



TESIS - SS142501

MODEL ARIMAX, *RADIAL BASIS FUNCTION NETWORK* (RBFN), DAN *HYBRID* ARIMAX-RBFN UNTUK PERAMALAN *INFLOW* DAN *OUTFLOW* UANG KARTAL DI PROVINSI PAPUA

**MAYA PAEMBONAN
NRP 1314201042**

**DOSEN PEMBIMBING
Dr. Drs. Brodjol Sutijo Suprih Ulama, M.Si.
Dr. Suhartono, M.Sc.**

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



THESIS - SS142501

**ARIMAX MODEL, RADIAL BASIS FUNCTION NETWORK
(RBFN), AND HYBRID ARIMAX-RBFN FOR FORECASTING
INFLOW AND OUTFLOW OF CURRENCY AT PAPUA
PROVINCE**

**MAYA PAEMBONAN
NRP 1314201042**

**SUPERVISOR
Dr. Drs. Brodjol Sutijo Suprih Ulama, M.Si.
Dr. Suhartono, M.Sc.**

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

**MODEL ARIMAX, RADIAL BASIS FUNCTION NETWORK (RBFN), DAN
HYBRID ARIMAX-RBFN UNTUK PERAMALAN INFLOW DAN
OUTFLOW UANG KARTAL DI PROVINSI PAPUA**

**Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si)**

di

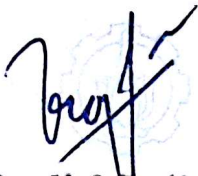
Institut Teknologi Sepuluh Nopember

Oleh :

**MAYA PAEMBONAN
NRP. 1314201042**

**Tanggal Ujian : 20 Juli 2016
Periode Wisuda : September 2016**

Disetujui oleh :



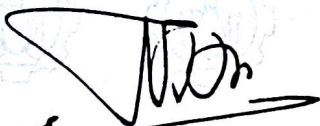
**1. Dr. Brodjol Sutijo Ulama, M.Si
NIP. 19660125 199002 1 001**

(Pembimbing I)



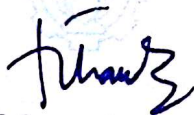
**2. Dr. Suhartono, M.Sc
NIP. 19710929 199512 1 001**

(Pembimbing II)



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

(Penguji)



**4. Irhamah, M.Si, Ph.D
NIP. 19780406 2001 12 2 002**

(Penguji)



Direktur Pascasarjana ITS

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

MODEL ARIMAX, RADIAL BASIS FUNCTION NETWORK (RBFN), DAN HYBRID ARIMAX-RBFN UNTUK PERAMALAN INFLOW DAN OUTFLOW UANG KARTAL DI PROVINSI PAPUA

Name : Maya Paembonan
NRP : 1314201042
Pembimbing : Dr. Drs. Brodjol Sutijo Suprih Ulama, M.Si
Co Pembimbing : Dr. Suhartono, M.Sc

ABSTRAK

Dalam banyak kasus peramalan deret waktu, hubungan antar kejadian pada waktu yang berbeda seringkali tidak linier. Dalam kondisi seperti ini, pendekatan metode deret waktu linier dianggap tidak sesuai untuk melakukan pemodelan dan peramalan. ARIMAX merupakan model ARIMA dengan penambahan variabel prediktor, sedangkan *Radial Basis Function Network* (RBFN) merupakan model *Neural Network* yang mentransformasi input secara nonlinear dengan menggunakan fungsi aktivasi Gaussian pada lapisan unit hidden sebelum diproses secara linear pada lapisan output. Tujuan dari penelitian ini adalah untuk mengetahui model ARIMAX, RBFN, dan *hybrid* ARIMAX-RBFN serta mengetahui perbandingan akurasi dari ketiga model tersebut. Data berasal dari Bank Indonesia. Data periode waktu 2003 sampai 2013 sebagai *in-sample* dan tahun 2014 sebagai *out-sample*. Hasil yang diperoleh berdasarkan nilai sMAPE diketahui bahwa baik pada deret *inflow* maupun *outflow* model ARIMAX merupakan model terbaik, dimana model tersebut adalah ARIMAX(0,0,[1,13])(3,0,0)¹² pada *inflow* dan ARIMAX(3,0,1)(0,0,1)¹² pada *outflow*. Penambahan variabel *dummy* pada model ARIMA mampu meningkatkan akurasi model, terutama pada saat kejadian hari raya Idul Fitri.

Kata kunci : ARIMAX, RBFN, Hybrid ARIMAX-RBFN, Inflow, Outflow

ARIMA MODEL, RADIAL BASIS FUNCTION NETWORK (RBFN), AND HYBRID ARIMAX-RBFN FOR FORECASTING INFLOW AND OUTFLOW OF CURRENCY AT PAPUA PROVINCE

Name : Maya Paembonan
Student Id. : 1314201042
Supervisor : Dr. Drs. Brodjol Sutijo Suprih Ulama, M.Si
Co Supervisor : Dr. Suhartono, M.Sc

ABSTRACT

In many time series forecasting cases, the relationship between events at different times are often not linear. Under these conditions, the approach linear time series methods are considered not suitable for modeling and forecasting. ARIMAX an ARIMA model with the addition of predictor variables, while the Radial Basis Function Network (RBFN) is a model of Neural Network, which transform inputs nonlinear using Gaussian activation function in the hidden layer unit before being processed linearly in output layer. The purpose of this study was to determine the ARIMA model, RBF, and hybrid ARIMAX-RBFN and compare the accuracy of the three models. Data derived from the Indonesian bank. Data period from 2003 through 2013 as the in-sample and 2014 as out-sample. The results obtained by the value sMAPE known that both the inflow and outflow series ARIMAX the model is the best model, where the model is $ARIMAX(0,0,[1,13])(3,0,0)^{12}$ on the inflow and $ARIMAX(3,0,1)(0,0,1)^{12}$ on the outflow. The addition of dummy variables in ARIMA model can improve the accuracy of the model, especially at the time of the incident Eid.

Key words: *ARIMAX, RBFN, Hybrid ARIMAX-RBFN, Inflow, Outflow*

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR TABEL	xv
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN	xix
BAB 1 PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
BAB 2 TINJAUAN PUSTAKA	
2.1 Kestasioneran Data	7
2.2 Model ARIMA <i>Box-Jenkins</i>	10
2.2.1 Identifikasi Model	11
2.2.2 Estimasi Parameter	12
2.2.3 <i>Diagnostic Checking</i>	13
2.3 Model ARIMAX	15
2.4 <i>Neural Network</i> (NN).....	18
2.4.1 Pengertian <i>Neural Network</i>	18
2.4.2 Feed-forward Neuron Network	19
2.4.3 Proses Pembelajaran	20
2.4.4 <i>Radial Basis Function Neural Network</i> (RBFN)	20
2.4.4.1 Fungsi Radial Basis	21
2.4.4.2 Algoritma Pembelajaran Pelatihan Jaringan	22
2.4.5 Pemilihan Model Terbaik Berdasar <i>Cross Validation</i>	24
2.5 <i>Hybrid</i> ARIMAX-RBFN	25

2.6 Pemilihan Model Terbaik.....	25
2.7 <i>Inflow</i> dan <i>Outflow</i>	26
BAB 3 METODOLOGI PENELITIAN	
3.1 Sumber Data	27
3.2 Variabel Penelitian	27
3.3 Metode Analisis.....	28
BAB 4 HASIL DAN PEMBAHASAN	
4.1 Karakteristik <i>Inflow</i> dan <i>Outflow</i> Uang Kartal periode tahun 2003-2014.....	33
4.1.1 <i>Inflow</i> dan <i>Outflow</i> Uang Kartal.....	33
4.2 Model Variasi Kalender <i>Inflow</i> dan <i>Outflow</i> Uang Kartal.....	35
4.3 Model Regresi <i>Time Series Inflow</i> dan <i>Outflow</i>	39
4.4 Peramalan <i>Inflow</i> dan <i>Outflow</i> dengan ARIMAX.....	46
4.4.1 Peramalan <i>Inflow</i> dengan ARIMAX.....	46
4.4.2 Peramalan <i>Outflow</i> dengan ARIMAX.....	50
4.4.2.1 Peramalan Testing 12 Bulan Sebelum Penambahan Variabel Dummy Mingguan	50
4.4.2.2 Peramalan Testing 12 Bulan . Dengan Penambahan Variabel Dummy Mingguan	57
4.4.2.3 Peramalan 36 Bulan (2015 sampai 2017)	60
4.5 Peramalan <i>Inflow</i> dan <i>Outflow</i> dengan RBFN.....	62
4.6 <i>Hybrid</i> ARIMAX-RBFN	64
4.6.1 Pemodelan <i>Inflow</i> dengan Model <i>Hybrid</i> ARIMAX-RBFN.....	64
4.6.2 Pemodelan <i>Outflow</i> dengan Model <i>Hybrid</i> ARIMAX-RBFN.....	66
4.7 Perbandingan Akurasi Model.....	68
BAB 5 SIMPULAN DAN SARAN	
5.1 Kesimpulan.....	75
5.2 Saran	76
DAFTAR PUSTAKA	77
LAMPIRAN.....	79

DAFTAR TABEL

Tabel 2.1	Transformasi <i>Box-Cox</i>	10
Tabel 2.2	Pola ACF dan PACF dari Model ARIMA (p,q)	11
Tabel 3.1	Definisi operasional dari Variabel yang digunakan.....	27
Tabel 3.2	Tanggal Terjadinya Hari Raya Idul Fitri Tahun 2003-2013.....	28
Tabel 4.1	Statistik Deskriptif <i>Inflow</i> dan <i>Outflow</i> Uang Kartal Selama Periode Pengamatan (dalam miliar).....	33
Tabel 4.2	Perubahan Kebijakan Bank Indonesia 2003-2014.....	34
Tabel 4.3	Tanggal Idul Fitri dan Deskriptif <i>Inflow</i> dan <i>Outflow</i> Terendah dan Tertinggi Tahun 2003-2014	36
Tabel 4.4	Variabel <i>Dummy</i>	38
Tabel 4.5	Hasil Uji <i>Augmented Dickey Fuller Inflow</i> dan <i>Outflow</i> Uang Kartal	40
Tabel 4.6	Transformasi Box-Cox Data <i>Inflow</i> dan <i>Outflow</i> Uang Kartal ..	41
Tabel 4.7	Hasil Uji <i>Augmented Dickey Fuller Inflow</i> dan <i>Outflow</i> Uang Kartal Setelah dilakukan <i>differencing</i> orde 1	42
Tabel 4.8	Hasil Estimasi Parameter Regresi <i>Dummy</i> pada Deret <i>Inflow</i>	43
Tabel 4.9	Hasil Estimasi Parameter Regresi <i>Dummy</i> pada Deret <i>Outflow</i>	44
Tabel 4.10	Hasil Uji <i>White Noise</i> Residual Model Regresi <i>Time Series</i> untuk <i>Inflow</i> dan <i>Outflow</i> Uang Kartal.....	45
Tabel 4.11	Model ARIMA <i>Inflow</i> Uang Kartal Berdasarkan Plot ACF dan PACF Regresi <i>Dummy</i>	47
Tabel 4.12	Hasil Uji <i>White Noise</i> Residual Model ARIMAX (0,0,[1,13])(3,0,0) ₁₂ untuk <i>Inflow</i> Uang Kartal	47
Tabel 4.13	Hasil Uji Normalitas Residual.....	48
Tabel 4.14	Uji Signifikansi Parameter Model ARIMAX (0,0,[1,13])(3,0,0) ₁₂ untuk <i>Inflow</i> Uang Kartal	48

Tabel 4.15	Model ARIMAX <i>Inflow</i> Uang Kartal.....	49
Tabel 4.16	Model ARIMA <i>Outflow</i> Uang Kartal Berdasarkan Plot ACF dan PACF Regresi <i>Dummy</i>	51
Tabel 4.17	Hasil Uji <i>White Noise</i> Residual Model ARIMAX(3,0,1)(0,0,1) ¹² untuk <i>Outflow</i> Uang Kartal.....	51
Tabel 4.18	Hasil Uji Normalitas Residual.....	52
Tabel 4.19	Uji Signifikansi Parameter Model ARIMAX(3,0,1)(0,0,1) ¹² untuk <i>Outflow</i> Uang Kartal.....	52
Tabel 4.20	Model ARIMAX <i>Outflow</i> Uang Kartal.....	53
Tabel 4.21	Hasil Uji <i>White Noise</i> Residual Model ARIMAX([10],0,1)(1,0,0) ¹² untuk <i>Outflow</i> Uang Kartal	54
Tabel 4.22	Hasil Uji Normalitas Residual.....	55
Tabel 4.23	Uji Signifikansi Parameter Model ARIMAX([10],0,1)(1,0,0) ¹² untuk <i>Outflow</i> Uang Kartal.....	55
Tabel 4.24	Hasil Uji <i>White Noise</i> Residual Model ARIMAX (3,0,1)(0,0,1) ¹²	57
Tabel 4.25	Hasil Uji Normalitas Residual.....	57
Tabel 4.26	Uji Signifikansi Parameter Model ARIMAX(3,0,1)(0,0,1) ¹² dengan Penambahan <i>Dummy</i> Variasi Kalender Mingguan	58
Tabel 4.27	Hasil Nilai Ramalan 36 Bulan (2015-2017).....	62
Tabel 4.28	Nilai sMAPE untuk setiap input.....	63
Tabel 4.29	Perbandingan Hasil Ramalan Model ARIMAX, RBFN dan Gabungan ARIMAX-RBFN dengan Data Aktual <i>Inflow</i>	69
Tabel 4.30	Perbandingan Hasil Ramalan Model ARIMAX, RBFN dan Gabungan ARIMAX-RBFN dengan Data Aktual <i>Outflow</i>	69
Tabel 4.31	Hasil Nilai Ramalan <i>Inflow</i> Tiap Metode.....	72
Tabel 4.32	Hasil Nilai Ramalan <i>Outflow</i> Tiap Metode	73

