukan peramalan *outflow-inflow* uang kartal dengan gabungan model fungsi transfer dan variasi kalender -

Autoregressive Conditional Heteroscedasticity (ARCH). Peramalan terbaik yang diperoleh pada penelitian ini adalah model variasi kalender berbasis regresi *time series*.

ARIMAX merupakan model ARIMA dengan penambahan variabel tertentu. Sebagai salah satu metode dalam analisis data *time series*, ARIMA dan ARIMAX menjadi metode yang banyak digunakan dalam kasus peramalan. Metode ini mensyaratkan beberapa kondisi yang harus dipenuhi, antara lain data harus stasioner, baik stasioner dalam *mean* dan stasioner dalam varians. Selain itu, residual dari model tersebut harus bersifat *white noise* yaitu residual mempunyai mean nol dan mempunyai varians yang konstan (Box, Jenkins dan Reinsel, 1994). Penelitian dengan ARIMAX salah satunya pernah dilakukan oleh Lee, Suhartono, dan Hamzah (2010) yang meneliti pengaruh efek hari raya Idul Fitri terhadap penjualan baju muslim. Model ARIMAX dua level merupakan pengembangan dari model ARIMAX dengan efek variasi kalender. Model ARIMAX dua level didasarkan pada dua metode yaitu metode ARIMAX pada level pertama dan Regresi pada level kedua. Secara umum peramalan ARIMA untuk data *time series* yang dipengaruhi oleh efek variasi kalender biasanya memberikan prediksi yang kurang baik. Model ARIMAX dua level dapat memberikan prediksi yang lebih baik untuk data *time series* yang dipengaruhi oleh efek variasi kalender baik pada *in-sample* maupun *out-sample*, karena pada level kedua akan dilakukan estimasi parameter *dummy* pada data *out-sample*. Model ARIMAX dua level diharapkan memberikan hasil prediksi yang lebih baik dari model ARIMAX yang tidak mengestimasi nilai parameter pada data *out-sample*. Penelitian dengan ARIMAX dua level sebelumnya pernah dilakukan oleh Suhartono, Lee dan Prastyo (2015) untuk meneliti pengaruh efek hari raya Idul Fitri terhadap penjualan celana pria dan perempuan. Pada penelitian tersebut, model ARIMAX dua level memberikan hasil prediksi yang lebih baik dibandingkan dengan model ARIMA dan *Neural Network* (NN).

Dalam praktek, pemodelan ARIMAX pada suatu data ekonomi seringkali memberikan residual dengan varian yang tidak konstan (heterogen). Engle (1982) memperkenalkan model *Autoregressive Conditional Heteroscedasticity* (ARCH) untuk memodelkan inflasi di Inggris yang mengandung *varians* tidak konstan.

Pada model ARCH varian *error* sangat dipengaruhi oleh *error* pada periode sebelumnya (Wei, 2006:368). Model ini mampu mengatasi heteroskedastisitas dalam data *time series*. Pada data yang mempunyai volatilitas yang tinggi, model ARCH memerlukan orde yang besar dalam memodelkan ragamnya. Hal tersebut mempersulit dalam proses identifikasi dan pendugaan model. Kemudian model ARCH disempurnakan menjadi *Generalized ARCH* (GARCH) oleh Bollerslev (1986). Metode ini mampu mengatasi heterokedastisitas dalam data *time series*. Beberapa penelitian yang menggunakan model ARCH-GARCH antara lain Widasari dan Wahyuningsih (2012) yang mengaplikasikan model ARCH-GARCH dalam peramalan tingkat inflasi di Indonesia. Rukini dan Suhartono (2013) menunjukkan bahwa model intervensi adalah model terbaik serta hasil deteksi GARCH dengan uji *Lagrange Multiplier* tidak ditemukan adanya unsur heteroskedastisitas pada model ARIMAX (baik model fungsi transfer maupun model intervensi) pada inflasi di kota Denpasar.

Data *time series* dari fenomena real seperti data finansial biasanya bersifat nonlinier. Karena data *time series* seperti ini tidak mengikuti fenomena teoritis yang telah dibakukan, maka dilakukan analisis secara terus menerus menggunakan berbagai teknik “bebas model” yang bersifat nonlinier seperti *system fuzzy* dan NN. Teknik-teknik kecerdasan buatan seperti algoritma genetik, jaringan yaraf, dan model *hybrid statistical-neural* telah dilakukan untuk analisis runtun waktu stasioner dan non-stasioner. Namun teknik ini tidak dibangun dalam fasilitas inferensi atau interpretasi. Menurut Jang (1993), keterbatasan ini diatasi oleh sistem berbasis logika fuzzy, yang merupakan “*universal approximators*” dari fungsi nonlinier. Sistem fuzzy didefinisikan sebagai teknik-teknik yang erkaitan dengan ketidakpastian yang didasarkan pada himpunan fuzzy. Sistem tersebut mempunyai kelebihan bahwa model yang dikembangkan dicirikan oleh kemampuan interpretasi linguistik, dan aturan-aturan yang dapat dipahami, diverifikasi dan dikembangkan (Jang, Sun dan Mizutani, 1997). *System fuzzy* mempunyai kemampuan untuk menghampiri fungsi nonlinier yang mengandung ketakpastian yang tinggi melalui derajat keanggotaan fuzzy.

Model NN merupakan salah satu contoh model nonlinier yang mempunyai bentuk fungsional fleksibel dan mengandung beberapa parameter yang tidak dapat

diinterpretasikan seperti pada model parametrik (Fausset, 1994). Neural Networks sebagai suatu metode *machine learning* tersupervisi, memberikan suatu kerangka kerja yang bagus untuk merepresentasikan suatu hubungan pada data, termasuk data runtun waktu. Dibandingkan dengan algoritma yang lain, NN memiliki kemampuan adaptif yang lebih baik, pembelajaran, dan kemampuan mempolakan signal non-stasioner (Gooijer dan Hyndman, 2006). Namun demikian NN dapat memproses signal dengan baik untuk signal input dengan resolusi yang halus. Sehingga NN memerlukan pemrosesan awal data (*preprocessing*) untuk mereduksi beban komputasi dan meningkatkan hasil output secara optimal.

Pada model *Adaptive Neuro Fuzzy Inference System* (ANFIS) jumlah *hidden node* pada NN disesuaikan dengan sistem fuzzy yang terdiri dari tiga bagian yaitu: fuzzyifikasi (*layer 1*), sistem inferensi fuzzy (*layer 2* dan *3*) dan defuzzyifikasi (*layer 4*). Arsitektur NN yang digunakan sudah ditentukan yaitu sebanyak 5 lapisan tetap (Jang, Sun dan Mizutani, 1997). Metode ANFIS memiliki beberapa kelebihan yaitu metode ANFIS dapat digunakan meskipun jumlah data yang digunakan untuk membentuk model sedikit (Jaya *et al.*, 2013). Data input yang merupakan prediktor tidak hanya terbatas pada data numerik saja melainkan juga dapat menggunakan data input kategorik (Liu, Dong dan Wu, 2010). Sedangkan untuk kasus musiman, metode ANFIS juga terbukti dapat memberikan hasil yang baik (Yang dan Entchev, 2014). Peramalan dengan menggunakan asumsi volatilitas yang konstan terhadap variasi biasanya dilakukan dengan menggunakan standar deviasi biasa, sedangkan untuk melakukan peramalan terhadap volatilitas yang tidak konstan terhadap waktu telah dikembangkan banyak model seperti model ARCH dan kemudian dikembangkan lagi menjadi GARCH. Residual pada peramalan data *time series* keuangan dengan menggunakan metode linier maupun metode nonlinier seringkali memberikan varians yang tidak konstan. Sehingga perlu dilakukan peramalan varians dengan menggunakan ARCH/GARCH. Tarno (2015) pernah melakukan penelitian dengan menggunakan metode ANFIS untuk menganalisis data *time series* inflasi Indonesia dalam kaitannya dengan estimasi mean proses yang memuat efek GARCH.

Dalam dunia nyata seringkali data mengandung pola linier dan nonlinier. Jika hal ini terjadi, maka ARIMA atau ANFIS tidak memadai dalam pemodelan

dan peramalan. Model ARIMA tidak dapat menangani hubungan nonlinier sementara model ANFIS saja tidak mampu menangani pola linier dan pola nonlinier sama baiknya. Oleh karena itu, diperlukan model multilevel kombinasi beberapa metode yang dapat digunakan dalam pemodelan linier maupun pemodelan nonlinier agar data dapat dimodelkan lebih akurat. Pemodelan multilevel kombinasi beberapa metode dapat dilakukan untuk mendapatkan ramalan data *time series* dan variansnya (Wei, 2006). Model gabungan dua metode pernah dilakukan oleh Zhang (2003) untuk membandingkan model ARIMA, ANN dengan *Hybrid* ARIMA dan ANN, hasilnya adalah model *Hybrid* ARIMA dan ANN lebih baik dibandingkan dengan model ARIMA maupun Model ANN. Penelitian yang serupa juga pernah dilakukan oleh Wang, Zou, Su, Li dan Chaudhry (2013) tetapi dengan data yang berbeda, hasilnya adalah *Hybrid* ARIMA dan ANN lebih baik dibandingkan dengan ARIMA, ANN maupun model aditif. Puspitasari, Akbar, Lee dan Suhartono menggunakan model *hybrid* ARIMA-ANFIS untuk meramalkan beban listrik jangka pendek di Indonesia. Model *hybrid* ARIMA-ANFIS juga pernah digunakan oleh Faulina dan Suhartono (2013) untuk meramalkan curah hujan di Indonesia.

Berdasarkan latar belakang tersebut, maka dalam penelitian ini akan dilakukan kajian tentang model multilevel gabungan ARIMAX dua level dan ANFIS dengan deteksi GARCH untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua.

1.2 Rumusan Masalah

Permasalahan yang akan dibahas dalam penelitian ini adalah:

1. Bagaimana model ARIMAX dua level dengan deteksi GARCH yang sesuai untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua?
2. Bagaimana model ANFIS dengan deteksi GARCH yang sesuai untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua?

3. Bagaimana model gabungan ARIMAX dua level dan ANFIS dengan deteksi GARCH yang sesuai untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua?
4. Bagaimana perbandingan akurasi ketiga model tersebut untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua?

1.3 Tujuan penelitian

Berdasarkan rumusan masalah tersebut maka tujuan penelitian ini adalah:

1. Mendapatkan model ARIMAX dua level dengan deteksi GARCH yang sesuai untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua.
2. Mendapatkan model ANFIS dengan deteksi GARCH yang sesuai untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua.
3. Mendapatkan model gabungan ARIMAX dua level dan ANFIS dengan deteksi GARCH yang sesuai untuk peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua.
4. Mendapatkan model terbaik peramalan *outflow-inflow* uang kartal di Bank Indonesia Provinsi Papua.

1.4 Manfaat Penelitian

Manfaat yang ingin diperoleh dari hasil penelitian ini adalah sebagai berikut:

1. Bagi Bank Indonesia, khususnya Bank Indonesia wilayah Papua, dapat dijadikan sebagai bahan acuan dalam membuat kebijakan yang berkaitan dengan arus masuk dan keluar uang kartal di Provinsi Papua.
2. Bagi ilmu pengetahuan, penelitian ini memberikan informasi dan wawasan keilmuan mengenai aplikasi model ARIMAX dua level, ANFIS dan gabungan ARIMAX dua level dan ANFIS serta GARCH dalam bidang peramalan.

1.5 Batasan Masalah

Dalam melakukan suatu peramalan ada banyak metode yang dapat digunakan, tetapi pada penelitian ini metode yang akan digunakan untuk menganalisis permasalahan tersebut adalah ARIMAX dua level, ANFIS dan

gabungan ARIMAX dan ANFIS serta deteksi GARCH. Data yang digunakan adalah data *inflow* dan *outflow* pada periode 2003 sampai 2014 di Bank Indonesia Provinsi Papua.

BAB 2

TINJAUAN PUSTAKA

Pustaka yang digunakan untuk menganalisis permasalahan dalam penelitian ini adalah Analisis *Time Series*, ARIMA, ARIMAX, ANFIS, *Hybrid ARIMAX-ANFIS*, dan deteksi GARCH.

2.1 Analisis *Time Series*

Data *time series* merupakan serangkaian data yang berupa nilai pengamatan yang diukur selama kurun waktu tertentu berdasarkan interval waktu yang tetap (Wei, 2006:1). Observasi yang diamati merupakan barisan data yang bernilai kontinyu atau diskrit yang diperoleh pada interval waktu yang sama, misalnya harian, mingguan, bulanan, tahunan atau yang lainnya. Time series merupakan realisasi atau contoh fungsi dari suatu proses stokastik yang dibentuk oleh variabel random $Z(\omega, t)$ dengan ω adalah ruang sampel dan t adalah indeks waktu (Wei, 2006:6). Dalam analisis *time series* dengan model ARIMA terdapat beberapa tahapan yang harus dilakukan, diantaranya kestasioneran data, *Autocorrelation Function* (ACF), dan *Partial Autocorrelation Function* (PACF).

Time series adalah urutan secara kronologis dari suatu pengamatan pada suatu variabel yang diteliti. Model time series menerapkan sifat-sifat statistika pada data historis untuk menentukan model formal kemudian menaksir parameter yang tidak diketahui dari model ini (biasanya) dengan metode kuadrat terkecil (Montgomery, Jennings dan Kulahci, 2008:4).

2.2 Model ARIMA

Dalam analisa data *time series* dikenal beberapa model peramalan, untuk data yang bersifat linear antara lain dapat digunakan model *Autoregressive* (AR), *Moving Average* (MA), gabungan antara model AR dan MA dengan *differencing* orde d disebut *Autoregressive Integrated Moving Average* atau (ARIMA). Secara umum model ARIMA(p, d, q) dapat ditulis dalam bentuk (Wei, 2006:72):

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t . \quad (2.1)$$

Model ARIMA yang mempunyai efek musiman dalam pengamatan waktu ke- t dinotasikan dengan ARIMA $(P,D,Q)^s$. Secara umum model ARIMA musiman dapat dituliskan dalam bentuk (Wei, 2006:166):

$$\Phi_P(B^s)(1-B^s)^D Z_t = \Theta_Q(B^s)a_t . \quad (2.2)$$

Apabila terdapat efek non-musiman dan musiman, maka model yang terbentuk adalah multiplikatif ARIMA $(p,d,q)(P,D,Q)^s$. Secara matematis dituliskan dalam bentuk.

$$\Phi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\Theta_Q(B^s)a_t , \quad (2.3)$$

dengan

p	= orde AR non musiman
q	= orde MA non musiman
P	= orde AR musiman
Q	= orde MA musiman
s	= periode musiman
ϕ_p	= parameter AR non musiman
θ_q	= parameter MA non musiman
Φ_P	= parameter AR musiman
Θ_Q	= parameter MA musiman
$\phi_p(B)$	$= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$
$\theta_q(B)$	$= 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$
$\Phi_P(B^s)$	$= 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps}$
$\Theta_Q(B^s)$	$= 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{qs}$
$(1-B)^d$	= differencing non musiman dengan orde d
$(1-B^s)^D$	= differencing musiman dengan orde D periode s .

2.2.1 Stasioneritas

Suatu data dapat dimodelkan ARIMA jika stasioneritas terpenuhi. Suatu data dikatakan sudah stasioner jika data tersebut stasioner dalam *mean* dan stasioner dalam *varians*.

a. Stasioner dalam *mean*

Data dikatakan stasioner dalam *mean* jika plot data berfluktuasi di sekitar garis sejajar dengan sumbu waktu (t) atau di sekitar nilai *mean* yang konstan.

$$E(Z_t) = E(Z_{t+k}) = \mu. \quad (2.4)$$

Apabila data time series tidak stasioner dalam *mean* perlu dilakukan proses *differencing*. Secara umum proses *differencing* pada orde ke- k dapat dituliskan sebagai berikut

$$\Delta^k(Z_t) = (1 - B)^k Z_t. \quad (2.5)$$

b. Stasioner dalam *varians*

Data dikatakan stasioner dalam *varians* jika memenuhi persamaan berikut

$$Var(Z_t) = Var(Z_{t+k}) = \sigma^2. \quad (2.6)$$

Jika data tidak stasioner dalam *varians* maka dapat ditransformasi dengan menggunakan transformasi Box-Cox dalam Wei (2006:85).

$$T(Z_t) = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda} & , \lambda \neq 0 \\ \ln(Z_t) & , \lambda = 0 \end{cases} \quad (2.7)$$

Untuk nilai λ (*lambda*) tertentu maka bentuk transformasi Box Cox yang sering digunakan disajikan pada tabel 2.1 (Wei, 2006:85).

Tabel 2.1 Transformasi Box-Cox

λ	Transformasi
-1	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1,0	Z_t (tidak ditransformasi)

2.2.2 Autocorrelation Function (ACF)

Fungsi autokorelasi merupakan suatu hubungan linear pada data *time series* antara Z_t dengan Z_{t+k} yang dipisahkan oleh waktu lag k . ACF dapat digunakan untuk mengidentifikasi model *time series* dan melihat kestasioneran data dalam *mean*. Fungsi autokorelasi yang dihitung berdasarkan sampel data dituliskan sebagai berikut (Wei, 2006:20).

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

2.2.3 Partial Autocorrelation Function (PACF)

Fungsi autokorelasi parsial digunakan sebagai alat untuk mengukur tingkat keeratan antara Z_t dan Z_{t+k} setelah dependensi antar variabel $Z_{t+k}, Z_{t+k+1}, \dots$ dan Z_{t+k-1} dihilangkan. Sampel PACF dinotasikan dengan $\hat{\phi}_{kk}$ dengan perhitungan seperti yang diberikan oleh Durbin dalam Wei (2006:22).

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} , k = 0, 1, 2, \dots \quad (2.9)$$

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

2.2.4 Idenifikasi Model ARIMA

Penentuan orde dari model $AR(p)$, $MA(q)$, $ARMA(p,q)$, dan $ARIMA(p,d,q)$ dapat dilihat dari plot ACF dan PACF. Karakteristik dari model AR, MA, ARMA, dan ARIMA berdasarkan plot ACF dan PACF yang telah stasioner ditampilkan pada Tabel 2.2 (Bowerman dan O'Connell, 1993:475).

Tabel 2.2 Pola ACF dan PACF dari Model ARMA

Proses	ACF	PACF
$AR(p)$	<i>dies down</i>	<i>cut off after lag p</i>
$MA(q)$	<i>cut off after lag q</i>	<i>dies down</i>
$AR(p)$ atau $MA(q)$	<i>cut off after lag q</i>	<i>cut off after lag p</i>
$ARMA(p, q)$	<i>dies down</i>	<i>dies down</i>

2.2.5 Estimasi Parameter

Salah satu metode penaksiran parameter yang dapat digunakan adalah *conditional least square* (CLS). Metode ini bekerja dengan membuat *error* yang tidak diketahui sama dengan nol dan meminimumkan jumlah kuadrat *error* (SSE). Misalkan diterapkan pada model AR(1) dan dinyatakan sebagai berikut (Cryer dan Chan, 2008:154).

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + a_t \quad (2.10)$$

dan nilai SSE adalah sebagai berikut.

$$S(\phi, \mu) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2. \quad (2.11)$$

kemudian diturunkan terhadap μ dan ϕ dan disamakan dengan nol sehingga diperoleh nilai taksiran parameter untuk μ sebagai berikut:

$$\hat{\mu} = \frac{\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1}}{(n-1)(1-\phi)} = \bar{Z} \quad (2.12)$$

dan nilai taksiran parameter ϕ didapatkan sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2}. \quad (2.13)$$

Misalkan β adalah suatu parameter pada model ARIMA (mencakup ϕ, θ) dan $\hat{\beta}$ adalah taksiran dari β maka pengujian signifikansi parameter dapat dinyatakan sebagai berikut.

Hipotesis :

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

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

Statistik uji :

$$t = \frac{\hat{\beta}}{\hat{SE}(\hat{\beta})} \quad (2.14)$$

daerah penolakan : tolak H_0 jika $|t| > t_{\frac{\alpha}{2}; n-n_p}$

dengan:

$\hat{SE}(\hat{\beta})$ = standar *error* dari nilai taksiran β

n_p = banyaknya parameter yang ditaksir

2.2.6 Cek Diagnostik

Setelah parameter dari model signifikan maka perlu dilakukan pengujian terhadap residual untuk mengetahui ketepatan model tersebut. Pemeriksaan residual terbagi menjadi dua bagian, yaitu pemeriksaan residual *white noise* dan residual berdistribusi normal.

a. *White Noise*

Residual model dikatakan *white noise* jika residual telah memenuhi asumsi identik (variasi residual homogen) dan independen atau antar residual tidak berkorelasi (Wei, 2006:153). Pengujian asumsi independen dilakukan dengan menggunakan uji *Ljung-Box*.

Hipotesis:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$$

$$H_1 : \text{minimal terdapat satu } \rho_i \text{ yang tidak sama dengan nol}, i = 1, 2, \dots, k$$

Statistik uji:

$$Q = n(n+2) \sum_{i=1}^k (n-i)^{-1} \hat{\rho}_i^2 \quad (2.15)$$

daerah penolakan : tolak H_0 jika $Q > \chi^2_{(\alpha;k-m)}$

dengan,

$\hat{\rho}_k$ = ACF dari residual pada lag $ke - k$

n = banyaknya residual

k = lag $ke - k$

m = $p + q$ (orde ARMA)

Varians residual dikatakan homogen jika tidak terdapat korelasi antar kuadrat residual. Pengujian asumsi varians residual homogen dilakukan dengan menggunakan uji portmanteau Q (Wei, 2006:373).

Hipotesis:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$$

$$H_1 : \text{minimal terdapat satu } \rho_k \text{ yang tidak sama dengan nol}, k = 1, 2, \dots, K$$

Statistik uji:

$$Q(k) = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 (\hat{a}_t^2) \quad (2.16)$$

daerah penolakan : tolak H_0 jika $Q > \chi^2_{(\alpha;K)}$

dengan

n = banyaknya residual

$\hat{\rho}_k(\hat{a}_t^2)$ = ACF dari residual kuadrat pada lag $ke - k$

b. Kenormalan

Asumsi lain yang harus dipenuhi yaitu residual berdistribusi normal. Pengujian kenormalan dapat dihitung dengan menggunakan Kolmogorov-Smirnov.

Hipotesis :

$$H_0: F(a_t) = F_0(a_t) \text{ (residual berdistribusi normal)}$$

$$H_1: F(a_t) \neq F_0(a_t) \text{ (residual tidak berdistribusi normal)}$$

Statistik uji :

$$D = \sup_{a_t} |F(a_t) - F_0(a_t)| \quad (2.17)$$

daerah penolakan: tolak H_0 jika $D > D_{(1-\alpha;n)}$

dengan:

$F(a_t)$ = fungsi peluang kumulatif yang dihitung dari data sampel

$F_0(a_t)$ = fungsi peluang kumulatif distribusi normal atau fungsi yang dihipotesiskan

\sup = nilai supremum (maksimum) semua a_t dari $|F(a_t) - F_0(a_t)|$

2.3 Model ARIMAX

Model ARIMAX adalah model ARIMA dengan penambahan variabel prediktor (lee, Suhartono dan Hamzah, 2010). Secara umum model ARIMAX adalah suatu *time series* dengan efek variasi kalender. Variabel prediktor yang digunakan untuk memodelkan ARIMAX yaitu variabel *dummy* bulan Januari hingga Desember, variabel *dummy* jumlah sebelum hari Raya Idul Fitri. Penelitian dengan menggunakan model ARIMAX banyak digunakan pada berbagai kasus, beberapa tahun terakhir ARIMAX dikembangkan menjadi ARIMAX dua level.

Pemodelan ARIMAX dua level (Suhartono, Lee dan Prastyo, 2015).

Model ARIMAX dengan tren stokastik adalah sebagai berikut

$$Z_t = \sum_{j=0}^{30} \alpha_j D_{j,t} + \sum_{j=0}^{30} \gamma_j D_{j,t-1} + \sum_{j=0}^{30} \xi_j D_{j,t+1} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)} a_t \quad (2.21)$$

Model ARIMAX dengan tren deterministik adalah sebagai berikut

$$\begin{aligned} Z_t = & \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=0}^{30} \alpha_j D_{j,t} + \sum_{j=0}^{30} \gamma_j D_{j,t-1} + \sum_{j=0}^{30} \xi_j D_{j,t+1} + \\ & \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)} a_t \end{aligned} \quad (2.22)$$

dengan

- δ = koefisien tren
- t = *dummy* waktu untuk bulan
- β_i = koefisien bulan $ke - i$, dimana $i = 1, 2, \dots, 12$
- $M_{i,t}$ = variabel *dummy* bulan $ke - i$, dimana $i = 1, 2, \dots, 12$
- α_j = koefisien variabel *dummy* jumlah hari sebelum Idul Fitri
- γ_j = koefisien variabel *dummy* bulan sebelum Idul Fitri
- ξ_j = koefisien variabel *dummy* bulan sesudah Idul Fitri
- $D_{j,t}$ = variabel *dummy* jumlah hari sebelum Idul Fitri
- $D_{j,t-1}$ = variabel *dummy* bulan sebelum Idul Fitri
- $D_{j,t+1}$ = variabel *dummy* bulan sesudah Idul Fitri

dengan $j = 0, 1, 2, \dots, 30$.

Berikut adalah langkah-langkah pemodelan ARIMAX dua level (Suhartono, Lee dan Prastyo, 2015).

1. Langkah pertama yaitu menentukan variabel *dummy* berdasarkan periode kalender variasi.
2. Menghilangkan pengaruh variasi kalender dengan menggunakan model

$$Z_t = \beta_0 + \sum_{j=0}^{30} \alpha_j D_{j,t} + \sum_{j=0}^{30} \gamma_j D_{j,t-1} + \sum_{j=0}^{30} \xi_j D_{j,t+1} + N_t \quad (2.23)$$

untuk tren dan musiman stokastik, atau model

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=0}^{30} \alpha_j D_{j,t} + \sum_{j=0}^{30} \gamma_j D_{j,t-1} + \sum_{j=0}^{30} \xi_j D_{j,t+1} + N_t \quad (2.24)$$

untuk tren dan musiman deterministik, sehingga diperoleh residual

3. Mendapatkan model ARIMA yang terbaik untuk N_t dengan menggunakan prosedur Box-Jenkins.
4. Order ARIMA yang diperoleh pada langkah 3 digunakan untuk memodelkan data real dengan menambahkan variabel *dummy* sebagai *input* secara simultan seperti pada persamaan (2.21) untuk tren dan musiman stokastik dan persamaan (2.22) untuk tren dan musiman deterministik.
5. Melakukan uji signifikansi parameters dan uji diagnostik sampai diperoleh proses yang stasioner dan residual yang *white noise*.
6. Mengestimasi model level 2 untuk memprediksi pengaruh variasi kalender untuk setiap kemungkinan banyaknya hari sebelum Idul Fitri. Model level 2 ini mengandung pengaruh terhadap data, yaitu data pada bulan Idul Fitri, satu bulan sebelum Idul Fitri dan satu bulan setelah Idul Fitri. Pada langkah ini digunakan fungsi sebagai berikut.

6.1. Model untuk bulan Idul Fitri

$$\hat{\alpha}_j = \nu_0 + \nu_1 j \quad (2.25)$$

6.2. Model untuk satu bulan sebelum Idul Fitri

$$\hat{\gamma}_j = \omega_0 + \omega_1 j \quad (2.26)$$

6.3. Model untuk satu bulan setelah Idul Fitri

$$\hat{\xi}_j = \varsigma_0 + \varsigma_1 j \quad (2.27)$$

dengan j adalah banyaknya hari sebelum Idul Fitri. Variabel respon pada model ini adalah estimasi koefisien regresi pada persamaan (2.21) atau (2.22), yaitu $\hat{\alpha}_j, \hat{\gamma}_j, \hat{\xi}_j$

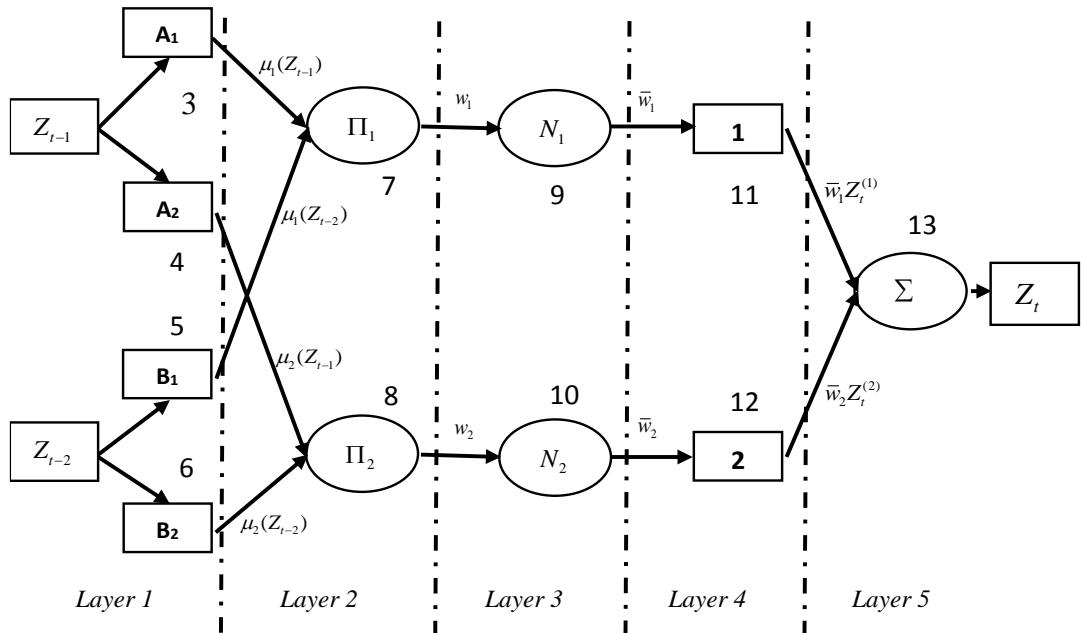
2.4 Adative Neuro-Fuzzy Inference System (ANFIS)

ANFIS adalah suatu metode yang mana dalam penyetelan aturan digunakan algoritma pembelajaran terhadap sekumpulan data. Arsitektur ANFIS secara fungsional sama dengan *fuzzy rule base* model Sugeno (Kusumadewi dan Hartati, 2006:359). Jaringan terdiri dari lima *layer*. Misalkan terdapat dua input Z_{t-1} dan Z_{t-2} dan satu output Z_t serta terdapat dua aturan model Sugeno:

$$\text{If } Z_{t-1} \text{ is } A_1 \text{ and } Z_{t-2} \text{ is } B_1 \text{ then } Z_t^{(1)} = c_{1,1}Z_{t-1} + c_{1,2}Z_{t-2} + c_{1,0} \quad (2.28)$$

$$\text{If } Z_{t-1} \text{ is } A_2 \text{ and } Z_{t-2} \text{ is } B_2 \text{ then } Z_t^{(2)} = c_{2,1}Z_{t-1} + c_{2,2}Z_{t-2} + c_{2,0} \quad (2.29)$$

Secara lengkap, teori dan tahapan pemrosesan input ke output pada setiap layer di ANFIS dapat dilihat pada Jang, Sun, dan Mizutani (1997). Gambar 2.2 adalah ilustrasi proses inferensi fuzzy untuk peramalan time series dimana input pada proses ini adalah lag 1 dan 2 suatu kejadian dan outputnya adalah kejadian pada suatu waktu.



Gambar 2.2 Framework dari ANFIS untuk peramalan *time series*

Penjelasan dari masing-masing *layer* pada Gambar 2.2 adalah sebagai berikut:

Layer 1: tiap-tiap neuron i pada *layer 1* adaptif terhadap parameter suatu fungsi aktivasi. Output dari tiap neuron berupa derajat keanggotaan yang diberikan oleh fungsi keanggotaan input. Misalkan fungsi keanggotaan diberikan sebagai:

$$\mu(Z_{t-1}) = \frac{1}{1 + \left| \frac{Z_{t-1} - c}{a} \right|^{2b}} \quad (2.30)$$

Dengan μ adalah derajat keanggotaan, Z_{t-1} dan Z_{t-2} adalah variabel input serta $\{a, b, c\}$ adalah parameter. Parameter-parameter tersebut dikenal dengan nama *premise parameter*.

Layer 2: tiap-tiap neuron i pada *layer 2* berupa neuron tetap outputnya adalah hasil dari masukan. Biasanya digunakan operator AND.

Layer 3: tiap-tiap neuron i pada *layer 3* berupa node tetap yang merupakan hasil perhitungan rasio dari α predikat dari aturan ke- i (w_i) terhadap jumlah dari keseluruhan α predikat. Hasil ini dikenal dengan nama *normalized fitting strength*

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}; i = 1, 2 \quad (2.31)$$

Layer 4: tiap-tiap neuron i pada *layer 4* merupakan *node* adaptif terhadap suatu output dengan \bar{w}_i adalah *normalized fitting strength* pada layer ketiga dan $\{c_{i,1}, c_{i,2}, c_{i,0}\}$ adalah parameter-parameter tersebut dinamakan *consequent parameter*.

$$\bar{w}_i Z_t^{(i)} = \bar{w}_i (c_{i,1} Z_{t-1} + c_{i,2} Z_{t-2} + c_{i,0}); i = 1, 2 \quad (2.32)$$

Layer 5: Neuron pada *layer 5* adalah *node* tetap yang merupakan jumlahan dari semua masukan

$$\hat{Z}_t = \bar{w}_{1,t} Z_t^{(1)} + \bar{w}_{2,t} Z_t^{(2)} \quad (2.33)$$

Pada saat *premise parameters* ditemukan, output yang terjadi akan merupakan kombinasi linear dari *consequent parameter*. Algoritma *hybrid* akan mengatur parameter-parameter $c_{i,j}$ ($i = 1, 2$ dan $j = 0, 1, 2$) secara maju (*forward*) dan akan mengatur parameter-parameter $\{a_i, b_i, c_i\}$ secara mundur (*backward*).

Pada langkah maju, input jaringan akan berjalan maju sampai pada layer keempat, dimana parameter $c_{i,j}$ akan diidentifikasi menggunakan metode *least-square*. Pada langkah mundur, error sinyal akan merambat mundur dan parameter-parameter $\{a_i, b_i, c_i\}$ akan diperbaiki dengan menggunakan metode *gradient-descent*.

Jaringan adaptif seperti pada Gambar 2.2 terdiri dari 5 layer, dan memiliki sebanyak $N(L)$ neuron pada layer $ke-L$. Maka jumlah kuadrat error (SSE) pada layer $ke-L$ data $ke-p$, $1 \leq p \leq N$ adalah

$$E_p = \sum_{k=1}^{N(L)} (d_k - Z_{L,k})^2 \quad (2.34)$$

Propagasi *error* menuju layer *ke-5* yang hanya memiliki 1 neuron pada layer output (neuron 13) dapat dirumuskan sebagai berikut.

$$\varepsilon_{13} = \frac{\partial E_p}{\partial Z_{13}} = -2(d_{13} - Z_{13}) \quad (2.35)$$

Propagasi *error* menuju layer *ke-4* yaitu neuron 12 dan neuron 11 dapat dirumuskan sebagai berikut.

$$\varepsilon_{12} = \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{12}} = \varepsilon_{13} \frac{\partial f_{13}}{\partial Z_{12}} = \varepsilon_{13}(1) = \varepsilon_{13}, \quad (2.36)$$

$$\varepsilon_{11} = \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{11}} = \varepsilon_{13} \frac{\partial f_{13}}{\partial Z_{11}} = \varepsilon_{13}(1) = \varepsilon_{13}. \quad (2.37)$$

Propagasi *error* menuju layer *ke-3* yaitu neuron 10 dan neuron 9 dapat dirumuskan sebagai berikut.

$$\varepsilon_{10} = \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{12}} \frac{\partial f_{12}}{\partial Z_{10}} = \varepsilon_{12} \frac{\partial f_{12}}{\partial Z_{10}} = \varepsilon_{12} f_2, \quad (2.38)$$

$$\varepsilon_9 = \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{11}} \frac{\partial f_{11}}{\partial Z_9} = \varepsilon_{11} \frac{\partial f_{11}}{\partial Z_9} = \varepsilon_{11} f_1. \quad (2.39)$$

Propagasi *error* menuju layer *ke-2* yaitu neuron 8 dan neuron 7 dapat dirumuskan sebagai berikut.

$$\begin{aligned} \varepsilon_8 &= \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{11}} \frac{\partial f_{11}}{\partial Z_9} \frac{\partial f_9}{\partial Z_8} + \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{12}} \frac{\partial f_{12}}{\partial Z_{10}} \frac{\partial f_{10}}{\partial Z_8} \\ &= \varepsilon_9 \frac{\partial f_9}{\partial Z_8} + \varepsilon_{10} \frac{\partial f_{10}}{\partial Z_8} = \varepsilon_9 \left(-\frac{w_1}{(w_1 + w_2)^2} \right) + \varepsilon_{10} \left(\frac{w_1}{(w_1 + w_2)^2} \right) \\ &= \frac{w_1}{(w_1 + w_2)^2} (\varepsilon_{10} - \varepsilon_9) \end{aligned} \quad (2.40)$$

$$\begin{aligned}
\varepsilon_7 &= \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{11}} \frac{\partial f_{11}}{\partial Z_9} \frac{\partial f_9}{\partial Z_7} + \frac{\partial E_p}{\partial Z_{13}} \frac{\partial f_{13}}{\partial Z_{12}} \frac{\partial f_{12}}{\partial Z_{10}} \frac{\partial f_{10}}{\partial Z_7} \\
&= \varepsilon_9 \frac{\partial f_9}{\partial Z_7} + \varepsilon_{10} \frac{\partial f_{10}}{\partial Z_7} = \varepsilon_9 \left(\frac{w_2}{(w_1 + w_2)^2} \right) + \varepsilon_{10} \left(-\frac{w_2}{(w_1 + w_2)^2} \right) \\
&= \frac{w_2}{(w_1 + w_2)^2} (\varepsilon_9 - \varepsilon_{10})
\end{aligned} \tag{2.41}$$

Propagasi *error* menuju layer *ke*-1 dapat dirumuskan sebagai berikut.

$$\varepsilon_6 = \varepsilon_8 \frac{\partial f_8}{\partial Z_6} = \varepsilon_8 \mu_{A2}(Z_{t-1}) \tag{2.42}$$

$$\varepsilon_5 = \varepsilon_7 \frac{\partial f_7}{\partial Z_7} = \varepsilon_7 \mu_{A1}(Z_{t-1}) \tag{2.43}$$

$$\varepsilon_4 = \varepsilon_8 \frac{\partial f_8}{\partial Z_4} = \varepsilon_8 \mu_{B2}(Z_{t-2}) \tag{2.44}$$

$$\varepsilon_3 = \varepsilon_7 \frac{\partial f_7}{\partial Z_3} = \varepsilon_7 \mu_{B1}(Z_{t-2}) \tag{2.45}$$

Selanjutnya, *error* tersebut digunakan untuk mencari informasi *error* terhadap parameter-parameter ANFIS.

2.5 Model Peramalan Gabungan

Model hibrida adalah suatu metode kombinasi dari dua model dalam fungsi suatu system. Zhang (2003) adalah salah satu peneliti peramalan yang memperkenalkan model peramalan hibrida dalam prosedur dua level untuk mendapatkan nilai ramalan, yaitu model linier pada level pertama dan model nonlinier pada level kedua. Zhang menggunakan kombinasi antara ARIMA sebagai model linier dan *Artificial Neural Network* (ANN) sebagai model nonlinier yang selanjutnya dikenal dengan hibrida ARIMA-ANN. Penelitian yang serupa juga pernah dilakukan oleh Faulina dan Suhartono (2013) dengan menggunakan *hybrid* ARIMA-ANFIS untuk meramalkan curah hujan di Indonesia. Model *hybrid* ARIMA-ANFIS juga pernah digunakan oleh Puspitasari, Akbar, Lee dan Suhartono untuk meramalkan beban listrik jangka pendek di Indonesia. Model hibrida digunakan karena dalam dunia nyata jarang ditemukan kejadian *time*

series yang murni linier ataupun murni non linier (Zhang, 2003). Selain itu penggunaan kombinasi model linier dan nonlinier dilakukan dengan tujuan untuk menangkap secara simultan pola linier dan nonlinier yang ada pada data *time series*. Secara umum kombinasi dari model time series yang memiliki struktur autokorelasi linier dan non linier dapat dituliskan sebagai berikut:

$$Z_t = L_t + N_t \quad (2.46)$$

dengan

L_t = komponen linier

N_t = komponen non linier.

Model ARIMAX dua level digunakan untuk menyelesaikan kasus linier, dimana residual dari model linier masih mengandung informasi hubungan non linier. Secara matematis dapat dituliskan sebagai berikut:

$$e_t = Z_t - \hat{L}_t \quad (2.47)$$

dengan

\hat{L}_t = nilai peramalan pada waktu t

Z_t = data awal waktu ke- t .

Langkah selanjutnya adalah mengembangkan model untuk residual dari model ARIMAX tersebut menggunakan model ANFIS yang terbukti dapat menangkap pola nonlinier dari time series. Hasil ramalan dari metode ANFIS yang dinotasikan dengan \hat{N}_t kemudian dikombinasikan dengan hasil ramalan dari model ARIMAX. Secara matematis, hasil ramalan secara keseluruhan yang diperoleh adalah sebagai berikut.

$$\hat{Z}_t = \hat{L}_t + \hat{N}_t \quad (2.48)$$

\hat{Z}_t merupakan hasil peramalan yang merupakan gabungan nilai ramalan dari model ARIMAX dua level dan nilai ramalan model ANFIS. Selain itu, Wei (2006:372) menjelaskan bahwa model gabungan dapat juga dilakukan pada kombinasi model-model linier untuk mendapatkan ramalan data time series dan variansnya. Secara umum, Wei menyatakan bahwa kombinasi tiga level antara

model regresi, AR(p) untuk residual dan GARCH untuk varians residual dapat digunakan dalam bentuk seperti berikut

$$Y_t = \mathbf{X}_t' \boldsymbol{\beta} + a_t \quad (2.49)$$

dengan

$$a_t = \phi_1 a_{t-1} + \phi_2 a_{t-2} + \cdots + \phi_p a_{t-p} + n_t$$

$$n_t = \sigma_t e_t$$

$$\sigma_t^2 = \theta_0 + \varphi_1 \sigma_{t-1}^2 + \cdots + \varphi_r \sigma_{t-r}^2 + \theta_1 n_{t-1}^2 + \cdots + \theta_s n_{t-s}^2$$

dan e_t adalah i.i.d $N(0,1)$.

2.6 Model ARCH dan GARCH

Pada umumnya, pemodelan data *time series* dilakukan dengan asumsi varians residual a_t konstan (*homoskedastisitas*) yaitu sebesar σ_t^2 . Pada kenyataanya, banyak time series yang mempunyai *homoskedastisitas*, khususnya untuk data time series di bidang keuangan. Hal ini menyebabkan pemodelan dengan memakai analisis time series biasa, yang mempunyai asumsi homoskedastisitas tidak dapat digunakan.

Model ARCH mengasumsikan bahwa *conditional variance* hari ini dipengaruhi oleh waktu sebelumnya. Model ini menganalisis time series yang memperbolehkan adanya heteroskedastisitas yang diperkenalkan pertama kali oleh Engle (1982). Model ARCH digunakan untuk memodelkan varians residual yang sebelumnya secara autoregresi atau digunakan untuk memodelkan varians bersyarat.

Misalkan dimiliki model:

$$Y_t = \alpha + \beta x_t + a_t \quad (2.50)$$

Pada analisis time series biasa a_t diasumsikan *white noise* $a_t \sim N(0, \sigma^2)$ karena time series bidang keuangan seringkali bersifat heteroskedastisitas maka varians bersyarat akan mengikuti model

$$h_t = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_q a_{t-q}^2 \quad (2.51)$$

Proses *white noise* a_t yang mengikuti persamaan (2.38) didefinisikan sebagai model ARCH *orde*– q dengan $v_t \sim N(0, \sigma^2)$, bentuk lain dari ARCH (q) adalah:

$$a_t = \sqrt{\sigma_t^2} \cdot v_t \quad (2.52)$$

$$h_t = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_q a_{t-q}^2 + \quad (2.53)$$

dengan $q > 0, \alpha_0 > 0$ dan $\alpha_i \geq 0$ untuk $i = 1, 2, \dots, q$, syarat $\alpha_0 > 0$ dan $\alpha_i \geq 0$ dibutuhkan agar varians bersyarat $h_t > 0$.

Seringkali pada saat menentukan model ARCH dibutuhkan orde besar agar didapatkan model yang tepat untuk data *time series*. Oleh karena itu, Bollerslev (1986) mengembangkan model ARCH ke dalam GARCH untuk menghindari orde ARCH yang besar dan memberikan hasil yang lebih praktis daripada model ARCH, mirip dengan kondisi dimana model ARMA lebih dipilih daripada model AR. Sementara model GARCH lebih sering digunakan dan mempunyai performa yang lebih baik memiliki persamaan *conditional variance*. Dalam model GARCH, perubahan varians bersyaratnya selain dipengaruhi oleh nilai pada periode sebelumnya, juga dipengaruhi oleh varians bersyarat pada periode sebelumnya. Secara umum varians residual σ_t^2 dalam model GARCH (p, q) mengikuti model berikut:

$$h_t = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_q a_{t-q}^2 \quad (2.54)$$

bentuk lain dari GARCH (p, q) adalah:

$$h_t = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_q a_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \cdots + \beta_p \sigma_{t-p}^2 \quad (2.55)$$

dengan

h_t = varian dari residual pada waktu t

α_0 = konstanta

α_i = koefisien ARCH dimana $i = 1, 2, \dots, q$

β_j = koefisien AR dimana $j = 1, 2, \dots, p$

a_t = error

dengan $q > 0, \alpha_0 > 0, \alpha_i \geq 0$ dan $\beta_j \geq 0$ untuk $i = 1, 2, \dots, q$ dan $j = 1, 2, \dots, p$.

Seperti ARCH syarat $\alpha_0 > 0, \alpha_i \geq 0$ dan $\beta_j \geq 0$ dibutuhkan agar varians bersyarat $h_t > 0$.

Adakalanya pemodelan ekonometrik asumsi varians dari *error term* atau faktor pengganggu yang konstan menjadi tidak masuk akal, hal ini disebabkan sangat mungkin terjadi kejadian dimana varians dari *error term* tidak konstan terhadap waktu, hal tersebut ditunjukkan oleh *volatility clustering* yang terjadi pada data *time series* keuangan, dimana adanya kecenderungan volatilitas yang tinggi pada periode berikutnya, demikian juga berlaku sebaliknya.

Peramalan dengan menggunakan asumsi volatilitas yang konstan terhadap variasi biasanya dilakukan dengan menggunakan standar deviasi biasa, sedangkan untuk melakukan peramalan terhadap volatilitas yang tidak konstan terhadap waktu telah dikembangkan banyak model seperti model ARCH dan kemudian dikembangkan lagi menjadi GARCH.

Pengujian asumsi varians residual homogen dapat dilakukan dengan menggunakan uji portmanteau Q (Wei, 2006:373). Uji portmanteau pada persamaan (2.16) akan digunakan untuk mendeteksi keberadaan proses ARCH, yaitu keheterogenan ragam sisaan yang dipengaruhi kuadrat sisaan periode sebelumnya atau biasa disebut keheterogenan ragam sisaan bersyarat (*conditional heteroscedasticity*) dalam deret waktu. Dengan hipotesis nol adalah ragam sisaan heterogen tidak bersyarat (tidak terdapat proses ARCH).

2.7 Pemilihan Model Terbaik

Dalam analisis *time series*, terdapat banyak model yang digunakan untuk meramal data pada periode tertentu. Oleh karena itu, dibutuhkan kriteria untuk menentukan model yang terbaik dan akurat. Pemilihan model peramalan terbaik dapat dilakukan dengan menggunakan pendekatan *out-sample*. Kriteria pemilihan model terbaik pada penelitian ini akan diukur dengan menggunakan *symmetric mean absolute percentage error* (*sMAPE*) pada model peramalan dengan formulasi sebagai berikut .

$$sMAPE = \frac{1}{L} \sum_{l=1}^L \frac{|Z_{n+l} - \hat{Z}_n(l)|}{(|Z_{n+l}| + |\hat{Z}_n(l)|)/2} \times 100\% \quad (2.56)$$

dengan

L = banyaknya ramalan

Z_{n+l} = nilai sebenarnya pada periode $n+l$

$\hat{Z}_n(l)$ = nilai ramalan l kedepan

model terbaik adalah model yang memiliki nilai sMAPE *out-sample* paling kecil.

2.8 Tujuan dan Tugas Bank Indonesia

Bank Indonesia (BI) merupakan bank sentral Republik Indonesia yang mempunyai satu tujuan tunggal, yaitu mencapai dan memelihara kestabilan nilai rupiah. Bank sentral memiliki wewenang untuk mengeluarkan dan mengedarkan uang kartal yang terdiri dari uang kertas dan uang logam. Dalam praktik, bank sentral juga menerima simpanan giro bank umum. Uang kartal dan simpanan giro bank umum di bank sentral tersebut selanjutnya disebut sebagai uang primer yang terdiri dari uang kartal dan uang giral atau uang yang berada dalam rekening giro di bank umum (Bank Indonesia, 2013).

Dalam kapasitasnya sebagai bank sentral, Bank Indonesia mempunyai satu tujuan tunggal, yaitu mencapai dan memelihara kestabilan nilai rupiah. Kestabilan nilai rupiah ini mengandung dua aspek, yaitu kestabilan nilai mata uang terhadap barang dan jasa, serta kestabilan terhadap mata uang negara lain. Aspek pertama tercermin pada perkembangan laju inflasi, sementara aspek kedua tercermin pada perkembangan nilai tukar rupiah terhadap mata uang negara lain. Perumusan tujuan tunggal ini dimaksudkan untuk memperjelas sasaran yang harus dicapai Bank Indonesia serta batas-batas tanggung jawabnya. Dengan demikian, tercapai atau tidaknya tujuan Bank Indonesia ini kelak akan dapat diukur dengan mudah (Bank Indonesia, 2013). Untuk dapat memenuhi tujuan tersebut, maka salah satu segmen yang senantiasa dipantau oleh BI adalah *outflow-inflow* uang kartal. Hal ini dilakukan agar BI dapat mengambil kebijakan terhadap proses pencetakan uang, serta mengatur uang keluar masuk pada BI. Pemantauan *inflow-outflow* uang kartal salah satunya dengan melakukan peramalan *outflow-inflow* uang kartal.

BAB 3

METODOLOGI PENELITIAN

3.1 Sumber Data

Penelitian ini menggunakan data *outflow* dan *inflow* uang kartal yang dicatat tiap bulan oleh Bank Indonesia. Periode waktu yang digunakan mulai Januari 2003 sampai Desember 2014. Variable-variabel yang digunakan pada penelitian ini adalah:

- $Z_{1,t}$ = *Outflow* uang kartal di Bank Indonesia Provinsi Papua
 $Z_{2,t}$ = *Inflow* uang kartal di Bank Indonesia Provinsi Papua
 t = *dummy* waktu untuk bulan
 $M_{i,t}$ = variabel *dummy* bulan $ke-i$, dimana $i = 1, 2, \dots, 12$
 $D_{j,t}$ = variabel *dummy* jumlah hari sebelum Idul Fitri
 $D_{j,t-1}$ = variabel *dummy* bulan sebelum Idul Fitri
 $D_{j,t+1}$ = variabel *dummy* bulan sesudah Idul Fitri
dengan $j = 0, 1, 2, \dots, 30$

Untuk menjaga keseragaman persepsi dalam penelitian ini maka digunakan beberapa konsep dan definisi operasional sebagai berikut:

- a. *Outflow* (Penarikan Uang) : Kegiatan Bank melakukan penarikan Uang yang masih layak edar (ULE) dari Bank Indonesia (BI, 2011)
- b. *Inflow* (Penyetoran Uang) : Kegiatan Bank melakukan penyetoran Uang ke Bank Indonesia (BI, 2011)

3.2 Metode Analisis Data

Tahapan analisis yang dilakukan dalam mencapai tujuan penelitian ini adalah sebagai berikut. Mengidentifikasi karakteristik pola *outflow* dan *inflow* uang kartal di Bank Indonesia Provinsi Papua. Menentukan model ARIMAX dua level, ANFIS dan kombinasi ARIMAX dua level dan ANFIS serta varians

residual kuadrat dideteksi dengan GARCH untuk deret *output* data *outflow* dan *inflow* di Bank Indonesia Provinsi Papua.

Data dalam penelitian ini akan dibagi menjadi dua bagian, yaitu *in-sample* dan *out-sample*. Dimana untuk data *in-sample* sebanyak 132, dimulai periode bulan Januari 2003 hingga Desember 2013. Sedangkan data *out-sample* sebanyak 12, dimulai periode bulan Januari 2014 hingga Desember 2014.

Berikut adalah langkah-langkah pemodelan ARIMAX dua level (Suhartono, Lee dan Prastyo, 2015).

1. Langkah pertama yaitu menentukan variabel *dummy* berdasarkan periode kalender variasi. Variasi kalender yang dimaksud dalam penelitian ini adalah perayaan hari raya Idul Fitri. Informasi tentang hari raya Idul Fitri mulai tahun 2003 hingga tahun 2014 dapat dilihat pada Tabel 3.1.

Tabel 3.1 Tanggal Terjadinya Hari Raya Idul Fitri Tahun 2003-2014

Tahun	Tanggal Idul Fitri
2003	25-26 Nopember
2004	14-15 Nopember
2005	04-05 Nopember
2006	23-24 Oktober
2007	12-13 Oktober
2008	01-02 Oktober
2009	21-22 September
2010	10-11 September
2011	30-31 Agustus
2012	19-20 Agustus
2013	08-09 Agustus
2014	28-29 Juli

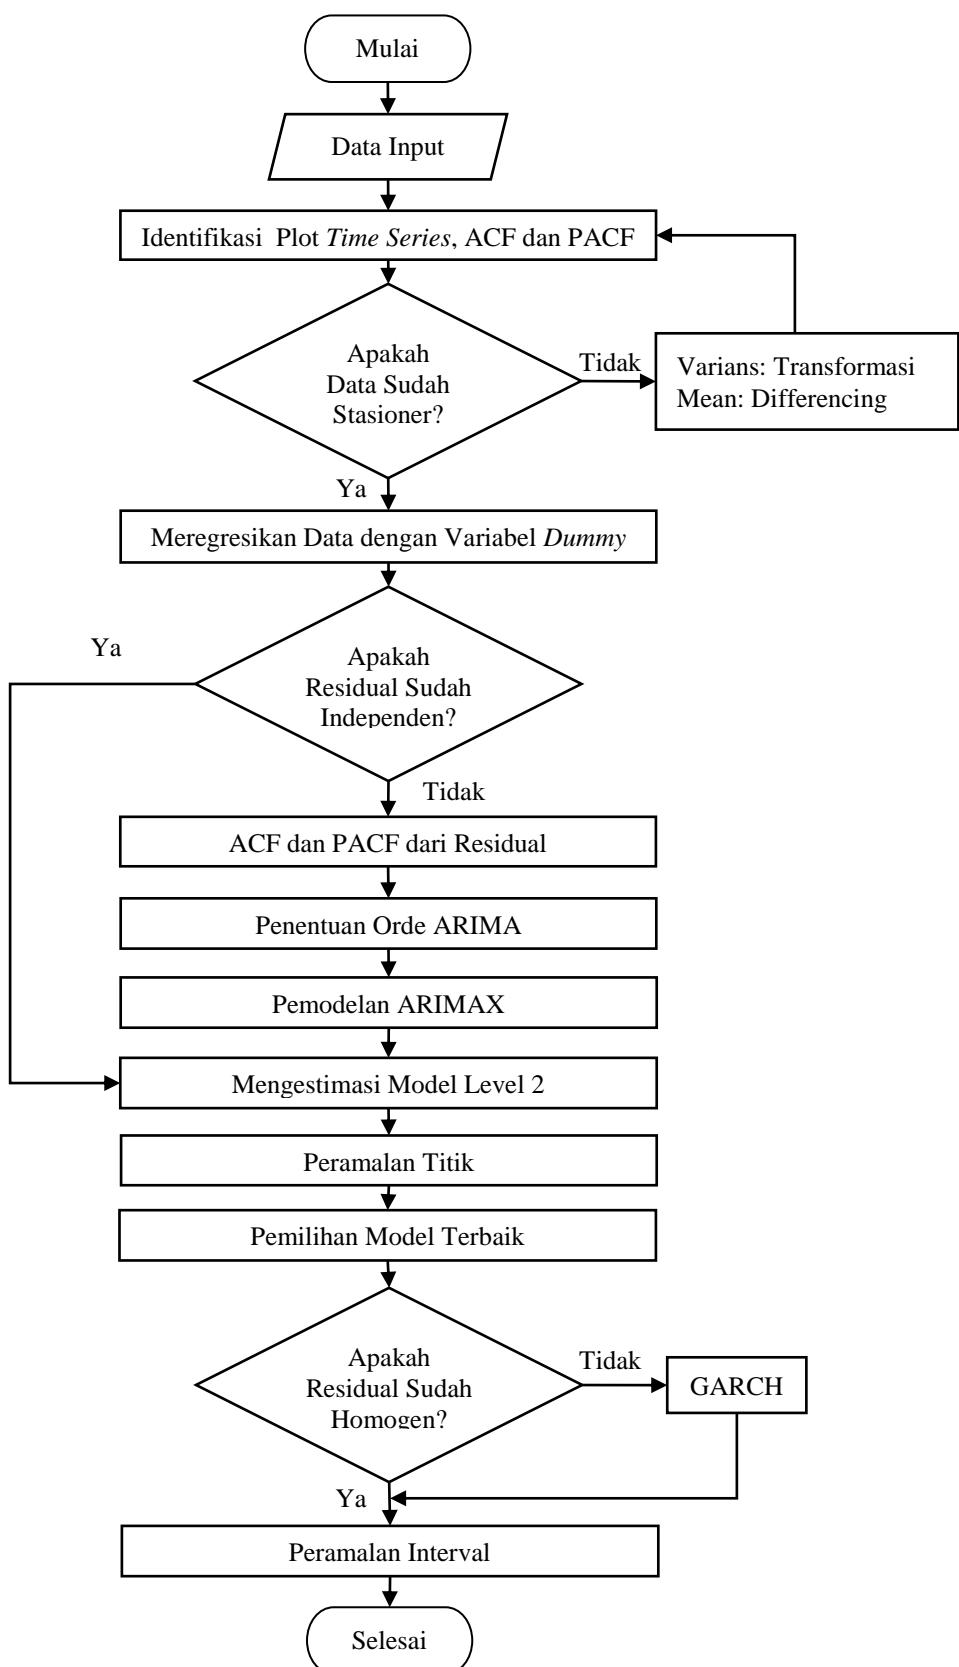
Selain *dummy* perayaan hari raya Idul Fitri akan digunakan juga *dummy* intervensi yang terjadi karena adanya perubahan kebijakan BI. Informasi mengenai kebijakan BI dapat dilihat pada Tabel 3.2.

Tabel 3.2 Perubahan Kebijakan Bank Indonesia

Tahun	Kebijakan
2003-2006	PBI Nomor 6/14/PBI/2004
2007-2010	PBI Nomor 9/10/PBI/2007
2011-2014	UU No.7 Tahun 2011

2. Meregresikan *outflow/inflow* dengan variabel *dummy* pada data *in-sample* yang telah ditentukan pada langkah 1 dengan menggunakan model pada persamaan (2.24).
3. Mendapatkan model ARIMA yang terbaik untuk ε_t dengan menggunakan prosedur Box-Jenkins, jika ε_t dari hasil regresi *time series* pada langkah 2 belum memenuhi asumsi independen.
4. Memodelkan data real secara simultan dengan menggunakan order ARIMA yang diperoleh pada langkah 3 dan variabel *dummy* pada langkah 2 sebagai *input* seperti pada persamaan (2.22).
5. Melakukan uji signifikansi parameters dan uji diagnostik sampai diperoleh residual yang independen dan berdistribusi normal.
6. Mengestimasi model level 2 untuk memprediksi pengaruh variasi kalender untuk setiap kemungkinan banyaknya hari sebelum Idul Fitri. Model level 2 ini mengandung pengaruh terhadap data, yaitu data pada bulan Idul Fitri, satu bulan sebelum Idul Fitri dan satu bulan setelah Idul Fitri. Pada level kedua akan dilakukan estimasi parameter *dummy* pada data *out-sample*. Fungsi yang digunakan untuk mengestimasi parameter tersebut adalah sebagai berikut:
 - 6.1. Model untuk bulan Idul Fitri adalah model persamaan (2.25)
 - 6.2. Model untuk satu bulan sebelum Idul Fitri adalah model persamaan (2.26)
 - 6.3. Model untuk satu bulan setelah Idul Fitri adalah model persamaan (2.27).
7. Melakukan peramalan titik.
8. Menghitung sMAPE data *out-sample*.
9. Mendeteksi GARCH, jika residual tidak homogen maka dimodelkan dengan GARCH. Model GARCH digunakan untuk peramalan varians.
10. Melakukan peramalan interval.

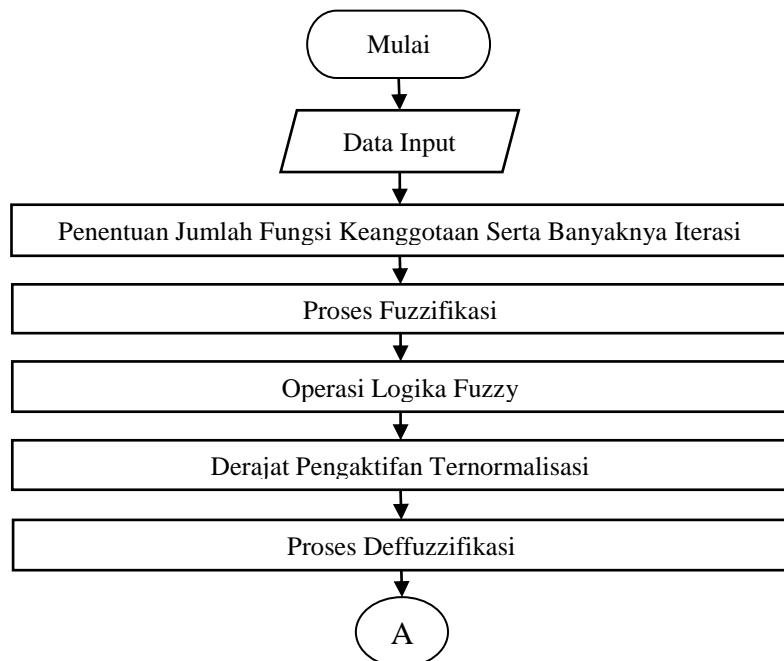
Pada pemodelan ARIMAX dua level akan dilakukan 2 skenario. Skenario pertama yaitu melakukan pemodelan ARIMAX dua level dengan menggunakan semua parameter tanpa memperhatikan signifikansi. Skenario kedua yaitu melakukan pemodelan ARIMAX dua level dengan hanya menggunakan parameter yang signifikan.



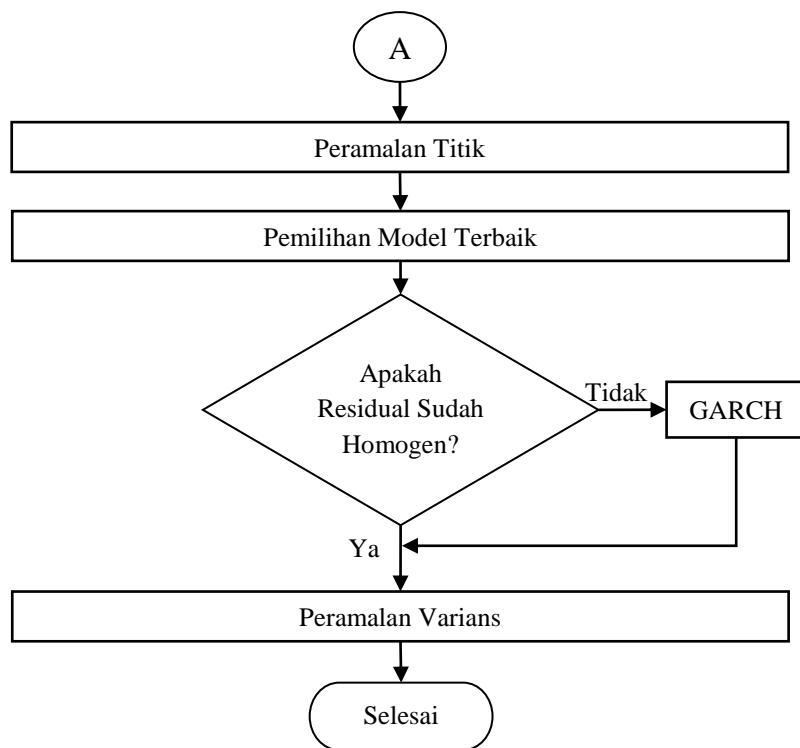
Gambar 3.1 Diagram Alir Model ARIMAX

Berikut adalah langkah-langkah analisis untuk mendapatkan model ANFIS

1. Menentukan variabel *input* melalui pendekatan model ARIMA berdasarkan orde AR atau lag PACF yang signifikan.
2. Menentukan banyak fungsi keanggotaan untuk mencari nilai awal parameter *premise*. Setelah menentukan jumlah fungsi keanggotan maka langkah selanjutnya adalah melakukan clustering dengan menggunakan algoritma Fuzzy C-Means (FCM).
3. Menentukan tipe fungsi keanggotaan. Fungsi keanggotaan yang digunakan dalam penelitian ini adalah *Gaussian*.
4. Menentukan *epoch* untuk mendapatkan parameter-parameter yang ANFIS meminimumkan residual.
5. Menjalankan setiap fungsi pada tiap lapisan ANFIS dan melakukan peramalan dengan metode ANFIS.
6. Melakukan peramalan Titik.
7. Menghitung sMAPE data *out-sample*.
8. Mendeteksi GARCH, jika residual tidak homogen maka dimodelkan dengan GARCH. Model GARCH digunakan untuk peramalan varians.
9. Melakukan peramalan interval jika ada proses GARCH.



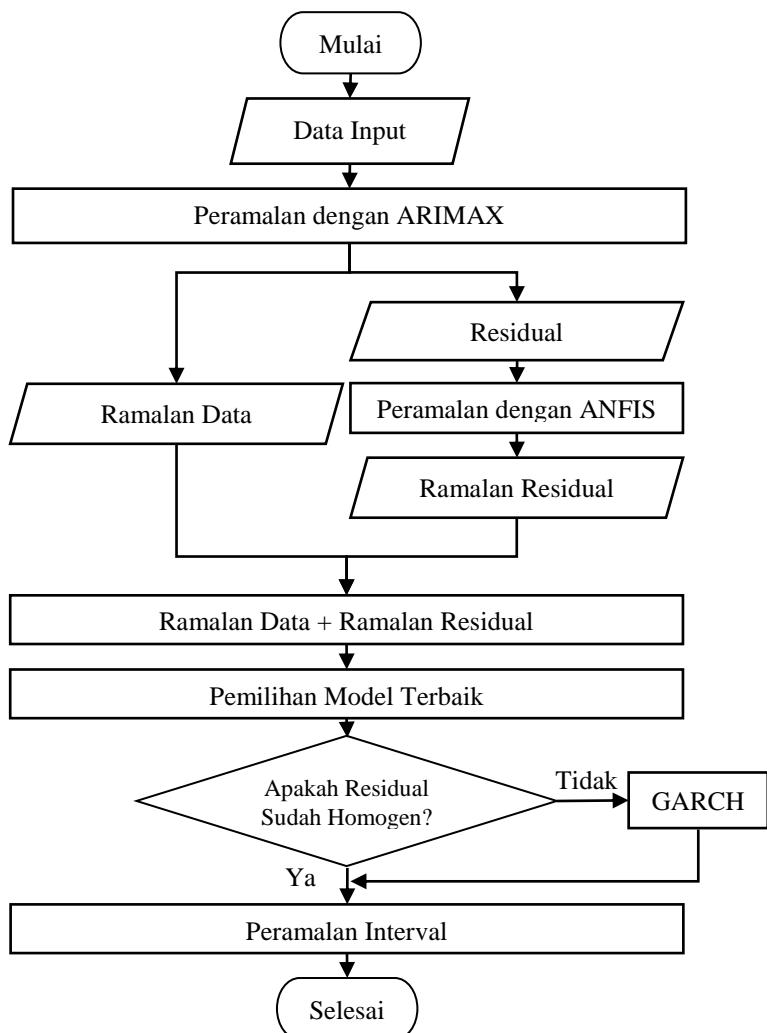
Gambar 3.2 Diagram Alir Model ANFIS



Gambar 3.2 Diagram Alir Model ANFIS (Lanjutan)

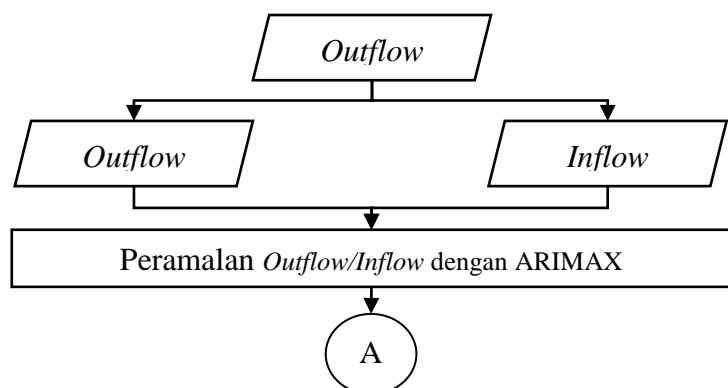
Berikut adalah langkah-langkah analisis untuk mendapatkan model kombinasi ARIMAX-ANFIS

1. Melakukan pemodelan dan peramalan dengan model ARIMAX seperti langkah yang telah dijelaskan sebelumnya.
2. Melakukan pemodelan dan peramalan menggunakan model ANFIS pada residual yang diperoleh dari peramalan ARIMAX. Analisis menggunakan ANFIS dilakukan seperti pada langkah yang telah dijelaskan sebelumnya.
3. Menggabungkan hasil ramalan menggunakan metode ARIMAX dan hasil ramalan menggunakan metode ANFIS.
4. Menghitung sMAPE data *out sample*
5. Deteksi GARCH, jika residual kuadrat tidak homogen maka dimodelkan dengan GARCH. Model GARCH digunakan untuk peramalan varians.
6. Melakukan peramalan interval jika ada proses GARCH.