DAFTAR GAMBAR

Gambar 2.1	Bentuk Dasar Neuron.....	19
Gambar 2.2	Disain RBF network	21
Gambar 3.1	Diagram Alir Model ARIMAX	29
Gambar 3.2	Flowchart Proses Training RBFN.....	31
Gambar 4.1	<i>Box Plot Inflow</i> (a) dan <i>Outflow</i> (b) Uang Kartal pada Setiap Kebijakan.....	34
Gambar 4.2	Time Series Plot <i>Inflow</i> Uang Kartal Tahun 2003-2014	35
Gambar 4.3	Time Series Plot <i>Outflow</i> Uang Kartal Tahun 2003-2014.....	35
Gambar 4.4	Diagram Batang Rata-Rata <i>Inflow</i> Uang Kartal Sebelum, Saat, dan Setelah Idul Fitri.....	37
Gambar 4.5	Diagram Batang Rata-Rata <i>Outflow</i> Uang Kartal Sebelum, Saat, dan Setelah Idul Fitri.....	37
Gambar 4.6	Plot <i>Time series Inflow</i> Uang Kartal.....	39
Gambar 4.7	Plot <i>Time series Outflow</i> Uang Kartal	39
Gambar 4.8	Plot Box-Cox Data <i>Inflow</i> (a) dan <i>Outflow</i> (b) Uang Kartal ..	41
Gambar 4.9	Plot <i>Time Series</i> Data <i>Inflow</i> (a) dan <i>Outflow</i> (b) Uang Kartal yang Telah Stasioner.....	41
Gambar 4.10	Plot ACF dan PACF Data <i>Inflow</i> (a) dan <i>Outflow</i> (b) Uang Kartal yang Telah Stasioner.....	42
Gambar 4.11	ACF dan PACF untuk Residual Regresi <i>Dummy</i> Data <i>Inflow</i>	46
Gambar 4.12	ACF dan PACF untuk Residual Regresi <i>Dummy</i> Data <i>Outflow</i> Uang Kartal.....	50
Gambar 4.13	Plot Ramalan 2015 Sampai 2017 Sebelum dan Sesudah penambahan <i>dummy</i> Variasi Kalender Berdasarkan Minggu Terjadinya Idul Fitri.....	61
Gambar 4.14	Arsitektur RBFN <i>Inflow</i> (a) dan <i>Outflow</i> (b) Uang Kartal	63
Gambar 4.15	Arsitektur RBFN <i>Inflow</i> Uang Kartal.....	65

Gambar 4.16	Arsitektur RBFN <i>Outflow</i> Uang Kartal	67
Gambar 4.17	Perbandingan Hasil Peramalan tiap Metode pada Model <i>Inflow</i>	74
Gambar 4.18	Perbandingan Hasil Peramalan Tiap Metode pada Model <i>Outflow</i>	74

DAFTAR LAMPIRAN

Lampiran A.	
1.	Syntax SAS Uji <i>Augmented Dickey Fuller Inflow</i> 81
2.	Output SAS Uji <i>Augmented Dickey Fuller Inflow</i> 81
3.	Output SAS Uji <i>Augmented Dickey Fuller Outflow</i> 81
4.	Plot ACF dan PACF Data <i>Inflow</i> dan <i>Outflow</i> 81
5.	Plot Box-Cox <i>Inflow</i> dan <i>Outflow</i> 82
6.	Syntax SAS Regresi <i>Dummy Inflow</i> 82
7.	Estimasi Parameter Regresi <i>Dummy</i> untuk Deret <i>Inflow</i> 83
8.	Cek Diagnosa Residual Model Regresi <i>Dummy Inflow</i> 83
9.	Estimasi Parameter Regresi <i>Dummy</i> untuk Deret <i>Outflow</i> 84
10.	Cek Diagnosa Residual Model Regresi <i>Dummy Outflow</i> 84
Lampiran B.	
1.	Syntax SAS Model ARIMAX (0,0,[1,13])(3,0,0) ¹² untuk Deret <i>Inflow</i> 84
2.	Deteksi Outlier Awal pada Data <i>Inflow</i> 85
3.	Estimasi Parameter Model ARIMAX(0,0,[1,13])(3,0,0) ¹² untuk Deret <i>Inflow</i> 85
4.	Cek Diagnosa Residual Model ARIMAX(0,0,[1,13])(3,0,0) ¹² untuk Deret <i>Inflow</i> 86
5.	Estimasi Parameter Model ARIMAX(3,0,1)(0,0,1) ¹² untuk Deret <i>Outflow</i> 86
6.	Cek Diagnosa Residual Model ARIMAX(3,0,1)(0,0,1) ¹² untuk Deret <i>Outflow</i> 87
Lampiran C.	
1.	Syntax Matlab untuk Model RBFN <i>Inflow</i> dengan input $Z_{1,t-1}$ dan $Z_{1,t-12}$ 87
2.	Output RBFN Plot Hasil Ramalan <i>Inflow</i> dengan Input $Z_{1,t-1}$ dan $Z_{1,t-12}$ 88
3.	Output RBFN Plot Hasil Ramalan <i>Inflow</i> dengan Input ε_{t-1} dan ε_{t-13} 88
4.	Output RBFN Plot Hasil Ramalan <i>Outflow</i> dengan input $Z_{1,t-1}$, $Z_{1,t-3}$ dan $Z_{1,t-12}$ 89
5.	Output RBFN Plot Hasil Ramalan <i>Outflow</i> dengan Input ε_{t-1} , ε_{t-2} , ε_{t-3} dan ε_{t-12} 89

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 *et al.*, 2008:2). Tujuan dari analisis deret waktu ada dua, yaitu untuk memodelkan suatu mekanisme stokastik yang terdapat pada pengamatan yang berdasarkan waktu dan untuk memprediksi atau meramalkan nilai pengamatan di waktu yang akan datang berdasarkan data yang telah ada (Cryer dan Chan, 2008:1). Jika dilihat dari jumlah variabel yang diteliti, deret waktu dapat dikelompokkan menjadi dua bagian yaitu deret waktu secara *univariate* dan deret waktu secara *multivariate*. Selain itu deret waktu juga dapat dikelompokkan berdasarkan linieritas data yaitu linear dan non linier (Terasvirta, Tjostheim, dan Granger, 1992).

Analisis deret waktu satu variabel (*univariate*) merupakan analisis deret waktu yang menggunakan satu variabel dalam pemodelan dan peramalan dengan melihat historis data series yang ada, tanpa perlu mempertimbangkan variabel lain yang mempengaruhinya. Metode yang banyak digunakan dalam model *univariate* diantaranya adalah *Autoregressive Integrated Moving Average* (ARIMA). ARIMA merupakan generalisasi metode *Autoregressive* (AR) dan metode *Moving Average* (MA) untuk pemodelan deret waktu linier (Box, Jenkins dan Reinsel, 1994). Pada banyak kasus, peramalan melibatkan variabel eksogen. ARIMAX merupakan model ARIMA dengan penambahan variabel eksogen (Lee, Suhartono dan Hamzah 2010). Sebagai salah satu metode dalam analisis data time series, ARIMA dan ARIMAX menjadi metode yang dipakai secara luas dalam ekonometrika. Model ARIMAX merupakan gabungan model fungsi transfer yang didalamnya terdapat variabel intervensi dan variasi kalender. Metode ini mensyaratkan beberapa kondisi yang harus dipenuhi, antara lain data harus stasioner, baik stasioner dalam mean ataupun 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).

Dalam banyak kasus, suatu variabel seringkali tidak linier. Dalam kondisi seperti ini, pendekatan metode deret waktu linier dianggap tidak sesuai untuk melakukan pemodelan dan peramalan secara memadai. *Artificial Neural Networks* (ANN) yang seringkali disebut sebagai *Neural Networks* (NN) merupakan suatu sistem pengolahan informasi dengan karakteristik performa tertentu yang memiliki kesamaan dengan jaringan syaraf manusia dan telah banyak diaplikasikan untuk pemodelan yang non linier. NN telah dikembangkan sebagai generalisasi model matematika terhadap kognisi pada manusia atau syaraf biologi. Arsitektur *Neural Network* (NN) tersusun atas tiga jenis *layer*, yaitu *input layer*, *hidden layer*, dan *output layer*. Antar lapisan memiliki penghubung yang memiliki pembobot tertentu yang selalu berubah setiap diberikan input baru untuk proses. Lapisan *input* berfungsi sebagai tempat neuron untuk *input* data, dimana *input* data tersebut diproses lebih lanjut pada *hidden layer*, untuk selanjutnya *output layer* menampilkan hasil dari proses tersebut. NN dikenali dari karakteristiknya berupa pola hubungan antar neuron (disebut sebagai arsitektur jaringan), metode dalam menentukan bobot penghubung (disebut sebagai *training/learning/ algoritma*), dan fungsi aktivasi yang biasanya nonlinier (Fausett, 1994:3). NN dapat diaplikasikan pada banyak kasus, diantaranya adalah pengenalan pola (*pattern recognition*), pemrosesan sinyal (*signal processing*), dan peramalan. Kemampuan peramalan dengan NN berdasarkan historis data dikarenakan NN dapat mengingat dan membuat generalisasi dari data yang ada.

Dalam model NN yang sering ditemui yaitu permasalahan *overfitting*, dimana model yang dibuat hanya menghasilkan *output* yang baik untuk data yang dilatih saja dan tidak untuk data yang divalidasi (data yang tidak termasuk proses *training*). Ini adalah *fenomena overfitting* yang termasuk masalah yang sering ditemui ketika menggunakan model NN. Di sisi lain, permasalahan tersebut dapat diminimalisir dengan pengembangan yang mengkombinasikannya dengan model lain. Gabungan antara ARIMAX dengan NN atau yang biasa disebut *Hybrid ARIMAX-NN* diharapkan mampu memberikan hasil ramalan yang baik. Menurut Zhang (2003) terdapat tiga hal yang menjadi alasan penggabungan metode linier

dengan nonlinier. Pertama, sering kali terjadi kesulitan untuk menerapkan penggunaan model linier atau model nonlinier pada suatu permasalahan deret waktu, sehingga model kombinasi ini menjadi alternatif yang lebih mudah. Kedua, dalam kenyataannya deret waktu jarang yang linier atau nonlinier dan sering mengandung keduanya, dimana tidak hanya model ARIMAX dan NN masing-masing dapat memodelkan setiap kasusnya, sehingga pengkombinasian ini dapat digunakan untuk memodelkan data deret waktu yang memiliki pola linier dan nonlinier. Ketiga, dalam beberapa literatur peramalan menyatakan bahwa tidak ada model tunggal yang terbaik pada setiap situasi. Penggabungan metode tersebut dengan cara menjumlahkan hasil ramalan dari model linier dengan hasil ramalan model non linier, dimana *input* dari model nonlinier diperoleh dari residual dari model linier. Penelitian sebelumnya yang menggunakan metode *hybrid* antara lain, Gde (2015) menggunakan *hybrid* ARIMA-NN untuk meramalkan inflow dan outflow uang kartal di provinsi Bali, Kusumaningrum dan Suhartono (2012) meramalkan kebutuhan bahan bakar dengan *hybrid* ARIMA-NN. Dalam penelitian tersebut menunjukkan bahwa metode *hybrid* dapat memprediksi lebih baik dibandingkan dengan metode tunggal.

Ada beberapa arsitektur pada model NN, antara lain *back-propagation (feed forward)*, *recurrent network*, *self organizing map*, *radial basis function network* (RBFN) dan sebagainya. Metode NN yang akan digunakan adalah *Radial Basis Function Network* (RBFN). Penelitian Zhang (2003) dan Merh *et al.*, (2010) memberikan kesimpulan bahwa penggabungan model deret waktu dan NN memberikan hasil peramalan lebih baik daripada model deret waktu atau NN. Donald dan Cios (1996) menggunakan *hybrid* RBFN-Box Jenkins untuk meramalkan jumlah bintik-bintik pada matahari, Fengxia dan Shouming (2014) meramalkan *Canadian lynx* dengan pendekatan *hybrid* RBFNN-AR untuk peramalan deret waktu di mana pada kumpulan data dilakukan proses *smoothing* dengan teknik *binomial smoothing*, kemudian dimodelkan dengan RBFNN.

Masalah dalam dunia nyata merupakan masalah yang kompleks dan satu model mungkin tidak mampu mengatasi masalah tersebut dengan baik. Dapat dikatakan bahwa kelebihan suatu komponen dapat melengkapi kekurangan komponen lainnya. Bahkan menurut Fauziah dan Suhartono (2012) kelebihan dari

menggabungkan beberapa model menjadi satu adalah menghasilkan ramalan dengan tingkat akurasi yang lebih baik secara rata-rata dibandingkan dengan model individu lainnya. Alasan lain adalah adanya asumsi bahwa model tunggal tidak dapat secara total mengidentifikasi semua karakteristik dari *deret waktu* (Terui dan Van Dijk, 2002).

Uang kartal adalah uang yang ada di tangan masyarakat (di luar bank umum) dan siap dibelanjakan setiap saat, terutama untuk pembayaran-pembayaran dalam jumlah yang tidak terlalu besar. Di Indonesia, uang kartal adalah uang kertas dan uang logam yang beredar di masyarakat yang dikeluarkan dan diedarkan oleh Bank Indonesia yang berfungsi sebagai otoritas moneter. Pembayaran tunai tidak hanya dilakukan dengan membayar menggunakan uang tunai, tetapi juga dapat dilakukan dengan cek. Namun apabila seseorang ingin membayar dengan cek sebelumnya harus mempunyai simpanan dalam bentuk rekening giro di suatu bank umum (*demand deposits*). Rekening giro adalah suatu rekening simpanan di bank umum yang penarikannya dapat dilakukan sewaktu-waktu. Uang yang berada di rekening giro di bank umum tersebut sering disebut sebagai uang giral. Selain itu, pembayaran juga bisa dilakukan dengan penarikan simpanan uang tunai dalam bentuk tabungan dan deposito di bank. Uang yang disimpan dalam rekening tabungan dan deposito berjangka disebut sebagai uang kuasi.

Provinsi Papua mempunyai total pendapatan daerah tertinggi nomor lima di Indonesia, diurutkan pertama adalah provinsi DKI Jakarta, disusul Jawa Barat, Jawa Timur dan Jawa Tengah (Kementrian Dalam Negeri, 2015). Namun jumlah pendapatan daerah yang tinggi ternyata tidak menjadi jaminan kesejahteraan masyarakat Papua. Hal ini terlihat bahwa Papua merupakan provinsi dengan tingkat kemiskinan tertinggi kedua di Indonesia. Pertumbuhan ekonomi di Papua diakui masih sangat lambat. Salah satu faktor yang dapat menggambarkan keadaan ekonomi di suatu daerah adalah peredaran uang kartal. Uang kartal merupakan unsur terpenting dalam suatu sistem perekonomian modern. Kehadiran uang sudah melembaga dalam masyarakat, sehingga segala aktivitas masyarakat dipengaruhi, diukur dan banyak ditentukan oleh uang. Tingkat belanja masyarakat yang tinggi akan mengakibatkan permintaan uang meningkat. Ketika menjelang hari raya Natal pada bulan Desember *outflow* meningkat signifikan, hal ini

dikarenakan mayoritas masyarakat Papua beragama Kristen, sedangkan peningkatan *inflow* terjadi pada bulan Januari. Selain pada bulan Desember, *inflow* dan *outflow* juga mengalami peningkatan disekitar bulan hari raya Idul Fitri.

Bank Indonesia (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 sering dihadapi adalah nilai proyeksi yang terlalu jauh dari nilai realisasinya. Untuk memenuhi kebutuhan praktis dalam menghitung peramalan *inflow-outflow*, akan dilakukan peramalan dengan pendekatan model ARIMAX dan *Radial Basis Function Network* (RBFN).

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka penulis mencoba untuk menggunakan pendekatan ARIMAX, RBFN dan *hybrid* ARIMAX-RBFN untuk meramalkan data *inflow* dan *outflow* uang kartal pada Bank Indonesia wilayah Papua, sekaligus akan dilakukan perbandingan dalam melihat kebaikan model dan keakuratan peramalannya.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut maka tujuan penelitian ini adalah:

1. Untuk mengetahui model ARIMAX yang sesuai untuk peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia Provinsi Papua.
2. Untuk mengetahui model *Radial Basis Function Network* (RBFN) yang sesuai untuk peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia Provinsi Papua.
3. Untuk mengetahui model *hybrid* ARIMAX-RBFN yang sesuai untuk peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia Provinsi Papua.
4. Untuk mengetahui perbandingan akurasi dari model ARIMAX, RBFN, dan *hybrid* ARIMAX-RBFN.

1.4 Manfaat Penelitian

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

1. Dapat membantu Bank Indonesia dalam meramalkan inflow dan outflow untuk periode kedepan.
2. Sebagai masukan kepada pihak terkait, khususnya Bank Indonesia Provinsi Papua, dalam mengambil kebijakan ekonomi berkaitan dengan inflow dan outflow.
3. Mengembangkan wawasan dan pengetahuan mengenai model ARIMAX, RBFNN, dan *hybrid* ARIMAX-RBFN

1.5 Batasan Masalah

Ada banyak jenis metode yang dapat digunakan dalam melakukan peramalan. Akan tetapi metode yang akan digunakan pada penelitian ini adalah ARIMAX dan *Radial Basis Function Network*. Data yang digunakan adalah data bulanan periode Januari 2003 sampai dengan Desember 2014. Data pada tahun 2003-2013 digunakan sebagai *in-sample* dan data pada tahun 2014 digunakan sebagai *out-sample*.

BAB 2

TINJAUAN PUSTAKA

Bab ini menjelaskan tentang uraian teori dan konsep yang berkaitan dengan analisis yang digunakan dalam penelitian yang mencakup model ARIMA, model ARIMAX, *Radial Basis Function Neural* (RBFN), *hybrid* ARIMAX-RBFN, serta informasi terkait *inflow*, *outflow*.

2.1 Kestasioneran Data

Stasioneritas adalah suatu keadaan dimana terjadi perubahan atau fluktuasi data berada disekitar nilai rata-rata yang konstan. Apabila diperoleh nilai observasi sebanyak n , maka plot (terhadap waktu) dari nilai tersebut dapat dibuat untuk membantu menentukan apakah nilai tersebut stasioner atau tidak. Secara umum, jika nilai n observasi tersebut terlihat berfluktuasi terhadap nilai varians dan *mean* konstan serta tidak tergantung waktu, maka dapat dikatakan bahwa deret waktu tersebut adalah stasioner. Sebaliknya bila nilai n observasi tidak berfluktuasi terhadap nilai *variens* dan *mean* secara konstan, maka data deret waktu tersebut tidak stasioner (Bowerman dan O'Connell, 1993:437).

a. *Autocorrelation Function* (ACF)

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

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad k = 0, 1, 2, \dots \quad (2.1)$$

a. *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 $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$

dihilangkan. Sampel PACF dinotasikan dengan $\hat{\phi}_{kk}$ dengan perhitungan seperti yang diberikan oleh Durbin dalam Wei (2006:22).

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad k = 0, 1, 2, \dots \quad (2.2)$$

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

b. Uji Akar Unit (*Unit Root Test*).

Uji akar unit pertama kali dikembangkan oleh Dickey dan Fuller yang dikenal dengan uji akar unit Dickey-Fuller (DF). Proses awal *unit root* dinyatakan dengan:

$$Z_t = \rho Z_{t-1} + \varepsilon_t, \quad -1 \leq \rho \leq 1 \quad (2.3)$$

dengan ε_t adalah *error* yang bersifat *white noise* dan ρ adalah besarnya hubungan antara Z_t dan Z_{t-1} . Jika $\rho = 1$, maka dikatakan bahwa data deret waktu tersebut mengandung *unit root* atau mengalami proses non stasioner. Untuk menguji *unit root* maka dilakukan regresi Z_t terhadap lag dari Z_{t-1} , sehingga persamaan (2.3) dapat ditulis sebagai berikut:

$$\begin{aligned} Z_t &= \rho Z_{t-1} + \varepsilon_t \\ Z_t - Z_{t-1} &= \rho Z_{t-1} - Z_{t-1} + \varepsilon_t \\ &= (\rho - 1) Z_{t-1} + \varepsilon_t, \end{aligned} \quad (2.4)$$

sehingga menjadi:

$$\Delta Z_t = \delta Z_{t-1} + \varepsilon_t, \quad \text{dimana } \delta = (\rho - 1).$$

Untuk menguji apakah data mengandung *unit root* atau tidak, Dickey-Fuller menyarankan untuk melakukan tiga model regresi:

$$\Delta Z_t = \delta Z_{t-1} + \varepsilon_t \quad (2.5)$$

$$\Delta Z_t = \beta_1 + \delta Z_{t-1} + \varepsilon_t \quad (2.6)$$

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \varepsilon_t \quad (2.7)$$

Persamaan (2.6) memasukkan unsur konstanta dan persamaan (2.7) memasukkan konstanta dan variabel *trend* waktu. Dalam setiap model, jika data deret waktu

mengandung *unit root* berarti data tidak stasioner. Hipotesis untuk uji *unit root* adalah:

$H_0 : \delta = 0$ (data mengandung *unit root* atau tidak stasioner)

$H_1 : \delta < 0$ (data tidak mengandung *unit root* atau stasioner)

Untuk menentukan data stasioner atau tidak adalah dengan membandingkan nilai statistik DF dengan nilai kritisnya yaitu mengikuti distribusi statistik t . Nilai statistik DF ditunjukkan oleh nilai t statistik yaitu koefisien δ . Jika nilai absolut statistik DF lebih besar dari nilai kritisnya maka tolak H_0 , artinya data menunjukkan stasioner.

Uji akar unit Dickey-Fuller pada persamaan (2.5), (2.6) dan (2.7) adalah model sederhana dan diasumsikan bahwa ε_t tidak berkorelasi. Pada banyak kasus dinyatakan bahwa ε_t adalah berkorelasi. Dickey-Fuller kemudian mengembangkan uji akar unit yang disebut *Augmented Dickey-Fuller* (ADF) dengan menambahkan nilai *lag* variabel ΔZ_t . Uji ADF merupakan estimasi yang mengikuti regresi berikut:

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \sum_{i=1}^m \alpha_i \Delta Z_{t-i} + \varepsilon_t \quad (2.8)$$

dimana $\Delta Z_{t-1} = (Z_{t-1} - Z_{t-2})$, $\Delta Z_{t-2} = (Z_{t-2} - Z_{t-3})$, dan seterusnya. Hipotesis dan uji yang digunakan dalam ADF *test* sama dengan hipotesis dan uji dalam DF *test*.

Suatu deret waktu yang tidak stasioner harus diubah menjadi data stasioner. Data tidak stasioner dalam varians dilakukan transformasi Box-Cox. Sedangkan data tidak stasioner dalam rata-rata dilakukan *differencing*. *Differencing* adalah menghitung perubahan atau selisih nilai observasi. Nilai selisih yang diperoleh dicek lagi apakah stasioner atau belum stasioner. Jika belum stasioner maka dilakukan *differencing* lagi. Bila kondisi stasioner dalam varians tidak terpenuhi, Box dan Cox dalam Wei (2006:85) memperkenalkan transformasi pangkat (*power transformation*), yaitu:

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.9)$$

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

Apabila data deret waktu tidak stasioner dalam *mean* perlu dilakukan proses *differencing*. Operator *shift* mundur tepat digunakan untuk menggambarkan proses *differencing*. Misalkan dilakukan *differencing* orde 1 (Makridakis, Wheelwright, dan McGee, 1999). *Differencing* orde pertama:

$$W_t = Z_t - Z_{t-1} \quad (2.10)$$

Differencing orde kedua:

$$W_t = (1 - B)^2 Z_t,$$

sehingga, secara umum proses *differencing* orde ke- k dapat ditulis:

$$W_t = (1 - B)^k Z_t, \quad (2.11)$$

dengan W_t merupakan nilai *series* setelah dilakukan pembedaan atau *differencing*.

2.2 Model ARIMA *Box-Jenkins*

Model *Box-Jenkins* merupakan salah satu teknik peramalan model deret waktu yang hanya berdasarkan perilaku data variabel yang diamati. Model *Box-Jenkins* secara teknis dikenal sebagai model *Autoregressive Integrated Moving Average* atau ARIMA (Makridakis *et al.*, 1999). Prosedur Box dan Jenkins digunakan untuk memilih model ARIMA yang sesuai pada data deret waktu. Syarat yang harus dipenuhi untuk membuat model peramalan yaitu data telah stasioner dalam *mean* dan varians. Prosedur ARIMA meliputi empat tahapan.