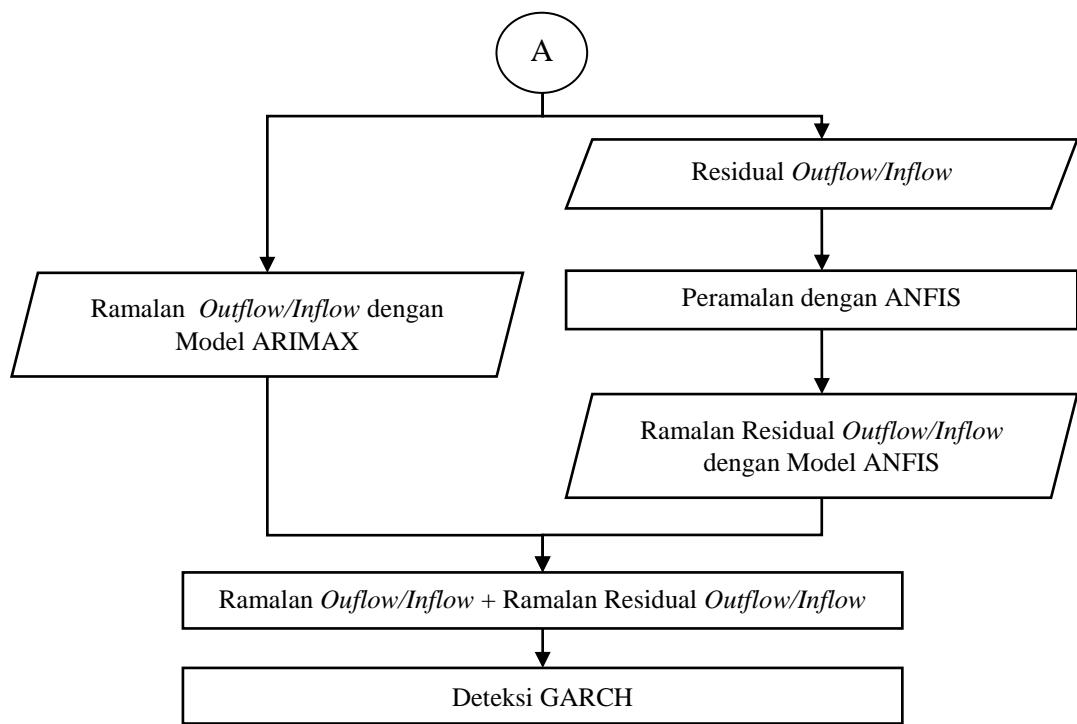


Gambar 3.3 Diagram Alir Model Kombinasi ARIMAX-ANFIS

Langkah-langkah yang dilakukan dalam mencapai tujuan penelitian ini dijelaskan dalam gambar berikut.



Gambar 3.4 Tahapan Penelitian



Gambar 3.4 Tahapan Penelitian (Lanjutan)

BAB 4

ANALISIS DAN PEMBAHASAN

Pada bab ini dilakukan analisis data *outflow* dan *inflow* uang kartal di BI Provinsi Papua selama periode pengamatan. Pembahasan diawali dengan melakukan eksplorasi data untuk mengetahui karakteristik dari data penelitian, kemudian dilanjutkan dengan pemodelan menggunakan ARIMAX, ANFIS dan hybrid ARIMAX-ANFIS. Selanjutnya memilih model terbaik yang akan digunakan untuk meramalkan *outflow* dan *inflow* uang kartal pada masa yang akan datang.

4.1 Karakteristik *Outflow* dan *Inflow* Uang Kartal periode tahun 2003-2014

Analisis deskriptif dilakukan untuk menjelaskan mengenai gambaran umum dari data *outflow* dan *inflow* mulai bulan Januari 2003 hingga Desember 2014. Data bulan januari 2003 hingga desember 2013 digunakan sebagai data *in-sample*, dan data bulan januari hingga desember 2014 digunakan sebagai data *out-sample*. Data *in-sample* ada sebanyak 132 data dan *out-sample* ada 12 data.

Hasil statistik deskriptif data data *outflow* dan *inflow* uang kartal di BI Papua selama periode pengamatan dapat dilihat pada Tabel 4.1. Hasil statistik deskriptif data *outflow* uang kartal di BI Papua selama periode pengamatan dapat dilihat pada Tabel 4.1. Pada tabel tersebut diketahui bahwa rata-rata *outflow* uang kartal selama periode pengamatan yaitu Januari 2003 hingga Desember 2014 sebesar 550,4 sedangkan rata-rata untuk data *in-sample* yaitu dari Januari 2003 hingga Desember 2013 sebesar 514,8 dan rata-rata *out-sample* yaitu Januari hingga Desember 2014 sebesar 942. Berdasarkan Tabel 4.1 dapat diketahui pula bahwa rata-rata *inflow* uang kartal selama periode pengamatan yaitu Januari 2003 hingga Desember 2014 sebesar 251,5 sedangkan rata-rata untuk data *in-sample* yaitu dari Januari 2003 hingga Desember 2013 sebesar 222,9 dan rata-rata *out-sample* yaitu Januari hingga Desember 2014 sebesar 566. Nilai standar deviasi untuk *outflow* pada Januari 2003 hingga Desember 2014 sebesar 682,8 sedangkan standar deviasi pada *in-sample* sebesar 643 dan standar deviasi pada *out-sample*

sebesar 977. Nilai standar deviasi untuk *inflow* pada Januari 2003 hingga Desember 2014 sebesar 251,4 sedangkan standar deviasi pada *in-sample* sebesar 209,5 dan standar deviasi pada *out-sample* sebesar 425. Hal tersebut menjelaskan bahwa data uang kartal selama periode pengamatan menyebar cukup jauh dari ukuran pemusatan data (dalam hal ini nilai rata-rata) atau dengan kata lain pergerakan *outflow* dan *inflow* uang kartal selama periode pengamatan memiliki varians yang tinggi.

Tabel 4.1 Statistik Deskriptif Data *Outflow* dan *Inflow* Uang Kartal BI Papua

Berdasarkan *I-Sample* dan *Out-Sample*

Variabel	Periode	Keterangan	Mean	St. Dev	Varians	Min	Max
<i>Outflow</i>	2003-2014	Total	550,4	682,8	466185,3	3,0	4080,4
	2003-2013	<i>In-Sample</i>	514,8	643,0	413406,9	3,0	4080,4
	2014	<i>Out-Sample</i>	942,0	977,0	954531,0	174,0	3726,0
<i>Inflow</i>	2003-2014	Total	251,5	251,4	63178,3	14,5	1800,6
	2003-2013	<i>In-Sample</i>	222,9	209,5	43879,6	14,5	1423,5
	2014	<i>Out-Sample</i>	566,0	425,0	180923,0	227,0	1801,0

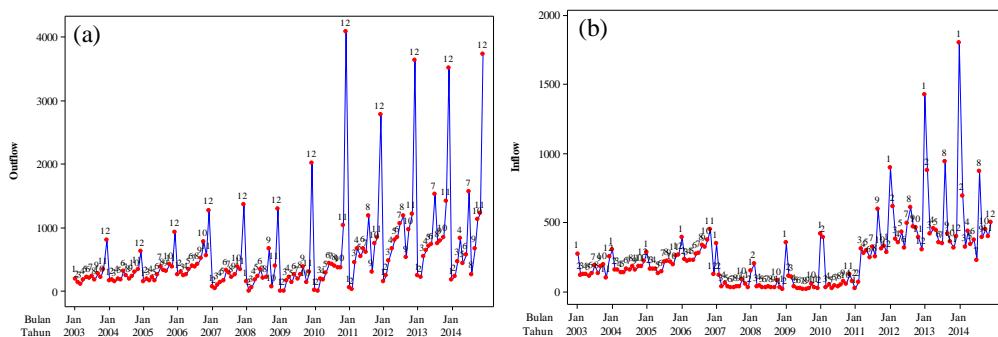
Statistik deskriptif data *outflow* dan *inflow* uang kartal BI papua tiap tahun dari tahun 2003 hingga 2014 (dalam miliar rupiah) dapat dilihat pada Tabel 4.2.

Tabel 4.2 Statistik Deskriptif Data *Outflow* dan *Inflow* Uang Kartal Tiap Tahun

<i>Outflow</i>				<i>Inflow</i>			
Tahun	Mean	St.Dev	Variance	Tahun	Mean	St.Dev	Variance
2003	259,2	179,9	32373,5	2003	160,3	57,0	3249,1
2004	263,0	131,7	17342,4	2004	177,3	45,4	2061,1
2005	326,6	213,2	45437,5	2005	201,6	50,4	2545,2
2006	478,7	292,8	85743,8	2006	286,3	90,9	8268,7
2007	307,0	349,0	121935,0	2007	74,2	90,6	8214,7
2008	317,0	355,0	126246,0	2008	57,4	57,2	3269,2
2009	343,0	538,0	289864,0	2009	67,2	96,5	9314,0
2010	648,0	1113,0	1239283,0	2010	113,7	138,7	19247,5
2011	742,0	717,0	514181,0	2011	274,4	141,2	19930,0
2012	983,0	900,0	810031,0	2012	476,8	165,9	27520,0
2013	996,0	878,0	771720,0	2013	562,4	339,3	115117,0
2014	942,0	977,0	954531,0	2014	566,0	425,0	180923,0

Berdasarkan Tabel 4.2 terlihat bahwa rata-rata *outflow* uang kartal yang paling tinggi terjadi pada tahun 2013 dan yang paling rendah terjadi pada tahun

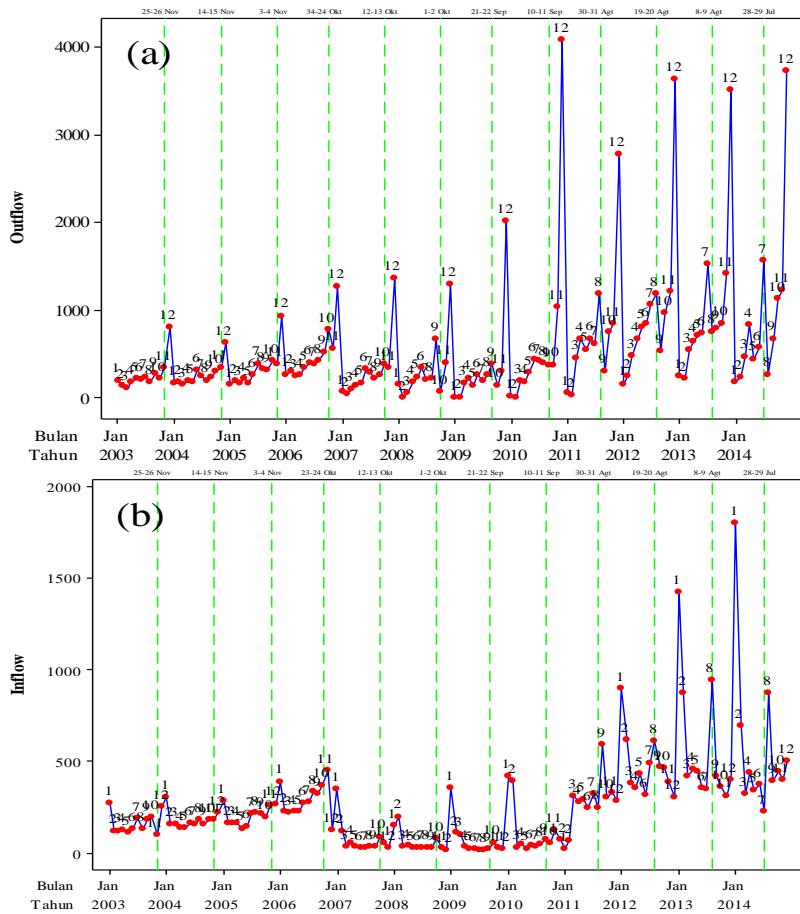
2003. Sedangkan rata-rata *inflow* uang kartal yang paling tinggi terjadi pada tahun 2014 dan yang paling rendah terjadi pada tahun 2008. Pada umumnya rata-rata *outflow* dan *inflow* naik dari tahun ke tahun. Namun pada tahun 2007 *outflow* dan *inflow* mengalami penurunan yang cukup besar hal ini disebabkan adanya kebijakan baru yang dikeluarkan BI dalam rangka meningkatkan efektifitas dan efisiensi manajemen kas perbankan serta mengoptimalkan pengolahan uang oleh perbankan sehingga uang yang beredar di masyarakat meningkat kualitasnya. Kebijakan tersebut tercantum dalam peraturan BI Nomor 9/10/PBI/2007 (Lembar Negara Republik Indonesia Tahun 2007 Nomor 113, Tambahan Lembaran Negara Republik Indonesia Nomor 4762) tentang pengeluaran, pengedaran, pencabutan dan penarikan serta pemusnahan uang rupiah. Kemudian pada tahun 2010 terdapat kebijakan baru lagi yang dikeluarkan oleh BI tentang mata uang yaitu UU No.7 tahun 2011 dengan tujuan untuk menegaskan Rupiah sebagai Mata Uang Republik Indonesia beserta seluruh informasi tentang fisik dan penggunaan serta sanksi terhadap penyelewengan, penyalahgunaan, Rupiah dalam transaksi bisnis dan pembayaran di Republik Indonesia. Setelah kebijakan baru tersebut berlaku *outflow* dan *inflow* uang kartal pada BI papua kembali dari tahun ke tahun. Secara visual dapat dilihat pada gambar 4.1



Gambar 4.1 Time Series Plot (a) Outflow (b) Inflow Uang Kartal

Berdasarkan visualisasi Gambar 4.1 yang disesuaikan dengan informasi pada Tabel 4.2 dapat disimpulkan bahwa terdapat tiga periode yang berbeda selama pengamatan baik *outflow* maupun *inflow*. Perbedaan tersebut dikarenakan adanya perubahan kebijakan BI dimana periode yang pertama yaitu pada tahun 2003 hingga 2006, periode kedua pada tahun 2007 hingga 2010, dan periode ketiga pada tahun 2011 hingga 2014. Untuk lebih jelasnya dapat dilihat pada

Tabel 3.2 yang menjelaskan tentang kebijakan yang diberlakukan BI. Pada Gambar 4.1 (a) dapat dilihat juga bahwa *outflow* uang kartal pada umumnya cukup tinggi terjadi pada bulan Desember setiap tahun, sehingga dapat disimpulkan adanya pola musisman pada data *outflow* uang kartal di BI Papua. Pada Gambar 4.1 (b) dapat dilihat bahwa *inflow* uang kartal pada umumnya cukup tinggi terjadi pada bulan Januari setiap tahun, sehingga dapat disimpulkan adanya pola musisman pada data *inflow* uang kartal di BI Papua. Variasi kalender yang diduga berpengaruh adalah perayaan tahunan Idul Fitri yang pelaksanaanya didasarkan pada kalender Hijryah. Pada inflow maupun outflow uang kartal BI Papua pada umumnya tertinggi kedua pada bulan perayaan Idul Fitri atau 1 bulan sebelum perayaan Idul Fitri atau 1 bulan setelah perayaan Idul Fitri. Gambar 4.2 memuat informasi mengenai tanggal terjadinya Idul Fitri pada tahun 2003 hingga tahun 2014.



Gambar 4.2 Time Series Plot (a) Outflow (b) Inflow Uang Kartal dengan Tanggal Terjadinya Idul Fitri

Gambar 4.2 menguatkan dugaan awal bahwa pola data *outflow* dan *inflow* uang kartal dipengaruhi oleh variasi kalender. Dari Gambar 4.2 (a) terlihat bahwa apabila hari raya Idul Fitri terjadi pada tanggal awal bulan maka *outflow* uang kartal cukup tinggi pada bulan berikutnya setelah hari raya Idul Fitri, apabila hari raya Idul Fitri terjadi pada tanggal mendekati akhir bulan maka *outflow* uang kartal cukup tinggi pada bulan yang sama dengan hari raya Idul Fitri. Dari Gambar 4.2 (b) terlihat bahwa apabila hari raya Idul Fitri terjadi pada tanggal awal bulan maka *inflow* uang kartal cukup tinggi pada bulan yang sama dengan hari raya Idul Fitri, apabila hari raya Idul Fitri terjadi pada tanggal mendekati akhir bulan maka *inflow* uang kartal cukup tinggi pada bulan berikutnya setelah hari raya Idul Fitri.

4.2 Model ARIMAX *Outflow* dan *Inflow* Uang Kartal

Dalam metodologi regresi *time series* terdapat lima tahapan prosedur, yaitu pertama, menentukan variabel *dummy* jumlah hari sebelum hari raya Idul Fitri dan *dummy* saat adanya perubahan kebijakan yang dikeluarkan oleh BI; kedua, menentukan tren yang sifatnya deterministik; ketiga, estimasi secara simultan model yang diidentifikasi; keempat, melakukan cek diagnosa; kelima, melakukan estimasi ulang jika masih ada asumsi yang belum terpenuhi.

Tabel 4.3 Notasi dari Variabel *Dummy* Efek Kariasi Kalender yang Digunakan

Tahun	Tanggal	Keterangan		
2003	25-26 November	$D_{24,t}=November$	$D_{24,t-1}=Okttober$	$D_{24,t+1}=Desember$
2004	14-15 November	$D_{13,t}=November$	$D_{13,t-1}=Okttober$	$D_{13,t+1}=Desember$
2005	03-04 November	$D_{2,t}=November$	$D_{2,t-1}=Okttober$	$D_{2,t+1}=Desember$
2006	23-24 Oktober	$D_{22,t}=Okttober$	$D_{22,t-1}=September$	$D_{22,t+1}=November$
2007	12-13 Oktober	$D_{11,t}=Okttober$	$D_{11,t-1}=September$	$D_{11,t+1}=November$
2008	01-02 Oktober	$D_{0,t}=Okttober$	$D_{0,t-1}=September$	$D_{0,t+1}=November$
2009	21-22 September	$D_{20,t}=September$	$D_{20,t-1}=September$	$D_{20,t+1}=Okttober$
2010	10-11 September	$D_{09,t}=September$	$D_{09,t-1}=September$	$D_{09,t+1}=Oktober$
2011	30-31 Agustus	$D_{29,t}=Agustus$	$D_{29,t-1}=Juli$	$D_{29,t+1}=September$
2012	19-20 Agustus	$D_{18,t}=Agustus$	$D_{18,t-1}=Juli$	$D_{18,t+1}=September$
2013	08-09 Agustus	$D_{07,t}=Agustus$	$D_{07,t-1}=Juli$	$D_{07,t+1}=September$
2014	28-29 Juli	$D_{27,t}=Juli$	$D_{27,t-1}=Juni$	$D_{27,t+1}=Agustus$

$$D_{j,t} = \begin{cases} 1, & \text{untuk kejadian Idul Fitri pada bulan } ke-t \text{ dengan } j \text{ adalah jumlah hari sebelum Idul Fitri} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

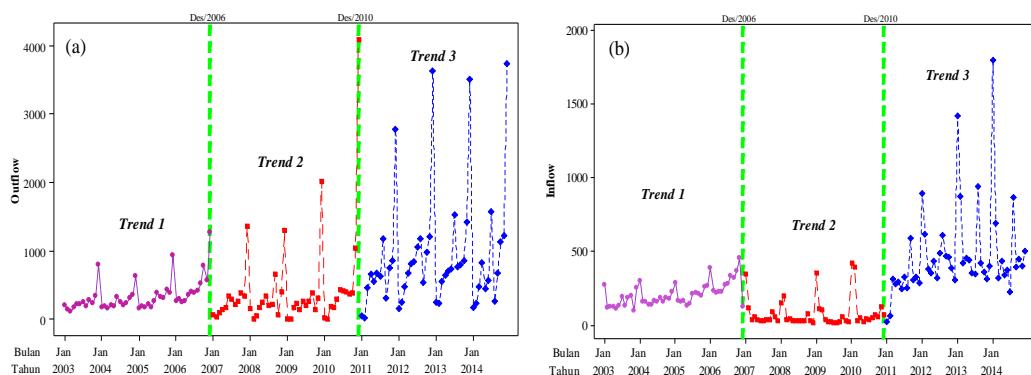
$$D_{j,t-1} = \begin{cases} 1, & \text{untuk kejadian Idul Fitri pada bulan } ke-(t-1) \text{ dengan } j \text{ adalah jumlah hari sebelum Idul Fitri} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

$$D_{j,t+1} = \begin{cases} 1, & \text{untuk kejadian Idul Fitri pada bulan } ke-(t+1) \text{ dengan } j \text{ adalah jumlah hari sebelum Idul Fitri} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

dengan $j = 0, 1, 2, \dots, 30$

Berdasarkan dugaan awal dan eksplorasi data diketahui bahwa ada efek hari raya Idul Fitri pada *outflow* dan *inflow* uang kartal di BI Papua. Pada penelitian ini akan digunakan ARIMAX dua level, sehingga variabel *dummy* yang terbentuk akibat adanya variasi kalender untuk *outflow* dan *inflow* dapat dilihat pada Tabel 4.3.

Selain pembentukan variabel *dummy* yang menyatakan variasi kalender, juga akan dibentuk variabel *dummy* yang menyatakan pola *trend* dan musiman. Berdasarkan eksplorasi data, diduga terdapat tiga periode yang berbeda pada pola data *outflow* dan *inflow* uang kartal karena adanya beberapa perubahan kebijakan yang dikeluarkan oleh BI yaitu periode pertama pada januari 2003 hingga desember 2006, periode kedua pada januari 2007 hingga desember 2010, dan periode ketiga pada januari 2011 hingga desember 2014. Variabel yang menyatakan adanya *trend* positif pada data *outflow* dan *inflow* uang kartal dinyatakan dengan t . Secara visual dapat dilihat pada Gambar 4.3 berikut.



Gambar 4.3 Time Series Plot (a) Outflow dan (b) Inflow Uang Kartal dengan Tiga Trend

Berdasarkan Gambar 4.3 terlihat bahwa ada tiga *trend* yang menguatkan adanya variabel *dummy* akibat dari perubahan kebijakan yang berlakukan oleh BI.

Pola *dummy* untuk tiga periode kebijakan tersebut dapat dilihat pada Tabel 4.4, sedangkan variabel yang menyatakan adanya pola musiman dinyatakan dengan *dummy* bulanan, yaitu $M_{1,t}$ untuk bulan januari, $M_{2,t}$ untuk bulan februari dan seterusnya hingga $M_{12,t}$ untuk bulan desember.

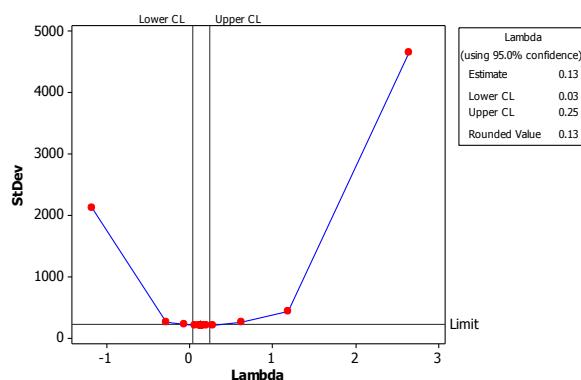
Tabel 4.4 Variabel *Dummy* untuk Tiga Periode Kebijakan

t	I_1	I_2	$t \times I_1$	$t \times I_2$
1	0	0	0	0
2	0	0	0	0
\vdots	\vdots	\vdots	\vdots	\vdots
48	0	0	0	0
49	1	0	49	0
50	1	0	50	0
\vdots	\vdots	\vdots	\vdots	\vdots
96	1	0	96	0
97	0	1	0	97
98	0	1	0	98
\vdots	\vdots	\vdots	\vdots	\vdots
132	0	1	0	132

Berikut ini merupakan hasil analisis metode regresi deret waktu terhadap data *outflow* dan *inflow* periode tahun 2003-2013.

4.2.1 Model ARIMAX untuk Data *Outflow*

Data *outflow* uang kartal pada penelitian ini belum stasioner dalam varians. Hal tersebut dapat dilihat pada Gambar 4.4 dengan nilai *rounded value* yang dihasilkan sebesar 0,13 dengan batas atas sebesar 0,25 dan batas bawah sebesar 0,03.



Gambar 4.4 Box-Cox Data *Outflow* Uang Kartal

Oleh karena itu data *outflow* perlu distasionerkan terlebih dahulu sebelum dianalisis lebih lanjut dengan menggunakan transformasi Box-Cox yang memiliki nilai *rounded value* sebesar 0,13 sehingga hasil transformasi tersebut dapat dituliskan sebagai berikut.

$$Z_{1,t}^* = \frac{Z_{1,t}^{(0,13)} - 1}{0,13} .$$

Tahap awal pembentukan model ARIMAX mengacu pada pemodelan regresi *time series*. Model regresi *time series* untuk *outflow* uang kartal dapat diduga sebagai berikut.

$$\begin{aligned} Z_{1,t}^* = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \\ & \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \\ & \varphi_1 I_t^{(49)} + \varphi_2 t I_t^{(49)} + \varphi_3 I_t^{(97)} + \varphi_4 t I_t^{(97)} + \gamma_0 D_{0,t-1} + \gamma_2 D_{2,t-1} + \\ & \gamma_7 D_{7,t-1} + \gamma_9 D_{9,t-1} + \gamma_{11} D_{11,t-1} + \gamma_{13} D_{13,t-1} + \gamma_{18} D_{18,t-1} + \gamma_{20} D_{20,t-1} + \\ & \gamma_{22} D_{22,t-1} + \gamma_{24} D_{24,t-1} + \gamma_{27} D_{27,t-1} + \gamma_{29} D_{29,t-1} + \\ & \alpha_0 D_{0,t} + \alpha_2 D_{2,t} + \alpha_7 D_{7,t} + \alpha_9 D_{9,t} + \alpha_{11} D_{11,t} + \alpha_{13} D_{13,t} + \alpha_{18} D_{18,t} + \\ & \alpha_{20} D_{20,t} + \alpha_{22} D_{22,t} + \alpha_{24} D_{24,t} + \alpha_{27} D_{27,t} + \alpha_{29} D_{29,t} + \varepsilon_t. \end{aligned} \quad (4.1)$$

dengan $I_t^{(T)}$ merupakan variabel *dummy* intervensi akibat adanya kebijakan baru yang diberlakukan oleh BI.

Tahap selanjutnya adalah melakukan estimasi parameter dari model dugaan regresi *time series* tersebut. Hasil estimasi parameter tersebut dapat dilihat pada Tabel 4.5. Berdasarkan nilai estimasi parameter pada Tabel 4.5 Maka persamaan (4.1) dapat dituliskan menjadi.

$$\begin{aligned} Z_{1,t}^* = & 0,016t + 5,735M_{1,t} + 5,112M_{2,t} + 7,17M_{3,t} + 7,83M_{4,t} + \\ & 7,95M_{5,t} + 8,567M_{6,t} + 8,385M_{7,t} + 8,041M_{8,t} + 7,674M_{9,t} + \\ & 8,383M_{10,t} + 9,484M_{11,t} + 11,9M_{12,t} - 2,028I_t^{(49)} - 0,006tI_t^{(49)} + \\ & -3,965I_t^{(97)} + 0,037tI_t^{(97)} + 3,092D_{0,t-1} + 0,301D_{2,t-1} + 1,154D_{7,t-1} + \\ & 1,068D_{9,t-1} + 1,255D_{11,t-1} - 0,239D_{13,t-1} + 0,87D_{18,t-1} + 0,482D_{20,t-1} + \\ & 1,256D_{22,t-1} - 0,696D_{24,t-1} + \gamma_{27} D_{27,t-1} + 0,223D_{29,t-1} - 2,278D_{0,t} \\ & -1,068D_{2,t} - 0,283D_{7,t} + 1,25D_{9,t} + 1,369D_{11,t} - 1,068D_{13,t} + 1,43D_{18,t} + \\ & 1,611D_{20,t} + 1,474D_{22,t} - 0,924D_{24,t} + \alpha_{27} D_{27,t} + 2,063D_{29,t} + \varepsilon_t. \end{aligned} \quad (4.2)$$

Tabel 4.5 Hasil Estimasi Parameter Regresi *Time Series Outflow*

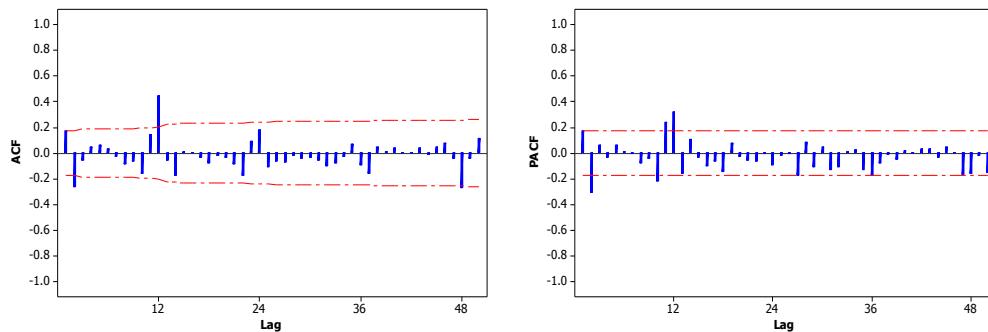
Parameter	Estimasi	Standard Error	t-value	p-value
δ	0,0155	0,0142	1,09	0,2767
β_1	5,7352	0,5114	11,21	<0,0001
β_2	5,1123	0,5143	9,94	<0,0001
β_3	7,1701	0,5174	13,86	<0,0001
β_4	7,8303	0,5206	15,04	<0,0001
β_5	7,9496	0,5240	15,17	<0,0001
β_6	8,5671	0,5275	16,24	<0,0001
β_7	8,3847	0,5738	14,61	<0,0001
β_8	8,0410	0,6246	12,87	<0,0001
β_9	7,6735	0,6147	12,48	<0,0001
β_{10}	8,3829	0,7075	11,85	<0,0001
β_{11}	9,4875	0,6226	15,24	<0,0001
β_{12}	11,9001	0,5519	21,56	<0,0001
φ_1	-2,0280	1,1071	-1,83	0,0702
φ_2	0,0058	0,0200	0,29	0,7713
φ_3	-3,9645	2,5215	-1,57	0,1193
φ_4	0,0370	0,0257	1,44	0,1539
$\gamma_{0,t-1}$	3,0915	1,3496	2,29	0,0242
$\gamma_{2,t-1}$	0,3008	1,3813	0,22	0,8281
$\gamma_{7,t-1}$	1,1538	1,3603	0,85	0,3985
$\gamma_{9,t-1}$	1,0679	1,3813	0,77	0,4414
$\gamma_{11,t-1}$	1,2549	1,3659	0,92	0,3606
$\gamma_{13,t-1}$	-0,2385	1,3745	-0,17	0,8626
$\gamma_{18,t-1}$	0,8691	1,3302	0,65	0,5152
$\gamma_{20,t-1}$	0,4819	1,3491	0,36	0,7217
$\gamma_{22,t-1}$	1,2558	1,3725	0,91	0,3626
$\gamma_{24,t-1}$	-0,6960	1,3887	-0,50	0,6174
$\gamma_{29,t-1}$	0,2229	1,3514	0,16	0,8693
$\alpha_{0,t}$	-2,2781	1,3633	-1,67	0,0981
$\alpha_{2,t}$	-1,0681	1,3265	-0,81	0,4227
$\alpha_{7,t}$	-0,2827	1,3909	-0,20	0,8394
$\alpha_{9,t}$	1,2497	1,3823	0,90	0,3683
$\alpha_{11,t}$	1,3688	1,3900	0,98	0,3273
$\alpha_{13,t}$	-1,0679	1,3227	-0,81	0,4215
$\alpha_{18,t}$	1,4303	1,3568	1,05	0,2945
$\alpha_{20,t}$	1,6109	1,3551	1,19	0,2376
$\alpha_{22,t}$	1,4735	1,4089	1,05	0,2983
$\alpha_{24,t}$	-0,9241	1,3407	-0,69	0,4924
$\alpha_{29,t}$	2,0634	1,3729	1,50	0,1362

Model ARIMAX *outflow* uang kartal mengacu pada model regresi *time series* pada persamaan (4.2). Persamaan tersebut menghasilkan residual yang belum independen karena semua nilai *p-value* yang kurang dari $\alpha = 5\%$ hingga lag ke 36. Hal ini dapat dilihat pada Tabel 4.6.

Tabel 4.6 Hasil Uji Asumsi Independen Residual Regresi *Time Series Outflow*

Lag	χ^2	Df	<i>p-value</i>
6	15,26	6	0,0183
12	53,49	12	<0,0001
18	59,80	18	<0,0001
24	72,73	24	<0,0001
30	76,79	30	<0,0001
36	82,82	36	<0,0001

Tahap pertama yang dilakukan karena model pada persamaan (4.2) belum memenuhi asumsi independen adalah pembentukan model ARIMA dari residual pada persamaan tersebut dengan tujuan memperoleh model yang memenuhi asumsi independen. Plot ACF dan PACF dari residual pada persamaan (4.2) dapat dilihat pada Gambar 4.5.



Gambar 4.5 Plot ACF dan PACF dari Residual Regresi Time Series *Outflow* Uang Kartal.

Berdasarkan plot ACF dan PACF pada Gambar 4.5 Dapat dibentuk model ARIMA $(2,0,0)(1,0,0)^{12}$, ARIMA $(1,0,[2])(1,0,0)^{12}$ dan ARIMA $([2],0,1)(1,0,0)^{12}$. Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter, asumsi residual independen. Hasil pengujian tersebut dapat dilihat pada Tabel 4.7.

Tabel 4.7 Hasil Estimasi Parameter dan Uji Signifikansi Parameter *Outflow*

Model	Parameter	Estimasi	t-value	p-value	Kesimpulan
ARIMA $(2,0,0)(1,0,0)^{12}$	ϕ_1	0,2681	3,15	0,002	Signifikan
	ϕ_2	-0,2674	-3,14	0,0021	Signifikan
	Φ_1	0,4470	5,61	<0,0001	Signifikan
ARIMA $(1,0,[2])(1,0,0)^{12}$	θ_2	0,2387	2,66	0,0089	Signifikan
	ϕ_1	0,2756	3,12	0,0022	Signifikan
	Φ_1	0,4400	5,47	<0,0001	Signifikan
ARIMA $([2],0,1)(1,0,0)^{12}$	θ_1	-0,2730	-3,11	0,0023	Signifikan
	ϕ_2	-0,2060	-2,32	0,0221	Signifikan
	Φ_1	0,4421	5,52	<0,0001	Signifikan

Berdasarkan Tabel 4.7 dapat dilihat bahwa semua parameter pada model ARIMA $(2,0,0)(1,0,0)^{12}$, ARIMA $(1,0,[2])(1,0,0)^{12}$ dan ARIMA $([2],0,1)(1,0,0)^{12}$ signifikan dan menghasilkan residual yang independen. Pernyataan tersebut dijelaskan pada Tabel 4.8. Tidak ada nilai *p-value* yang kurang dari $\alpha = 5\%$ hingga lag ke 36.