2.2.1 Identifikasi Model

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 ARIMA (p,q)

Proses	ACF	PACF
$AR(p)$	Turun cepat secara eksponensial	Terpotong setelah lag p
$MA(q)$	Terpotong setelah lag q	Turun cepat secara eksponensial
$AR(p)$ atau $MA(q)$	Terpotong setelah lag q	Terpotong setelah lag p
$ARMA(p, q)$	Turun cepat secara eksponensial	Turun cepat secara eksponensial

a. Model ARIMA non-musiman

Model ARIMA merupakan gabungan antara model $AR(p)$ dan $MA(q)$ dengan *differencing* orde d . Secara umum model $ARIMA(p, d, q)$ dapat ditulis dalam bentuk (Wei, 2006:72):

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)\varepsilon_t, \quad (2.12)$$

dengan :

(p, d, q) = order AR (p), order differencing (d), dan order MA (q)

$\phi_p(B)$ = koefisien komponen AR non musiman dengan derajat p

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

$\theta_q(B)$ = koefisien komponen MA non musiman dengan derajat q

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

b. Model ARIMA musiman

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 persamaan 2.13 (Wei, 2006:166).

$$\Phi_p(B^S)(1-B^S)^D Z_t = \Theta_Q(B^S)\varepsilon_t, \quad (2.13)$$

dengan :

s adalah periode musiman

$(P, D, Q)^S$ = order AR (P), order differencing (D), dan order MA (Q), order musiman (S) untuk data musiman

$\Phi_p(B^S)$ = koefisien komponen AR musiman S dengan derajat P

$$\Phi_p(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_p B^{pS})$$

$\Theta_Q(B^S)$ = koefisien komponen MA musiman Q dengan derajat S

$$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS})$$

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:

$$\Phi_p(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S)\varepsilon_t \quad (2.14)$$

2.2.2 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):

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + \varepsilon_t \quad (2.15)$$

dan nilai SSE adalah sebagai berikut:

$$S(\phi, \mu) = \sum_{t=2}^n \varepsilon_t^2 = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (2.16)$$

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

$$\hat{\mu} = \frac{\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1}}{(n-1)(1-\phi)} = \frac{\sum_{t=2}^n Z_t}{n-1} \quad (2.17)$$

dan nilai taksiran parameter ϕ didapatkan sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.18)$$

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 :

$H_0 : \beta = 0$ atau parameter tidak signifikan

$H_1 : \beta \neq 0$ atau parameter signifikan

Statistik uji :

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

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

dengan:

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

n_p = banyaknya parameter yang ditaksir.

2.2.3 Diagnostic Checking

Setelah parameter dari model signifikan maka perlu dilakukan pengujian terhadap residual untuk mengetahui ketepatan model tersebut. Pemeriksaan residual diuji dengan menggunakan asumsi white noise yang terbagi menjadi tiga bagian (Wei, 2006:15), yaitu pemeriksaan independensi, residual berasal dari distribusi tertentu dengan mean konstan $E(\varepsilon_t) = \mu_\varepsilon$ biasanya diasumsikan dengan 0 (nol) atau berdistribusi normal, dan variansi konstan $Var(\varepsilon_t) = \sigma_\varepsilon^2$ dan $\gamma_k = Cov(\varepsilon_t, \varepsilon_{t+k}) = 0$ dan $k \neq 0$.

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:

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

$$H_1 : \exists \rho_k \neq 0, k= 1,2,\dots,K$$

Statistik uji

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

daerah penolakan : tolak H_0 jika $Q > \chi_{(\alpha;K-m)}^2$,

dengan,

n = banyaknya residual

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

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:

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

$$H_1 : \exists \rho_i \neq 0, i= 1,2,\dots,k$$

Statistik uji:

$$Q(k) = n(n+2) \sum_{i=1}^k (n-i)^{-1} \hat{\rho}_i^2(\hat{\varepsilon}_i^2) \quad (2.19)$$

daerah penolakan : tolak H_0 jika $Q > \chi_{(\alpha;k)}^2$

dengan

n = banyaknya residual

$\hat{\rho}_i(\hat{\varepsilon}_i^2)$ = ACF dari residual kuadrat pada lag $ke - i$

b. Kenormalan

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

$H_0 : F(\varepsilon_t) = F_0(\varepsilon_t)$ (residual berdistribusi normal)

$H_1 : F(\varepsilon_t) \neq F_0(\varepsilon_t)$ (residual tidak berdistribusi normal)

Statistik uji :

$$D = \sup_x |F(\varepsilon_t) - F_0(\varepsilon_t)|.$$

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

dengan:

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

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

\sup = nilai *supremum* (maksimum) semua x dari $|F(\varepsilon_t) - F_0(\varepsilon_t)|$

2.3 Model ARIMAX

Model ARIMAX adalah model ARIMA dengan penambahan variabel prediktor (Lee, Suhartono dan Hamzah, 2010). Variabel prediktor yang digunakan untuk memodelkan ARIMAX yaitu variabel *dummy* bulan sebelum hari raya Idul Fitri, variabel *dummy* bulan hari raya Idul Fitri, variabel *dummy* bulan setelah hari raya Idul Fitri.

Model ARIMAX dengan tren stokastik adalah sebagai berikut

$$Z_t = \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \alpha_1 D_{t-1} + \alpha_2 D_t + \alpha_3 D_{t+1} + \omega_1 K_{2,t} + \omega_2 t K_{2,t} + \omega_3 K_{3,t} + \omega_4 t K_{3,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} \varepsilon_t \quad (2.20)$$

Model ARIMAX dengan tren deterministik adalah sebagai berikut

$$Z_t = \delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \alpha_1 D_{t-1} + \alpha_2 D_t + \alpha_3 D_{t+1} + \omega_1 K_{2,t} + \omega_2 t K_{2,t} + \omega_3 K_{3,t} + \omega_4 t K_{3,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)} \varepsilon_t, \quad (2..21)$$

dengan

- δ = koefisien trend
- T = *dummy* waktu untuk bulan
- β_z = koefisien bulan ke- z , dimana $z = 1, 2, 3, \dots, 12$
- $M_{z,t}$ = variabel *dummy* bulan ke- z , dimana $z = 1, 2, 3, \dots, 12$
- θ_i = parameter MA non musiman, $i = 1, 2, 3, \dots, q$
- Θ_i = parameter MA musiman, $i = 1, 2, 3, \dots, Q$
- ϕ_i = parameter AR non musiman, $i = 1, 2, 3, \dots, p$
- Φ_i = parameter AR musiman, $i = 1, 2, 3, \dots, P$
- D_{t-1} = variabel *dummy* bulan sebelum Idul Fitri
- D_t = variabel *dummy* bulan Idul Fitri
- D_{t+1} = variabel *dummy* bulan sesudah Idul Fitri

Selanjutnya adalah menaksir parameter $\delta, \beta, \alpha, \omega, \phi, \Phi, \theta$, dan Θ

$$Z_t[\phi_p(B)\Phi_p(B^S)] = (\delta t + \beta_1 M_{1,t} + \dots + \beta_{12} M_{12,t} + \alpha_1 D_{t-1} + \alpha_2 D_t + \alpha_3 D_{t+1} + \omega_1 K_{2,t} + \omega_2 t K_{2,t} + \omega_3 K_{3,t} + \omega_4 t K_{3,t})[\phi_p(B)\Phi_p(B^S)] + \theta_q(B)\Theta_Q(B^S)\varepsilon_t, \quad (2.22)$$

dimana

$$\begin{aligned} (\phi_p(B)\Phi_p(B^S)) &= (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_p B^{pS}) \\ &= (1 - \phi_1 \Phi_1 B^{1+S} - \phi_2 \Phi_2 B^{2+2S} - \dots - \phi_p \Phi_p B^{p+PS}) \\ (\theta_q(B)\Theta_Q(B^S)) &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)(1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_p B^{pS}) \\ &= (1 - \theta_1 \Theta_1 B^{1+S} - \theta_2 \Theta_2 B^{2+2S} - \dots - \theta_q \Theta_q B^{q+QS}) \end{aligned}$$

sehingga persamaan (2.22) menjadi

$$\begin{aligned} \varepsilon_t &= Z_t - \phi_1 \Phi_1 Z_{t-(1+s)} - \dots - \phi_p \Phi_p Z_{t-(p+Ps)} - \delta t + \phi_1 \Phi_1 \delta(t - (1+s)) + \dots + \\ &\quad \phi_p \Phi_p \delta(t - (p+Ps)) - \beta_1 M_{1,t} + \phi_1 \Phi_1 \beta_1 M_{1,t-(1+s)} + \dots + \phi_p \Phi_p \beta_1 M_{1,t-(p+Ps)} + \\ &\quad \dots - \beta_{12} M_{12,t} + f_1 \Phi_1 \beta_{12} M_{12,t-(1+s)} + \dots + f_p \Phi_p \beta_{12} M_{12,t-(p+Ps)} - \alpha_1 D_{t-1} + \\ &\quad f_1 \Phi_1 \alpha_1 D_{(t-1)-(1+s)} + \dots + f_p \Phi_p \alpha_1 D_{(t-1)-(p+Ps)} - \alpha_2 D_t + f_1 \Phi_1 \alpha_2 D_{t-(1+s)} + \dots + \\ &\quad f_p \Phi_p \alpha_2 D_{t-(p+Ps)} - \alpha_3 D_{t+1} + f_1 \Phi_1 \alpha_3 D_{(t+1)-(1+s)} + \dots + f_p \Phi_p \alpha_3 D_{(t+1)-(p+Ps)} - \end{aligned}$$

$\omega_1 K_{2,t} + f_1 \Phi_1 \omega_1 K_{2,t-(1+s)} + \dots + f_p \Phi_p \omega_1 K_{2,t-(p+Ps)} - \omega_2 t K_{2,t} + f_1 \Phi_1 \omega_2 t K_{2,t-(1+s)} +$
 $\dots + f_p \Phi_p \omega_2 t K_{2,t-(p+Ps)} - \omega_3 K_{3,t} + f_1 \Phi_1 \omega_3 K_{3,t-(1+s)} + \dots + f_p \Phi_p \omega_3 K_{3,t-(p+Ps)} -$
 $\omega_4 t K_{3,t} + f_1 \Phi_1 \omega_4 t K_{3,t-(1+s)} + \dots + f_p \Phi_p \omega_4 t K_{3,t-(p+Ps)} + \theta_1 \Theta_1 \varepsilon_{t-(1+s)} + \dots + \theta_q \Theta_q \varepsilon_{t-(q+Qs)}$

sehingga

$$S(\delta, \beta_1, \dots, \beta_{12}, \alpha_1, \dots, \alpha_3, \omega_1, \dots, \omega_4, \phi, \Phi, \theta, \Theta) = \sum_{t=2}^n \varepsilon_t^2 \quad (2.23)$$

Estimasi parameter $\delta, \beta, \alpha, \omega, \phi, \Phi, \theta$, dan Θ dapat dicari dengan meminimumkan persamaan (2.23), akan tetapi tidak cukup diestimasi menggunakan *least squares* karena memberikan penyelesaian yang tidak *close form*, sehingga estimasi parameter bisa dilakukan dengan pendekatan non-linear dalam parameter menggunakan metode Gauss Newton atau Levenberg Marquadt (Cryer & Chan, 2008). Berikut merupakan hasil estimasi untuk model ARIMA (1,0,0) dengan variabel X merupakan variabel waktu.

$$Z_t = \delta t + \frac{\varepsilon_t}{(1 - \phi B)}$$

$$\varepsilon_t = Z_t - \phi Z_{t-1} - \delta t + \delta \phi(t-1)$$

$$\sum_{t=2}^n \varepsilon_t^2 = \sum_{t=2}^n [(Z_t - \phi Z_{t-1} - \delta t + \delta \phi(t-1))^2] = 0$$

estimasi untuk parameter ϕ

$$\begin{aligned} \frac{\partial \sum_{t=2}^n \varepsilon_t^2}{\partial \phi} &= -2 \sum_{t=2}^n [(Z_t - \phi Z_{t-1} - \delta t + \delta \phi(t-1)) [Z_{t-1} - \delta(t-1)]] = 0 \\ &= -2 \sum_{t=2}^n Z_t [Z_{t-1} - \delta(t-1)] + 2\phi \sum_{t=2}^n Z_{t-1} [Z_{t-1} - \delta(t-1)] + 2\delta \sum_{t=2}^n t [Z_{t-1} - \delta(t-1)] - \\ &\quad 2\delta\phi \sum_{t=2}^n (t-1) [Z_{t-1} - \delta(t-1)] = 0 \\ 2\delta\phi \sum_{t=2}^n (t-1) [Z_{t-1} - \delta(t-1)] - 2\phi \sum_{t=2}^n Z_{t-1} [Z_{t-1} - \delta(t-1)] &= 2\delta \sum_{t=2}^n t [Z_{t-1} - \delta(t-1)] - 2 \sum_{t=2}^n Z_t [Z_{t-1} - \delta(t-1)] \\ 2\phi \sum_{t=2}^n [Z_{t-1} - \delta(t-1)] [\delta(t-1) - Z_{t-1}] &= 2 \sum_{t=2}^n [Z_{t-1} - \delta(t-1)] [\delta t - Z_t] \\ \phi &= \frac{2 \sum_{t=2}^n [Z_{t-1} - \delta(t-1)] [\delta t - Z_t]}{2 \sum_{t=2}^n [Z_{t-1} - \delta(t-1)] [\delta(t-1) - Z_{t-1}]} \end{aligned} \quad (2.24)$$

estimasi untuk parameter δ

$$\begin{aligned}
\frac{\partial \sum_{t=2}^n \varepsilon_t^2}{\partial \phi} &= -2 \sum_{t=2}^n [(Z_t - \phi Z_{t-1} - \delta t + \delta \phi(t-1))[t - \phi(t-1)]] \\
&= -2 \sum_{t=2}^n Z_t [t - \phi(t-1)] + 2\phi \sum_{t=2}^n Z_{t-1} [t - \phi(t-1)] + \\
&\quad 2\delta \sum_{t=2}^n t [t - \phi(t-1)] - 2\delta \phi \sum_{t=2}^n (t-1) [t - \phi(t-1)] \\
2\delta \phi \sum_{t=2}^n (t-1) [t - \phi(t-1)] - 2\delta \sum_{t=2}^n t [t - \phi(t-1)] &= 2\phi \sum_{t=2}^n Z_{t-1} [t - \phi(t-1)] - 2 \sum_{t=2}^n Z_t [t - \phi(t-1)] \\
2\delta \sum_{t=2}^n [t - \phi(t-1)] [\phi(t-1) - t] &= 2 \sum_{t=2}^n [t - \phi(t-1)] [\phi Z_{t-1} - Z_t] \\
\delta &= \frac{2 \sum_{t=2}^n [t - \phi(t-1)] [\phi Z_{t-1} - Z_t]}{2 \sum_{t=2}^n [t - \phi(t-1)] [\phi(t-1) - t]} \tag{2.25}
\end{aligned}$$

Dari persamaan (2.24) dan (2.25) diperoleh bahwa penyelesaian tidak *close form* karena hasil estimasi pada parameter ϕ dan δ terdapat parameter lain yang belum diketahui.