Tabel 4.8 Hasil Uji Asumsi Independen Residual Regresi *Time Series Outflow*

Hingga Lag	ARIMA $(2,0,0)(1,0,0)^{12}$			ARIMA $(1,0,[2])(1,0,0)^{12}$			ARIMA $([2],0,1)(1,0,0)^{12}$		
	χ^2	Df	p-value	χ^2	Df	p-value	χ^2	Df	p-value
6	2,56	3	0,464	3,65	3	0,3024	2,45	3	0,4851
12	5,85	9	0,754	7,24	9	0,6117	6,25	9	0,7142
18	12,42	15	0,647	14,76	15	0,4688	13,28	15	0,5810
24	16,67	21	0,731	19,52	21	0,5520	17,61	21	0,6738
30	24,74	27	0,589	27,22	27	0,4520	25,85	27	0,5268
36	31,42	33	0,546	33,66	33	0,4354	32,00	33	0,5165

Ketiga model tersebut akan dianalisis lebih lanjut untuk membentuk model ARIMAX. Model pertama yang akan dianalisis adalah ARIMA $([2],0,1)(1,0,0)^{12}$ yang mengikuti persamaan

$$\varepsilon_t = -0,206\varepsilon_{t-2} + 0,442\varepsilon_{t-12} - 0,091\varepsilon_{t-14} + a_t + 0,273a_{t-1}. \quad (4.3)$$

Model ARIMA dari residual regresi *time series* pada persamaan (4.3) telah memenuhi asumsi independen, tahap berikutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series*

variasi kalender dan kemudian diestimasi secara simultan. Berdasarkan hasil estimasi parameter yang dilakukan, model ARIMAX dengan efek variasi kalender yang diperoleh adalah sebagai berikut

$$\begin{aligned}
 Z_{1,t}^* = & 0,016t + 5,878M_{1,t} + 5,513M_{2,t} + 7,018M_{3,t} + 7,687M_{4,t} + 7,883M_{5,t} + \\
 & 8,304M_{6,t} + 8,267M_{7,t} + 7,921M_{8,t} + 7,835M_{9,t} + 8,723M_{10,t} + 8,868M_{11,t} + \\
 & 11,785M_{12,t} - 2,1038I_t^{(49)} - 0,007tI_t^{(49)} - 3,005I_t^{(97)} + 0,028tI_t^{(97)} + \\
 & -1,842D_{0,t-1} - 1,082D_{2,t-1} - 0,647D_{7,t-1} + 0,777D_{9,t-1} + 1,141D_{11,t-1} + \\
 & 2,897D_{13,t-1} + 0,612D_{18,t-1} + 0,99D_{20,t-1} - 0,369D_{22,t-1} + 0,683D_{24,t-1} + \\
 & \gamma_{27}D_{27,t-1} + 1,476D_{29,t-1} + 0,087D_{0,t} + 0,159D_{2,t} + 0,02D_{7,t} + 0,52D_{9,t} + \\
 & 1,549D_{11,t} - 1,598D_{13,t} + 1,559D_{18,t} + 1,794D_{20,t} + 2,568D_{22,t} + 1,661D_{24,t} + \\
 & \alpha_{27}D_{27,t} - 0,749D_{29,t} + \frac{(1+0,608B)}{(1+0,248B^2)(1-0,574B^{12})} a_t. \tag{4.4}
 \end{aligned}$$

Selanjutnya dilakukan uji Kolmogorov-Smirnov (KS) komponen residual pada persamaan (4.4). Hasil pengujian ini menyimpulkan bahwa residual belum berdistribusi normal karena *p-value* kurang dari 0,05 (kurang dari $\alpha=5\%$) dengan nilai $D=0,109854$. Ketidaknormalan residual biasanya disebabkan kerena adanya *outlier* sehingga perlu dideteksi *outlier*, data *outlier* tersebut dapat dilihat pada Tabel 4.9. Setelah didapatkan *outlier* (observasi ke-61) ditambahkan dalam persamaan (4.4) dan kemudian diestimasi kembali diperoleh residual yang telah memenuhi asumsi independen dan berdistribusi normal dengan nilai $D=0,06717$ dan *p-value* sebesar 0,1488.

Tabel 4.9 Hasil Deteksi Data *Outlier Outflow*

Observasi	Type	Estimasi	χ^2	<i>p-value</i>
61	Additive	3,4093	57,03	<0,0001
73	Additive	-2,0047	20,25	<0,0001
96	Additive	1,5088	11,17	0,0008
110	Additive	1,6511	13,63	0,0002
85	Additive	-1,4829	11,11	0,0009
62	Additive	-1,3894	9,60	0,0019

Model ARIMAX yang diperoleh dengan residual independen hingga lag 36 dan berdistribusi normal dengan *p-value* sebesar 0,1488 (lebih dari sa) dapat dilihat pada persamaan (4.5). dengan penambahan variabel *dummy outlier* yang bersifat adatif, maka persamaan (4.4) dapat dituliskan menjadi persamaan (4.5).

$$\begin{aligned}
Z_{1,t}^* = & 0,016t + 5,878M_{1,t} + 5,513M_{2,t} + 7,018M_{3,t} + 7,687M_{4,t} + 7,883M_{5,t} + \\
& 8,304M_{6,t} + 8,267M_{7,t} + 7,921M_{8,t} + 7,835M_{9,t} + 8,723M_{10,t} + 8,868M_{11,t} + \\
& 11,785M_{12,t} - 2,1038I_t^{(49)} - 0,007tI_t^{(49)} - 3,005I_t^{(97)} + 0,028tI_t^{(97)} + \\
& -1,842D_{0,t-1} - 1,082D_{2,t-1} - 0,647D_{7,t-1} + 0,777D_{9,t-1} + 1,141D_{11,t-1} + \\
& 2,897D_{13,t-1} + 0,612D_{18,t-1} + 0,99D_{20,t-1} - 0,369D_{22,t-1} + 0,683D_{24,t-1} + \\
& \gamma_{27}D_{27,t-1} + 1,476D_{29,t-1} + 0,087D_{0,t} + 0,159D_{2,t} + 0,02D_{7,t} + 0,52D_{9,t} + \\
& 1,549D_{11,t} - 1,598D_{13,t} + 1,559D_{18,t} + 1,794D_{20,t} + 2,568D_{22,t} + 1,661D_{24,t} + \\
& \alpha_{27}D_{27,t} - 0,749D_{29,t} + 3,972V_{A,t}^{(61)} + \frac{(1+0,608B)}{(1+0,248B^2)(1-0,574B^{12})}a_t.
\end{aligned} \tag{4.5}$$

Dengan $V_{A,t}^{(T)}$ merupakan variabel *dummy outlier* yang bersifat adatif dengan T adalah observasi ke 61.

Dari persamaan (4.5) akan dilanjutkan ke ARIMAX level 2 yaitu untuk mengestimasi nilai parameter untuk γ_{27} dan α_{27} dengan rumus pada persamaan (4.6) dan (4.7) sebagai berikut.

$$\begin{aligned}
\hat{\gamma}_j &= \omega_0 + \omega_1 j \\
&= 1,43 - 0,0719 j
\end{aligned} \tag{4.6}$$

$$\begin{aligned}
\hat{\alpha}_j &= \nu_0 + \nu_1 j \\
&= -0,492 + 0,0838 j
\end{aligned} \tag{4.7}$$

yang diperoleh dari regresi *dummy* jumlah hari raya sebelum Idul Fitri dengan nilai estimasi parameternya. Dengan menggunakan rumus pada persamaan (4.6) dan (4.7) diperoleh nilai $\hat{\gamma}_{27} = -0,507$ dan $\hat{\alpha}_{27} = 1,77$. Sehingga persamaan (4.5) dapat dituliskan menjadi persamaan (4.8). Model ARIMAX pada persamaan (4.8) menggunakan semua parameter baik parameter yang signifikan maupun parameter yang tidak signifikan.

$$\begin{aligned}
Z_{1,t}^* = & 0,016t + 5,878M_{1,t} + 5,513M_{2,t} + 7,018M_{3,t} + 7,687M_{4,t} + 7,883M_{5,t} + \\
& 8,304M_{6,t} + 8,267M_{7,t} + 7,921M_{8,t} + 7,835M_{9,t} + 8,723M_{10,t} + 8,868M_{11,t} + \\
& 11,785M_{12,t} - 2,104I_t^{(49)} - 0,007tI_t^{(49)} - 3,005I_t^{(97)} + 0,028tI_t^{(97)} - 1,84D_{0,t-1} + \\
& -1,082D_{2,t-1} - 0,647D_{7,t-1} + 0,777D_{9,t-1} + 1,141D_{11,t-1} + 2,897D_{13,t-1} + \\
& 0,612D_{18,t-1} + 0,99D_{20,t-1} - 0,369D_{22,t-1} + 0,683D_{24,t-1} - 0,507D_{27,t-1} + \\
& 1,476D_{29,t-1} + 0,087D_{0,t} + 0,159D_{2,t} + 0,02D_{7,t} + 0,52D_{9,t} + 1,549D_{11,t} + \\
& -1,598D_{13,t} + 1,559D_{18,t} + 1,794D_{20,t} + 2,568D_{22,t} + 1,661D_{24,t} + 1,77D_{27,t} + \\
& -0,749D_{29,t} + 3,972V_{A,t}^{(61)} + \frac{(1+0,608B)}{(1+0,248B^2)(1-0,574B^{12})}a_t.
\end{aligned} \tag{4.8}$$

Tahap selanjutnya adalah mengeliminasi parameter yang tidak signifikan dari model pada persamaan (4.8). Hasil estimasi parameter yang signifikan tersebut dapat dilihat pada Tabel 4.10.

Tabel 4.10 Hasil Estimasi Parameter ARIMAX yang Telah Signifikan Data

Outflow

Parameter	Estimasi	Standard Error	t-value	p-value
θ_1	-0,8404	0,0569	-14,78	<0,0001
ϕ_2	0,6813	0,0795	8,57	<0,0001
δ	0,0208	0,0055	3,76	0,0003
β_1	5,8721	0,6220	9,44	<0,0001
β_2	5,3874	0,7794	6,91	<0,0001
β_3	6,6930	0,7748	8,64	<0,0001
β_4	7,3754	0,7768	9,49	<0,0001
β_5	7,6042	0,7785	9,77	<0,0001
β_6	8,4618	0,7982	10,60	<0,0001
β_7	8,2158	0,7824	10,50	<0,0001
β_8	8,0260	0,7870	10,20	<0,0001
β_9	7,9471	0,7873	10,09	<0,0001
β_{10}	8,0217	0,7911	10,14	<0,0001
β_{11}	8,7704	0,7912	11,08	<0,0001
β_{12}	11,4508	0,6379	17,95	<0,0001
φ_1	-1,2204	0,2841	-4,30	<0,0001
$\gamma_{0,t-1}$	1,7895	0,6588	2,72	0,0077
$\alpha_{0,t}$	-2,8895	0,7042	-4,10	<0,0001
$\alpha_{7,t}$	-2,4284	0,5119	-4,74	<0,0001
$\alpha_{29,t}$	2,6002	0,3878	6,70	<0,0001

Berdasarkan hasil estimasi parameter pada Tabel 4.10 Maka persamaan (4.8) dapat dituliskan menjadi

$$\begin{aligned}
 Z_{1,t}^* = & 0,021t + 5,872M_{1,t} + 5,387M_{2,t} + 6,693M_{3,t} + 7,375M_{4,t} + 7,604M_{5,t} + \\
 & 8,462M_{6,t} + 8,216M_{7,t} + 8,026M_{8,t} + 7,947M_{9,t} + 8,022M_{10,t} + 8,77M_{11,t} + \\
 & 11,451M_{12,t} - 1,22I_t^{(49)} + 1,789D_{0,t-1} - 2,889D_{0,t} - 2,428D_{7,t} + 2,075D_{27,t} + \quad (4.9) \\
 & 2,6D_{29,t} + 2,896V_{A,t}^{(61)} - 2,177V_{A,t}^{(73)} + 1,69V_{A,t}^{(110)} - 1,37V_{A,t}^{(6)} + \frac{(1+0,840B)}{(1-0,681B^{12})}a_t.
 \end{aligned}$$

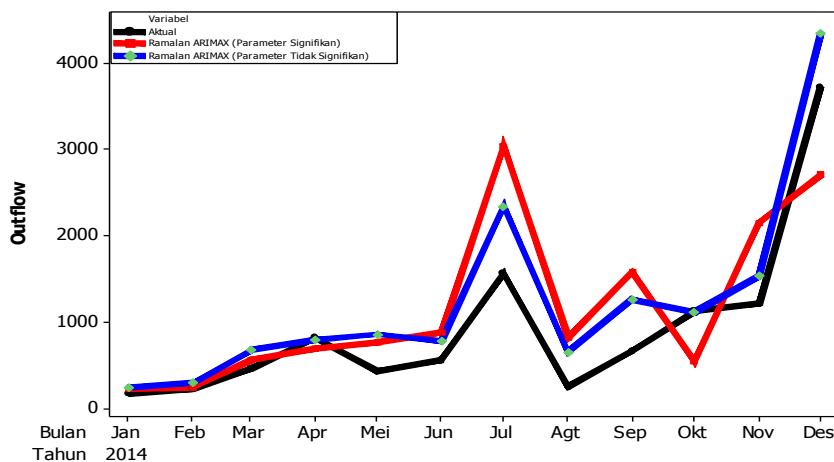
Analisis selanjutnya adalah membandingkan kebaikan model dengan kriteria sMAPE *out-sample*. Perbandingan antara model ARIMAX yang memuat parameter yang tidak signifikan dengan model ARIMAX yang hanya memuat

parameter signifikan dapat dilihat pada Tabel 4.11. Model ARIMAX yang memuat parameter yang tidak signifikan memberikan hasil yang lebih baik untuk meramalkan *outflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 38,62%. Mengacu pada pernyataan Hyndman dan Kostenko (2008), maka model yang akan digunakan untuk meramalkan *outflow* hingga 12 bulan kedepan adalah ARIMAX yang memuat parameter yang tidak signifikan.

Tabel 4.11 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data *Outflow*

ARIMAX	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
Parameter signifikan	219,78	694,55	25,31%	47,87%
Semua parameter	235,80	397,57	25,73%	35,55%

Secara visual perbandingan hasil ramalan *outflow* antara model ARIMAX yang memuat semua parameter dengan model ARIMAX yang hanya memuat parameter signifikan dapat dilihat pada Gambar 4.6.



Gambar 4.6 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data *Outflow*

Dengan cara yang sama model ARIMA $(2,0,0)(1,0,0)^{12}$ dan ARIMA $(1,0,[2])(1,0,0)^{12}$ juga dianalisis lebih lanjut untuk membentuk model ARIMAX. Sehingga diperoleh hasil ramalan yang dijelaskan pada Tabel 4.12.

Tabel 4.12 Nilai Ramalan *Out-sample* Model ARIMAX untuk Data *Outflow*

t (Bulan)	Aktual	Ramalan ARIMAX		
		$(2,0,0)(1,0,0)^{12}$	$(1,0,[2])(1,0,0)^{12}$	$([2],0,1)(1,0,0)^{12}$
1	173,99	301,31	302,42	251,47
2	234,36	310,81	298,82	301,81
3	468,82	697,19	659,10	680,61
4	827,07	815,12	825,82	795,92
5	442,07	854,64	892,19	867,84
6	570,11	781,85	875,61	794,52
7	1566,17	2622,75	2155,03	2346,59
8	265,48	701,29	956,61	663,78
9	675,74	1395,19	1210,03	1271,83
10	1133,79	1093,96	1246,68	1123,60
11	1221,34	1567,75	1845,84	1544,88
12	3726,05	4152,80	4414,96	4343,25

Perbandingan kebaikan model dengan kriteria sMAPE *out-sample* dapat dilihat pada Tabel 4.13 Model ARIMAX $([2],0,1)(1,0,0)^{12}$ dengan efek variasi kalender merupakan model terbaik yang bisa digunakan untuk meramalkan data *outflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 38,62%.

Tabel 4.13 Perbandingan Hasil Ramalan Model ARIMAX

ARIMAX	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
$(2,0,0)(1,0,0)^{12}$	256,49	448,79	25,81%	38,88%
$(1,0,[2])(1,0,0)^{12}$	263,99	441,59	26,53%	40,86%
$([2],0,1)(1,0,0)^{12}$	235,80	397,57	25,73%	35,55%

Setelah memenuhi kedua asumsi yaitu residual independen dan distribusi normal, maka uji residual dilanjutkan pada pengujian varians residual homogen. Apabila varians residual tidak homogen maka akan dilanjutkan pemodelan GARCH. Untuk mendeteksi apakah varians homogen atau tidak adalah dengan melakukan pemeriksaan terhadap residual dari model ARIMAX dengan efek variasi kalender pada persamaan (4.8) menggunakan uji *portmanteau*. Hipotesis awal varians residual adalah homogen (tidak terdapat proses GARCH). Hasil uji *portmanteau* dapat dilihat pada Tabel 4.14. Tabel tersebut menunjukkan hasil uji varians homogen menggunakan uji *portmanteau* bahwa varians residual telah homogen karena semua nilai *p-value* lebih dari 0,05 ($\alpha = 5\%$). Sehingga dapat diperoleh kesimpulan bahwa model ARIMAX dengan efek variasi kalender

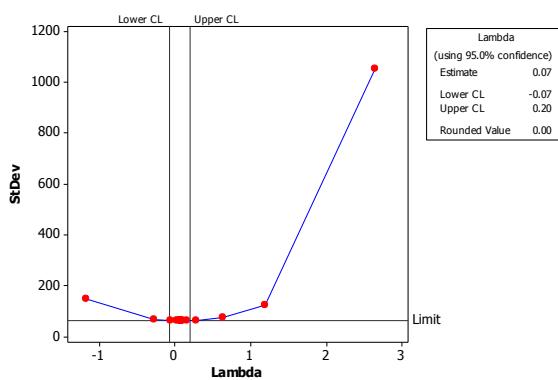
outflow uang kartal pada persamaan (4.8) telah memenuhi asumsi residual *white noise* dan berdistribusi normal. Model tersebut mempunyai nilai RMSE *in-sample* sebesar 235,8. Apabila dibandingkan dengan nilai standard deviasi, maka dapat disimpulkan bahwa model ARIMAX dengan efek variasi kalender tersebut sudah layak digunakan karena mempunyai nilai RMSE yang lebih kecil dibandingkan dengan standard deviasi sebesar *outflow* sebesar 643.

Tabel 4.14 Uji Heteroskedastisitas Model ARIMAX Data *Outflow*

<i>k</i>	<i>Q</i>	Pr> <i>Q</i>
1	0,4974	0,4806
2	0,5370	0,7645
3	0,5931	0,8980
4	0,5975	0,9633
5	0,6240	0,9869
6	0,6719	0,9951
7	0,7240	0,9981
8	0,7268	0,9995
9	0,8269	0,9997
10	0,9475	0,9999
11	1,4608	0,9997
12	8,3593	0,7565

4.2.2 Model ARIMAX untuk Data *Inflow*

Data *inflow* uang kartal pada penelitian ini belum stasioner dalam varians. Hal tersebut dapat dilihat pada Gambar 4.7 dengan nilai *rounded value* yang dihasilkan sebesar 0,00 dengan batas atas sebesar 0,20 dan batas bawah sebesar -0,07. Oleh karena itu perlu dilakukan transformasi data dengan menggunakan transformasi Box-Cox.



Gambar 4.7 Box-Cox Data *Inflow* Uang Kartal

Tahap awal pembentukan model ARIMAX mengacu pada pemodelan regresi *time series*. Data *outflow* pada penelitian ini belum stasioner dalam varians, sehingga data perlu distasionerkan terlebih dahulu dengan transformasi Box-Cox dengan nilai *rounded value* sebesar 0,00 sehingga hasil transformasi tersebut dapat dituliskan sebagai berikut.

$$Z_{2,t}^* = \ln(Z_{2,t})$$

Model regresi *time series* untuk *inflow* uang kartal dapat diduga sebagai berikut.

$$\begin{aligned} Z_{2,t}^* = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{5,t} + \beta_6 M_{6,t} + \\ & \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \\ & \varphi_1 I_t^{(49)} + \varphi_2 t I_t^{(49)} + \varphi_3 I_t^{(97)} + \varphi_4 t I_t^{(97)} + \alpha_0 D_{0,t} + \alpha_2 D_{2,t} + \alpha_7 D_{7,t} + \\ & \alpha_9 D_{9,t} + \alpha_{11} D_{11,t} + \alpha_{13} D_{13,t} + \alpha_{18} D_{18,t} + \alpha_{20} D_{20,t} + \alpha_{22} D_{22,t} + \quad (4.10) \\ & \alpha_{24} D_{24,t} + \alpha_{27} D_{27,t} + \alpha_{29} D_{29,t} + \xi_0 D_{0,t+1} + \xi_2 D_{2,t+1} + \xi_7 D_{7,t+1} + \\ & \xi_9 D_{9,t+1} + \xi_{11} D_{11,t+1} + \xi_{13} D_{13,t+1} + \xi_{18} D_{18,t+1} + \xi_{20} D_{20,t+1} + \xi_{22} D_{22,t+1} + \\ & \xi_{24} D_{24,t+1} + \xi_{27} D_{27,t+1} + \xi_{29} D_{29,t+1} + \varepsilon_t. \end{aligned}$$

dengan $I_t^{(T)}$ merupakan variabel *dummy* intervensi akibat adanya kebijakan baru yang diberlakukan oleh BI.

Tahap selanjutnya adalah melakukan estimasi parameter dari model dugaan regresi *time series* tersebut. Hasil estimasi parameter tersebut dapat dilihat pada Tabel 4.15.

Tabel 4.15 Hasil Estimasi Parameter Regresi *Time Series Inflow*

Parameter	Estimasi	Standard Error	t-value	p-value
δ	0,0175	0,0069	2,53	0,013
β_1	5,6880	0,2470	23,03	<0,0001
β_2	5,2720	0,2484	21,23	<0,0001
β_3	4,7752	0,2498	19,11	<0,0001
β_4	4,7372	0,2514	18,84	<0,0001
β_5	4,5458	0,2530	17,97	<0,0001
β_6	4,5466	0,2547	17,85	<0,0001
β_7	4,6106	0,2565	17,97	<0,0001
β_8	4,5634	0,2796	16,32	<0,0001
β_9	4,7058	0,3048	15,44	<0,0001
β_{10}	4,7873	0,2994	15,99	<0,0001
β_{11}	4,7063	0,3429	13,72	<0,0001
β_{12}	4,2697	0,3018	14,15	<0,0001
φ_1	-1,2210	0,5362	-2,28	0,0251

Tabel 4.15 (Lanjutan)

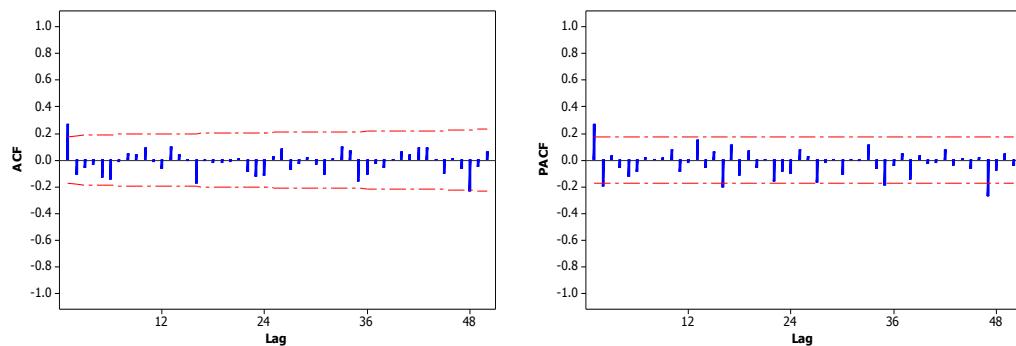
Parameter	Estimasi	Standard Error	t-value	p-value
φ_2	-0,0127	0,0097	-1,30	0,1956
φ_3	-3,7727	1,2245	-3,08	0,0027
φ_4	0,0248	0,0126	1,97	0,0513
$\alpha_{0,t}$	0,4535	0,6530	0,69	0,4891
$\alpha_{2,t}$	0,2450	0,6702	0,37	0,7156
$\alpha_{7,t}$	0,6498	0,6615	0,98	0,3285
$\alpha_{9,t}$	0,3496	0,6701	0,52	0,6031
$\alpha_{11,t}$	0,6380	0,6599	0,97	0,3362
$\alpha_{13,t}$	0,0872	0,6658	0,13	0,8961
$\alpha_{18,t}$	0,7241	0,6442	1,12	0,2638
$\alpha_{20,t}$	-0,8808	0,6537	-1,35	0,1811
$\alpha_{22,t}$	0,3223	0,6656	0,48	0,6293
$\alpha_{24,t}$	-0,3153	0,6715	-0,47	0,6398
$\alpha_{29,t}$	0,3353	0,6518	0,51	0,6082
$\xi_{0,t+1}$	-0,5695	0,6597	-0,86	0,3902
$\xi_{2,t+1}$	0,6906	0,6430	1,07	0,2856
$\xi_{7,t+1}$	-0,3420	0,6766	-0,51	0,6144
$\xi_{9,t+1}$	-0,0026	0,6710	0,00	0,997
$\xi_{11,t+1}$	0,2628	0,6721	0,39	0,6967
$\xi_{13,t+1}$	0,7133	0,6402	1,11	0,2681
$\xi_{18,t+1}$	0,2787	0,6572	0,42	0,6725
$\xi_{20,t+1}$	0,0810	0,6568	0,12	0,9021
$\xi_{22,t+1}$	0,5873	0,6847	0,86	0,3932
$\xi_{24,t+1}$	1,0473	0,6479	1,62	0,1094
$\xi_{29,t+1}$	1,0179	0,6624	1,54	0,1278

Model ARIMAX *inflow* uang kartal mengacu pada model regresi *time series* pada persamaan (4.11). Persamaan tersebut menghasilkan residual yang belum independen karena masih ada nilai *p-value* yang kurang dari $\alpha=5\%$ hingga lag ke 36. Hal ini dapat dilihat pada Tabel 4.16.

Tabel 4.16 Hasil Uji Independen Residual Regresi *Time Series Inflow*

Lag	χ^2	Df	p-value
6	17,48	6	0,0077
12	20,01	12	0,0670
18	26,25	18	0,0941
24	32,13	24	0,1239
30	34,48	30	0,2621
36	46,33	36	0,1162

Tahap pertama yang dilakukan karena model pada persamaan (4.11) belum memenuhi asumsi independen adalah pembentukan model ARIMA dari residual pada persamaan tersebut dengan tujuan memperoleh model yang memenuhi asumsi independen. Plot ACF dan PACF dari residual pada persamaan (4.11) dapat dilihat pada Gambar 4.8.



Gambar 4.8 Plot ACF dan PACF dari Residual Model Regresi Time Series *Inflow* Uang Kartal.

Berdasarkan plot ACF dan PACF pada Gambar 4.8 dapat dibentuk model ARIMA $(1,0,0)(1,0,0)^{48}$ dan ARIMA $(0,0,1)(1,0,0)^{48}$. Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter dan asumsi residual independen. Hasil pengujian tersebut dapat dilihat pada Tabel 4.17.

Tabel 4.17 Estimasi Parameter dan Uji Signifikansi Parameter *Inflow*

Model	Parameter	Estimasi	t-value	p-value	Kesimpulan
ARIMA $(1,0,0)(1,0,0)^{48}$	ϕ_1	0,2979	3,55	0,0005	Signifikan
	Φ_1	-0,6683	-4,94	<0,0001	Signifikan
ARIMA $(0,0,1)(1,0,0)^{48}$	θ_1	-0,3371	-4,06	<0,0001	Signifikan
	Φ_1	-0,6170	-4,63	<0,0001	Signifikan

Dari Tabel 4.17 dapat dilihat bahwa semua parameter pada model ARIMA $(1,0,0)(1,0,0)^{48}$ dan $(0,0,1)(1,0,0)^{48}$ signifikan dan menghasilkan residual yang independen. Pernyataan tersebut dapat dilihat pada Tabel 4.18 Tidak ada nilai p-value yang kurang dari $\alpha = 5\%$ hingga lag ke 36.

Tabel 4.18 Hasil Uji Asumsi Independen Residual Regresi *Time Series Inflow*

Lag	ARIMA (1,0,0)(1,0,0) ⁴⁸			ARIMA (0,0,1)(1,0,0) ⁴⁸		
	χ^2	df	p-value	χ^2	df	p-value
6	3,37	4	0,4978	1,55	4	0,8181
12	9,36	10	0,4980	7,21	10	0,7057
18	18,12	16	0,3171	17,80	16	0,3360
24	22,54	22	0,4280	22,18	22	0,4494
30	24,67	28	0,6456	24,35	28	0,6629
36	34,58	34	0,4403	32,46	34	0,5433

Kedua model tersebut akan dianalisis lebih lanjut untuk membentuk model ARIMAX. Model pertama yang akan dianalisis adalah ARIMA (1,0,0)(1,0,0)⁴⁸ yang mengikuti persamaan

$$\varepsilon_t = 0,298\varepsilon_{t-1} - 0,668\varepsilon_{t-48} + 0,199\varepsilon_{t-49} + a_t. \quad (4.12)$$

Model ARIMA dari residual regresi *time series* pada persamaan (4.12) yang memenuhi asumsi independen, tahap berikutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* variasi kalender dan kemudian diestimasi secara simultan. Berdasarkan hasil estimasi parameter yang dilakukan, model ARIMAX yang diperoleh adalah sebagai berikut

$$\begin{aligned} Z_{2,t}^* = & 0,014t + 5,871M_{1,t} + 5,382M_{2,t} + 4,843M_{3,t} + 4,781M_{4,t} + 4,564M_{5,t} + \\ & 4,568M_{6,t} + 4,61M_{7,t} + 4,634M_{8,t} + 4,713M_{9,t} + 4,78M_{10,t} + 4,445M_{11,t} + \\ & 4,277M_{12,t} - 1,959I_t^{(49)} + 0,002tI_t^{(49)} - 3,113I_t^{(97)} + 0,02tI_t^{(97)} + 0,835D_{0,t} + \\ & 0,442D_{2,t} + 0,295D_{7,t} + 0,224D_{9,t} + 0,989D_{11,t} + 0,196D_{13,t} + 0,403D_{18,t} + \\ & -0,445D_{20,t} + 0,454D_{22,t} - 0,228D_{24,t} + \alpha_{27}D_{27,t} + 0,14D_{29,t} + \\ & 0,236D_{0,t+1} + 0,543D_{2,t+1} - 0,195D_{7,t+1} - 0,551D_{9,t+1} + 0,916D_{11,t+1} + \\ & 0,489D_{13,t+1} - 0,006D_{18,t+1} + 0,099D_{20,t+1} + 1,343D_{22,t+1} + \\ & 1,175D_{24,t+1} + \xi_{27}D_{27,t+1} + 0,855D_{29,t+1} + \frac{a_t}{(1-0,445B)(1+0,904B^{48})}. \end{aligned} \quad (4.13)$$

Selanjutnya dilakukan uji Kolmogorov-Smirnov (KS) komponen residual pada persamaan (4.13). Hasil pengujian ini menyimpulkan bahwa residual belum berdistribusi normal karena p-value kurang dari 0,05 (kurang dari $\alpha=5\%$) dengan nilai $D=0,092008$. Ketidaknormalan residual biasanya disebabkan kerena adanya *outlier* sehingga perlu dideteksi *outlier*, data *outlier* tersebut dapat dilihat pada Tabel 4.19.

Tabel 4.19 Hasil Deteksi Data *Outlier Inflow*

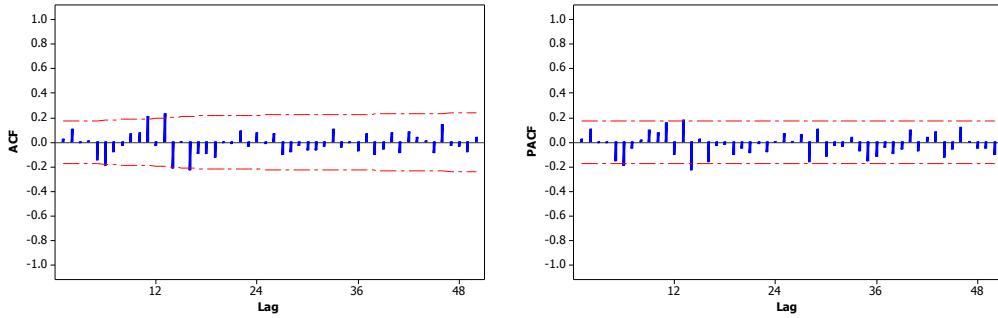
Observasi	Type	Estimasi	χ^2	p-value
97	Additive	-1,7567	117,67	<0,0001
73	Additive	0,8688	50,16	<0,0001
62	Additive	0,8280	44,20	<0,0001
98	Additive	-1,0637	40,15	<0,0001
87	Additive	-1,0224	37,09	<0,0001
75	Additive	0,7190	29,58	<0,0001
1	Additive	0,8259	20,20	<0,0001
123	Shift	-0,4055	18,34	<0,0001
92	Shift	0,2446	23,57	<0,0001
127	Additive	-0,6067	13,46	0,0002
86	Additive	0,5357	10,50	0,0012
69	Shift	-0,1021	12,68	0,0004
85	Shift	0,1523	13,80	0,0002

Setelah beberapa *outlier* (observasi ke 97, 98 dan 86) ditambahkan dalam persamaan (4.13) dan kemudian diestimasi kembali diperoleh residual yang telah berdistribusi normal dengan nilai $D = 0,05664$ dan p-value sebesar 0,15 namun Model ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan efek variasi kalender tersebut menjadi tidak memenuhi asumsi residual independen. Pernyataan tersebut dijelaskan pada Tabel 4.20 masih ada nilai p-value yang kurang dari $\alpha = 5\%$ hingga lag ke 36.

Tabel 4.20 Hasil Uji Asumsi Independen Residual ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender

Lag	χ^2	Df	p-value
6	17,48	6	0,0077
12	20,01	12	0,0670
18	26,25	18	0,0941
24	32,13	24	0,1239
30	34,48	30	0,2621
36	46,33	36	0,1162

Karena residual model ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan efek variasi kalender belum independen maka perlu dilakukan pemodelan ARIMAX yang memenuhi asumsi residual independen dengan menggunakan plot ACF dan PACF dari residual ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan efek variasi kalender. Plot ACF dan PACF dari residual ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan efek variasi kalender dapat dilihat pada Gambar 4.9.



Gambar 4.9 Plot ACF dan PACF dari Residual ARIMAX $(1,0,0)(1,0,0)^{48}$ dengan Efek Variasi Kalender *Inflow* Uang Kartal.

Berdasarkan plot ACF dan PACF pada Gambar 4.9 dapat dibentuk model ARIMAX $([1,13,14],0,0)(1,0,0)^{48}$ dan ARIMAX $([1,2,6,14],0,0)(1,0,0)^{48}$ dengan efek variasi kalender yang telah memenuhi asumsi residual independen. Pernyataan tersebut dapat dilihat pada Tabel 4.21 masih ada nilai *p-value* yang kurang dari $\alpha=5\%$ hingga lag ke 36. Residual juga telah berdistribusi normal dengan nilai $D=0,042628$ untuk ARIMAX $([1,13,14],0,0)(1,0,0)^{48}$ dan nilai $D=0,062568$ untuk ARIMAX $([1,2,6,14],0,0)(1,0,0)^{48}$.

Tabel 4.21 Hasil Uji Independen Residual ARIMAX Data *Inflow*

Lag	ARIMAX ([1,13,14],0,0)(1,0,0) ⁴⁸			ARIMAX ([1,2,6,14],0,0)(1,0,0) ⁴⁸		
	χ^2	Df	<i>p-value</i>	χ^2	Df	<i>p-value</i>
6	5,11	2	0,0778	2,33	1	0,1268
12	7,80	8	0,4528	7,41	7	0,3872
18	14,74	14	0,3960	17,86	13	0,1630
24	16,26	20	0,7003	24,76	19	0,1686
30	20,59	26	0,7629	28,99	25	0,2645
36	28,52	32	0,6434	33,20	31	0,3604

$$\begin{aligned}
 Z_{2,t}^* = & 0,017t + 6,015M_{1,t} + 5,376M_{2,t} + 4,723M_{3,t} + 4,671M_{4,t} + 4,452M_{5,t} + \\
 & 4,47M_{6,t} + 4,515M_{7,t} + 4,588M_{8,t} + 4,675M_{9,t} + 4,69M_{10,t} + 4,404M_{11,t} + \\
 & 4,204M_{12,t} - 1,555I_t^{(49)} - 0,009tI_t^{(49)} + 0,183I_t^{(97)} - 0,008tI_t^{(97)} - 0,337D_{0,t} + \\
 & 0,074D_{2,t} + 0,819D_{7,t} + 0,551D_{9,t} + 1,156D_{11,t} + 1,108D_{13,t} - 0,053D_{18,t} + \\
 & 0,277D_{20,t} - 0,092D_{22,t} + 0,173D_{24,t} + \alpha_{27}D_{27,t} + 0,467D_{29,t} + 1,279D_{0,t+1} + \\
 & 0,81D_{2,t+1} + 0,68D_{7,t+1} + 1,011D_{9,t+1} + 1,29D_{11,t+1} + 0,613D_{13,t+1} + 0,527D_{18,t+1} + \\
 & -0,524D_{20,t+1} + 0,53D_{22,t+1} + 0,06D_{24,t+1} + \xi_{27}D_{27,t+1} - 0,21D_{29,t+1} - 4,225V_{A,t}^{97} + \\
 & -2,464V_{A,t}^{98} + 0,859V_{A,t}^{86} + \frac{a_t}{(1 - 0,504B - 0,355B^{13} + 0,571B^{14})(1 + 0,493B^{48})}. \tag{4.14}
 \end{aligned}$$

Model ARIMAX $([1,13,14], 0,0)(1,0,0)^{48}$ dengan efek variasi kalender yang telah memenuhi asumsi residual independen dan berdistribusi normal mengikuti persamaan (4.14) dengan $V_{A,t}^{(T)}$ merupakan variabel *dummy outlier* yang bersifat adatif dengan T adalah observasi ke 97, 98 dan 86.

Dari persamaan (4.14) akan dilanjutkan ke ARIMAX level 2 yaitu untuk mengestimasi nilai parameter untuk α_{27} dan ξ_{27} dengan rumus pada persamaan (4.15) dan (4.16) sebagai berikut.

$$\begin{aligned}\hat{\alpha}_j &= \nu_0 + \nu_1 j \\ &= 0,928 - 0,0392 j\end{aligned}\tag{4.15}$$

$$\begin{aligned}\hat{\xi}_j &= \zeta_0 + \zeta_1 j \\ &= 0,317 + 0,0166 j\end{aligned}\tag{4.16}$$

yang diperoleh dari regresi *dummy* jumlah hari raya sebelum Idul Fitri dengan nilai estimasi parameternya. Dengan menggunakan rumus pada persamaan (4.15) dan (4.16) diperoleh nilai $\hat{\alpha}_{27} = -0,128811$ dan $\hat{\xi}_{27} = 0,764869$. Sehingga persamaan (4.14) dapat dituliskan menjadi persamaan (4.17). Model ARIMAX pada persamaan (4.17) menggunakan semua parameter baik parameter yang signifikan maupun parameter yang tidak signifikan.

$$\begin{aligned}Z_{2,t}^* = & 0,017t + 6,015M_{1,t} + 5,376M_{2,t} + 4,723M_{3,t} + 4,671M_{4,t} + 4,452M_{5,t} + \\ & 4,47M_{6,t} + 4,515M_{7,t} + 4,588M_{8,t} + 4,675M_{9,t} + 4,692M_{10,t} + 4,404M_{11,t} + \\ & 4,204M_{12,t} - 1,555I_t^{(49)} - 0,009tI_t^{(49)} + 0,183I_t^{(97)} - 0,008tI_t^{(97)} - 0,337D_{0,t} + \\ & 0,074D_{2,t} + 0,819D_{7,t} + 0,551D_{9,t} + 1,156D_{11,t} + 1,108D_{13,t} - 0,053D_{18,t} + \\ & 0,277D_{20,t} - 0,092D_{22,t} + 0,173D_{24,t} - 0,129D_{27,t} + 0,467D_{29,t} + 1,279D_{0,t+1} + \\ & 0,813D_{2,t+1} + 0,679D_{7,t+1} + 1,011D_{9,t+1} + 1,288D_{11,t+1} + 0,613D_{13,t+1} + 0,53D_{18,t+1} + \\ & -0,524D_{20,t+1} + 0,529D_{22,t+1} + 0,055D_{24,t+1} + 0,77D_{27,t+1} - 0,21D_{29,t+1} - 4,23V_{A,t}^{97} + \\ & -2,464V_{A,t}^{98} + 0,859V_{A,t}^{86} + \frac{a_t}{(1 - 0,504B - 0,355B^{13} + 0,571B^{14})(1 + 0,493B^{48})}.\end{aligned}\tag{4.17}$$

Tahap selanjutnya adalah mengeliminasi parameter yang tidak signifikan dari model pada persamaan (4.17). Hasil estimasi parameter yang signifikan tersebut dapat dilihat pada Tabel 4.22. Berdasarkan hasil estimasi parameter pada Tabel 4.22 maka persamaan (4.17) dapat dituliskan menjadi persamaan (4.18).

Tabel 4.22 Hasil Estimasi Parameter ARIMAX yang Telah Signifikan Data

Inflow

Parameter	Estimasi	Standard Error	t-value	p-value
ϕ_1	0,4757	0,0836	5,69	<0,0001
ϕ_{13}	0,2898	0,0982	2,95	0,0039
ϕ_{14}	-0,4696	0,1003	-4,68	<0,0001
ϕ_{48}	-0,5852	0,1195	-4,90	<0,0001
δ	0,0100	0,0012	8,54	<0,0001
β_1	6,1491	0,1190	51,68	<0,0001
β_2	5,5100	0,1234	44,64	<0,0001
β_3	4,8617	0,1206	40,31	<0,0001
β_4	4,8020	0,1215	39,53	<0,0001
β_5	4,5826	0,1223	37,46	<0,0001
β_6	4,6088	0,1228	37,55	<0,0001
β_7	4,6634	0,1232	37,86	<0,0001
β_8	4,7784	0,1236	38,65	<0,0001
β_9	4,8150	0,1258	38,27	<0,0001
β_{10}	5,1984	0,1262	41,18	<0,0001
β_{11}	4,6187	0,1378	33,51	<0,0001
β_{12}	4,3450	0,1381	31,47	<0,0001
φ_1	-1,7412	0,1436	-12,13	<0,0001
$\alpha_{2,t}$	0,7465	0,2889	2,58	0,0112
$\xi_{2,t+1}$	0,6364	0,2889	2,20	0,0299
$\xi_{9,t+1}$	-0,8773	0,3038	-2,89	0,0047
$\xi_{11,t+1}$	0,8005	0,2931	2,73	0,0074
$\xi_{13,t+1}$	0,7403	0,2703	2,74	0,0073
$\xi_{22,t+1}$	1,0349	0,2754	3,76	0,0003
$\xi_{24,t+1}$	1,4069	0,2666	5,28	<0,0001
$\xi_{29,t+1}$	0,6521	0,3036	2,15	0,0341

$$\begin{aligned}
 Z_{2,t}^* = & 0,01t + 6,149M_{1,t} + 5,51M_{2,t} + 4,862M_{3,t} + 4,802M_{4,t} + 4,583M_{5,t} + \\
 & 4,609M_{6,t} + 4,663M_{7,t} + 4,778M_{8,t} + 4,815M_{9,t} + 5,198M_{10,t} + 4,619M_{11,t} + \\
 & 4,345M_{12,t} - 1,741I_t^{(49)} + 0,746D_{2,t} + 0,636D_{2,t+1} - 0,877D_{9,t+1} + 0,801D_{11,t+1} + \\
 & 0,74D_{13,t+1} + 1,035D_{22,t+1} + 1,407D_{24,t+1} + 0,765D_{27,t+1} + 0,652D_{29,t+1} - 4,168V_{A,t}^{(97)} + \\
 & -2,362V_{A,t}^{(98)} + 0,898V_{A,t}^{(86)} + \frac{a_t}{(1 - 0,476B - 0,29B^{13} + 0,47B^{14})(1 + 0,585B^{48})}. \quad (4.18)
 \end{aligned}$$

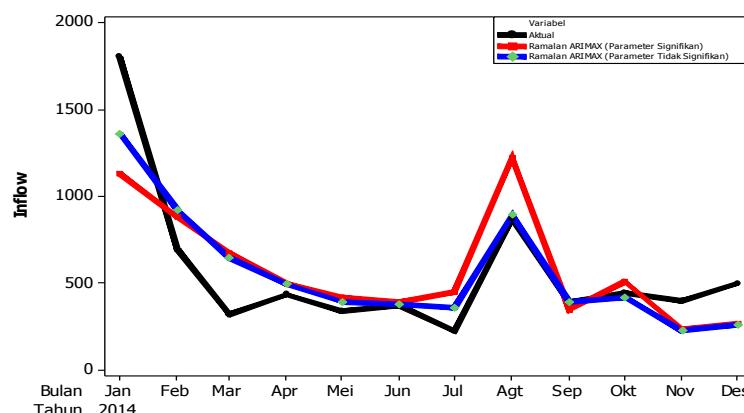
Analisis selanjutnya adalah membandingkan kebaikan model dengan kriteria sMAPE *out-sample*. Perbandingan antara model ARIMAX yang memuat parameter yang tidak signifikan dengan model ARIMAX yang hanya memuat parameter signifikan dapat dilihat pada Tabel 4.23. Model ARIMAX yang

memuat parameter yang tidak signifikan memberikan hasil yang lebih baik untuk meramalkan *inflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 38,62%. Mengacu pada pernyataan Hyndman dan Kostenko (2008), maka model yang akan digunakan untuk meramalkan *inflow* hingga 12 bulan kedepan adalah ARIMAX yang memuat parameter yang tidak signifikan.

Tabel 4.23 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data *Inflow*

ARIMAX	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
Parameter signifikan	96,55	271,04	24,24%	34,72%
Semua parameter	76,89	196,53	21,27%	27,08%

Secara visual perbandingan hasil ramalan *inflow* antara model ARIMAX yang memuat semua parameter dengan model ARIMAX yang hanya memuat parameter signifikan dapat dilihat pada Gambar 4.10.



Gambar 4.10 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX yang Memuat Parameter Signifikan dengan Semua Parameter Data *Inflow*

Dengan menggunakan cara yang sama ARIMA $(0,0,1)(1,0,0)^{48}$ juga dianalisis lebih lanjut untuk membentuk model ARIMAX dan diperoleh model ARIMAX $([13,14],0,1)(1,0,0)^{48}$ yang memenuhi asumsi residual independen dan berdistribusi normal. Sehingga dari ketiga model ARIMAX dengan efek variasi kalender yang memenuhi asumsi residual independen dan berdistribusi normal diperoleh hasil ramalan yang dijelaskan pada Tabel 4.24.

Tabel 4.24 Nilai Ramalan *Out-sample* Model ARIMAX untuk Data *Inflow*

t (Bulan)	Aktual	Ramalan ARIMAX		
		([1,13,14],0,0)(1,0,0) ⁴⁸	([1,2,6,14],0,0)(1,0,0) ⁴⁸	([13,14],0,1)(1,0,0) ⁴⁸
1	1800,582	1361,660	1205,681	1376,184
2	691,509	921,765	549,166	545,957
3	321,080	646,026	515,146	536,851
4	435,544	494,838	398,924	477,976
5	339,995	395,429	328,981	378,501
6	372,520	380,456	265,440	363,297
7	227,390	361,423	283,278	348,792
8	870,095	892,573	617,923	755,177
9	391,761	391,145	267,866	373,160
10	446,039	421,669	272,446	369,420
11	397,412	227,027	243,355	199,408
12	499,743	259,994	211,349	212,698

Perbandingan kebaikan model dengan kriteria sMAPE *out-sample* dapat dilihat pada Tabel 4.25 Model ARIMAX $([1,13,14],0,0)(1,0,0)^{48}$ dengan efek variasi kalender merupakan model terbaik yang bisa digunakan untuk meramalkan data *outflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 27,08%.

Tabel 4.25 Perbandingan Hasil Ramalan Model ARIMAX Data *Inflow*

ARIMAX	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
$([1,13,14],0,0)(1,0,0)^{48}$	76,89	196,53	21,27%	27,08%
$([1,2,6,14],0,0)(1,0,0)^{48}$	69,75	231,64	21,32%	35,45%
$([13,14],0,1)(1,0,0)^{48}$	75,65	184,16	21,62%	29,16%

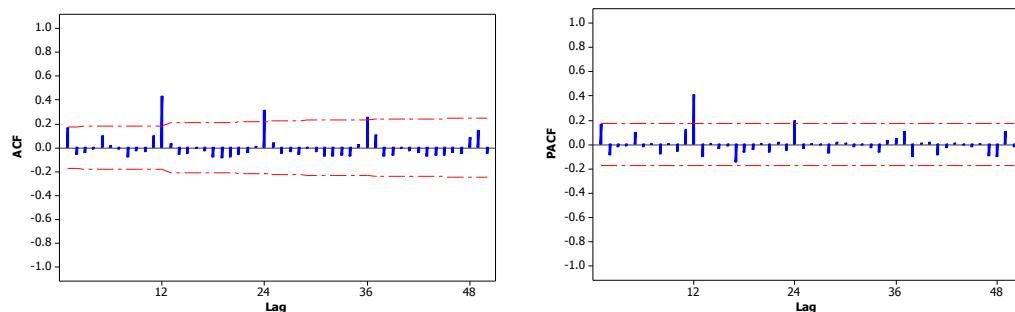
Setelah mendapatkan semua variabel yang signifikan dan memenuhi kedua asumsi yaitu residual independen dan distribusi normal, maka uji residual dilanjutkan pada pengujian varians residual homogen. Apabila varians residual tidak homogen maka akan dilanjutkan pemodelan GARCH. Untuk mendeteksi apakah varians homogen atau tidak adalah dengan melakukan pemeriksaan terhadap residual kuadrat dari model regresi *time series* pada persamaan (4.17) menggunakan uji *portmanteau*. Hipotesis awal varians residual adalah homogen (tidak terdapat proses GARCH). Hasil uji *portmanteau* tersebut dapat dilihat pada Tabel 4.26.

Tabel 4.26 Uji Heteroskedastisitas Model ARIMAX Data *Inflow*

<i>k</i>	<i>Q</i>	Pr> <i>Q</i>
1	3,9032	0,0482
2	4,3143	0,1157
3	4,5498	0,2079
4	4,5798	0,3332
5	6,0199	0,3043
6	6,0775	0,4146
7	6,0938	0,5288
8	6,9917	0,5375
9	7,0913	0,6276
10	7,2458	0,7021
11	8,7596	0,6441
12	36,2730	0,0003

Hasil pengujian varians residual homogen pada Tabel 4.26 menunjukkan bahwa menolak hipotesis awal yang berarti asumsi varians homogen tidak terpenuhi karena terdapat *p-value* yang kurang dari 0,05 ($\alpha = 5\%$). Oleh karena itu, perlu dilakukan pemodelan GARCH.

Tahap pertama yang dilakukan untuk pemodelan GARCH adalah menentukan orde GARCH. Penentuan orde didasarkan pada *lag* yang signifikan terhadap plot ACF dan PACF dari residual kuadrat. Plot ACF dan PACF tersebut dapat dilihat pada gambar berikut.



Gambar 4.11 Plot ACF dan PACF Residual Kuadrat pada Model ARIMAX *Inflow* Uang Kartal

Berdasarkan pada Gambar 4.11 dapat diduga model residual kuadrat yang terbentuk adalah GARCH ([12],[12]), sehingga dapat ditulis model dugaan GARCH sebagai

$$\hat{\sigma}_t^2 = \theta_0 + \phi_{12}\sigma_{t-12}^2 + \theta_{12}a_{t-12}^2.$$

Tabel 4.27 Hasil Estimasi Parameter GARCH Data *Inflow*

Parameter	Estimasi	Standard Error	t-value	p-value
θ_0	1044	243,7104	4,28	<,0001
θ_{12}	0,6991	0,2062	3,39	0,0007
ϕ_{12}	0,2703	0,0995	2,72	0,0066

selanjutnya dilakukan estimasi parameter pada persamaan tersebut , hasil estimasi tersebut dapat dilihat pada Tabel 4.27. Sehingga persamaan tersebut menjadi

$$\hat{\sigma}_t^2 = 1044 + 0,2703\sigma_{t-12}^2 + 0,6991a_{t-12}^2.$$

Meskipun residual tidak memenuhi asumsi homogen, model ARIMAX dengan efek variasi kalender untuk *inflow* uang kartal pada persamaan (4.17) dapat digunakan sebagai peramalan karena mempunyai nilai RMSE *in-sample* sebesar 76,89 yang lebih kecil dibandingkan dengan standard deviasi sebesar 209,5. Model GARCH tersebut hanya akan berpengaruh terhadap penentuan batas atas dan batas bawah untuk ramalan interval. Batas atas dan bawah dapat diperoleh dari $\hat{Z}_t \pm 1,96\sqrt{\hat{\sigma}_t^2}$ dengan $\hat{\sigma}_t^2$ merupakan model dari GARCH. Hasil peramalan interval *inflow* uang kartal menggunakan model ARIMAX deteksi GARCH dapat dilihat pada Tabel 4.28.

Tabel 4.28 Hasil Peramalan Interval *Out-sample* Uang Kartal Menggunakan Model ARIMAX dengan Efek Variasi Kalender dan GARCH Data *Inflow*

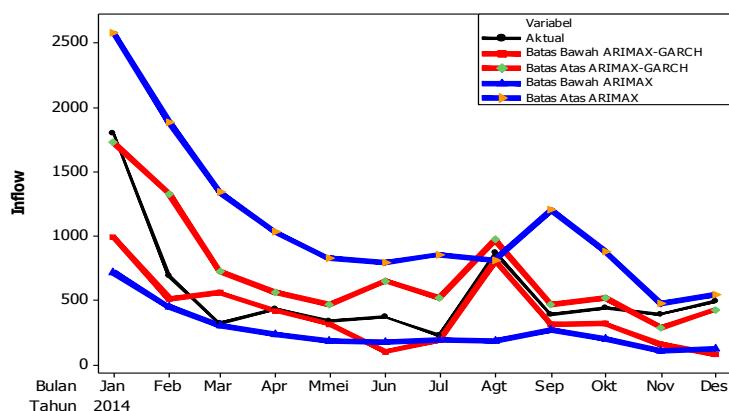
Bulan	Aktual	Ramalan	$\hat{\sigma}^2$	$\sqrt{\hat{\sigma}^2}$	Selang Kepercayaan (95%)	
					Batas Bawah	Batas Atas
Januari	1800,58	1361,66	35147,21	187,48	994,21	1729,11
Februari	691,51	921,76	42808,49	206,90	516,24	1327,29
Maret	321,08	646,03	1853,96	43,06	561,63	730,42
April	435,54	494,84	1334,09	36,53	423,25	566,43
Mei	339,99	395,43	1484,78	38,53	319,90	470,95
Juni	372,52	380,46	19613,45	140,05	105,96	654,95
Juli	227,39	361,42	6912,52	83,14	198,47	524,38
Agustus	870,09	892,57	1669,66	40,86	812,48	972,66
September	391,76	391,14	1558,00	39,47	313,78	468,51
Oktober	446,04	421,67	2637,79	51,36	321,00	522,33
November	397,41	227,03	1129,47	33,61	161,16	292,90
Desember	499,74	259,99	7696,69	87,73	88,04	431,95

Sedangkan peramalan interval *inflow* uang kartal dengan menggunakan konfiden interval dapat dilihat pada Tabel 4.29. Batas bawah dan batas atas diperoleh dari $\hat{Z}_t \pm 1,96(\hat{SE})$.

Tabel 4.29 Hasil Peramalan Interval *Out-sample* Uang Kartal Menggunakan Model ARIMAX dengan Efek Variasi Kalender Data *Inflow*

Bulan	Aktual	Ramalan	Selang Kepercayaan (95%)	
			Batas Bawah	Batas Atas
Januari	1800,58	1361,66	719,39	2577,56
Februari	691,51	921,76	451,10	1883,52
Maret	321,08	646,03	310,44	1344,40
April	435,54	494,84	236,73	1034,42
Mei	339,99	395,43	188,93	827,58
Juni	372,52	380,46	181,74	796,48
Juli	227,39	361,42	196,37	860,75
Agustus	870,09	892,57	185,94	815,01
September	391,76	391,14	274,73	1204,24
Oktober	446,04	421,67	201,40	882,80
November	397,41	227,03	108,44	475,33
Desember	499,74	259,99	124,18	544,35

Secara visual peramalan interval *inflow* dapat dilihat pada Gambar 4.12 berikut



Gambar 4.12 Ramalan Interval *Out-sample* Uang Kartal dengan Menggunakan Metode ARIMAX Data *Inflow*

Berdasarkan Gambar 4.12 dapat disimpulkan bahwa peramalan interval dengan menggunakan GARCH lebih kecil dibandingkan dengan peramalan interval dengan menggunakan konfiden interval. Pada bulan Januari, Maret, November dan Desember berada diluar peramalan interval dengan menggunakan

GARCH. Hal tersebut terjadi karena residual pada bulan tersebut cukup tinggi. Sedangkan pada bulan lainnya menghasilkan residual yang kecil sehingga berada dalam ramalan interval GARCH.

4.3 Peramalan *Outflow* dan *Inflow* dengan menggunakan ANFIS

Peramalan dengan menngukan metode ANFIS bergantung pada fungsi keanggotaan dan jumlah keanggotaan. Dalam pemodelan ANFIS, data yang digunakan terbagi dalam variabel *input* dan *output*. Variabel *input* dalam penelitian ini adalah *lag* yang signifikan dalam model ARIMA sedangkan variabel *output* adalah target nilai keluaran Z_t .

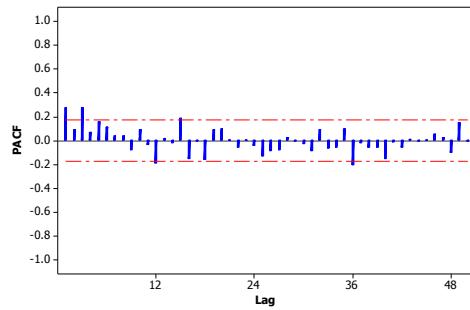
Jenis fungsi keanggotaan yang akan digunakan dalam penelitian ini adalah *Gaussian* dengan jumlah keanggotaan sebanyak 2 yang dikelompokkan dengan metode *grid partition*. Selain itu juga dilakukan peramalan ANFIS dari *outflow* dan *inflow* dengan fungsi keanggotaan *Gaussian* dengan jumlah keanggotaan sebanyak 2 yang dilakukan dengan metode FCM (*Fuzzy Clustering Mean*). Peramalan *outflow* dan *inflow* dengan ANFIS dilakukan dengan mengkombinasikan fungsi dan jumlah keanggotaan. Pemilihan model terbaik didasarkan pada kriteria sMAPE *out sample* terkecil.

4.3.1 Peramalan Data *Outflow* Menggunakan Metode ANFIS

Input pada model ANFIS dapat ditentukan dengan pendekatan model ARIMA berdasarkan orde AR atau berdasarkan lag PACF yang signifikan. *Input* untuk data *outflow* ditentukan berdasarkan lag yang signifikan pada plot PACF. Data *outflow* pada penelitian ini belum stasioner baik dalam varians maupun dalam mean. Sehingga data perlu distasionerkan terlebih dahulu dengan transformasi Box-Cox dan differencing. Nilai *rounded value* sebesar 0,13 sehingga hasil transformasi tersebut dapat dituliskan sebagai berikut.

$$Z_{1,t}^* = \frac{Z_{1,t}^{0,13} - 1}{0,13} .$$

Kemudian *differencing* 12 sehingga $Z_{1,t}^*$ menjadi $Y_{1,t} = Z_{1,t}^* - Z_{1,t-12}^*$. Plot PACF $Y_{1,t}$ dapat dilihat pada Gambar 4.13.

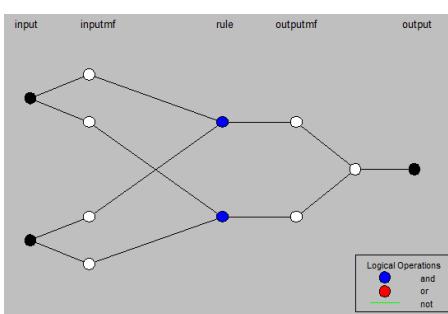


Gambar 4.13 Plot PACF untuk Data *Outflow* yang Sudah Stasioner

Berdasarkan plot PACF pada Gambar 4.13 dapat dilihat bahwa lag-lag yang signifikan adalah lag 1, 3, 12 dan 15. Lag-lag tersebut akan digunakan sebagai input pada model ANFIS. Input yang akan digunakan pada model ANFIS adalah sebagai berikut:

1. Lag 3 dan 12
2. Lag 1 dan 12
3. Lag 1, 3 dan 12
4. Lag 1 dan 3
5. Lag 1, 3, 12 dan 15

Model ANFIS yang akan dianalisis terlebih dahulu adalah dengan menggunakan lag 3 dan 12 sebagai *input*, jumlah keanggotaan sebanyak 2 dan fungsi keanggotaan adalah *Gaussian*. Peramalan menggunakan metode ANFIS ini dilakukan dengan cara mengkombinasikan jumlah dan jenis fungsi keanggotaan hingga didapatkan model terbaik berdasarkan kriteria SMAPE. Terdapat 5 tahapan pemodelan menggunakan metode ANFIS yang digambarkan dengan 5 lapisan sesuai Gambar 4.14 yaitu fuzzifikasi, operasi logika *fuzzy*, *normalized firing strength*, defuzzifikasi, dan perhitungan *output*.



Gambar 4.14 Arsitektur ANFIS untuk Data *Outflow*

Tahapan fuzzifikasi merupakan suatu proses mengubah himpunan bilangan *crisp* menjadi himpunan bilangan *fuzzy*. Data *outflow* menghasilkan parameter nonlinier (parameter *premise*) dan parameter linier (parameter *consequent*). Nilai parameter *premise* pada *layer 1* dapat dilihat pada tabel 4.30 berikut.

Tabel 4.30 Parameter *Premise* Akhir Pada Model ANFIS untuk Data *Outflow*

Input	a_i	c_i
$Y_{1,t-3}(A_1)$	1,050	0,317
$Y_{1,t-3}(A_2)$	1,137	-0,590
$Y_{1,t-12}(B_1)$	1,039	0,276
$Y_{1,t-12}(B_2)$	1,016	0,119

Nilai parameter *premise* yang dihasilkan pada *layer 1* selanjutnya digunakan untuk membentuk fungsi keanggotaan. Secara matematis fungsi keanggotaan pada masing-masing input pada data *outflow* dapat dituliskan sebagai berikut.

$$\begin{aligned}\mu_{A1}(Y_{1,t-3}) &= \exp\left(\frac{-(Y_{1,t-3} - 0,317)^2}{2(1,050)^2}\right) & \mu_{A2}(Y_{1,t-3}) &= \exp\left(\frac{-(Y_{1,t-3} + 0,590)^2}{2(1,137)^2}\right) \\ \mu_{B1}(Y_{1,t-12}) &= \exp\left(\frac{-(Y_{1,t-12} - 0,276)^2}{2(1,039)^2}\right) & \mu_{B2}(Y_{1,t-12}) &= \exp\left(\frac{-(Y_{1,t-12} - 0,119)^2}{2(1,016)^2}\right)\end{aligned}$$

Tahapan selanjutnya pada *layer 2* yaitu proses operasi logika *fuzzy*. Pada *layer 2* biasanya digunakan operator *AND* yaitu menggunakan operasi perkalian pada semua input pada *layer 2*. Berikut ini merupakan aturan logika yang terdapat pada *layer 2*.

If $(Y_{1,t-3} \text{ is } A_1)$ and $(Y_{1,t-12} \text{ is } B_1)$ then (output is w_{1t})

If $(Y_{1,t-3} \text{ is } A_2)$ and $(Y_{1,t-12} \text{ is } B_2)$ then (output is w_{2t})

Setelah mendapatkan output pada *layer 2* berupa $w_{i,t}$ dimana i merupakan jumlah aturan ($i = 1, 2$) dan t merupakan jumlah pengamatan ($t = 1, 2, \dots, 132$), maka pada *layer 3* terjadi proses *normalized firing strength*. Output pada *layer 3* merupakan rasio dari $w_{i,t}$ dari aturan $ke-i$ terhadap jumlah keseluruhan dari $w_{i,t}$.

yang disimbolkan dengan $\bar{w}_{i,t}$ dan banyaknya *output* pada *layer 3* sama dengan banyaknya *output* pada *layer 2*.

Tahapan selanjutnya yaitu proses defuzzifikasi yang terjadi pada *layer 4*. Nilai parameter di setiap node pada *layer 4* merupakan nilai parameter *consequent* yang ditampilkan pada Tabel 4.31.

Tabel 4.31 Parameter *consequent* Akhir Pada Model ANFIS untuk Data *Outflow*

i	$c_{i,3}$	$c_{i,12}$	$c_{i,0}$
1	-0,460	0,210	2,669
2	-0,479	-0,184	-2,606

Penggunaan algoritma *hybrid* diterapkan pada metode ANFIS ini, yaitu mengatur parameter *consequent* secara maju (*forward*) dan akan mengatur parameter *premise* secara mundur (*backward*). Pada langkah maju, input jaringan akan merambat maju sampai pada lapisan keempat dimana parameter *consequent* diidentifikasi menggunakan metode *least square*.

Parameter *consequent* yang diperoleh secara matematis dapat dituliskan dengan persamaan linier pada setiap *rule*.

$$Y_{1,t}^{(1)} = -0,460Y_{1,t-3} + 0,210Y_{1,t-12} + 2,669$$

$$Y_{1,t}^{(2)} = -0,479Y_{1,t-3} - 0,184Y_{1,t-12} - 2,606$$

Layer 5 merupakan *layer* terakhir dalam proses ANFIS yang merupakan proses mendapatkan nilai output jaringan ANFIS. Secara keseluruhan model ANFIS yang diperoleh untuk data *outflow* adalah sebagai berikut.

$$\begin{aligned}\hat{Y}_{1,t} &= \bar{w}_{1,t} Y_{1,t}^{(1)} + \bar{w}_{2,t} Y_{1,t}^{(2)} \\ &= \frac{\bar{w}_{1,t}}{\bar{w}_{1,t} + \bar{w}_{2,t}} (-0,460Y_{t-3} + 0,210Y_{t-12} + 2,669) + \\ &\quad \frac{\bar{w}_{2,t}}{\bar{w}_{1,t} + \bar{w}_{2,t}} (-0,479Y_{t-3} - 0,184Y_{t-12} - 2,606)\end{aligned}$$

$$\text{dengan } w_{1,t} = \exp\left(\frac{-(Y_{1,t-3} - 0,317)^2}{2(1,050)^2}\right) \exp\left(\frac{-(Y_{1,t-12} - 0,276)^2}{2(1,039)^2}\right)$$

$$w_{2,t} = \exp\left(\frac{-(Y_{1,t-3} + 0,590)^2}{2(1,137)^2}\right) \exp\left(\frac{-(Y_{1,t-12} - 0,119)^2}{2(1,016)^2}\right)$$

Nilai ramalan yang telah diperoleh akan dikembalikan ke data asli dengan menggunakan rumus berikut.

$$\hat{Z}_{1,t}^* = \hat{Y}_{1,t} + Z_{1,t-12}^*$$

sehingga

$$\hat{Z}_{1,t} = (0,13 \hat{Z}_{1,t}^* + 1)^{(1/0,13)}$$

Input lain dengan lag yang telah ditentukan sebelumnya dilakukan pemodelan dengan cara yang sama. Sehingga diperoleh nilai ramalan yang dijelaskan pada Tabel 4.32.

Tabel 4.32 Nilai Ramalan *Out-sample* Model ANFIS untuk Data *Outflow*

t (Bulan)	Aktual	Lag untuk <i>Input</i> ANFIS				
		(1,3,12)	(1,12)	(3,12)	(1,3)	(1,3,12,15)
1	173.99	194.62	262.50	267.18	269.81	241.94
2	234.36	233.81	270.98	252.40	261.28	306.13
3	468.82	559.30	678.05	574.35	605.04	638.66
4	827.07	720.43	804.78	694.31	729.88	769.97
5	442.07	875.35	865.16	756.76	799.55	875.59
6	570.11	942.67	899.96	769.94	829.79	943.15
7	1566.17	1638.90	1860.87	1785.05	1697.46	1671.60
8	265.48	1056.23	879.93	757.69	854.37	959.44
9	675.74	959.33	960.92	939.97	899.74	853.80
10	1133.79	1078.37	1034.45	939.52	959.47	1104.13
11	1221.34	1739.72	1745.24	1533.80	1586.25	1333.30
12	3726.05	4234.09	4187.48	3850.30	3872.06	4071.92

Perbandingan kebaikan model berdasarkan sMAPE *out-sample* dapat dilihat pada Tabel 4.33 Model ANFIS dengan input lag 3 dan 12 merupakan model terbaik yang bisa digunakan untuk meramalkan data *outflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 29,70%.

Tabel 4.33 Perbandingan Hasil Ramalan Model ANFIS Data *Outflow*

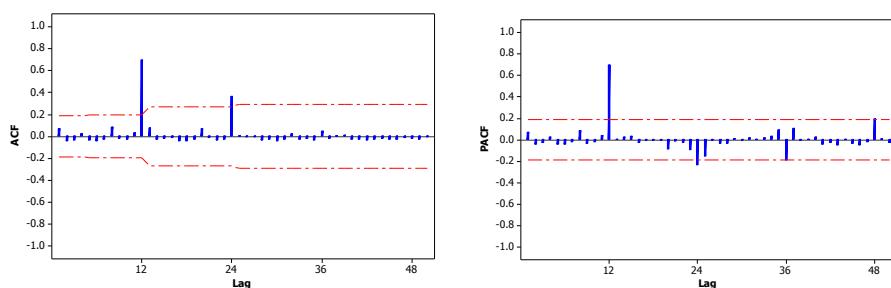
<i>Input</i> ANFIS	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
Lag 1, 3 dan 12	419,47	363,71	39,59%	30,79%
Lag 1 dan 12	270,21	339,64	39,94%	34,95%
Lag 3 dan 12	368,86	239,36	41,37%	29,70%
Lag 1 dan 3	296,78	263,34	42,21%	31,23%
Lag 1, 3, 12 dan 15	285,22	292,46	40,38%	31,30%

Setelah mendapatkan model terbaik, maka uji residual dilanjutkan pada pengujian varians residual homogen. Apabila varians residual tidak homogen maka akan dilanjutkan pemodelan GARCH. Untuk mendeteksi apakah varians homogen atau tidak adalah dengan melakukan pemeriksaan terhadap residual dari model ANFIS dengan menggunakan uji *portmanteau*. Hipotesis awal varians residual adalah homogen (tidak terdapat proses GARCH). Hasil uji *portmanteau* terdapat pada Tabel 4.34. Hasil pengujian varians residual homogen pada Tabel 4.34 menunjukkan bahwa menolak hipotesis awal yang berarti asumsi varians homogen tidak terpenuhi karena terdapat *p-value* yang kurang dari 0,05 ($\alpha = 5\%$). Oleh karena itu perlu dilakukan pemodelan GARCH.

Tabel 4.34 Uji Heteroskedastisitas Model ANFIS Data *Outflow*

<i>k</i>	<i>Q</i>	Pr> <i>Q</i>
1	0,5131	0,4738
2	0,6759	0,7132
3	0,7850	0,8531
4	0,8619	0,9300
5	0,9776	0,9643
6	1,2208	0,9758
7	1,2741	0,9891
8	2,1542	0,9759
9	2,1950	0,9880
10	2,2892	0,9936
11	2,4219	0,9964
12	62,5080	<,0001

Tahap pertama yang dilakukan untuk pemodelan GARCH adalah menentukan orde GARCH. Penentuan orde didasarkan pada *lag* yang signifikan terhadap plot ACF dan PACF dari residual kuadrat. Plot ACF dan PACF tersebut dapat dilihat pada Gambar 4.15.