2.4 Neural Network (NN)


2.4.1 Pengertian Neural Network

Jaringan Syaraf Tiruan (NN) adalah suatu system komputasi dengan arsitektur dan operasinya diilhami oleh pengetahuan tentang sel syaraf biologis di dalam otak. Arsitektur ini merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba menstimulasi proses pembelajaran pada otak manusia tersebut. NN dapat digambarkan sebagai model matematika dan komputasi untuk fungsi aproksimasi non-linear, klasifikasi data cluster dan regresi nonparametric atau sebuah simulasi dari koleksi model syaraf biologis (Hermawan, 2006).

Pada dasarnya NN adalah suatu prosesor yang melakukan pendistribusian pengetahuan secara besar-besaran, memiliki kecenderungan alami untuk menyimpan suatu pengenalan yang pernah dialaminya, dengan kata lain NN ini

memiliki kemampuan untuk dapat melakukan pembelajaran dan pendektasian terhadap sesuatu objek.

System pembelajaran merupakan proses penambahan pengetahuan pada NN yang sifatnya kontinu sehingga pada saat digunakan pengetahuan tersebut akan dieksploitasikan secara maksimal dalam mengenali suatu objek. Neuron adalah bagian dasar dari pemrosesan suatu NN. Gambar 2.1 merupakan bentuk dasar dari suatu neuron (Brenton, 1999).



GAMBAR 2.1 Bentuk Dasar Neuron

Dalam suatu arsitektur NN, terdapat tiga jenis layer/lapisan, yaitu input layer/lapisan input, hidden layer/lapisan tersembunyi dan output layer/lapisan output. Input layer berfungsi sebagai tempat data dimasukkan untuk proses lebih lanjut, hidden layer merupakan unit proses dari data yang telah dimasukkan, output layer merupakan tempat keluaran hasil dari proses yang telah dilakukan, sedangkan weights adalah bobot dari sinyal yang akan diroses lebih lanjut. Pada hidden layer memiliki satu atau lebih neuron yang menerima input dari neuron-neuron pada layer sebelumnya dan meneruskan output ke neuron-neuron pada layer sesudahnya.

2.4.2 Feed-forward Neuron Networks

Model *Feed-forward Neuron Networks* (FFNN) merupakan salah satu bentuk model NN yang dapat dipandang sebagai suatu kelompok dari model yang sangat fleksibel dari fungsi-fungsi nonlinear dan dapat digunakan untuk berbagai aplikasi. Model ini mencakup semua model NN yang bersifat acyclic, dengan kata lain informasi dipropagasi/disampaikan secara searah dari neuron input ke neuron

output. Contoh model ini adalah single-layer perceptron, multi-layer perceptron, *Radial Basis Function* (RBF) dan Kohonen self-organizing map (SOM).

2.4.3 Proses Pembelajaran

Proses pembelajaran terhadap perubahan bobot dalam Jaringan Syaraf Tiruan ada dua.

(i) Pembelajaran terawasi (*supervised learning*)

Metode pembelajaran pada jaringan syaraf disebut terawasi jika output yang diharapkan telah diketahui sebelumnya. Pada proses pembelajaran, satu pola input akan diberikan ke satu neuron pada lapisan input. Pola ini akan dirambatkan di sepanjang jaringan syaraf hingga sampai ke neuron pada lapisan output. Lapisan output ini akan membangkitkan pola output yang nantinya akan dicocokkan dengan pola output targetnya. Apabila terjadi perbedaan antara pola output hasil pembelajaran dengan pola target, maka akan muncul error. Apabila nilai error cukup besar, mengindikasikan bahwa masih perlu dilakukan lebih banyak pembelajaran lagi.

(ii) Pembelajaran tak terawasi (*unsupervised learning*)

Pada metode pembelajaran yang tak terawasi ini tidak memerlukan target output. Pada metode ini, tidak dapat ditentukan hasil yang seperti apakah yang diharapkan selama proses pembelajaran. Selama proses pembelajaran, nilai bobot disusun dalam suatu *range* tertentu tergantung pada nilai input yang diberikan. Tujuan pembelajaran ini adalah mengelompokkan unit-unit yang hampir sama dalam suatu area tertentu.

2.4.4 Radial Basis Function Neural Network (RBFNN)

Model *neural network* (NN) mempunyai struktur model yaitu input melewati unit hidden sebelum diproses pada output. Desain dari RBFNN adalah model NN mentransformasi input secara nonlinear dengan menggunakan fungsi aktivitas Gaussian pada lapisan unit hidden sebelum diproses secara linear pada lapisan output.

Dalam penerapannya, model RBFNN mengandung sejumlah parameter (*weight*) yang harus ditaksir. Untuk mendapatkan model RBF yang sesuai, perlu

menentukan kombinasi yang tepat antara jumlah variabel input, jumlah node (*cluster*) pada unit *hidden layers*, rata-rata dan standar deviasi (skala atau *width*) dari variabel input pada setiap node.

2.4.4.1 Fungsi Radial Basis

RBFN didesain untuk membentuk pemetaan non linear dari variabel input ke unit *hidden layer* dan pemetaan linear dari hidden layer ke *output*. Sehingga pada RBFN dilakukan pemetaan input dari ruang berdimensi p ke output ruang berdimensi 1.

$$s = \mathfrak{R}^p \rightarrow \mathfrak{R}^1$$


Berdasarkan teori interpolasi multivariate : jika diberikan n buah titik berbeda $\{x_i \in \mathfrak{R}^p \mid i = 1, 2, \dots, n\}$ yang berhubungan dengan n buah bilangan real di $\{d_i \in \mathfrak{R}^1 \mid i = 1, 2, \dots, n\}$. Fungsi $F : \mathfrak{R}^p \rightarrow \mathfrak{R}^1$ adalah fungsi yang memenuhi:

$$F(x_i) = d_i, i = 1, 2, \dots, n. \quad (2.26)$$

Agar memenuhi teori di atas, interpolasi dengan menggunakan fungsi $F(x)$ harus meloloskan semua data. Teori interpolasi multivariate secara ringkas dapat dinyatakan dengan:

$$F : \mathfrak{R}^p \rightarrow \mathfrak{R}^1$$

Disain dari model RBFN untuk pendekatan suatu fungsi adalah sebagai berikut:



Gambar 2.2 Disain RBF network

Pada pemodelan RBFN dilakukan dengan memilih suatu fungsi $F(x)$ sehingga (2.26) dipenuhi. Interpolasi input-output (2.26) dengan melihat disain model RBFN, maka (2.26) dapat dinyatakan dengan:

$$F(x) = \sum_{i=1}^n w_i \phi(\|\mathbf{x} - \mathbf{x}_i\|) \quad (2.27)$$

Dimana $F(x)$ adalah output RBFN, w_i adalah bobot, \mathbf{x}_i merupakan *center*, $\phi(\|\mathbf{x} - \mathbf{x}_i\|)$ adalah fungsi aktivasi, $i = 1, 2, \dots, n$ dan $\|\cdot\|$ adalah jarak Euclid. Fungsi aktivasi yang sering digunakan adalah fungsi Gaussian karena mempunyai sifat local, yaitu bila input dekat dengan rata-rata (pusat), maka fungsi akan menghasilkan nilai satu.

Apabila diketahui n buah titik data $\{x_i \in \mathfrak{R}^p \mid i = 1, 2, \dots, n\}$ adalah pusat dari RBF, maka persamaan (2.27) dapat ditulis:

$$\begin{bmatrix} \phi_{11} & \phi_{12} & \cdots & \phi_{1n} \\ \phi_{21} & \phi_{22} & \cdots & \phi_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{n1} & \phi_{n2} & \cdots & \phi_{nn} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_n \end{bmatrix} \quad (2.28)$$

Dimana $\phi_{ij} = \phi(\|\mathbf{x}_i - \mathbf{x}_j\|); i, j = 1, 2, \dots, n$

Bila (2.28) dinyatakan dalam bentuk persamaan matriks, akan menjadi $\mathbf{fw} = \mathbf{d}$

dimana

$$d = [d_1, d_2, \dots, d_n]$$

$$w = [w_1, w_2, \dots, w_n]$$

$$f = \phi_{ij}$$

Matriks ϕ adalah matriks interpolasi yang definit positif dan mempunyai invers.

2.4.4.2 Algoritma Pembelajaran Pelatihan Jaringan

Berguna atau tidaknya suatu jaringan saraf tiruan ditentukan dari hasil pelatihannya yang berupa bobot neuronnya. RBFN memiliki algoritma pelatihan yang agak unik karena terdiri atas cara pembelajaran terawasi (*supervised*) dan pembelajaran tak terawasi (*unsupervised*) sekaligus. Pelatihan RBFN terdiri dari dua tahap yaitu clustering data dan estimasi parameter.

Tahap Pertama:

Data di-cluster atau dikelompokkan berdasarkan kedekatan tertentu, misalnya kedekatan jarak antar 2 titik. Penentuan cluster dengan sendirinya akan menghasilkan center atau pusat dari kelompok data. Jumlah cluster menentukan hidden unit yang dipakai.

Metode K-mean cluster atau pengelompokkan dengan menggunakan metode K-mean adalah salah satu metode dari beberapa metode unsupervised pada pemodelan RBFNN. Pada metode K-mean, data dipartisi kedalam sub group atau cluster, dimana pada setiap cluster mempunyai sifat yang homogen serta antar cluster mempunyai ciri yang berbeda. Jika ada m buah unit cluster pada RBFNN, maka akan ada \mathbf{x}_i , $i = 1, 2, 3, \dots, m$ nilai rata-rata atau pusat kluster. Penentuan nilai rata-rata dari setiap cluster dilakukan dengan iterasi. Nilai rata-rata kluster untuk iterasi ke n adalah $\mathbf{x}_i(n)$.

1. Inisialisasi :

Memilih nilai secara random sebagai nilai awal dari pusat kluster $\mathbf{x}_i(0)$, $i = 1, 2, 3, \dots, m$.

2. Similaritas :

Dapatkan nilai $k(x)$, indeks dari kesesuaian terbaik untuk pusat kluster, dengan meminimumkan jarak Euclidian, dengan kriteria :

$$k(x) = \arg \min_k \|\mathbf{x}(n) - \mathbf{x}_k(n)\|; \quad k = 1, 2, \dots, m \quad (2.29)$$

3. Update :

Menghitung nilai pusat baru, dengan menggunakan suatu pendekatan, sebagai berikut:

$$\mathbf{x}_k(n+1) = \begin{cases} \mathbf{x}_k(n) + \eta [\mathbf{x}(n) - \mathbf{x}_k(n)], & k = k(x) \\ \mathbf{x}_k(n) & , \text{ yang lain} \end{cases}$$

Dimana η adalah parameter laju pembelajaran

4. Ulangi langkah 2 dan 3 sampai tidak ada perubahan nilai pusat.

Tahap ke-dua

Tahapan ini adalah untuk estimasi parameter lapisan output. Pada tahap ini juga, dibutuhkan data training beserta targetnya.

Langkah-langkah pada tahap ini adalah sebagai berikut:

1. Sinyal input diteruskan ke hidden layer dan menghitung nilai fungsi aktivasinya pada tiap hidden layer. Untuk itu, digunakan rumus:

$$\phi_{ij}(\|\mathbf{x} - \mathbf{x}_i\|) = \exp\left(-\frac{1}{\sigma_j^2} \|\mathbf{x} - \mathbf{x}_i\|^2\right) \quad (2.30)$$

i = 1,2,3,...,n (sesuai dengan jumlah hidden unit)

\mathbf{x} = input

\mathbf{x}_i = center

σ_j = *spread* ke- j , dimana $j=1,2,\dots,n$, n adalah banyak pusat data

2. Menyusun matriks Gaussian, dari hasil perhitungan pada langkah 1.

$$G = \begin{bmatrix} \phi_{11} & \phi_{12} & \cdots & \phi_{1n} \\ \phi_{21} & \phi_{22} & \cdots & \phi_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{n1} & \phi_{n2} & \cdots & \phi_{nn} \end{bmatrix}$$

3. Menghitung bobot baru (W) dengan mengalikan pseudo invers dari matriks G , dengan vector target \mathbf{d} dari data training.