Gambar 4.15 Plot ACF dan PACF Residual Kuadrat pada Model ANFIS *Outflow*
Uang Kartal

Berdasarkan pada Gambar 4.15 dapat diduga model residual kuadrat yang terbentuk adalah ARCH (12), sehingga dapat ditulis model dugaan ARCH sebagai

$$\hat{\sigma}_t^2 = \theta_0 + \theta_{12} a_{t-12}^2.$$

Tabel 4.35 Hasil Estimasi Parameter Model ARCH

Parameter	Estimasi	Standard Error	t-value	p-value
θ_0	136056	32948	4,13	<,0001
θ_{12}	0,4036	0,1744	2,31	0,0207

Selanjutnya dilakukan estimasi parameter pada persamaan tersebut, hasil estimasi tersebut dapat dilihat pada Tabel 4.35. Sehingga persamaan tersebut menjadi

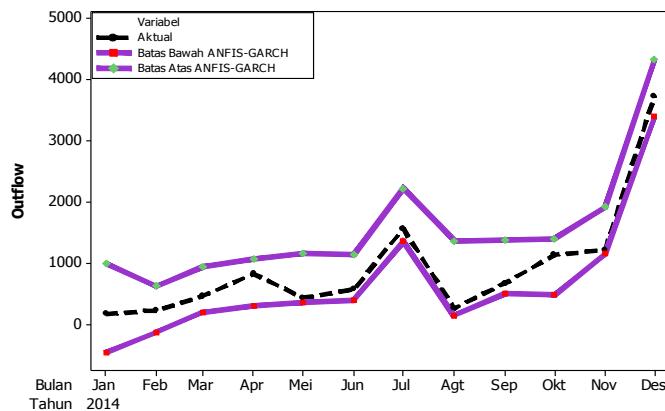
$$\hat{\sigma}_t^2 = 136056 + 0,4036 a_{t-12}^2.$$

Meskipun residual tidak memenuhi asumsi homogen, model ANFIS dengan input lag 3 dan lag 12 untuk *outflow* uang kartal dapat digunakan sebagai peramalan karena mempunyai nilai RMSE *in sample* sebesar 296,78 yang lebih kecil dibandingkan dengan standard deviasi sebesar 643. Model ARCH tersebut hanya akan berpengaruh terhadap penentuan batas atas dan batas bawah untuk ramalan interval. Batas atas dan bawah dapat diperoleh dari $\hat{Z}_t \pm 1,96\sqrt{\hat{\sigma}_t^2}$ dengan $\hat{\sigma}_t^2$ merupakan model dari ARCH. Hasil peramalan interval *inflow* uang kartal menggunakan model ARIMAX deteksi ARCH dapat dilihat pada Tabel 4.36.

Tabel 4.36 Hasil Peramalan Interval *Out-sample* Uang Kartal menggunakan model ANFIS Data *Outflow*

Bulan	Aktual	Ramalan	$\hat{\sigma}^2$	$\sqrt{\hat{\sigma}^2}$	Selang Kepercayaan (95%)	
					Batas Bawah	Batas Atas
Januari	173,99	267,18	137069,73	370,23	-458,47	992,83
Februari	234,36	252,40	139443,95	373,42	-121,02	625,82
Maret	468,82	574,35	136258,39	369,13	205,22	943,48
April	827,07	694,31	144119,05	379,63	314,68	1073,94
Mei	442,07	756,75	160634,08	400,79	355,96	1157,54
Juni	570,11	769,94	139087,75	372,94	397,00	1142,89
Juli	1566,17	1785,04	188449,56	434,11	1350,94	2219,15
Agustus	265,48	757,69	368014,84	606,64	151,04	1364,33
September	675,74	939,96	183915,13	428,85	511,11	1368,82
Okttober	1133,79	939,52	209035,53	457,20	482,31	1396,72
November	1221,34	1533,80	143690,76	379,07	1154,73	1912,86
Desember	3726,05	3850,27	217048,03	465,88	3384,39	4316,16

Secara visual peramalan interval *inflow* dapat dilihat pada Gambar 4.16. Berdasarkan Gambar tersebut dapat disimpulkan bahwa peramalan *outflow* uang kartal menggunakan metode ANFIS dengan deteksi GARCH baik untuk digunakan. Peramalan tersebut dikatakan baik untuk digunakan karena tidak ada data yang keluar dari permalan interval untuk semua data *out-sample*.

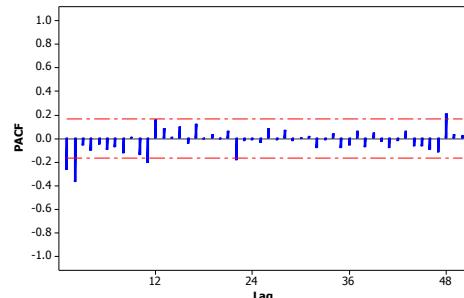


Gambar 4.16 Ramalan Interval *Out-sample* Uang Kartal dengan Menggunakan Metode ANFIS Data *Outflow*

4.3.2 Peramalan Data *Inflow* Menggunakan Metode ANFIS

Pada data *inflow* input untuk model ANFIS juga ditentukan berdasarkan lag yang signifikan pada plot PACF. Sama halnya dengan data *outflow*, data *inflow* pada penelitian ini juga belum stasioner varians maupun dalam mean. Sehingga data perlu distasionerkan terlebih dahulu dengan transformasi Box-Cox dan differencing. Nilai *rounded value* yang diperoleh sebesar 0,00 sehingga $Z_{2,t}^* = \ln(Z_{2,t})$ kemudian hasil tersebut *differencing* 1 sehingga $Z_{2,t}^*$ menjadi

$$Y_{2,t} = Z_{2,t}^* - Z_{2,t-1}^*. \text{ Plot PACF dari } Y_{2,t} \text{ dapat dilihat pada Gambar 4.17.}$$

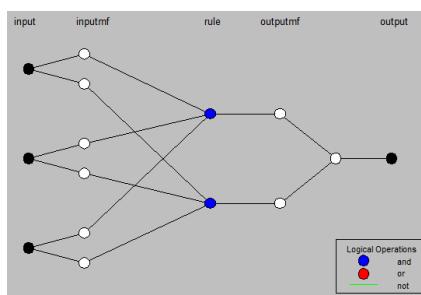


Gambar 4.17 Plot PACF untuk Data *Inflow* yang Sudah Stasioner

Berdasarkan plot PACF pada Gambar 4.17 dapat dilihat bahwa lag-lag yang signifikan adalah lag 1, 2, 11, 12 dan 48. Input yang akan digunakan pada model ANFIS adalah sebagai berikut:

1. Lag 1, 12 dan 48
2. Lag 2 dan 12
3. Lag 1, 2 dan 12
4. Lag 1, 2, 11 dan 12
5. Lag 1, 11 dan 12
6. Lag 1 dan 12

Pertama yang akan dianalisis adalah lag 1, 12 dan 48 sebagai *input* pada model ANFIS dengan jumlah keanggotaan sebanyak 2 dan fungsi keanggotaan adalah *Gaussian* yang akan dijelaskan dalam pembahasan ini. Peramalan menggunakan metode ANFIS ini dilakukan dengan cara mengkombinasikan jumlah dan jenis fungsi keanggotaan hingga didapatkan model terbaik berdasarkan kriteria SMAPE. Terdapat 5 tahapan pemodelan menggunakan metode ANFIS yang digambarkan dengan 5 *layer* sesuai Gambar 4.18 yaitu fuzzifikasi, operasi logika *fuzzy*, *normalized firing strength*, defuzzifikasi, dan perhitungan *output*.



Gambar 4.18 Arsitektur ANFIS untuk Data *Inflow*

Tahapan fuzzifikasi merupakan suatu proses mengubah himpunan bilangan *crisp* menjadi himpunan bilangan *fuzzy*. Data *inflow* menghasilkan parameter *premise* dan parameter *consequent*. Nilai parameter *premise* pada *layer 1* dapat dilihat pada tabel 4.37. Nilai parameter *premise* yang dihasilkan pada *layer 1* selanjutnya digunakan untuk membentuk fungsi keanggotaan. Secara matematis fungsi keanggotaan pada masing-masing *input* pada data *inflow* dapat dituliskan sebagai berikut.

$$\begin{aligned}
n\mu_{A1}(Y_{2,t-1}) &= \exp\left(\frac{-(Y_{2,t-1} + 0,229)^2}{2(0,415)^2}\right) & \mu_{A2}(Y_{2,t-1}) &= \exp\left(\frac{-(Y_{2,t-1} - 0,290)^2}{2(0,633)^2}\right) \\
\mu_{B1}(Y_{2,t-12}) &= \exp\left(\frac{-(Y_{2,t-12} - 0,026)^2}{2(0,423)^2}\right) & \mu_{B2}(Y_{2,t-12}) &= \exp\left(\frac{-(Y_{2,t-12} + 0,047)^2}{2(0,414)^2}\right) \\
\mu_{C1}(Y_{2,t-48}) &= \exp\left(\frac{-(Y_{2,t-48} + 0,028)^2}{2(0,378)^2}\right) & \mu_{C2}(Y_{2,t-48}) &= \exp\left(\frac{-(Y_{2,t-48} + 0,013)^2}{2(0,364)^2}\right)
\end{aligned}$$

Tabel 4.37 Parameter *Premise* Akhir Pada Model ANFIS untuk Data *Inflow*

Input	a_i	c_i
$Y_{2,t-1}(A_1)$	0,415	-0,229
$Y_{2,t-1}(A_2)$	0,633	0,290
$Y_{2,t-12}(B_1)$	0,423	0,026
$Y_{2,t-12}(B_2)$	0,414	-0,047
$Y_{2,t-48}(C_1)$	0,378	-0,028
$Y_{2,t-48}(C_2)$	0,364	-0,013

Tahapan selanjutnya pada *layer 2* yaitu proses operasi logika *fuzzy*. Pada *layer 2* biasanya digunakan operator *AND* yaitu menggunakan operasi perkalian pada semua input pada *layer 2*. Berikut ini merupakan aturan logika yang terdapat pada *layer 2*.

If $(Y_{2,t-1} \text{ is } A_1) \text{ and } (Y_{2,t-12} \text{ is } B_1) \text{ and } (Y_{2,t-48} \text{ is } C_1) \text{ then } (\text{output is } w_{1t})$

If $(Y_{2,t-1} \text{ is } A_2) \text{ and } (Y_{2,t-12} \text{ is } B_2) \text{ and } (Y_{2,t-48} \text{ is } C_2) \text{ then } (\text{output is } w_{2t})$

Setelah mendapatkan output pada *layer 2* berupa $w_{i,t}$ dimana i merupakan jumlah aturan ($i = 1, 2$) dan t merupakan jumlah pengamatan ($t = 1, 2, \dots, 143$), maka pada *layer 3* terjadi proses *normalized firing strength*. Output pada *layer 3* merupakan rasio dari $w_{i,t}$ dari aturan $ke-i$ terhadap jumlah keseluruhan dari $w_{i,t}$ yang disimbolkan dengan $\bar{w}_{i,t}$ dan banyaknya *output* pada *layer 3* sama dengan banyaknya *output* pada *layer 2*.

Tahapan selanjutnya yaitu proses defuzzifikasi yang terjadi pada *layer 4*. Nilai parameter di setiap node pada *layer 4* merupakan nilai parameter *consequent* yang ditampilkan pada Tabel 4.38.

Tabel 4.38 Parameter *consequent* Akhir Pada Model ANFIS untuk Data *Inflow*

i	$c_{i,1}$	$c_{i,12}$	$c_{i,48}$	$c_{i,0}$
1	-0,038	0,253	0,393	0,440
2	-0,129	-0,072	-0,393	-0,359

Penggunaan algoritma *hybrid* diterapkan pada metode ANFIS ini, yaitu mengatur parameter *consequent* secara maju (*forward*) dan akan mengatur parameter *premise* secara mundur (*backward*). Pada langkah maju, input jaringan akan merambat maju sampai pada lapisan keempat dimana parameter *consequent* diidentifikasi menggunakan metode *least square*.

Parameter *consequent* yang diperoleh secara matematis dapat dituliskan dengan persamaan linier pada setiap *rule*.

$$Y_{2,t}^{(1)} = -0,038Y_{2,t-1} + 0,253Y_{2,t-12} + 0,393Y_{2,t-48} + 0,44$$

$$Y_{2,t}^{(2)} = -0,129Y_{2,t-1} - 0,072Y_{2,t-12} - 0,393Y_{2,t-48} - 0,359.$$

Layer 5 merupakan *layer* terakhir dalam proses ANFIS yang merupakan proses mendapatkan nilai output jaringan ANFIS. Secara keseluruhan model ANFIS yang diperoleh untuk data *inflow* adalah sebagai berikut.

$$\begin{aligned}\hat{Y}_{2,t} &= \bar{w}_{1,t} Y_{2,t}^{(1)} + \bar{w}_{2,t} Y_{2,t}^{(2)} \\ &= \frac{w_{1,t}}{w_{1,t} + w_{2,t}} (-0,038Y_{2,t-1} + 0,253Y_{2,t-12} + 0,393Y_{2,t-48} + 0,44) + \\ &\quad \frac{w_{2,t}}{w_{1,t} + w_{2,t}} (-0,129Y_{2,t-1} - 0,072Y_{2,t-12} - 0,393Y_{2,t-48} - 0,359)\end{aligned}$$

dengan

$$w_{1,t} = \exp\left(\frac{-(Y_{2,t-1} + 0,229)^2}{2(0,415)^2}\right) \exp\left(\frac{-(Y_{2,t-12} - 0,026)^2}{2(0,423)^2}\right) \exp\left(\frac{-(Y_{2,t-48} + 0,028)^2}{2(0,378)^2}\right)$$

$$w_{2,t} = \exp\left(\frac{-(Y_{2,t-1} - 0,290)^2}{2(0,633)^2}\right) \exp\left(\frac{-(Y_{2,t-12} + 0,047)^2}{2(0,414)^2}\right) \exp\left(\frac{-(Y_{2,t-48} + 0,013)^2}{2(0,364)^2}\right)$$

Nilai ramalan yang telah diperoleh akan dikembalikan ke data asli dengan menggunakan rumus berikut.

$$\hat{Z}_{2,t}^* = \hat{Y}_{2,t} + Z_{2,t-1}^*$$

Sehingga

$$\hat{Z}_{2,t} = \exp(\hat{Z}_{2,t}^*)$$

Input lain dengan lag yang telah ditentukan sebelumnya dilakukan pemodelan dengan cara yang sama. Sehingga diperoleh nilai ramalan yang dijelaskan pada Tabel 4.39.

Tabel 4.39 Nilai Ramalan *Out-sample* Model ANFIS untuk Data *Inflow*

t (Bulan)	Aktual	Lag untuk <i>Input</i> ANFIS					
		(1,12)	(2,12)	1,2,12)	1,2,11,12)	(1,11,12)	(1,12,48)
1	1800,58	1045,90	388,11	923,39	1320,19	1311,59	2189,74
2	691,51	992,31	1516,08	1176,80	999,34	1004,12	1073,11
3	321,08	587,76	836,26	609,44	352,41	1198,47	378,07
4	435,54	333,50	349,18	311,71	455,84	210,88	422,04
5	339,99	383,35	373,39	377,87	324,78	572,16	425,56
6	372,52	290,26	318,11	281,68	334,30	264,71	341,23
7	227,39	361,91	404,64	351,27	373,41	253,36	385,20
8	870,09	436,26	239,20	413,06	579,04	1331,07	299,16
9	391,76	548,87	975,04	575,73	693,68	542,55	675,02
10	446,04	401,97	374,03	386,30	207,41	510,10	429,87
11	397,41	370,94	404,90	348,99	626,71	327,55	424,88
12	499,74	468,07	402,12	460,16	305,43	245,07	439,30

Perbandingan kebaikan model berdasarkan sMAPE *out-sample* dapat dilihat pada Tabel 4.40. Model ANFIS dengan *input* lag 1, 12 dan 48 merupakan model terbaik yang bisa digunakan untuk meramalkan data *inflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 28,53%.

Tabel 4.40 Perbandingan Hasil Ramalan Model ANFIS Data *Inflow*

<i>Input</i> ANFIS	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
Lag 1 dan 12	197,31	286,48	38,11%	31,67%
Lag 2 dan 12	180,26	558,00	38,55%	53,02%
Lag 1, 2 dan 12	185,69	338,96	38,03%	36,45%
Lag 1, 2, 11 dan 12	104,76	236,84	30,87%	33,91%
Lag 1, 11 dan 12	107,98	357,35	32,75%	43,67%
Lag 1, 12 dan 48	159,42	249,09	46,74%	28,53%

Setelah mendapatkan model terbaik, maka uji residual dilanjutkan pada pengujian varians residual homogen. Apabila varians residual tidak homogen maka akan dilanjutkan pemodelan GARCH. Untuk mendeteksi apakah varians homogen atau tidak adalah dengan melakukan pemeriksaan terhadap residual dari model ANFIS dengan menggunakan uji *portmanteau*. Hipotesis awal varians residual adalah homogen (tidak terdapat proses GARCH). Hasil uji *portmanteau* terdapat pada Tabel 4.41.

Tabel 4.41 Uji Heteroskedastisitas Model ANFIS Data *Inflow*

<i>k</i>	<i>Q</i>	Pr> <i>Q</i>
1	0,0351	0,8513
2	0,5126	0,7739
3	1,2069	0,7513
4	1,2089	0,8766
5	10,1183	0,0720
6	10,1666	0,1178
7	11,3598	0,1237
8	11,7582	0,1623
9	11,8231	0,2235
10	11,9969	0,2853
11	12,0799	0,3577
12	12,5432	0,4031

Tabel 4.41 menunjukkan hasil uji varians homogen menggunakan uji *portmentiau* memberikan kesimpulan bahwa varians residual homogen karena semua nilai *p-value* lebih dari 0,05 ($\alpha = 5\%$). Sehingga dapat diperoleh kesimpulan bahwa model ANFIS dengan *input* lag 1, 12 dan 48 layak digunakan untuk peramalan 12 bulan kedepan karena mempunyai nilai RMSE *in sample* sebesar 158,27 yang lebih kecil dibandingkan dengan standard deviasi sebesar 209,5.

4.4 Peramalan Gabungan

Peramalan gabungan dengan model ARIMAX-ANFIS-GARCH merupakan peramalan yang menggabungkan tiga model ramalan yaitu model ARIMAX pada level pertama, ANFIS pada level kedua dan GARCH pada level ketiga. Peramalan level pertama yang dimaksudkan adalah meramalkan *outflow* dan *inflow* uang kartal dengan menggunakan model ARIMAX, peramalan pada level kedua dengan menggunakan ANFIS adalah meramalkan residual dari model ARIMAX yang telah diperoleh pada level pertama. Dengan kata lain *input* pada ANFIS adalah residual pada model ARIMAX. Banyaknya *input* pada ANFIS disesuaikan dengan *lag* yang signifikan pada model ARIMAX atau *input* ANFIS dengan menggunakan lag PACF yang signifikan. sedangkan pada level ketiga adalah mendeteksi adanya heterokedastisitas dari residual model ARIMAX-ANFIS dengan menggunakan GARCH. Secara matematis dapat dituliskan sebagai berikut.

Level 1: meramalkan data dengan menggunakan model ARIMAX

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \sum_{j=0}^{30} \alpha_j D_{j,t} + \sum_{j=0}^{30} \gamma_j D_{j,t-1} + \sum_{j=0}^{30} \xi_j D_{j,t+1} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)} a_t$$

Level 2: meramalkan residual dari model ARIMAX pada level 1 (a_t) dengan menggunakan model ANFIS.

$$\hat{a}_t = \bar{w}_1(c_{1,1}a_{t-1} + c_{1,2}a_{t-2} + \dots + c_{1,p}a_{t-p} + c_{1,0}) + \dots + \bar{w}_m(c_{m,1}a_{t-1} + c_{m,2}a_{t-2} + \dots + c_{m,p}a_{t-p} + c_{m,0})$$

misal hasil ramalan menggunakan model ARIMAX adalah \hat{Z}_t dan \hat{a}_t adalah hasil ramalan menggunakan model ANFIS maka hasil ramalan gabungan ARIMAX-ANFIS adalah $Z_t = \hat{Z}_t + \hat{a}_t + e_t$.

Level 3: melakukan deteksi heteroskedastisitas pada residual e_t dengan menggunakan GARCH untuk meramalkan varians yang akan digunakan sebagai ramalan interval.

$$\hat{\sigma}_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_q e_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_p \sigma_{t-p}^2$$

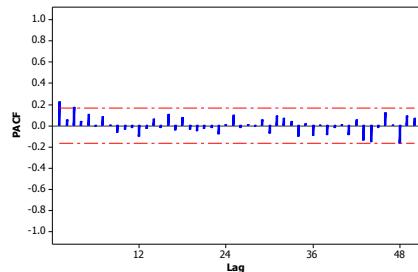
4.4.1 Peramalan Gabungan Data Outflow

Pada data *outflow* model ARIMAX dengan peramalan terbaik adalah ARIMAX([2],0,1)(1,0,0)¹² dengan efek variasi kalender yang mengikuti persamaan

$$\begin{aligned} Z_{1,t}^* = & 0,016t + 5,878M_{1,t} + 5,513M_{2,t} + 7,018M_{3,t} + 7,687M_{4,t} + 7,883M_{5,t} + \\ & 8,304M_{6,t} + 8,267M_{7,t} + 7,921M_{8,t} + 7,835M_{9,t} + 8,723M_{10,t} + 8,868M_{11,t} + \\ & 11,79M_{12,t} - 2,104I_t^{(49)} - 0,007tI_t^{(49)} - 3,005I_t^{(97)} + 0,028tI_t^{(97)} - 1,84D_{0,t-1} + \\ & -1,082D_{2,t-1} - 0,647D_{7,t-1} + 0,777D_{9,t-1} + 1,141D_{11,t-1} + 2,897D_{13,t-1} + \\ & 0,612D_{18,t-1} + 0,99D_{20,t-1} - 0,369D_{22,t-1} + 0,683D_{24,t-1} - 0,507D_{27,t-1} + \\ & 1,476D_{29,t-1} + 0,087D_{0,t} + 0,159D_{2,t} + 0,02D_{7,t} + 0,52D_{9,t} + 1,549D_{11,t} + \\ & -1,598D_{13,t} + 1,559D_{18,t} + 1,794D_{20,t} + 2,568D_{22,t} + 1,661D_{24,t} + 1,77D_{27,t} + \\ & -0,749D_{29,t} + 3,972V_{A,t}^{(61)} + \frac{(1+0,608B)}{(1+0,248B^2)(1-0,574B^{12})} a_t. \end{aligned}$$

Residual yang diperoleh dari model ARIMAX yaitu $Z_{1,t} = \hat{Z}_{1,t} + e_{1,t}$ kemudian dimodelkan menggunakan ANFIS dengan lag 2, lag 12 dan lag 14 sebagai *input*. Selain input berdasarkan orde AR, akan digunakan juga input dengan menggunakan lag yang signifikan pada plot PACF dari residual ARIMAX

$([2], 0, 1)(1, 0, 0)^{12}$ dengan efek variasi kalender. Plot PACF tersebut dapat dilihat pada Gambar 4.19.

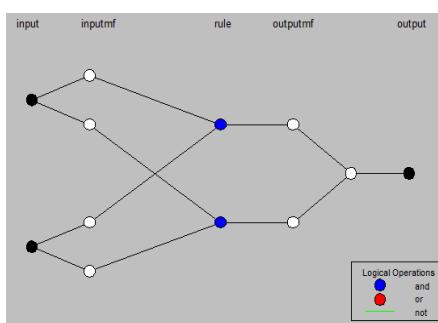


Gambar 4.19 Plot PACF Residual ARIMAX $([2], 0, 1)(1, 0, 0)^{12}$ dengan Efek Variasi Kalender untuk Data *Outflow*

Berdasarkan plot PACF pada Gambar 4.19 dapat dilihat bahwa lag-lag yang signifikan adalah lag 1, 3 dan 48. Input yang akan digunakan pada model ANFIS adalah sebagai berikut:

1. Lag 1 dan 3
2. Lag 1 dan 48
3. Lag 3 dan 48

Dalam peramalan ANFIS pada level kedua, yang akan dijelaskan dalam pembahasan ini adalah *input* berdasarkan lag signifikan pada plot PACF yaitu lag 1 dan 3. Jenis fungsi keanggotaan digunakan adalah *Gaussian* dengan jumlah keanggotaan sebanyak 2 dan pengklasteran dilakukan menggunakan metode FCM. Arsitektur ANFIS dari data residual *outflow* dijelaskan pada Gambar 4.20.



Gambar 4.20 Arsitektur ANFIS dari Data Residual *Outflow*

Arsitektur ANFIS menjelaskan alur proses pada saat pemodelan menggunakan ANFIS. Aturan atau *rule* yang digunakan pada proses ANFIS ini adalah sebagai berikut.

Rule 1-1 : jika *input* 1 ($e_{1,t-1}$) kelompok A_1 dan *input* 2 ($e_{1,t-3}$) kelompok B_1 maka

$$e_{1,t}^{(1)} = c_{1,1}e_{1,t-1} + c_{1,3}e_{1,t-3} + c_{1,0}$$

Rule 2-2 : jika *input* ($e_{1,t-1}$) kelompok A_2 dan *input* 2 ($e_{1,t-3}$) kelompok B_2 maka

$$e_{1,t}^{(2)} = c_{2,1}e_{1,t-1} + c_{2,3}e_{1,t-3} + c_{2,0}$$

ANFIS dengan 2 *input*, 2 jumlah keanggotaan dan 2 aturan ini menghasilkan 8 parameter *premise* dan 6 parameter *consequent* akhir. Nilai parameter *premise* dan parameter *consequent* akhir setelah dikenai pembelajaran pada proses ANFIS dapat dilihat pada Tabel 4.42 dan Tabel 4.43.

Tabel 4.42 Parameter *Premise* Akhir Pada Model ANFIS untuk Residual *Outflow*

<i>Input</i>	a_i	c_i
$e_{t-1}(A_1)$	94,12	21,53
$e_{t-1}(A_2)$	93,34	1,68
$e_{t-3}(B_1)$	90,94	-0,25
$e_{t-3}(B_2)$	93,41	25,73

Tabel 4.43 Parameter *Consequent* Akhir Pada Model ANFIS untuk Residual

<i>Outflow</i>			
<i>i</i>	$c_{i,1}$	$c_{i,3}$	$c_{i,0}$
1	-0,041	0,334	168,500
2	0,046	0,192	-156,600

Parameter *consequent* yang diperoleh secara matematis dituliskan dengan persamaan linier pada setiap *rule* yaitu

$$\begin{aligned} e_{1,t}^{(1)} &= -0,041e_{1,t-1} + 0,334e_{1,t-3} + 168,5 \\ e_{1,t}^{(2)} &= 0,046e_{1,t-1} + 0,192e_{1,t-3} - 156,6 \end{aligned}$$

Secara keseluruhan, model ANFIS yang diperoleh untuk residual *outflow* adalah sebagai berikut.

$$\begin{aligned}
\hat{e}_{1,t} &= \bar{w}_{1,t} e_{1,t}^{(1)} + \bar{w}_{2,t} e_{1,t}^{(2)} \\
&= \frac{w_{1,t}}{w_{1,t} + w_{2,t}} (-0,041 e_{1,t-1} + 0,334 e_{1,t-3} + 168,5) + \\
&\quad \frac{w_{2,t}}{w_{1,t} + w_{2,t}} (0,046 e_{1,t-1} + 0,192 e_{1,t-3} - 156,6)
\end{aligned}$$

dengan

$$\begin{aligned}
w_{1,t} &= \exp\left(\frac{-(e_{1,t-1} - 21,53)^2}{2(94,12)^2}\right) \exp\left(\frac{-(e_{1,t-3} + 0,25)^2}{2(90,94)^2}\right) \\
w_{2,t} &= \exp\left(\frac{-(e_{1,t-1} - 1,68)^2}{2(93,34)^2}\right) \exp\left(\frac{-(e_{1,t-3} - 25,73)^2}{2(93,41)^2}\right)
\end{aligned}$$

Setelah mendapatkan ramalan residual menggunakan metode ANFIS, langkah selanjutnya yaitu menjumlahkan hasil ramalan ARIMAX dengan ramalan residual ANFIS. Model ramalan untuk data *outflow* dapat ditulis sebagai berikut.

$$Z_{1,t} = \hat{Z}_{1,t} + \bar{w}_{1,t} (-0,041 e_{1,t-1} + 0,334 e_{1,t-3} + 168,5) + \bar{w}_{2,t} (0,046 e_{1,t-1} + 0,192 e_{1,t-3} - 156,6).$$

Input lain dengan lag yang telah ditentukan sebelumnya dilakukan pemodelan dengan cara yang sama. Sehingga diperoleh nilai ramalan yang dijelaskan pada Tabel 4.44.

Tabel 4.44 Nilai Ramalan *Out-sample* Model Gabungan ARIMAX-ANFIS untuk Data *Outflow*

t (Bulan)	Aktual	Gabungan ARIMAX-ANFIS			
		Lag untuk <i>Input</i> ANFIS	Orde AR(2,12,14)	(1,3)	(1,48)
1	173,99		260,68	125,05	409,91
2	234,36		457,10	273,64	462,73
3	468,82		684,80	340,46	790,32
4	827,07		845,26	741,63	925,51
5	442,07		854,72	864,15	721,28
6	570,11		830,89	754,50	775,66
7	1566,17		2359,53	2344,25	1991,79
8	265,48		721,46	670,16	671,90
9	675,74		1275,68	1278,42	1315,04
10	1133,79		1073,34	1131,65	930,47
11	1221,34		1551,15	1553,40	849,58
12	3726,05		3718,86	4351,86	2581,98
					4750,22

Perbandingan kebaikan model berdasarkan sMAPE *out-sample* dapat dilihat pada Tabel 4.45. Model gabungan ARIMAX-ANFIS dengan input ANFIS berdasarkan lag signifikan pada plot PACF yaitu lag 1 dan lag 3 merupakan model terbaik yang bisa digunakan untuk meramalkan data *outflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 37,27%.

Tabel 4.45 Perbandingan Hasil Ramalan Model Gabungan ARIMAX-ANFIS

Data *Outflow*

Gabungan ARIMAX-ANFIS dengan Input ANFIS	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
Orde AR (lag 2,12,14)	239,69	371,05	32,91%	39,05%
Lag (1,3)	235,56	395,20	25,19%	34,24%
Lag (1,48)	245,71	464,09	19,75%	46,16%
Lag (3,48)	283,50	466,14	26,09%	36,94%

Setelah mendapatkan model terbaik untuk *outflow*, maka uji residual dilanjutkan pada pengujian varians residual homogen. Apabila varians residual tidak homogen maka akan dilanjutkan pemodelan GARCH. Untuk mendeteksi apakah varians homogen atau tidak adalah dengan melakukan pemeriksaan terhadap residual kuadrat dari model gabungan ARIMAX-ANFIS dengan menggunakan uji *portmanteau*. Hipotesis awal varians residual adalah homogen (tidak terdapat proses GARCH). Hasil uji *portmanteau* terdapat pada Tabel 4.46.

Tabel 4.46 Uji Heteroskedastisitas Model Gabungan ARIMAX-ANFIS *Outflow*

<i>k</i>	<i>Q</i>	Pr > <i>Q</i>
1	0,5886	0,4429
2	0,6165	0,7347
3	0,6999	0,8732
4	0,7051	0,9507
5	0,7216	0,9818
6	0,7593	0,9931
7	0,8055	0,9974
8	0,8122	0,9992
9	0,9173	0,9996
10	1,0379	0,9998
11	1,5044	0,9996
12	6,8773	0,8656

Tabel 4.46 menunjukkan hasil uji varians homogen menggunakan uji *portmanteau* memberikan kesimpulan bahwa varians residual homogen karena

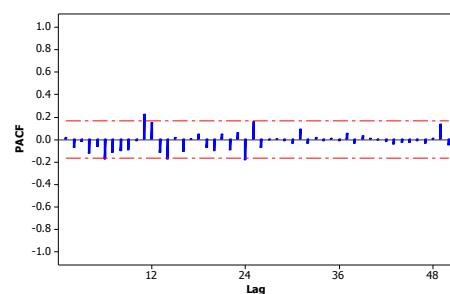
semua nilai $p\text{-value}$ lebih dari 0,05 ($\alpha = 5\%$). Sehingga dapat diperoleh kesimpulan bahwa model gabungan ARIMAX-ANFIS tersebut layak digunakan untuk peramalan 12 bulan kedepan karena mempunyai nilai RMSE *in sample* sebesar 243,95 yang lebih kecil dibandingkan dengan standard deviasi sebesar 643.

4.4.2 Peramalan Gabungan Data *Inflow*

Model ARIMAX dengan efek variasi kalender yang terbaik untuk data *inflow* adalah ARIMAX ([1,13,14],0,0)(1,0,0)⁴⁸ yang mengikuti persamaan

$$\begin{aligned} Z_{2,t}^* = & \quad 0,017t + 6,015M_{1,t} + 5,376M_{2,t} + 4,723M_{3,t} + 4,671M_{4,t} + 4,452M_{5,t} + \\ & 4,47M_{6,t} + 4,515M_{7,t} + 4,588M_{8,t} + 4,675M_{9,t} + 4,692M_{10,t} + 4,404M_{11,t} + \\ & 4,204M_{12,t} - 1,555I_t^{(49)} - 0,009tI_t^{(49)} + 0,183I_t^{(97)} - 0,008tI_t^{(97)} - 0,337D_{0,t} + \\ & 0,074D_{2,t} + 0,819D_{7,t} + 0,551D_{9,t} + 1,156D_{11,t} + 1,108D_{13,t} - 0,053D_{18,t} + \\ & 0,277D_{20,t} - 0,092D_{22,t} + 0,173D_{24,t} - 0,129D_{27,t} + 0,467D_{29,t} + 1,279D_{0,t+1} + \\ & 0,813D_{2,t+1} + 0,679D_{7,t+1} + 1,011D_{9,t+1} + 1,288D_{11,t+1} + 0,613D_{13,t+1} + 0,527D_{18,t+1} + \\ & -0,524D_{20,t+1} + 0,529D_{22,t+1} + 0,055D_{24,t+1} + 0,765D_{27,t+1} - 0,21D_{29,t+1} - 4,225V_{A,t}^{97} + \\ & -2,464V_{A,t}^{98} + 0,859V_{A,t}^{86} + \frac{a_t}{(1 - 0,504B - 0,355B^{13} + 0,571B^{14})(1 + 0,493B^{48})}. \end{aligned}$$

Residual yang diperoleh dari model ARIMAX yaitu $Z_{2,t} = \hat{Z}_{2,t} + e_{2,t}$ kemudian dimodelkan menggunakan ANFIS dengan lag 1, 13, 14, 48, 49, 61 dan 62 sebagai *input*. Selain penentuan *input* berdasarkan orde AR, input untuk ANFIS dapat juga ditentukan dengan menggunakan lag yang signifikan pada plot PACF dari residual ARIMAX ([1,13,14],0,0)(1,0,0)⁴⁸ dengan efek variasi kalender. Plot PACF tersebut dapat dilihat pada Gambar 4.21.

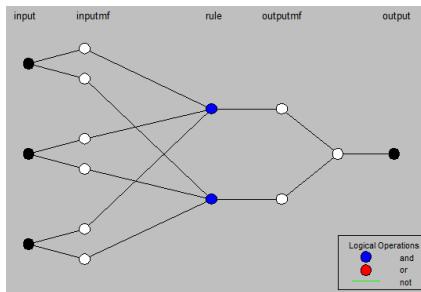


Gambar 4.21 Plot PACF Residual ARIMAX ([1,13,14],0,0)(1,0,0)⁴⁸ dengan Efek Variasi Kalender untuk *Inflow*

Berdasarkan plot PACF pada Gambar 4.21 dapat dilihat bahwa lag-lag yang signifikan adalah lag 6, 11, 12, 14 dan 24. *Input* yang akan digunakan pada model ANFIS adalah sebagai berikut:

1. Lag 6, 11, 12, 14 dan 24
2. Lag 11, 12, 14 dan 24
3. Lag 6, 11 dan 24
4. Lag 6, 11, dan 12
5. Lag 11 dan 24

Dalam peramalan ANFIS pada level kedua, yang akan dijelaskan dalam pembahasan ini adalah *input* berdasarkan lag PACF yang signifikan yaitu lag 6, 11 dan 24. Jenis fungsi keanggotaan digunakan adalah *Gaussian* dengan jumlah keanggotaan sebanyak 2 dan pengklasteran dilakukan menggunakan metode FCM. Arsitektur ANFIS dari data residual *inflow* dijelaskan pada Gambar 4.22.



Gambar 4.22 Arsitektur ANFIS dari Data Residual *Inflow*

Arsitektur ANFIS menjelaskan alur proses pada saat pemodelan menggunakan ANFIS. Aturan atau *rule* yang digunakan pada proses ANFIS ini adalah sebagai berikut.

Rule 1-1 : jika *input* 1 ($e_{2,t-6}$) kelompok A_1 , *input* 2 ($e_{1,t-11}$) kelompok B_1 dan *input* 3 ($e_{2,t-24}$) kelompok C_1 maka

$$e_{2,t}^{(1)} = c_{1,6}e_{2,t-6} + c_{1,11}e_{2,t-11} + c_{1,24}e_{2,t-24} + c_{1,0}$$

Rule 2-2 : jika *input* 1 ($e_{2,t-6}$) kelompok A_2 , *input* 2 ($e_{2,t-11}$) kelompok B_2 dan *input* 3 ($e_{2,t-24}$) kelompok C_2 maka

$$e_{2,t}^{(2)} = c_{2,6}e_{2,t-6} + c_{2,11}e_{2,t-11} + c_{2,24}e_{2,t-24} + c_{2,0}$$

ANFIS dengan 3 *input*, 2 jumlah keanggotaan dan 2 aturan ini menghasilkan 12 parameter *premise* dan 8 parameter *consequent* akhir. Nilai parameter *premise* dan parameter *consequent* akhir setelah dikenai pembelajaran pada proses ANFIS dapat dilihat pada Tabel 4.47 dan Tabel 4.48.

Tabel 4.47 Parameter *Premise* Akhir Pada Model ANFIS untuk Residual *Inflow*

Input	a_i	c_i
$e_{2,t-6}(A_1)$	40,70	0,90
$e_{2,t-6}(A_2)$	39,49	-4,00
$e_{2,t-11}(B_1)$	37,85	2,34
$e_{2,t-11}(B_2)$	37,36	-8,34
$e_{2,t-24}(C_1)$	36,39	-0,41
$e_{2,t-24}(C_2)$	35,11	-1,98

Tabel 4.48 Parameter *Consequent* Akhir Model ANFIS untuk Residual *Inflow*

i	$c_{i,6}$	$c_{i,11}$	$c_{i,24}$	$c_{i,0}$
1	0,44	0,15	-0,10	-63,15
2	-1,18	-0,08	-0,01	59,54

Parameter *consequent* yang diperoleh secara matematis dituliskan dengan persamaan linier pada setiap *rule* yaitu

$$e_{2,t}^{(1)} = 0,44e_{2,t-6} + 0,15e_{2,t-11} - 0,10e_{2,t-24} - 63,15$$

$$e_{2,t}^{(2)} = -1,18e_{2,t-6} - 0,08e_{2,t-11} - 0,01e_{2,t-24} + 59,54.$$

Secara keseluruhan, model ANFIS yang diperoleh untuk residual *inflow* adalah sebagai berikut.

$$\begin{aligned}\hat{e}_{2,t} &= \bar{w}_{1,t} e_{2,t}^{(1)} + \bar{w}_{2,t} e_{2,t}^{(2)} \\ &= \frac{w_{1,t}}{w_{1,t} + w_{2,t}} (0,44e_{2,t-6} + 0,15e_{2,t-11} - 0,10e_{2,t-24} - 63,15) + \\ &\quad \frac{w_{2,t}}{w_{1,t} + w_{2,t}} (-1,18e_{2,t-6} - 0,08e_{2,t-11} - 0,01e_{2,t-24} + 59,54)\end{aligned}$$

dengan

$$\begin{aligned}w_{1,t} &= \exp\left(\frac{-(e_{2,t-6} - 0,90)^2}{2(40,70)^2}\right) \exp\left(\frac{-(e_{2,t-11} - 2,34)^2}{2(37,85)^2}\right) \exp\left(\frac{-(e_{2,t-24} + 0,42)^2}{2(36,39)^2}\right) \\ w_{2,t} &= \exp\left(\frac{-(e_{2,t-6} + 4,00)^2}{2(39,49)^2}\right) \exp\left(\frac{-(e_{2,t-11} + 8,34)^2}{2(37,36)^2}\right) \exp\left(\frac{-(e_{2,t-24} + 1,98)^2}{2(35,11)^2}\right)\end{aligned}$$

Setelah mendapatkan ramalan residual menggunakan metode ANFIS, langkah selanjutnya yaitu menjumlahkan hasil ramalan ARIMAX dengan ramalan residual ANFIS. Model ramalan untuk data *inflow* dapat dituliskan sebagai berikut

$$Z_{2,t} = \hat{Z}_{2,t} + \bar{w}_{1,t} (0,44e_{2,t-6} + 0,15e_{2,t-11} - 0,10e_{2,t-24} - 63,15) + \\ \bar{w}_{2,t} (-1,18e_{2,t-6} - 0,08e_{2,t-11} - 0,01e_{2,t-24} + 59,54).$$

Input lain yang telah ditentukan sebelumnya juga dimodelkan dengan cara yang sama. Sehingga diperoleh ramalan yang dijelaskan pada Tabel 4.49.

Tabel 4.49 Nilai Ramalan *Out-sample* Model Gabungan ARIMAX-ANFIS untuk Data *Inflow*

t (Bulan)	Aktual	Gabungan ARIMAX-ANFIS Lag untuk <i>Input</i> ANFIS				
		(11,24)	(6,11,12)	(6,11,24)	(11,12,14,24)	(6,11,12,14,24)
1	1800,58	1331,60	1338,22	1323,33	1427,14	1441,19
2	691,51	915,44	938,19	825,79	697,04	821,54
3	321,08	665,86	651,89	663,13	640,10	561,66
4	435,54	458,26	509,41	486,24	384,53	395,49
5	339,99	359,86	385,22	409,24	435,81	391,78
6	372,52	439,94	353,11	342,95	389,34	383,36
7	227,39	327,22	379,58	312,20	373,28	414,04
8	870,09	902,24	884,77	946,63	853,30	990,56
9	391,76	435,16	384,16	390,06	389,78	453,00
10	446,04	455,75	419,29	424,76	413,57	447,91
11	397,41	205,44	232,87	208,60	188,67	256,26
12	499,74	298,61	250,74	288,75	238,66	310,87

Perbandingan kebaikan model berdasarkan sMAPE *out-sample* dapat dilihat pada Tabel 4.50. Model gabungan ARIMAX-ANFIS dengan *input* ANFIS berdasarkan lag signifikan pada plot PACF yaitu lag 6, 11, 12, 14 dan 24 merupakan model terbaik yang bisa digunakan untuk meramalkan data *inflow* hingga 12 bulan kedepan dengan nilai sMAPE sebesar 24,34%.

Tabel 4.50 Perbandingan Hasil Ramalan Model Gabungan ARIMAX-ANFIS Data *Inflow*

Gabungan ARIMAX-ANFIS dengan Input ANFIS	RMSE		sMAPE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
Lag (11,24)	75,95	200,98	71,40%	26,78%
Lag (6,11,12)	74,56	205,18	22,97%	28,31%
Lag (6,11,24)	75,51	196,79	35,02%	26,38%
Lag (11,12,14,24)	69,11	179,74	44,60%	27,70%
Lag (6,11,12,14,24)	60,65	162,55	53,53%	24,70%

Setelah mendapatkan model terbaik untuk *inflow*, maka uji residual dilanjutkan pada pengujian varians residual homogen. Apabila varians residual tidak homogen maka akan dilanjutkan pemodelan GARCH. Untuk mendeteksi apakah varians homogen atau tidak adalah dengan melakukan pemeriksaan terhadap residual kuadrat dari model gabungan ARIMAX-ANFIS dengan menggunakan uji *portmanteau*. Hipotesis awal varians residual adalah homogen (tidak terdapat proses GARCH). Hasil uji *portmanteau* terdapat pada Tabel 4.51.

Tabel 4.51 Uji Heteroskedastisitas Model Gabungan ARIMAX-ANFIS Data

Inflow

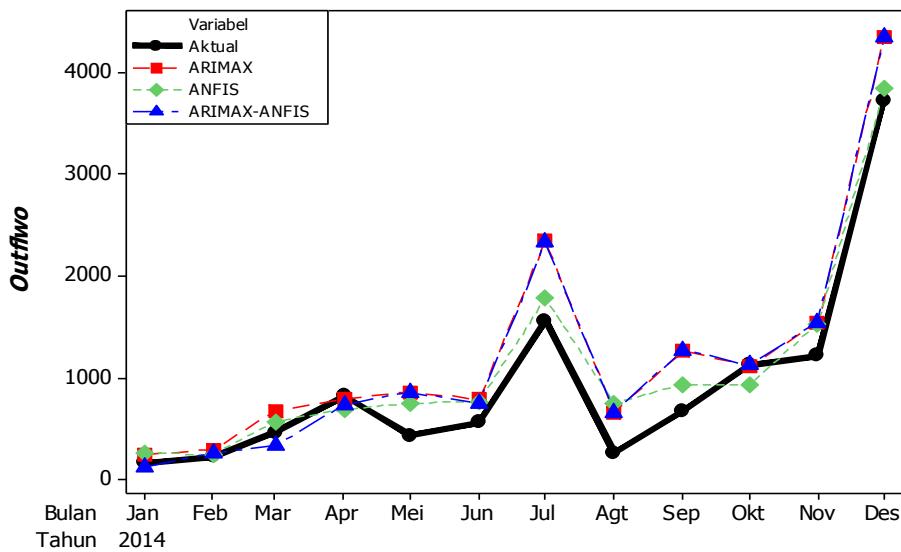
<i>k</i>	<i>Q</i>	Pr > <i>Q</i>
1	0,0432	0,8353
2	0,1038	0,9494
3	2,0260	0,5670
4	2,0438	0,7277
5	2,0965	0,8356
6	2,2605	0,8943
7	2,3491	0,9380
8	2,3581	0,9680
9	2,3587	0,9844
10	2,3899	0,9924
11	2,5118	0,9957
12	12,2038	0,4295

Tabel 4.51 menunjukkan hasil uji varians homogen menggunakan uji *portmanteau* memberikan kesimpulan bahwa varians residual homogen karena semua nilai *p-value* lebih dari 0,05 ($\alpha = 5\%$). Sehingga dapat diperoleh kesimpulan bahwa model gabungan ARIMAX-ANFIS tersebut layak digunakan untuk peramalan 12 bulan kedepan karena mempunyai nilai RMSE *in-sample* sebesar 60,64 yang lebih kecil dibandingkan dengan standard deviasi sebesar 209,5.

4.5 Pemilihan Model Terbaik

Metode peramalan dikatakan baik jika mempunyai tingkat akurasi yang lebih baik dibandingkan dengan model peramalan lainnya. Untuk mengetahui model yang baik digunakan untuk data *outflow* dan *inflow*, maka dilakukan

perbandingan nilai sMAPE dari model ARIMAX, ANFIS dan model gabungan ARIMAX-ANFIS. Secara visual, nilai ramalan data *outflow* model ARIMAX, ANFIS dan model gabungan ARIMAX-ANFIS untuk 12 bulan kedepan dijelaskan pada Gambar 4.23.



Gambar 4.23 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual *Outflow*

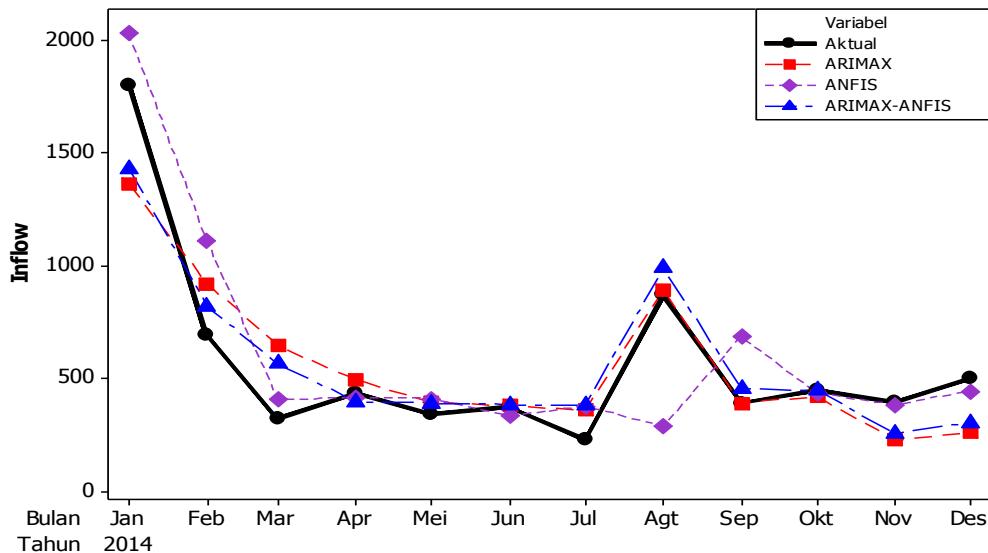
Plot antara hasil ramalan dengan data aktual pada Gambar 4.23 ini masih belum jelas menunjukkan metode terbaik yang hasil ramalannya mendekati nilai aktual. Oleh karena itu kebaikan model dapat dilihat berdasarkan nilai sMAPE pada Tabel 4.52.

Berdasarkan Tabel 4.52 maka dapat disimpulkan bahwa model terbaik untuk peramalan *outflow* uang kartal di Bank Indonesia Provinsi Papua untuk 1 dan 2 bulan kedepan adalah model gabungan ARIMAX-ANFIS sedangkan peramalan *outflow* uang kartal di Bank Indonesia Provinsi Papua untuk 3, 4, 5, 6, 7, 8, 9, 10, 11 dan 12 bulan kedepan adalah model ANFIS dengan nilai sMAPE yang disajikan pada Tabel 4.52. Nilai peramalan interval model terbaik untuk *outflow* 12 bulan kedepan yaitu dengan menggunakan metode ANFIS-GARCH dapat dilihat pada Tabel 4.36 dan secara visual dapat dilihat pada Gambar 4.16. Pada pemodelan data *outflow* residual yang mengandung heterokedastisitas hanya terdapat pada metode ANFIS.

Tabel 4.52 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual
Outflow

t (Bulan)	Nilai Aktual	ARIMAX			ANFIS			Gabungan ARIMAX-ANFIS		
		Ramalan	sAPE		Ramalan	sAPE		Ramalan	sAPE	
			Aditif	Kumulatif		Aditif	Kumulatif		Aditif	Kumulatif
1	173,99	251,47	36,42%	36,42%	267,18	42,24%	42,24%	125,05	32,73%	32,73%
2	234,36	301,81	25,16%	30,79%	252,40	7,41%	24,83%	273,64	15,46%	24,10%
3	468,82	680,61	36,85%	32,81%	574,35	20,23%	23,30%	340,46	31,72%	26,64%
4	827,07	795,92	3,84%	25,57%	694,31	17,45%	21,84%	741,63	10,89%	22,70%
5	442,07	867,84	65,01%	33,46%	756,75	52,50%	27,97%	864,15	64,63%	31,09%
6	570,11	794,52	32,89%	33,36%	769,94	29,82%	28,28%	754,50	27,84%	30,55%
7	1566,17	2346,59	39,89%	34,29%	1785,04	13,06%	26,10%	2344,25	39,80%	31,87%
8	265,48	663,78	85,72%	40,72%	757,69	96,21%	34,87%	670,16	86,50%	38,70%
9	675,74	1271,83	61,21%	43,00%	939,96	32,71%	34,63%	1278,42	61,68%	41,25%
10	1133,79	1123,60	0,90%	38,79%	939,52	18,74%	33,04%	1131,65	0,19%	37,14%
11	1221,34	1544,88	23,39%	37,39%	1533,80	22,68%	32,10%	1553,40	23,93%	35,94%
12	3726,05	4343,25	15,30%	35,55%	3850,27	3,28%	29,70%	4351,86	15,49%	34,24%

Secara visual, nilai ramalan data *inflow* model ARIMAX, ANFIS dan model gabungan ARIMAX-ANFIS untuk 12 bulan kedepan dijelaskan pada Gambar 4.24.



Gambar 4.24 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual *Inflow*

Plot antara hasil ramalan dengan data aktual pada Gambar 4.24 ini masih belum jelas menunjukkan metode terbaik yang hasil ramalannya mendekati nilai aktual. Oleh karena itu kebaikan model dapat dilihat berdasarkan nilai sMAPE pada Tabel 4.53.

Berdasarkan Tabel 4.53 maka dapat disimpulkan bahwa model terbaik untuk peramalan *inflow* uang kartal di Bank Indonesia Provinsi Papua untuk 1, 3, 4, 5, 6 dan 7 bulan kedepan adalah model ANFIS sedangkan peramalan *inflow* uang kartal di Bank Indonesia Provinsi Papua untuk 2, 8, 9, 10, 11 dan 12 bulan kedepan adalah model gabungan ARIMAX-ANFIS dengan nilai sMAPE yang disajikan pada Tabel 4.53. Pada pemodelan data *Inflow* residual yang mengandung heterokedastisitas hanya terdapat pada metode ARIMAX.

Tabel 4.53 Perbandingan Hasil Ramalan *Out-sample* Model ARIMAX, ANFIS dan Gabungan ARIMAX-ANFIS dengan Data Aktual
Inflow

t (Bulan)	Nilai Aktual	ARIMAX			ANFIS			Gabungan ARIMAX-ANFIS		
		Ramalan	sAPE		Ramalan	sAPE		Ramalan	sAPE	
			Aditif	Kumulatif		Aditif	Kumulatif		Aditif	Kumulatif
1	1800,58	1361,66	27,76%	27,76%	2031,44	12,05%	12,05%	1441,19	22,17%	22,17%
2	691,51	921,76	28,55%	28,15%	1108,77	46,36%	29,20%	821,54	17,19%	19,68%
3	321,08	646,03	67,20%	41,17%	405,75	23,30%	27,23%	561,66	54,51%	31,29%
4	435,54	494,84	12,75%	34,06%	417,42	4,25%	21,49%	395,49	9,64%	25,88%
5	339,99	395,43	15,08%	30,27%	411,64	19,06%	21,00%	391,78	14,15%	23,53%
6	372,52	380,46	2,11%	25,57%	335,20	10,55%	19,26%	383,36	2,87%	20,09%
7	227,39	361,42	45,53%	28,42%	377,74	49,69%	23,61%	414,04	58,20%	25,53%
8	870,09	892,57	2,55%	25,19%	288,06	100,51%	33,22%	990,56	12,95%	23,96%
9	391,76	391,14	0,16%	22,41%	687,08	54,75%	35,61%	453,00	14,50%	22,91%
10	446,04	421,67	5,62%	20,73%	435,85	2,31%	32,28%	447,91	0,42%	20,66%
11	397,41	227,03	54,57%	23,81%	384,65	3,26%	29,64%	256,26	43,19%	22,71%
12	499,74	259,99	63,11%	27,08%	444,27	11,75%	28,15%	310,87	46,60%	24,70%

(Halaman ini sengaja dikosongkan)

Lampiran 1 Data *Outflow* Uang Kartal di Bank Indonesia Provinsi Papua

Bulan	Tahun											
	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
Januari	198,32461	166,35377	155,85932	266,29973	64,69467	152,78426	3,01671	10,31630	52,04183	157,58305	249,31139	173,99063
Februari	137,15461	179,89398	188,72855	296,44533	39,61743	3,21369	7,57783	6,74910	24,65866	249,91433	223,30473	234,36432
Maret	113,55894	147,51372	163,96867	244,81503	92,81032	52,65176	166,01008	188,50747	456,49136	480,00299	545,05980	468,82431
April	175,35211	197,60158	215,31842	263,67749	145,35975	174,53369	226,40885	174,90059	663,42863	671,39993	647,00230	827,06580
Mei	218,00100	183,41334	165,54787	344,55402	172,67964	240,02032	144,22473	284,17173	552,84238	810,41676	705,65653	442,06816
Juni	211,48660	316,63732	260,86677	400,91642	331,57955	338,52045	262,45771	434,64087	675,04213	845,36813	736,28659	570,11261
Juli	239,68960	248,27262	389,52773	380,25138	285,61798	202,61052	193,35486	418,06054	620,07330	1058,02355	1518,57681	1566,16605
Agustus	181,79837	198,51193	327,90127	420,10878	218,73400	216,20497	265,81736	395,40656	1180,55998	1179,21368	756,15908	265,48211
September	271,06512	235,29616	312,27897	514,66798	255,01699	663,53510	384,74710	366,48958	302,14077	534,65664	797,43057	675,74330
Oktober	222,84244	304,54882	426,82213	773,72743	380,59311	66,05429	142,95096	375,64262	750,25102	969,18637	850,89702	1133,78665
November	342,39036	349,28207	380,82542	565,56147	344,18800	402,13319	303,93869	1035,07139	849,12086	1209,85472	1417,59238	1221,34415
Desember	798,21448	628,21217	931,09079	1272,96933	1357,08380	1293,30064	2015,67845	4080,41810	2773,05886	3627,99379	3503,70527	3726,05212

Lampiran 2 Data *Inflow* Uang Kartal di Bank Indonesia Provinsi Papua

Bulan	Tahun											
	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
Januari	270,45222	300,71234	285,42973	389,22951	348,22474	149,51609	355,58767	417,89021	20,65347	896,42325	1423,51840	1800,58228
Februari	118,15066	154,46247	162,02496	229,83930	117,33531	197,37291	110,41477	391,85000	64,47342	614,16945	872,97120	691,50944
Maret	121,30971	158,46292	160,12476	219,63867	35,82217	32,80076	101,87042	30,76674	310,17539	381,41282	419,92708	321,08024
April	123,17394	134,91312	162,96475	225,42048	57,14185	39,90277	33,01727	48,93560	277,77765	354,93598	455,19290	435,54429
Mei	112,73416	134,67030	133,20877	225,88517	34,77494	27,95175	24,48989	25,02999	292,94358	431,63915	443,35998	339,99470
Juni	128,89626	161,79580	145,90498	269,97485	28,66957	30,50977	23,60304	40,82158	245,79206	316,52860	354,48110	372,52000
Juli	187,94337	158,86711	214,36109	276,37493	28,83000	31,66799	15,86552	33,81100	324,00824	491,24891	347,49221	227,38995
Agustus	131,24686	180,96548	218,32424	335,98069	35,36203	31,38417	14,46531	48,92295	249,09766	609,95995	939,93717	870,09460
September	184,35920	158,69021	214,48093	319,72770	33,00323	28,87574	19,90671	72,15566	592,90238	469,92275	419,30186	391,76106
Oktober	196,65618	182,15009	195,19195	369,47047	88,35779	77,81023	56,77539	55,30785	306,25931	463,36744	358,73256	446,03917
November	97,79610	180,31992	260,30457	451,92573	56,26508	25,92378	28,79898	126,36451	326,25040	389,60006	312,75946	397,41237
Desember	251,22158	221,78027	267,29192	121,76041	26,93492	14,71538	21,50503	72,43040	282,84526	302,67919	400,79232	499,74344

Lampiran 3 Syntax MATLAB Model ANFIS

```
x=load('D:/outflow.txt');
x_1=x(15:119);
x_2=x(12:116);
x_3=x(3:107);
x_4=x(1:105);
x_11=[x_1 x_2 x_3 x_4];

x_21=x(120:131);
x_22=x(117:128);
x_23=x(108:119);
x_24=x(106:117);
x_12=[x_21 x_22 x_23 x_24];

y_1=x(16:120);
y_2=x(121:132);

epoch_n=50;
numMFs=2;
mfType='sugeno';
in_fis1=genfis3(x_11, y_1,mfType,numMFs);
out_fis1=anfis([x_11 y_1],in_fis1,epoch_n);

y_hat1=evalfis(x_11,out_fis1);
yt1=x;
for i=121:132;
yt1(i)=evalfis([yt1(i-1) yt1(i-3) yt1(i-12) yt1(i-15)],out_fis1);
end;
y_hat2=yt1(121:132);

er_in1=y_1-y_hat1;
er_out1=y_2-y_hat2;
rmse_in1=sqrt(sum(er_in1.*er_in1)/length(er_in1))
rmse_out1=sqrt(sum(er_out1.*er_out1)/length(er_out1))
mape_in1=sum(abs(er_in1./y_1)/length(er_in1))*100
mape_out1=sum(abs(er_out1./y_2)/length(er_out1))*100
smape_in1=sum(abs(er_in1./((y_1+y_hat1)/2))/length(er_in1))*100
smape_out1=sum(abs(er_out1./((y_2+y_hat2)/2))/length(er_out1))*100

ruleview(out_fis1)
showfis(out_fis1)
```

Lampiran 4 Syntax SAS Regresi Time Series

Lampiran 5 Syntax SAS Model ARIMA

Lampiran 6 Syntax SAS Model ARIMAX

Lampiran 7 Hasil Estimasi Parameter, Independen dan Kenormalan Residual

Regrisi Time Series untuk Data Outflow Uang Kartal

Conditional Least Squares Estimation								
Parameter	Estimate	Standard		Approx		Lag	Variable	Shift
		Error	t Value	Pr > t	Lag			
NUM1	0.01553	0.01419	1.09	0.2767	0	t	0	
NUM2	5.73518	0.51141	11.21	<.0001	0	M1	0	
NUM3	5.11225	0.51430	9.94	<.0001	0	M2	0	
NUM4	7.17010	0.51736	13.86	<.0001	0	M3	0	
NUM5	7.83032	0.52058	15.04	<.0001	0	M4	0	
NUM6	7.94962	0.52396	15.17	<.0001	0	M5	0	
NUM7	8.56710	0.52750	16.24	<.0001	0	M6	0	
NUM8	8.38467	0.57380	14.61	<.0001	0	M7	0	
NUM9	8.04104	0.62462	12.87	<.0001	0	M8	0	
NUM10	7.67345	0.61467	12.48	<.0001	0	M9	0	
NUM11	8.38291	0.70754	11.85	<.0001	0	M10	0	
NUM12	9.48751	0.62257	15.24	<.0001	0	M11	0	
NUM13	11.90009	0.55191	21.56	<.0001	0	M12	0	
NUM14	-0.69599	1.38871	-0.50	0.6174	0	D24tm1	0	
NUM15	-0.92412	1.34072	-0.69	0.4924	0	D24t	0	
NUM16	-0.23852	1.37452	-0.17	0.8626	0	D13tm1	0	
NUM17	-1.06786	1.32269	-0.81	0.4215	0	D13t	0	
NUM18	0.30084	1.38134	0.22	0.8281	0	D2tm1	0	
NUM19	-1.06809	1.32646	-0.81	0.4227	0	D2t	0	
NUM20	1.25579	1.37253	0.91	0.3626	0	D22tm1	0	
NUM21	1.47350	1.40887	1.05	0.2983	0	D22t	0	
NUM22	1.25490	1.36585	0.92	0.3606	0	D11tm1	0	
NUM23	1.36880	1.39000	0.98	0.3273	0	D11t	0	
NUM24	3.09148	1.34956	2.29	0.0242	0	D0tm1	0	
NUM25	-2.27812	1.36331	-1.67	0.0981	0	D0t	0	
NUM26	0.48191	1.34907	0.36	0.7217	0	D20tm1	0	
NUM27	1.61086	1.35514	1.19	0.2376	0	D20t	0	
NUM28	1.06789	1.38130	0.77	0.4414	0	D9tm1	0	
NUM29	1.24974	1.38233	0.90	0.3683	0	D9t	0	
NUM30	0.22293	1.35142	0.16	0.8693	0	D29tm1	0	
NUM31	2.06344	1.37285	1.50	0.1362	0	D29t	0	
NUM32	0.86910	1.33024	0.65	0.5152	0	D18tm1	0	
NUM33	1.43030	1.35679	1.05	0.2945	0	D18t	0	
NUM34	1.15376	1.36029	0.85	0.3985	0	D7tm1	0	
NUM35	-0.28274	1.39093	-0.20	0.8394	0	D7t	0	
NUM36	-2.02802	1.10707	-1.83	0.0702	0	I48t	0	
NUM37	0.0058153	0.01995	0.29	0.7713	0	tI48t	0	
NUM38	-3.96454	2.52151	-1.57	0.1193	0	I96t	0	
NUM39	0.03699	0.02573	1.44	0.1539	0	tI96t	0	

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	15.26	6	0.0183	0.175	-0.266	-0.059	0.050	0.063	0.031
12	53.49	12	<.0001	-0.025	-0.088	-0.063	-0.162	0.146	0.448
18	59.80	18	<.0001	-0.054	-0.177	0.014	0.007	-0.033	-0.079
24	72.73	24	<.0001	-0.020	-0.035	-0.086	-0.176	0.089	0.179
30	76.79	30	<.0001	-0.108	-0.066	-0.073	-0.018	-0.038	-0.033
36	82.82	36	<.0001	-0.054	-0.098	-0.080	-0.027	0.069	-0.095

Tests for Normality								
Test	--Statistic--			----p Value-----				
Shapiro-Wilk	W	0.923979	Pr < W	<0.0001				
Kolmogorov-Smirnov	D	0.123264	Pr > D	<0.0100				
Cramer-von Mises	W-Sq	0.661395	Pr > W-Sq	<0.0050				
Anderson-Darling	A-Sq	3.602077	Pr > A-Sq	<0.0050				

Lampiran 8 Hasil Estimasi Parameter, Independen dan Kenormalan Residual
 Model ARIMA (2,0,0)(1,0,0)¹² untuk Data *Outflow Uang Kartal*

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Pr > t	Approx Lag
AR1,1	0.26814	0.08506	3.15	0.0020	1
AR1,2	-0.26742	0.08524	-3.14	0.0021	2
AR2,1	0.44700	0.07962	5.61	<.0001	12
Variance Estimate	0.767801				
Std Error Estimate	0.876243				
AIC	342.6876				
SBC	351.336				
Number of Residuals	132				
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.56	3	0.4640	0.016	0.008	0.059	0.087	0.053	0.065
12	5.85	9	0.7544	-0.019	-0.127	0.035	-0.053	0.047	0.017
18	12.42	15	0.6469	-0.075	-0.088	0.100	-0.078	-0.001	-0.117
24	16.67	21	0.7306	0.010	-0.004	-0.013	-0.152	0.018	0.052
30	24.74	27	0.5893	-0.108	0.032	-0.158	-0.017	-0.099	-0.008
36	31.42	33	0.5459	-0.108	-0.087	-0.090	-0.041	0.060	-0.071

Tests for Normality									
Test	--Statistic---			----p Value-----					
Shapiro-Wilk	W	0.867022	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.102498	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.558968	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	3.193442	Pr > A-Sq	<0.0050					

Lampiran 9 Hasil Estimasi Parameter, Independen dan Kenormalan Residual
 Model ARIMA (1,0,[2])(1,0,0)¹² untuk Data *Outflow* Uang Kartal

conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Pr > t	Lag
MA1,1	0.23872	0.08990	2.66	0.0089	2
AR1,1	0.27556	0.08834	3.12	0.0022	1
AR2,1	0.44004	0.08049	5.47	<.0001	12
Variance Estimate	0.775249				
Std Error Estimate	0.880482				
AIC	343.9617				
SBC	352.6101				
Number of Residuals	132				
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations-----					
6	3.65	3	0.3024	0.007	-0.031	-0.022	0.122	0.077	0.063
12	7.24	9	0.6117	-0.024	-0.131	0.031	-0.043	0.068	0.008
18	14.76	15	0.4688	-0.074	-0.097	0.113	-0.067	-0.002	-0.131
24	19.52	21	0.5520	0.031	0.002	-0.014	-0.154	0.011	0.068
30	27.22	27	0.4520	-0.098	0.030	-0.162	-0.004	-0.093	0.014
36	33.66	33	0.4354	-0.104	-0.089	-0.093	-0.016	0.063	-0.068

Tests for Normality						
Test	--Statistic---		----p Value-----			
Shapiro-Wilk	W	0.864987	Pr < W	<0.0001		
Kolmogorov-Smirnov	D	0.103751	Pr > D	<0.0100		
Cramer-von Mises	W-Sq	0.582118	Pr > W-Sq	<0.0050		
Anderson-Darling	A-Sq	3.31297	Pr > A-Sq	<0.0050		

Lampiran 10 Hasil Estimasi Parameter, Independen dan Kenormalan Residual

Model ARIMA ([2],0,1)(1,0,0)¹² untuk Data *Outflow Uang Kartal*

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Pr > t	Lag
MA1,1	-0.27295	0.08779	-3.11	0.0023	1
AR1,1	-0.20604	0.08897	-2.32	0.0221	2
AR2,1	0.44212	0.08003	5.52	<.0001	12
Variance Estimate 0.767344					
Std Error Estimate 0.875982					
AIC 342.6089					
SBC 351.2573					
Number of Residuals 132					
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations-----					
6	2.45	3	0.4851	0.007	0.014	-0.018	0.086	0.075	0.064
12	6.25	9	0.7142	-0.022	-0.137	0.032	-0.046	0.062	0.010
18	13.28	15	0.5810	-0.068	-0.092	0.107	-0.077	0.007	-0.125
24	17.61	21	0.6738	0.026	-0.009	-0.008	-0.148	0.013	0.063
30	25.85	27	0.5268	-0.100	0.039	-0.168	-0.001	-0.096	0.009
36	32.00	33	0.5165	-0.107	-0.088	-0.084	-0.026	0.059	-0.064

Tests for Normality					
Test	--Statistic---		----p Value-----		
Shapiro-Wilk	W	0.866058	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.104881	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.560468	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	3.229794	Pr > A-Sq	<0.0050	

Lampiran 11 Hasil Estimasi Parameter, Independen dan Kenormalan Residual
 Model ARIMAX([2],0,1)(1,0,0)¹² dengan Efek Variasi Kalender
 untuk Data *Outflow* Uang Kartal