Dengan rumus sebagai berikut:

$$W = G^+ \mathbf{d} = (G^T G)^{-1} G^T \mathbf{d}$$

4. Menghitung nilai output dari jaringan, dengan rumus (2.27)

2.4.5 Strategi Pemilihan Model Terbaik Berdasarkan Cross Validation

Permasalahan yang dihadapi dalam neural network adalah bagaimana cara memilih arsitektur jaringan yang terbaik. Salah satu strategi pemilihan model yang diperkenalkan oleh Anders dan Korn (1999) adalah cross validation, yaitu strategi pemilihan model yang paling umum digunakan dimana seluruh data dibagi menjadi dua bagian yaitu data training dan data testing. Pembagian data training dan data testing dilakukan secara random. Data training digunakan untuk

pemodelan, sedangkan data testing digunakan untuk menguji atau memvalidasi model yang dihasilkan.

Pada prinsipnya, semua kombinasi variabel input dan hidden unit dapat dibandingkan. Hasil pemodelan menggunakan data training akan diterapkan pada data testing, dan model dengan sMAPE terkecil pada data testing adalah model yang akan dipilih.

2.5 Hybrid ARIMAX-RBFN

ARIMAX merupakan pendekatan untuk pemodelan linier, sedangkan *Neural Network* merupakan pendekatan untuk pemodelan non linier. Menurut Zhang (2003) secara matematis penggabungan dari model linier dan model non linier dapat dituliskan dengan persamaan berikut.

$$Z_t = \hat{Z}_t + \hat{e}_t + \eta_t \quad (2.31)$$

dengan

\hat{Z}_t = komponen linier dari model ARIMAX

\hat{e}_t = komponen non linier dari *Neural Network*

η_t = residual dari model *Hybrid ARIMAX-RBFN*.

dengan didapatkan *residual* dari model ARIMAX maka dijadikan input untuk pemodelan non linier e_t sebanyak p .

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-p}) + a_t \quad (2.32)$$

$f(\cdot)$ merupakan fungsi non linier yang diperoleh dari *RBFN* dan a_t merupakan *residual* dari model *Radial Basis*.

2.6 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. *Symmetric Mean Absolute Percentage Error* (sMAPE) merupakan salah satu kriteria yang dapat digunakan dalam pemilihan model terbaik dan merupakan penyempurnaan dari *Mean*

Absolute Percentage Error (MAPE). Perhitungan nilai sMAPE adalah sebagai berikut:

$$sMAPE = \left(\frac{1}{M} \sum_{l=1}^M \frac{|Z_{n+l} - \hat{Z}_n(l)|}{\left(\frac{|Z_{n+l}| + |\hat{Z}_n(l)|}{2} \right)} \right) \times 100\% \quad (2.33)$$

Dengan

M = banyaknya ramalan *out-sample*

Z_{n+l} = nilai sesungguhnya

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

2.7 Inflow dan Outflow

Uang didefinisikan sebagai segala sesuatu yang diterima secara umum sebagai alat pembayaran yang resmi dalam rangka memenuhi suatu kewajiban. Jika ditinjau dari bentuknya, uang dibedakan menjadi uang kartal dan uang giral. Uang kartal adalah uang rupiah kertas dan uang rupiah logam yang dikeluarkan dan diedarkan oleh Bank Indonesia, dan digunakan sebagai alat pembayaran yang sah wilayah Republik Indonesia. Sedangkan uang giral adalah uang yang dikeluarkan oleh bank umum, terdiri dari rekening giro, kiriman uang, simpanan berjangka, dan tabungan dalam rupiah yang sudah jatuh tempo, yang seluruhnya merupakan simpanan penduduk dalam rupiah pada system moneter (Bank Indonesia, 2014).

Penyetoran atau biasa disebut dengan *inflow* uang kartal adalah aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia. *Inflow* terdiri dari setoran bank dan non bank, penukaran masuk dari loket BI dan kas keliling, serta transaksi masuk kas titipan. Sedangkan yang dimaksud dengan penarikan atau yang biasa disebut dengan *outflow* uang kartal adalah informasi mengenai aliran uang kertas dan uang logam yang keluar dari BI kepada perbankan dan masyarakat, terdiri dari bayaran bank dan non bank, penukaran keluar dari loket BI dan kas keliling, serta transaksi keluar kas titipan (Bank Indonesia, 2015).

BAB 3

METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu data nasional inflow dan outflow uang kartal di Provinsi Papua yang diperoleh dari Bank Indonesia. Data yang digunakan adalah data bulanan dari Januari (2003) hingga Desember (2014). Data periode Januari 2003 hingga Desember 2013 digunakan sebagai data training (*in-sample*) dan data periode Januari 2014 hingga Desember 2014 sebagai data testing (*out-sample*).

3.2 Variabel Penelitian

Spesifikasi variabel yang digunakan dalam penelitian ini adalah sebagai berikut:

$Z_{1,t}$ = Jumlah *inflow* pada bulan ke t

$Z_{2,t}$ = Jumlah *outflow* pada bulan ke t

$M_{z,t}$ = Variabel *dummy* bulan ke- z , dimana $z = 1, 2, 3, \dots, 12$

D_{t-1} = variabel *dummy* bulan sebelum Idul Fitri

D_t = variabel *dummy* bulan Idul Fitri

D_{t+1} = variabel *dummy* bulan sesudah Idul Fitri

$D_{i,t-1}$ = variabel *dummy* minggu ke- i sebelum terjadinya Idul Fitri

$D_{i,t}$ = variabel *dummy* minggu ke- i saat terjadinya Idul Fitri

$D_{i,t+1}$ = variabel *dummy* minggu ke- i sesudah terjadinya Idul Fitri

dengan $i = 1, 2, 3, 4$

Tabel 3.1 Definisi Operasional dari Variabel yang Digunakan

Nama Variabel	Definisi Operasional
<i>Inflow</i> nasional per bulan	Jumlah kumulatif uang kartal yang masuk di seluruh BI melalui kegiatan setoran perbankan dan masyarakat tiap bulan
<i>Outflow</i> nasional per bulan	Jumlah kumulatif uang kartal yang masuk dari seluruh BI melalui proses penarikan perbankan dan masyarakat tiap bulan

3.3 Metode Analisis


Berikut adalah langkah-langkah analisis.

- 1) Membentuk variabel *dummy* untuk hari raya Idul Fitri mulai tahun 2003 hingga tahun 2013 dapat dilihat pada tabel berikut.

Tabel 3.2 Tanggal Terjadinya Hari Raya Idul Fitri Tahun 2003-2013

Tahun	Tanggal Idul Fitri
2003	25-26 Nopember
2004	14-15 Nopember
2005	03-04 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

- 2) Langkah-langkah analisis untuk mendapatkan model ARIMAX.
 - a. Menentukan variabel *dummy* berdasarkan periode kalender variasi dalam hal ini *dummy* hari raya Idul Fitri.
 - b. Melakukan pemodelan regresi dengan *dummy* (regresi *time series*)
 - c. Memodelkan residual hasil analisis regresi menggunakan ARIMA jika asumsi residual dari model regresi tidak memenuhi asumsi *white noise* (apabila residual dari model regresi sudah memenuhi asumsi *white noise* maka tidak perlu penambahan model ARIMA pada model regresi)
 - d. Melakukan pemodelan ARIMAX
 - e. Melakukan pengecekan signifikansi parameter.
 - f. Melakukan pengecekan residual dari model yang terbentuk apakah sudah mencapai kondisi *white noise*.
 - g. Melakukan pengecekan residual dari model yang terbentuk apakah sudah berdistribusi normal.



Gambar 3.1 Diagram Alir Model ARIMAX

3) Langkah-langkah analisis untuk mendapatkan model RBFN (*Radial Basis Network*).

- a. Menentukan banyak *K-Means Clustering* yang ingin dibentuk.
- b. Membangkitkan nilai random untuk pusat cluster awal (*centroid*) sebanyak k .
- c. Menghitung jarak setiap data input terhadap masing-masing *centroid* hingga ditemukan jarak yang paling dekat dari setiap data dengan *centroid*.
- d. Mengklasifikasi setiap data berdasarkan kedekatannya dengan *centroid*
- e. Menentukan sinyal input ke *hidden layer* dan menghitung nilai fungsi aktivasinya pada tiap *hidden layer* menggunakan rumus berikut:

$$\phi_{ij}(\|\mathbf{x} - \mathbf{x}_i\|) = \exp\left(-\frac{1}{\sigma_j^2} \|\mathbf{x} - \mathbf{x}_i\|^2\right) \quad (2.26)$$

$i = 1, 2, 3, \dots, n$ (sesuai dengan jumlah hidden unit)

\mathbf{x} = input

\mathbf{x}_i = center

σ_j = *spread* ke- j , dimana $j=1, 2, \dots, n$, n adalah banyak pusat data


- f. Menghitung bobot baru (W) dengan mengalikan pseudoinverse dari matriks G dengan vektor target (\mathbf{d}) dari data training dengan menggunakan rumus pada persamaan berikut:

$$W = G^+ \mathbf{d} = (G^T G)^{-1} G^T \mathbf{d}$$

- g. Menghitung nilai output jaringan menggunakan rumus pada persamaan berikut:

$$F(x) = \sum_{i=1}^n w_i \phi(\|\mathbf{x} - \mathbf{x}_i\|)$$

- h. Melakukan peramalan *inflow* dan *outflow* uang kartal.
- i. Menghitung nilai sMAPE.



Gambar 3.2 *Flowchart Proses Training RBFN*

- 4) Pemodelan *Hybrid* ARIMAX-RBFN terdiri dari dua tahapan sebagai berikut:
- a. Memodelkan ARIMAX untuk deret output yang digunakan untuk menganalisis komponen linear.
 - b. Memodelkan RBFN dari residual yang diperoleh dari model ARIMAX.
 - c. Menjumlahkan komponen linear dari proses ARIMAX dan komponen non linear dari proses RBFN untuk mendapatkan hasil peramalan *inflow* dan *outflow* untuk t -periode yang akan datang.
 - d. Menghitung nilai sMAPE

BAB 4

ANALISIS DAN PEMBAHASAN

Pada pembahasan ini dilakukan analisis *inflow* dan *outflow* uang kartal. Pembahasan diawali dengan eksplorasi data untuk mengetahui karakteristik dari data penelitian, kemudian dilakukan analisis dengan metode ARIMAX, RBFN, dan *hybrid* ARIMAX-RBFN.

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

Analisis deskriptif dilakukan untuk menjelaskan mengenai gambaran umum dari data *inflow* dan *outflow* mulai Januari 2003 hingga Desember 2014. Data bulan Januari 2003 hingga Desember 2013 digunakan sebagai data *in sample*, dan data bulan Januari 2014 sampai Desember 2014 digunakan sebagai data *out sample*.

4.1.1 *Inflow* dan *Outflow* Uang Kartal

Hasil statistik deskriptif data *inflow* dan *outflow* uang kartal dapat dilihat pada Tabel 4.1.

Tabel 4.1 Statistik Deskriptif *Inflow* dan *Outflow* Uang Kartal Selama Periode Pengamatan (dalam miliar)


Variabel	Periode	Keterangan	Mean	St.Dev	Min	Max
<i>Inflow</i>	2003-2014	Total	251,4	251,3	14,4	1800,5
	2003-2006	Kebijakan I	206,4	78,5	97,7	451,9
	2007-2010	Kebijakan II	78,1	99,1	14,4	417,8
	2011-2014	Kebijakan III	469,9	307,7	20,6	1800,5
<i>Outflow</i>	2003-2014	Total	550,3	682,7	3,0	4080,4
	2003-2006	Kebijakan I	331,8	224,5	113,5	1272,9
	2007-2010	Kebijakan II	403,7	660,5	3,0	4080,4
	2011-2014	Kebijakan III	915,6	851,2	24,6	3726,0

Pada tahun 2007 *inflow* uang kartal mengalami penurunan yang cukup tinggi hal ini disebabkan adanya kebijakan baru dalam rangka meningkatkan efektifitas dan efisiensi manajemen kas perbankan serta mengoptimalkan pengolahan uang oleh perbankan sehingga uang yang beredar di masyarakat meningkat kualitasnya. Kemudian pada tahun 2011 terdapat kebijakan baru lagi tentang mata uang 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. Sehingga dari tahun 2003 sampai 2014, Bank Indonesia telah mengeluarkan dua kali kebijakan dalam memenuhi tujuan tersebut. Untuk lebih jelasnya dapat dilihat pada Tabel 4.2.

Tabel 4.2 Perubahan Kebijakan Bank Indonesia 2003-2014

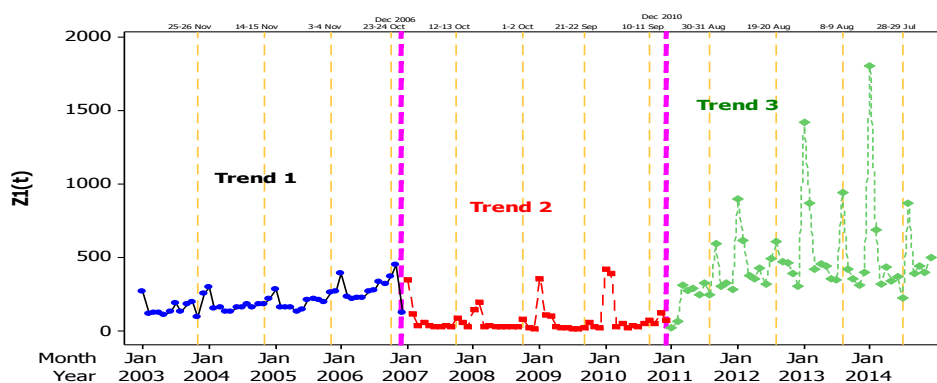
Periode	Kebijakan
2003-2006	PBI No 6/14/PBI/04
2007-2010	PBI No 9/10/PBI/07
2011-2014	UU No.7 Tahun 2011

Dari tabel 4.1 dapat dilihat bahwa periode kebijakan III memiliki nilai standar deviasi yang sangat tinggi, ini menunjukkan bahwa data pada periode kebijakan III sangat bervariasi dibandingkan periode kebijakan I dan II, hal ini diperkuat dengan Gambar 4.1 dimana *inter quartile range* (IQR) terbesar pada periode kebijakan III. Pada kebijakan II nilai standar deviasi lebih besar dari nilai rata-rata baik pada data *inflow* maupun *outflow*, hal ini menunjukkan selain data sangat bervariasi juga mean merupakan representasi yang buruk pada data periode kebijakan II.

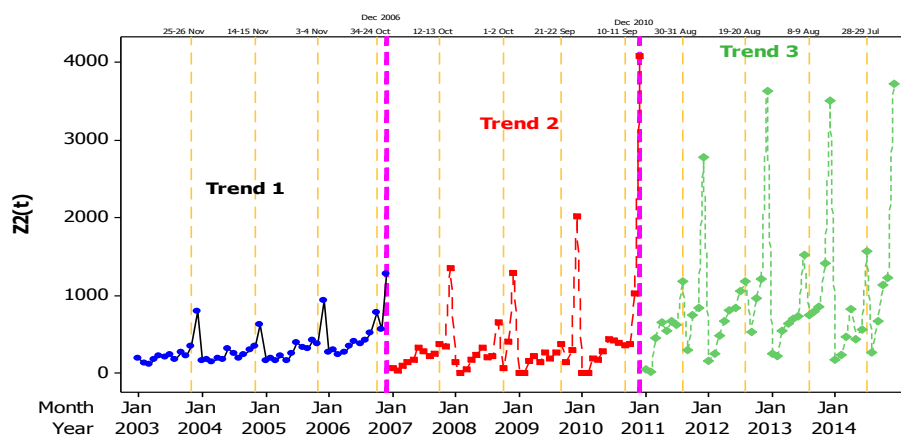


Gambar 4.1 Box Plot *Inflow* (a) dan *Outflow* (b) Uang Kartal pada Setiap Kebijakan

Perubahan kebijakan yang dikeluarkan BI menyebabkan perbedaan pola pada tiga periode selama pengamatan, yaitu pada tahun 2003 hingga 2006, periode kedua pada tahun 2007 hingga 2010, dan periode ketiga pada tahun 2011 hingga 2014. Hal ini dapat dilihat pada Gambar 4.2 dan Gambar 4.3. Pada deret *inflow*, rata-rata secara umum adalah 251,4 miliar dengan standar deviasi sebesar 251,3, sedangkan pada deret *outflow* rata-rata secara umum adalah 550,3 miliar dengan standar deviasi sebesar 682,7.



Gambar 4.2 Time Series Plot *Inflow* Uang Kartal Tahun 2003-2014



Gambar 4.3 Time Series Plot *Outflow* Uang Kartal Tahun 2003-2014

4.2 Model Variasi Kalender *Inflow* dan *Outflow* Uang Kartal

Inflow uang kartal yang tinggi umumnya terjadi pada bulan Januari, sementara untuk *outflow* yang tinggi terjadi pada bulan Desember, sehingga dapat diduga adanya pola musiman pada data *inflow* maupun *outflow* uang kartal. Adanya dugaan efek variasi kalender juga terlihat karena *inflow* dan *outflow* juga mengalami kenaikan disekitar perayaan tahunan Idul Fitri yang pelaksanaannya


didasarkan pada kalender hijriyah. Tabel 4.3 memuat informasi mengenai tanggal terjadinya Idul Fitri pada tahun 2003 hingga 2014 beserta informasi mengenai bulan terjadinya peningkatan *inflow* dan *outflow* uang kartal.

Tabel 4.3 Tanggal Idul Fitri dan Deskriptif *Inflow* dan *Outflow* Terendah dan Tertinggi Tahun 2003-2014


Tahun	Tanggal Idul Fitri	Minggu Terjadinya Idul Fitri	<i>Outflow</i> Uang Kartal		<i>Inflow</i> Uang Kartal	
			Tertinggi Pertama	Tertinggi Kedua	Tertinggi Pertama	Tertinggi Kedua
			2003	25-26 Nopember	Minggu ke-4	Desember
2004	14-15 Nopember	Minggu ke-2	Desember	November	Januari	Desember
2005	03-04 Nopember	Minggu ke-1	Desember	Oktober	Januari	Desember
2006	23-24 Oktober	Minggu ke-3	Desember	Oktober	November	Januari
2007	12-13 Oktober	Minggu ke-2	Desember	Oktober	Januari	Februari
2008	01-02 Oktober	Minggu ke-1	Desember	September	Februari	Januari
2009	21-22 September	Minggu ke-3	Desember	September	Januari	Februari
2010	10-11 September	Minggu ke-2	Desember	November	Januari	Februari
2011	30-31 Agustus	Minggu ke-4	Desember	Agustus	September	November
2012	19-20 Agustus	Minggu ke-3	Desember	Agustus	Januari	Februari
2013	08-09 Agustus	Minggu ke-2	Desember	Juli	Januari	Agustus
2014	28-29 Juli	Minggu ke-4	Desember	Juli	Januari	Agustus

Dari Tabel 4.3 menunjukkan dua bulan tertinggi *inflow* dan *outflow* uang kartal, dimana menguatkan dugaan bahwa data *inflow* dan *outflow* uang kartal bulanan terdapat pola musiman karena *outflow* uang kartal selalu tinggi pada bulan Desember, dan untuk *inflow* tinggi hampir disetiap bulan Januari, kecuali pada tahun 2006 dan 2011 dimana tertinggi pada bulan November dan September yang diakibatkan oleh pengaruh hari raya Idul Fitri. Hal ini menunjukkan bahwa *inflow* dan *outflow* juga dipengaruhi oleh adanya variasi kalender. Berdasarkan tabel tersebut didapatkan kesimpulan yaitu apabila hari raya Idul Fitri terjadi pada minggu pertama maka *outflow* uang kartal meningkat pada satu bulan sebelum terjadinya Idul Fitri, apabila Idul Fitri terjadi pada minggu kedua maka *outflow* uang kartal meningkat pada satu bulan sebelum Idul Fitri (2013) dan pada saat Idul Fitri (2004 dan 2007), sedangkan apabila hari raya Idul Fitri terjadi pada minggu ketiga dan keempat maka *outflow* uang kartal meningkat pada saat bulan terjadinya Idul Fitri. Hal yang perlu diperhatikan bahwa meskipun terdapat pengaruh hari Raya Idul Fitri tetapi pengaruh hari raya Natal masih mempunyai pengaruh yang lebih besar, dimana *outflow* tertinggi selalu berada pada bulan

Desember, sementara pengaruh hari raya Idul Fitri merupakan tertinggi kedua. Tingginya *outflow* pada bulan Desember mengakibatkan *inflow* mengalami kenaikan hampir disetiap bulan Januari kecuali pada tahun 2006 dan 2011 dimana pengaruh hari raya Idul Fitri lebih besar. Secara visual dapat dilihat pada Gambar 4.4 dan Gambar 4.5.



Gambar 4.4 Diagram Batang Rata-Rata *Inflow* Uang Kartal Sebelum, Saat, dan Setelah Idul Fitri



Gambar 4.5 Diagram Batang Rata-Rata *Outflow* Uang Kartal Sebelum, Saat, dan Setelah Idul Fitri

Berdasarkan uraian diatas diketahui bahwa peningkatan *inflow* dan *outflow* uang kartal merupakan kejadian musiman dan juga efek dari variasi kalender. Kejadian musiman ini dikarenakan hari raya Natal disetiap bulan Desember, sedangkan variasi kalender terjadi karena perayaan tahunan Idul Fitri yang terjadi

11 hari lebih awal dari tahun sebelumnya. Oleh karena itu berdasarkan Tabel 4.3 maka variabel *dummy* yang digunakan adalah variabel *dummy* bulanan yaitu bulan Januari hingga bulan Desember, kemudian variabel *dummy* perubahan kebijakan BI yaitu pada kebijakan II dan kebijakan III. Selain pembentukan variabel *dummy* yang menyatakan variasi kalender, juga akan dibentuk variabel *dummy* yang menyatakan pola *trend*. Berdasarkan eksplorasi data, diduga terdapat tiga periode yang berbeda pada pola data *inflow* dan *outflow* uang kartal karena adanya beberapa perubahan kebijakan 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. Sehingga variabel *dummy* yang menyatakan adanya perubahan kebijakan pada pola data dan variabel yang menyatakan adanya pola musiman dinyatakan dengan *dummy* bulanan. Sehingga variabel *dummy* yang terbentuk adalah sebagai berikut:

Tabel 4.4 Variabel *Dummy*

Variabel <i>Dummy</i>	Keterangan	Variabel <i>Dummy</i>	Keterangan
$M_{1,t}$	Bulan Januari	$M_{12,t}$	Bulan Desember
$M_{2,t}$	Bulan Februari	$K_{2,t}$	Kebijakan II BI
$M_{3,t}$	Bulan Maret	$tK_{2,t}$	Trend Kebijakan II BI
$M_{4,t}$	Bulan April	$K_{3,t}$	Kebijakan III BI
$M_{5,t}$	Bulan Mei	$tK_{3,t}$	Trend Kebijakan III BI
$M_{6,t}$	Bulan Juni	D_{t-1}	Bulan Sebelum Idul Fitri
$M_{7,t}$	Bulan Juli	D_t	Bulan saat Idul Fitri
$M_{8,t}$	Bulan Agustus	D_{t+1}	Bulan setelah Idul Fitri
$M_{9,t}$	Bulan September	$D_{i,t-1}$	Minggu ke- i sebelum terjadinya Idul Fitri, $i=1,2,3,4$
$M_{10,t}$	Bulan Oktober	$D_{i,t}$	Minggu ke- i saat terjadinya Idul Fitri, $i=1,2,3,4$
$M_{11,t}$	Bulan November	$D_{i,t+1}$	Minggu ke- i sesudah terjadinya Idul Fitri, $i=1,2,3,4$

Variabel *dummy* bulanan adalah

$$M_{1,t} = \begin{cases} 1, & \text{untuk bulan Januari} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

$$M_{2,t} = \begin{cases} 1, & \text{untuk bulan Februari} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

⋮

$$M_{12,t} = \begin{cases} 1, & \text{untuk bulan Desember} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

Variabel *dummy* Kebijakan BI adalah

$$K_{2t} = \begin{cases} 1, & \text{untuk 2007 sampai 2010} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

$$tK_{2t} = \begin{cases} 1t, & \text{untuk 2007 sampai 2010} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

$$K_{3t} = \begin{cases} 1, & \text{untuk 2011 sampai 2014} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

$$tK_{3t} = \begin{cases} 1t, & \text{untuk 2011 sampai 2014} \\ 0, & \text{untuk tahun yang lain} \end{cases}$$

Variabel *dummy* akibat variasi kalender adalah


$$D_{t-1} = \begin{cases} 1, & \text{untuk bulan ke-(t-1) satu bulan sebelum terjadinya Idul Fitri} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

$$D_t = \begin{cases} 1, & \text{untuk bulan ke-t pada saat Idul Fitri} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$


$$D_{t+1} = \begin{cases} 1, & \text{untuk bulan ke-(t+1) satu bulan sesudah terjadinya Idul Fitri} \\ 0, & \text{untuk bulan yang lain} \end{cases}$$

4.3 Model Regresi *Time Series Inflow dan Outflow*

Tahap awal adalah mengidentifikasi kestasioneran dari data dan penentuan orde lag dari AR dan MA. Identifikasi dengan melihat plot *time series* untuk mengetahui apakah terdapat pola-pola tertentu.