Parameter	Estimate	Conditional Least Squares Estimation						Shift
		Error	t Value	Pr > t	Lag	Variable	Approx	
MA1,1	-0.60812	0.10947	-5.56	<.0001	1	outflowtrans	0	
AR1,1	-0.24796	0.11841	-2.09	0.0391	2	outflowtrans	0	
AR2,1	0.57446	0.09703	5.92	<.0001	12	outflowtrans	0	
NUM1	0.01614	0.01387	1.16	0.2477	0	t	0	
NUM2	5.87816	0.63419	9.27	<.0001	0	M1	0	
NUM3	5.51307	0.71069	7.76	<.0001	0	M2	0	
NUM4	7.01849	0.71518	9.81	<.0001	0	M3	0	
NUM5	7.68664	0.71156	10.80	<.0001	0	M4	0	
NUM6	7.88282	0.71456	11.03	<.0001	0	M5	0	
NUM7	8.30430	0.72254	11.49	<.0001	0	M6	0	
NUM8	8.26741	0.75710	10.92	<.0001	0	M7	0	
NUM9	7.92111	0.80235	9.87	<.0001	0	M8	0	
NUM10	7.83544	0.74328	10.54	<.0001	0	M9	0	
NUM11	8.72314	0.95172	9.17	<.0001	0	M10	0	
NUM12	8.86752	0.87897	10.09	<.0001	0	M11	0	
NUM13	11.78470	0.65785	17.91	<.0001	0	M12	0	
NUM14	-1.84227	1.23121	-1.50	0.1381	0	D24tm1	0	
NUM15	0.08654	1.06956	0.08	0.9352	0	D24t	0	
NUM16	-1.08168	1.26306	-0.86	0.3941	0	D13tm1	0	
NUM17	0.15887	1.06640	0.15	0.8819	0	D13t	0	
NUM18	-0.64713	1.20211	-0.54	0.5917	0	D2tm1	0	
NUM19	0.01993	0.91319	0.02	0.9826	0	D2t	0	
NUM20	0.77704	0.92754	0.84	0.4044	0	D22tm1	0	
NUM21	0.51974	1.17289	0.44	0.6587	0	D22t	0	
NUM22	1.14060	1.08624	1.05	0.2965	0	D11tm1	0	
NUM23	1.54867	1.13143	1.37	0.1745	0	D11t	0	
NUM24	2.89748	1.06931	2.71	0.0081	0	D0tm1	0	
NUM25	-1.59826	0.91876	-1.74	0.0854	0	D0t	0	
NUM26	0.61215	0.91352	0.67	0.5045	0	D20tm1	0	
NUM27	1.55906	1.04113	1.50	0.1378	0	D20t	0	
NUM28	0.99007	1.08224	0.91	0.3627	0	D9tm1	0	
NUM29	1.79417	0.94140	1.91	0.0599	0	D9t	0	
NUM30	-0.36927	0.96539	-0.38	0.7030	0	D29tm1	0	
NUM31	2.56813	1.20408	2.13	0.0357	0	D29t	0	
NUM32	0.68339	1.12190	0.61	0.5440	0	D18tm1	0	
NUM33	1.66107	1.27573	1.30	0.1963	0	D18t	0	
NUM34	1.47610	1.22165	1.21	0.2301	0	D7tm1	0	
NUM35	-0.74903	1.34967	-0.55	0.5803	0	D7t	0	
NUM36	-2.10292	1.19392	-1.76	0.0816	0	I48t	0	
NUM37	0.0073308	0.02255	0.33	0.7458	0	tI48t	0	
NUM38	-3.00514	2.38622	-1.26	0.2112	0	I96t	0	
NUM39	0.02767	0.02504	1.11	0.2721	0	tI96t	0	
NUM40	3.97215	0.58686	6.77	<.0001	0	A61	0	

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelation Check of Residuals							
				-----Autocorrelations-----							
6	1.97	3	0.5778	0.002	0.011	0.034	0.064	0.064	0.064	0.069	
12	4.93	9	0.8400	-0.019	-0.080	0.052	-0.038	0.049	0.049	0.084	
18	10.84	15	0.7641	-0.033	-0.129	0.121	-0.011	-0.074	-0.074	-0.034	
24	17.08	21	0.7064	0.069	-0.062	0.082	-0.148	-0.036	-0.036	-0.020	
30	22.96	27	0.6872	0.008	-0.084	-0.081	-0.073	-0.071	-0.071	-0.103	
36	30.67	33	0.5838	-0.055	-0.065	-0.175	-0.049	-0.030	-0.030	-0.043	

Test	Tests for Normality		
	--Statistic--	-----	p Value-----
Shapiro-Wilk	W	0.96273	Pr < W 0.0011
Kolmogorov-Smirnov	D	0.06717	Pr > D 0.1488
Cramer-von Mises	W-Sq	0.115917	Pr > W-Sq 0.0719
Anderson-Darling	A-Sq	0.873818	Pr > A-Sq 0.0245

Lampiran 12 Hasil Estimasi Parameter yang Telah Signifikan, Independen dan Kenormalan Residual Model ARIMAX(0,0,1)(1,0,0)¹² dengan Efek Variasi Kalender untuk Data *Outflow Uang Kartal*

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr > t	Lag	Variable	Shift
MA1,1	-0.84043	0.05685	-14.78	<.0001	1	outflowtrans	0
AR1,1	0.68125	0.07952	8.57	<.0001	12	outflowtrans	0
NUM1	0.02082	0.0055385	3.76	0.0003	0	t	0
NUM2	5.87206	0.62201	9.44	<.0001	0	M1	0
NUM3	5.38736	0.77937	6.91	<.0001	0	M2	0
NUM4	6.69298	0.77483	8.64	<.0001	0	M3	0
NUM5	7.37543	0.77680	9.49	<.0001	0	M4	0
NUM6	7.60416	0.77848	9.77	<.0001	0	M5	0
NUM7	8.46182	0.79823	10.60	<.0001	0	M6	0
NUM8	8.21577	0.78242	10.50	<.0001	0	M7	0
NUM9	8.02603	0.78698	10.20	<.0001	0	M8	0
NUM10	7.94708	0.78732	10.09	<.0001	0	M9	0
NUM11	8.02168	0.79107	10.14	<.0001	0	M10	0
NUM12	8.77042	0.79123	11.08	<.0001	0	M11	0
NUM13	11.45075	0.63792	17.95	<.0001	0	M12	0
NUM14	1.78945	0.65882	2.72	0.0077	0	D0tm1	0
NUM15	-2.88948	0.70422	-4.10	<.0001	0	D0t	0
NUM16	2.60021	0.38783	6.70	<.0001	0	D29t	0
NUM17	-2.42837	0.51190	-4.74	<.0001	0	D7t	0
NUM18	-1.22044	0.28411	-4.30	<.0001	0	I48t	0
NUM19	2.89572	0.44267	6.54	<.0001	0	A61	0
NUM20	-2.17712	0.48748	-4.47	<.0001	0	A73	0
NUM21	1.69279	0.39354	4.30	<.0001	0	A110	0
NUM22	-1.36556	0.42781	-3.19	0.0019	0	A6	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.58	4	0.3334	-0.090	-0.036	0.092	0.023	0.072	0.098
12	9.16	10	0.5173	-0.020	-0.111	0.013	-0.056	-0.059	0.110
18	14.53	16	0.5593	-0.119	-0.087	0.075	-0.031	-0.076	-0.038
24	17.34	22	0.7445	0.026	0.128	0.019	-0.017	0.002	-0.005
30	22.37	28	0.7639	-0.001	0.051	-0.007	-0.090	0.050	-0.127
36	30.91	34	0.6200	0.026	0.035	-0.047	-0.139	0.138	-0.067

Tests for Normality							
Test	--Statistic--		----p Value----				
Shapiro-Wilk	W	0.96675	Pr < W	0.0025			
Kolmogorov-Smirnov	D	0.071845	Pr > D	0.0927			
Cramer-von Mises	W-Sq	0.112022	Pr > W-Sq	0.0808			
Anderson-Darling	A-Sq	0.898731	Pr > A-Sq	0.0221			

Lampiran 13 Hasil Estimasi Parameter, Independen dan Kenormalan Residual

Regrisi *Time Series* untuk Data *Inflow* Uang Kartal

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr > t	Lag	Variable	Shift
NUM1	0.01745	0.0068869	2.53	0.0130	0	t	0
NUM2	5.68795	0.24697	23.03	<.0001	0	M1	0
NUM3	5.27198	0.24836	21.23	<.0001	0	M2	0
NUM4	4.77523	0.24984	19.11	<.0001	0	M3	0
NUM5	4.73715	0.25139	18.84	<.0001	0	M4	0
NUM6	4.54580	0.25303	17.97	<.0001	0	M5	0
NUM7	4.54658	0.25474	17.85	<.0001	0	M6	0
NUM8	4.61063	0.25653	17.97	<.0001	0	M7	0
NUM9	4.56343	0.27962	16.32	<.0001	0	M8	0
NUM10	4.70581	0.30475	15.44	<.0001	0	M9	0
NUM11	4.78725	0.29938	15.99	<.0001	0	M10	0
NUM12	4.70630	0.34293	13.72	<.0001	0	M11	0
NUM13	4.26970	0.30182	14.15	<.0001	0	M12	0
NUM14	-0.31532	0.67151	-0.47	0.6398	0	D24t	0
NUM15	1.04729	0.64794	1.62	0.1094	0	D24tp1	0
NUM16	0.08718	0.66575	0.13	0.8961	0	D13t	0
NUM17	0.71330	0.64018	1.11	0.2681	0	D13tp1	0
NUM18	0.24496	0.67021	0.37	0.7156	0	D2t	0
NUM19	0.69060	0.64303	1.07	0.2856	0	D2tp1	0
NUM20	0.32233	0.66557	0.48	0.6293	0	D22t	0
NUM21	0.58728	0.68469	0.86	0.3932	0	D22tp1	0
NUM22	0.63795	0.65988	0.97	0.3362	0	D11t	0
NUM23	0.26280	0.67208	0.39	0.6967	0	D11tp1	0
NUM24	0.45349	0.65298	0.69	0.4891	0	D0t	0
NUM25	-0.56945	0.65967	-0.86	0.3902	0	D0tp1	0
NUM26	-0.88084	0.65372	-1.35	0.1811	0	D20t	0
NUM27	0.08098	0.65676	0.12	0.9021	0	D20tp1	0
NUM28	0.34959	0.67012	0.52	0.6031	0	D9t	0
NUM29	-0.0025524	0.67101	-0.00	0.9970	0	D9tp1	0
NUM30	0.33532	0.65182	0.51	0.6082	0	D29t	0
NUM31	1.01789	0.66238	1.54	0.1278	0	D29tp1	0
NUM32	0.72412	0.64415	1.12	0.2638	0	D18t	0
NUM33	0.27869	0.65721	0.42	0.6725	0	D18tp1	0
NUM34	0.64979	0.66151	0.98	0.3285	0	D7t	0
NUM35	-0.34203	0.67655	-0.51	0.6144	0	D7tp1	0
NUM36	-1.22096	0.53622	-2.28	0.0251	0	I48t	0
NUM37	-0.01267	0.0097171	-1.30	0.1956	0	tI48t	0
NUM38	-3.77269	1.22445	-3.08	0.0027	0	I96t	0
NUM39	0.02478	0.01255	1.97	0.0513	0	tI96t	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	17.48	6	0.0077	0.273	-0.109	-0.059	-0.037	-0.129	-0.141
12	20.01	12	0.0670	-0.014	0.049	0.043	0.095	-0.009	-0.063
18	26.25	18	0.0941	0.102	0.037	-0.004	-0.171	-0.007	-0.015
24	32.13	24	0.1239	-0.022	-0.012	0.013	-0.087	-0.122	-0.114
30	34.48	30	0.2621	0.023	0.081	-0.068	-0.029	0.015	-0.035
36	46.33	36	0.1162	-0.109	0.010	0.101	0.073	-0.161	-0.110

Tests for Normality							
Test	--Statistic---			----p Value-----			
Shapiro-Wilk	W	0.873727	Pr < W	<0.0001			
Kolmogorov-Smirnov	D	0.108652	Pr > D	<0.0100			
Cramer-von Mises	W-Sq	0.622505	Pr > W-Sq	<0.0050			
Anderson-Darling	A-Sq	3.393291	Pr > A-Sq	<0.0050			

Lampiran 14 Hasil Estimasi Parameter, Independen dan Kenormalan Residual
 Model ARIMA (1,0,0)(1,0,0)⁴⁸ untuk Data *Inflow* Uang Kartal

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Pr > t	Lag
AR1,1	0.29788	0.08396	3.55	0.0005	1
AR2,1	-0.66828	0.13537	-4.94	<.0001	48
Variance Estimate			0.196542		
Std Error Estimate			0.443331		
AIC			161.8364		
SBC			167.602		
Number of Residuals			132		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations-----					
6	3.37	4	0.4978	0.031	-0.107	0.006	0.041	-0.063	-0.079
12	9.36	10	0.4980	0.024	0.067	-0.011	0.062	0.049	-0.172
18	18.12	16	0.3171	0.077	0.047	0.097	-0.198	-0.000	-0.029
24	22.54	22	0.4280	-0.026	0.013	-0.049	-0.034	-0.076	-0.130
30	24.67	28	0.6456	-0.032	0.059	-0.084	-0.007	0.030	-0.014
36	34.58	34	0.4403	-0.110	-0.114	0.103	0.059	-0.115	-0.054

Tests for Normality						
Test	--Statistic---		----p Value-----			
Shapiro-Wilk	W	0.922987	Pr < W	<0.0001		
Kolmogorov-Smirnov	D	0.093243	Pr > D	<0.0100		
Cramer-von Mises	W-Sq	0.295745	Pr > W-Sq	<0.0050		
Anderson-Darling	A-Sq	1.75146	Pr > A-Sq	<0.0050		

Lampiran 15 Hasil Estimasi Parameter, Independen dan Kenormalan Residual
 Model ARIMA (0,0,1)(1,0,0)⁴⁸ untuk Data *Inflow* Uang Kartal

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Pr > t	Approx Lag
MA1,1	-0.33707	0.08306	-4.06	<.0001	1
AR1,1	-0.61699	0.13327	-4.63	<.0001	48
		Variance Estimate	0.193904		
		Std Error Estimate	0.440345		
		AIC	160.0527		
		SBC	165.8183		
		Number of Residuals	132		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations-----					
6	1.55	4	0.8181	-0.003	-0.018	-0.007	0.034	-0.064	-0.074
12	7.21	10	0.7057	0.016	0.063	-0.009	0.056	0.055	-0.168
18	17.80	16	0.3360	0.102	-0.000	0.113	-0.210	0.021	-0.045
24	22.18	22	0.4494	-0.026	0.006	-0.050	-0.045	-0.078	-0.125
30	24.35	28	0.6629	-0.039	0.055	-0.089	-0.001	0.012	-0.019
36	32.46	34	0.5433	-0.098	-0.101	0.088	0.051	-0.105	-0.065

Tests for Normality						
Test	--Statistic---		----p Value-----			
Shapiro-Wilk	W	0.924737	Pr < W	<0.0001		
Kolmogorov-Smirnov	D	0.087337	Pr > D	0.0149		
Cramer-von Mises	W-Sq	0.277495	Pr > W-Sq	<0.0050		
Anderson-Darling	A-Sq	1.63904	Pr > A-Sq	<0.0050		

Lampiran 16 Hasil Estimasi Parameter, Independen dan Kenormalan Residual
 Model ARIMAX([1,13,14],0,0)(1,0,0)⁴⁸ dengan Efek Variasi
 Kalender untuk Data *Inflow* Uang Kartal

Parameter	Estimate	Conditional Least Squares Estimation					
		Error	t Value	Pr > t	Lag	Variable	Shift
AR1,1	0.50422	0.08564	5.89	<.0001	1	inflowtrans	0
AR1,2	0.35517	0.09886	3.59	0.0005	13	inflowtrans	0
AR1,3	-0.57075	0.10055	-5.68	<.0001	14	inflowtrans	0
AR2,1	-0.49263	0.14562	-3.38	0.0011	48	inflowtrans	0
NUM1	0.01741	0.0058362	2.98	0.0037	0	t	0
NUM2	6.01496	0.17193	34.98	<.0001	0	M1	0
NUM3	5.37562	0.18486	29.08	<.0001	0	M2	0
NUM4	4.72272	0.18632	25.35	<.0001	0	M3	0
NUM5	4.67124	0.18692	24.99	<.0001	0	M4	0
NUM6	4.45221	0.18622	23.91	<.0001	0	M5	0
NUM7	4.46953	0.18509	24.15	<.0001	0	M6	0
NUM8	4.51537	0.18538	24.36	<.0001	0	M7	0
NUM9	4.58763	0.19349	23.71	<.0001	0	M8	0
NUM10	4.67501	0.20755	22.52	<.0001	0	M9	0
NUM11	4.69219	0.21607	21.72	<.0001	0	M10	0
NUM12	4.40384	0.22971	19.17	<.0001	0	M11	0
NUM13	4.20430	0.20843	20.17	<.0001	0	M12	0
NUM14	-0.33709	0.33098	-1.02	0.3113	0	D24t	0
NUM15	1.27911	0.29490	4.34	<.0001	0	D24tp1	0
NUM16	0.07385	0.33455	0.22	0.8258	0	D13t	0
NUM17	0.81286	0.31350	2.59	0.0112	0	D13tp1	0
NUM18	0.81919	0.32512	2.52	0.0136	0	D2t	0
NUM19	0.67867	0.31022	2.19	0.0314	0	D2tp1	0
NUM20	0.55146	0.34055	1.62	0.1090	0	D22t	0
NUM21	1.01137	0.32069	3.15	0.0022	0	D22tp1	0
NUM22	1.15619	0.37136	3.11	0.0025	0	D11t	0
NUM23	1.28847	0.35894	3.59	0.0005	0	D11tp1	0
NUM24	1.10787	0.35044	3.16	0.0022	0	D0t	0
NUM25	0.61260	0.35711	1.72	0.0899	0	D0tp1	0
NUM26	-0.05287	0.34075	-0.16	0.8771	0	D20t	0
NUM27	0.52674	0.35153	1.50	0.1377	0	D20tp1	0
NUM28	0.27683	0.31837	0.87	0.3870	0	D9t	0
NUM29	-0.52359	0.37893	-1.38	0.1706	0	D9tp1	0
NUM30	-0.09155	0.33714	-0.27	0.7866	0	D29t	0
NUM31	0.52910	0.32697	1.62	0.1093	0	D29tp1	0
NUM32	0.17298	0.34751	0.50	0.6199	0	D18t	0
NUM33	0.05461	0.36034	0.15	0.8799	0	D18tp1	0
NUM34	0.46671	0.36735	1.27	0.2073	0	D7t	0
NUM35	-0.20991	0.42022	-0.50	0.6187	0	D7tp1	0
NUM36	-1.55457	0.56653	-2.74	0.0074	0	I48t	0
NUM37	-0.0088597	0.01033	-0.86	0.3933	0	ti48t	0
NUM38	0.18253	1.36445	0.13	0.8939	0	I96t	0
NUM39	-0.0077193	0.01261	-0.61	0.5420	0	ti96t	0
NUM40	-4.22479	0.39634	-10.66	<.0001	0	A97	0
NUM41	-2.46391	0.36035	-6.84	<.0001	0	A98	0
NUM42	0.85930	0.28469	3.02	0.0033	0	A86	0

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelation Check of Residuals					
				Autocorrelations					
6	5.11	2	0.0778	-0.024	0.070	0.065	-0.087	-0.063	-0.125
12	7.80	8	0.4528	0.013	-0.005	-0.072	0.062	0.055	0.079
18	14.74	14	0.3960	-0.002	-0.143	0.082	-0.133	-0.031	0.012
24	16.26	20	0.7003	-0.087	-0.021	-0.013	-0.002	0.030	-0.023
30	20.59	26	0.7629	0.032	0.060	-0.030	0.013	-0.114	-0.081
36	28.52	32	0.6434	-0.155	-0.025	0.024	-0.062	0.044	-0.115

Tests for Normality						
Test	--Statistic--		----p Value----			
Shapiro-Wilk	W	0.992757	Pr < W	0.7360		
Kolmogorov-Smirnov	D	0.042628	Pr > D	>0.1500		
Cramer-von Mises	W-Sq	0.034391	Pr > W-Sq	>0.2500		
Anderson-Darling	A-Sq	0.206073	Pr > A-Sq	>0.2500		

Lampiran 17 Hasil Estimasi Parameter yang Telah Signifikan, Independen dan Kenormalan Residual Model ARIMAX([1,13,14],0,0)(1,0,0)⁴⁸ dengan Efek Variasi Kalender untuk Data *Inflow* Uang Kartal

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr > t	Lag	Variable	Shift
AR1,1	0.47570	0.08355	5.69	<.0001	1	inflowtrans	0
AR1,2	0.28977	0.09820	2.95	0.0039	13	inflowtrans	0
AR1,3	-0.46958	0.10028	-4.68	<.0001	14	inflowtrans	0
AR2,1	-0.58524	0.11952	-4.90	<.0001	48	inflowtrans	0
NUM1	0.0099660	0.0011666	8.54	<.0001	0	t	0
NUM2	6.14907	0.11899	51.68	<.0001	0	M1	0
NUM3	5.51000	0.12343	44.64	<.0001	0	M2	0
NUM4	4.86167	0.12061	40.31	<.0001	0	M3	0
NUM5	4.80197	0.12146	39.53	<.0001	0	M4	0
NUM6	4.58257	0.12232	37.46	<.0001	0	M5	0
NUM7	4.60882	0.12275	37.55	<.0001	0	M6	0
NUM8	4.66339	0.12317	37.86	<.0001	0	M7	0
NUM9	4.77840	0.12363	38.65	<.0001	0	M8	0
NUM10	4.81495	0.12581	38.27	<.0001	0	M9	0
NUM11	5.19840	0.12624	41.18	<.0001	0	M10	0
NUM12	4.61874	0.13784	33.51	<.0001	0	M11	0
NUM13	4.34501	0.13807	31.47	<.0001	0	M12	0
NUM14	1.40685	0.26659	5.28	<.0001	0	D24tp1	0
NUM15	0.74033	0.27025	2.74	0.0073	0	D13tp1	0
NUM16	0.74649	0.28887	2.58	0.0112	0	D2t	0
NUM17	0.63635	0.28893	2.20	0.0299	0	D2tp1	0
NUM18	1.03486	0.27537	3.76	0.0003	0	D22tp1	0
NUM19	0.80052	0.29306	2.73	0.0074	0	D11tp1	0
NUM20	-0.87729	0.30379	-2.89	0.0047	0	D9tp1	0
NUM21	0.65210	0.30359	2.15	0.0341	0	D29tp1	0
NUM22	-1.74123	0.14357	-12.13	<.0001	0	I48t	0
NUM23	-4.16765	0.34600	-12.05	<.0001	0	A97	0
NUM24	-2.36183	0.34305	-6.88	<.0001	0	A98	0
NUM25	0.89801	0.30770	2.92	0.0043	0	A86	0

Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----			
6	5.94	2	0.0513	-0.044	0.055	0.168	0.012
12	9.65	8	0.2901	-0.108	0.026	0.019	-0.019
18	20.99	14	0.1020	-0.017	-0.142	0.151	-0.161
24	27.26	20	0.1282	-0.176	0.037	-0.056	-0.008
30	33.69	26	0.1431	0.039	0.089	0.004	-0.028
36	45.83	32	0.0538	-0.081	-0.051	-0.102	-0.132

Tests for Normality						
Test	--Statistic--		----p Value----			
Shapiro-Wilk	W	0.99208	Pr < W	0.6663		
Kolmogorov-Smirnov	D	0.058427	Pr > D	>0.1500		
Cramer-von Mises	W-Sq	0.078741	Pr > W-Sq	0.2204		
Anderson-Darling	A-Sq	0.39833	Pr > A-Sq	>0.2500		

(Halaman ini sengaja dikosongkan)

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan rumusan masalah dan analisis yang telah dilakukan, dapat diperoleh kesimpulan sebagai berikut.

1. Model ARIMAX untuk deret *outflow* adalah ARIMAX([2],0,1)(1,0,0)¹² dengan efek variasi kalender yang memiliki nilai RMSE *in-sample* sebesar 235,80. Pada model ARIMAX untuk deret *outflow* tidak terdapat proses GARCH (residual telah homogen). Sedangkan model ARIMAX untuk deret *inflow* adalah ARIMAX([1,13,14],0,0)(1,0,0)⁴⁸ dengan efek variasi kalender memiliki nilai RMSE *in-sample* sebesar 76,89. Pada model ARIMAX untuk deret *inflow* terdapat proses GARCH yaitu GARCH([12],[12]).
2. Peramalan dengan menggunakan metode ANFIS diperoleh model terbaik untuk deret *outflow* adalah sebagai berikut

$$\hat{Y}_{1,t} = \frac{w_{1,t}}{w_{1,t} + w_{2,t}} (-0,460Y_{t-3} + 0,210Y_{t-12} + 2,669) + \frac{w_{2,t}}{w_{1,t} + w_{2,t}} (-0,479Y_{t-3} - 0,184Y_{t-12} - 2,606)$$

dengan RMSE *in sample* sebesar 296,78. Pada model ANFIS untuk deret *outflow* terdapat proses ARCH yaitu ARCH(12). Sedangkan peramalan dengan menggunakan metode ANFIS diperoleh model terbaik untuk deret *inflow* adalah sebagai berikut

$$\hat{Y}_{2,t} = \frac{w_{1,t}}{w_{1,t} + w_{2,t}} (-0,038Y_{2,t-1} + 0,253Y_{2,t-12} + 0,393Y_{2,t-48} + 0,44) + \frac{w_{2,t}}{w_{1,t} + w_{2,t}} (-0,129Y_{2,t-1} - 0,072Y_{2,t-12} - 0,393Y_{2,t-48} - 0,359)$$

dengan RMSE *in sample* sebesar 158,27. Pada model ANFIS untuk deret *inflow* tidak terdapat proses GARCH (residual telah homogen).

3. Model gabungan ARIMAX-ANFIS yang terbaik untuk deret *outflow* adalah ARIMAX ([2],0,1)(1,0,0)¹² dengan input pada ANFIS adalah lag 1 dan 3, serta nilai RMSE *in-sample* sebesar 243,95. Sedangkan model gabungan ARIMAX-ANFIS terbaik untuk deret *inflow* adalah ARIMAX ([1,13,14],0,0)(1,0,0)⁴⁸ dengan input pada ANFIS adalah lag 6, 11, 12, 14 dan 24, serta nilai RMSE *in-sample* sebesar 60,64. Pada model gabungan ARIMAX-ANFIS untuk deret *outflow* maupun deret *inflow* tidak terdapat proses GARCH (residual telah homogen).
4. Metode terbaik untuk peramalan *outflow* adalah peramalan dengan metode ANFIS yang memiliki nilai sMAPE *out-sample* sebesar 29,70%. Sedangkan pada peramalan *inflow* metode terbaik adalah gabungan ARIMAX-ANFIS dengan nilai sMAPE sebesar 24,34%. Nilai RMSE *in-sample* pada ketiga metode yang digunakan pada penelitian ini memberikan hasil lebih kecil dibandingkan dengan standar deviasi data *in-sample* baik *outflow* maupun *inflow*, hal ini menunjukkan bahwa metode ARIMAX, metode ANFIS dan metode gabungan ARIMAX-ANFIS baik digunakan untuk meramalkan data *outflow* maupun *inflow* uang kartal di Provinsi Papua.

5.2 Saran

Pada penelitian ini tidak memperhatikan hubungan *outflow* dan *inflow* secara ekonomi, sehingga pada penelitian selanjutnya disarankan untuk memperhatikan hubungan *outflow* dan *inflow* secara ekonomi. Disarankan juga untuk mencoba memasukkan faktor-faktor lain dalam pemodelan. Faktor-faktor tersebut misalnya IHK, Inflasi serta faktor sosial dan budaya masyarakat setempat. Sektor pendidikan juga mungkin berkontribusi terutama dalam hal biaya pendidikan yang rutin meningkat pada awal tahun ajaran baru. Semua faktor tersebut dapat dijadikan pertimbangan untuk dimasukkan dalam model, sehingga akurasi peramalan dapat lebih ditingkatkan.

Selain mempertimbangkan variabel-variabel yang berpengaruh terhadap model, pilihan penggunaan metode peramalan juga bisa dijadikan pertimbangan untuk meningkatkan akurasi model. Metode peramalan yang mampu menangkap fenomena data historis dengan lebih akurat menjadi kebutuhan dalam

mengembangkan model yang presisi. Model-model nonlinier selain ANFIS dapat diterapkan sebagai alternatif model konvensional, seiring dengan berkembangnya teknik komputasi modern. Nilai residual dari model regresi *time series* dan metode ARIMAX dengan efek variasi kalender dapat dimodelkan dengan menggunakan model-model berbasis *machine learning* sebagai salah satu metode nonlinier dalam melakukan peramalan, sehingga hasil pemodelan dari residual model diharapkan mampu meningkatkan akurasi model.

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

- Armstrong, J.S., (2007), “Significance Tests Harm Progress in Forecasting”, *International Journal of Forecasting*, 23, 321-327.
- Bank Indonesia, (2011), Surat Edaran Perihal Penyetoran dan Penarikan Uang Rupiah oleh Bank Umum di Indonesia, Bank Indonesia.
- Bank Indonesia, (2015), “*Fungsi Bank Indonesia*”, <http://www.bi.go.id/id/tentang-bi/fungsi-bi/tujuan/Contents/Default.aspx>
- Bollerslev, T., (1986), “A Generalized Autoregressive Conditional Heteroscedasticity”, *Journal of Econometrics*, vol.31:307-327
- Bowerman, B.L., dan O’Connell, R.T., (1993), “*Forecasting and Time Series: An Applied Approach*”, California: Duxbury Press.
- Box, G.E.P., Jenkins, G.M., dan Reinsel, G.C., (1994), “*Time Series Analysis Forecasting and Control*”, 3rd Edition, Prentice-Hall Inc., New Jersey.
- Cryer, J.D., dan Chan, K.S. (2008). “*Time Series Analysis With Applications in R*”, Second Edition. New York: Springer
- Engle, R.F. (1982), “Autoregressive Conditional Heteroscedasticity with Estimates of Varians of UK Inflation”, *Econometrics*, vol.50:987-1008
- Gooijer, J.G.D dan Hyndman, R. J., (2006). “25 years of time series forecasting. *International Journal of Forecasting*”, 22, 443-473.
- Fausett, L. (1994). “*Fundamental of Neural Network: Architectures, algorithm and applications*”, New Jersey: Prentice Hall Inc.
- Faulina, R., dan Suhartono, (2013), “Hybrid ARIMA-ANFIS for Rainfall Prediction in Indonesia”, *International Journal of Science and Research (IJSR)*, India Online ISSN:2319-7064.
- Hamilton, J.D., (1994), “*Time Series Analysis*”, Princeton University Press, New Jersey.
- Jaya, A., Hashim, S., Haron, H., Ngah, R., Muhammad, M.R., dan Rahman, M., (2013). “Modeling of ANFIS in Predicting TiN Coatings Roughness”. *Computer Science and Information Technology (CSIT)* (pp.13-18). Amman: IEEE

- Jang, J.S R., (1993), “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, *IEEE Transactions on Systems, MAN, and Cybernetics*, Vol.23, No.3, 665-685.
- Jang, J.S.R., Sun, C.T., dan Mizutani, E. (1997). “*euro-Fuzzy and Soft Computing, A Computational Approach to Learning and Machine Intelligence*”. Upper Saddle River , NJ: Prentice-Hall, Inc.
- Kostenko, A.V., dan Hyndman, R.J., (2008), “Forecasting Without Significance Tests”. <http://robjhyndman.com/working-papers/forecasting-without-significance-tests/>
- Kusumadewi, S dan Hartati, S. (2006), “*Neuro-Fuzzy Integrasi Sistem Fuzzy dan Jaringan Syaraf*”, Yogyakarta: Graha ilmu
- Lee, M. H., Suhartono dan Hamzah, N., (2010), “Calender Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect”, *Regional Conference on Statistical Science*.
- Lee, M. H., Suhartono, Puspitasari, I. dan Akbar, M.S., (2012), “Two-Level Seasonal Model Based on Hybrid ARIMA-ANFIS for Forecasting Short_Term Electricity Load in Indonesia”, *International Conference on Statistics in Science, Business and Engineering (ICSSBE)*.
- Liu, M., Dong, M., dan Wu, C., (2010). “A New ANFIS for Parameter Prediction with Numeric and Categorical Inputs”. *Automation Science and Engineering* 7, 645-653.
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. (1999). “*Metode dan Aplikasi Peramalan*” Edisi Kedua [Terjemahan Hari S.], Jakarta: Binarupa Aksara.
- Montgomery, D.C., Jennings, C.L., dan Kulahci, M., (2008), “*Introduction to time series analysis and forecasting*”, Wiley Interscience, USA
- Reganata, G.P. dan Suhartono, (2015), “*Peramalan Inflow Dan Outflow Uang Kartal dengan Fungsi Transfer Multi Input dan Hybrid ARIMA-ANN di Provinsi Bali*”, Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.
- Suhartono, Lee, M.H., dan Prastyo, D.D., (2015), “Two Levels ARIMAX and Regression Models For Forecasting Time Series Data with Calendar Variation Effects”, *AIP Conference Proceedings*.
- Tarno, (2015), “*Pemodelan Runtun Waktu Finansial dengan Volatilitas GARCH Menggunakan Adaptive Neuro Fuzzy Inference System (ANFIS)*”, Disertasi, Universitas Gadjah Mada, Yogyakarta.

Terasvirta, T. Tjostheim, D., dan Granger, C.W.J., (1992), “*Aspects Of Modelling Nonlinear Time Series*”, Research Report 1992:1. Department of Statistics. University of Goteborg, Finland.

Urusyiyah, L., Suharsono, A. dan Suhartono (2015), “Peramalan *Inflow* dan *Outflow* Uang Kartal dengan Kombinasi Model Fungsi Transfer dan Variasi Kalender-ACRH”, Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.

Wang L., Zou H., Su J., Li L. dan Chaudhry, S. (2013), “An ARIMA-ANN Hybrid Model for Time Series Forecasting”, *Systems Research and Behavioral Science. Syst. Res.* 30, 244–259

Wei, W.W.S., (2006), “*Time Series Analysis: Univariate and Multivariate Methods*”, Addison-Wesley Publishing Company Inc., Canada.

Widasari, L.P. dan Wahyuningsih, N., (2012). “Aplikasi Model ARCH-GARCH dalam Peramalan Tingkat Inflasi”. *Jurnal Sains dan Seni Pomits*, Vol.1, No.1.

Wulansari, R.E. dan Suhartono, (2014), “Peramalan *Netflow* Uang Kartal Dengan Metode ARIMAX dan Radial Basis Function Network (Studi Kasus Di Bank Indonesia)”, *Jurnal Sains Dan Seni POMITS*, Vol. 3, No.2.

Yang, L. dan Entchev, E., (2014). “Performance Prediction of a Hybrid Microgeneration System using Adative Neuro-Fuzzy Inference System (ANFIS) technique”, *Applied Energy* 134, 197-203.

Zhang, G. (2003), “Time Series Forecasting using a Hybrid ARIMA and Neural Network Model”, *Neurocomputing*, 50, 159-175.

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis dengan nama lengkap Bobi Frans Kuddi dilahirkan pada tanggal 30 Maret 1988 di Tanah Toraja. Merupakan anak pertama dari empat bersaudara. Pendidikan formal penulis dimulai dari SD Negeri 187 Bittuang, SLTP Negeri 3 Saluputti, SMA Negeri 1 Rantepao. Setelah lulus SMA, penulis diterima di Jurusan Matematika Universitas Cenderawasih melalui jalur SMPTN. Setelah lulus program Sarjana penulis sempat bekerja sebagai pegawai BUMN selama 3 tahun, sebelum melanjutkan program magister di Jurusan Statistika-Institut Teknologi Sepuluh Novermber.

Bidang minat statistika yang ditekuni penulis adalah Statistika Ekonomi, Finance dan Aktuaria serta Statistika Komputasi khususnya untuk peramalan data *time series*. Dengan dukungan dari berbagai pihak akhirnya penulis bisa menyelesaikan tesis ini. Apabila pembaca ingin memberikan kritik dan saran serta tertarik berdiskusi lebih lanjut mengenai tesis ini, pembaca dapat menghubungi penulis melalui *e-mail*: bobikuddi@gmail.com