Gambar 4.6 Plot *Time series Inflow* Uang Kartal



Gambar 4.7 Plot *Time series Outflow* Uang Kartal

Perubahan-perubahan kebijakan yang dikeluarkan Bank Indonesia menyebabkan nilai rata-rata tiap periode kebijakan bersifat fluktuatif. Hal ini terlihat jelas pada *inflow* uang kartal dimana pola data cenderung terbagi menjadi tiga bagian pada Gambar 4.6. Sedangkan untuk *outflow* uang kartal perubahan pada kebijakan III yang mempunyai pengaruh cukup besar. Akibat kebijakan III ini, nilai rata-rata *outflow* pada tahun 2011 hingga 2014 memiliki perubahan yang cukup jauh dibandingkan dengan kedua periode sebelumnya, dapat dilihat pada Gambar 4.7. Kecenderungan ini menandakan bahwa data masih belum stasioner baik dalam varian maupun rata-rata. Akan tetapi untuk memperkuat pernyataan tersebut, dilakukan pengujian stasioneritas *mean* dengan menggunakan uji *Augmented Dickey-Fuller*. Tabel 4.5 menunjukkan menunjukkan bahwa data *inflow* dan *outflow* uang kartal memang belum stasioner dalam *mean*.


Tabel 4.5 Hasil Uji *Augmented Dickey Fuller Inflow* dan *Outflow* Uang Kartal

Variabel	Tipe	Tau (τ)	P-value
<i>Inflow</i>	Zero mean	0,21	0,745
	Single mean	-0,93	0,775
	Trend	-1,07	0,929
<i>Outflow</i>	Zero mean	1,55	0,970
	Single mean	0,33	0,979
	Trend	-0,61	0,976

Stasioneritas data pada variabel *inflow* dan *outflow* dapat ditentukan dengan menggunakan transformasi Box-Cox jika data tidak stasioner dalam varians, dan *differencing* jika data tidak stasioner dalam rata-rata. Berikut adalah hasil dari transformasi Box-Cox.


Tabel 4.6 Transformasi Box-Cox Data *Inflow* dan *Outflow* Uang Kartal

	<i>Inflow</i>		<i>Outflow</i>	
	Sebelum Transformasi	Sesudah Transformasi	Sebelum Transformasi	Sesudah Transformasi
Lambda	0,07	1,33	0,13	1,00
Lower CL	-0,07	0,68	0,03	0,21
Upper CL	0,20	1,94	0,25	1,86
Rounded Value	0,00	1,00	0,13	1,00



Gambar 4.8 Plot Box-Cox Data *Inflow* (a) dan *Outflow* (b) Uang Kartal

Tabel 4.6 menunjukkan bahwa data *inflow* dan *outflow* uang kartal tidak stasioner dalam varians, sehingga perlu dilakukan transformasi data menggunakan fungsi \ln untuk *inflow* dan Z^λ untuk *outflow*. Setelah dilakukan transformasi diperoleh nilai *rounded value* sama dengan 1 atau dengan kata lain data telah stasioner dalam varians, dapat dilihat pada Gambar 4.9. Selain menggunakan transformasi Z^λ pada data *outflow* juga akan digunakan transformasi \ln , dan akan dibandingkan hasil ramalan yang lebih baik dengan melihat nilai sMAPE.




Gambar 4.9 Plot *Time Series* Data *Inflow* (a) dan *Outflow* (b) Uang Kartal yang Telah Stasioner

Dari plot ACF *inflow* dan *outflow* terlihat lag turun lambat di pola musiman dan non musiman sehingga dilakukan *differencing* orde 1. Hasil *differencing* dapat dilihat pada Tabel 4.7 yang menunjukkan bahwa setelah dilakukan *differencing* 1 data telah stasioner dalam mean.

Tabel 4.7 Hasil Uji *Augmented Dickey Fuller Inflow* dan *Outflow* Uang Kartal Setelah dilakukan *differencing* orde 1

Variabel	Tipe	τ	P-value
<i>Inflow</i>	Zero mean	-3,40	0,000
	Single mean	-3,41	0,012
	Trend	-3,54	0,039
<i>Outflow</i>	Zero mean	-4,76	0,000
	Single mean	-4,95	0,000
	Trend	-5,16	0,000

Dari Gambar 4.9 setelah dilakukan dilakukan *differencing* terlihat bahwa sudah tidak terdapat unsur *trend* dalam data atau fluktuasi data berada di sekitar nilai rata-rata yang konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut. Berikut adalah plot ACF dan PACF dari deret *inflow* dan *outflow*.



Gambar 4.10 Plot ACF dan PACF Data *Inflow* (a) dan *Outflow* (b) Uang Kartal yang Telah Stasioner.

Jika dilihat dari plot ACF pada Gambar 4.10 tidak lagi turun lambat baik pada pola musiman dan non musiman, sehingga dapat disimpulkan bahwa data telah stasioner dan dapat dilanjutkan ketahap berikutnya.

Sebelum kepada pemodelan ARIMAX, analisis regresi deret waktu akan dilakukan terlebih dahulu, yaitu meregresikan *inflow* dan *outflow* dengan variabel *dummy*. Untuk *inflow* model regresi deret waktu adalah

$$\begin{aligned}
 Z_{1,t}^* = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \\
 & \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \\
 & \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \alpha_1 D_{t-1} + \alpha_2 D_t + \\
 & \alpha_3 D_{t+1} + \omega_1 K_{2,t} + \omega_2 K_{2,t} + \omega_3 K_{3,t} + \omega_4 K_{3,t} + \varepsilon_t
 \end{aligned} \tag{4.1}$$

Kemudian dilakukan estimasi parameter dari model dugaan tersebut. Hasil estimasi parameter tersebut dapat dilihat pada Tabel 4.8.

Tabel 4.8 Hasil Estimasi Parameter Regresi *Dummy* pada Deret *Inflow*

Variabel	Parameter	Estimasi	Standar error	t _{hitung}	p-value
t	δ	0,018	0,006	3,04	0,003
$M_{1,t}$	β_1	5,679	0,231	24,64	0,0001
$M_{2,t}$	β_2	5,264	0,232	22,73	0,0001
$M_{3,t}$	β_3	4,769	0,233	20,48	0,0001
$M_{4,t}$	β_4	4,732	0,234	20,22	0,0001
$M_{5,t}$	β_5	4,542	0,235	19,3	0,0001
$M_{6,t}$	β_6	4,544	0,237	19,19	0,0001
$M_{7,t}$	β_7	4,616	0,244	18,9	0,0001
$M_{8,t}$	β_8	4,649	0,251	18,53	0,0001
$M_{9,t}$	β_9	4,600	0,264	17,45	0,0001
$M_{10,t}$	β_{10}	4,789	0,265	18,05	0,0001
$M_{11,t}$	β_{11}	4,560	0,260	17,52	0,0001
$M_{12,t}$	β_{12}	4,395	0,252	17,42	0,0001
D_{t-1}	α_1	-0,025	0,213	-0,12	0,9075
D_t	α_2	0,273	0,216	1,27	0,2082
D_{t+1}	α_3	0,378	0,213	1,78	0,0778
$K_{2,t}$	ω_1	-1,088	0,475	-2,29	0,0238

Tabel 4.8 (Lanjutan)

$tK_{2,t}$	ω_2	-0,016	0,008	-1,89	0,061
$K_{3,t}$	ω_3	-3,400	1,088	-3,13	0,0023
$tK_{3,t}$	ω_4	0,021	0,011	1,88	0,0622

Berdasarkan nilai estimasi parameter pada Tabel 4.8 Maka persamaan (4.1) dapat dituliskan menjadi.

$$\begin{aligned}
Z_{1,t}^* = & 0,018t + 5,679M_{1,t} + 5,264M_{2,t} + 4,769M_{3,t} + 4,732M_{4,t} + \\
& 4,542M_{5,t} + 4,544M_{6,t} + 4,616M_{7,t} + 4,649M_{8,t} + 4,600M_{9,t} + \\
& 4,789M_{10,t} + 4,560M_{11,t} + 4,395M_{12,t} - 0,025D_{t-1} + 0,273D_t + \\
& 0,378D_{t+1} - 1,088K_{2,t} - 0,016tK_{2,t} - 3,400K_{3,t} + 0,021K_{3,t} + \varepsilon_t
\end{aligned} \tag{4.2}$$

Sedangkan untuk deret *outflow* model regresi *dummy* adalah

$$\begin{aligned}
Z_{2,t}^* = & \delta t + \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \\
& \beta_5 M_{5,t} + \beta_6 M_{6,t} + \beta_7 M_{7,t} + \beta_8 M_{8,t} + \beta_9 M_{9,t} + \\
& \beta_{10} M_{10,t} + \beta_{11} M_{11,t} + \beta_{12} M_{12,t} + \alpha_1 D_{t-1} + \alpha_2 D_t + \\
& \alpha_3 D_{t+1} + \omega_1 K_{2,t} + \omega_2 t K_{2,t} + \omega_3 K_{3,t} + \omega_4 K_{3,t} + \varepsilon_t
\end{aligned} \tag{4.3}$$

Hasil estimasi parameter dari model dugaan tersebut dapat dilihat pada Tabel 4.9

Tabel 4.9 Hasil Estimasi Parameter Regresi *Dummy* pada Deret *Outflow*

Variabel	Parameter	Estimasi	Standar error	t_{hitung}	p -value
t	δ	0,003	0,002	1,87	0,0647
$M_{1,t}$	β_1	1,729	0,064	26,86	0,0001
$M_{2,t}$	β_2	1,645	0,065	25,43	0,0001
$M_{3,t}$	β_3	1,921	0,065	29,55	0,0001
$M_{4,t}$	β_4	2,010	0,065	30,76	0,0001
$M_{5,t}$	β_5	2,026	0,066	30,82	0,0001
$M_{6,t}$	β_6	2,109	0,066	31,90	0,0001
$M_{7,t}$	β_7	2,092	0,068	30,63	0,0001
$M_{8,t}$	β_8	2,094	0,069	30,25	0,0001
$M_{9,t}$	β_9	2,099	0,074	28,23	0,0001
$M_{10,t}$	β_{10}	2,079	0,075	27,74	0,0001

Tabel 4.9 (Lanjutan)

$M_{11,t}$	β_{11}	2,244	0,075	30,11	0,0001
$M_{12,t}$	β_{12}	2,593	0,071	36,76	0,0001
D_{t-1}	α_1	0,074	0,061	1,23	0,2226
D_t	α_2	-0,018	0,061	-0,29	0,7729
D_{t+1}	α_3	-0,121	0,061	-2,00	0,0483
$K_{2,t}$	ω_1	-0,240	0,133	-1,81	0,073
$tK_{2,t}$	ω_2	0,000	0,002	-0,01	0,9883
$K_{3,t}$	ω_3	-0,422	0,304	-1,39	0,1675
$tK_{3,t}$	ω_4	0,003	0,003	1,10	0,2746

Berdasarkan nilai estimasi parameter pada Tabel 4.9 Maka persamaan (4.3) dapat dituliskan menjadi.

$$\begin{aligned}
 Z_{2,t}^* = & 0,003t + 1,728M_{1,t} + 1,644M_{2,t} + 1,921M_{3,t} + 2,010M_{4,t} + \\
 & 2,025M_{5,t} + 2,109M_{6,t} + 2,091M_{7,t} + 2,094M_{8,t} + 2,098M_{9,t} + \\
 & 2,079M_{10,t} + 2,243M_{11,t} + 2,592M_{12,t} + 0,074D_{t-1} - 0,017D_t - \\
 & 0,121D_{t+1} - 0,239K_{2,t} - 0,000tK_{2,t} - 0,422K_{3,t} + 0,003tK_{3,t} + \varepsilon_t
 \end{aligned} \quad (4.4)$$

Tahapan berikutnya adalah melakukan cek diagnosa pada ε_t untuk melihat apakah ε_t telah memenuhi asumsi *white noise*. Residual dikatakan *white noise* apabila statistik uji *chi-square* lebih kecil dari nilai $\chi_{0,05,df}^2$ atau *p-value* $> \alpha$ (0,05).

Tabel 4.10 Hasil Uji *White Noise* Residual Model Regresi *Time Series* untuk *Inflow* dan *Outflow* Uang Kartal

<i>Inflow</i>				<i>Outflow</i>			
<i>Lag</i>	χ^2_{hitung}	<i>Df</i>	<i>p-value</i>	<i>Lag</i>	χ^2_{hitung}	<i>Df</i>	<i>p-value</i>
6	13,85	6	0,031	6	8,51	6	0,2028
12	16,66	12	0,163	12	40,16	12	0,0001
18	19,2	18	0,380	18	46,81	18	0,0002
24	29,21	24	0,213	24	55,18	24	0,0003
30	32,47	30	0,346	30	61,97	30	0,0005
36	42,89	36	0,200	36	69,96	36	0,0006


Dari hasil yang diperoleh pada Tabel 4.10 menunjukkan residual tidak memenuhi asumsi *white noise*. Untuk mengatasi residual yang tidak *white noise* maka diperlukan penambahan orde ARIMA pada model regresi.

4.4 Peramalan *Inflow* dan *Outflow* dengan ARIMAX

Penambahan orde ARIMA bertujuan untuk menghasilkan model dengan residual yang *white noise* pada model regresi *dummy*, sehingga model yang terbentuk adalah model ARIMAX. Untuk identifikasi orde ARIMA maka digunakan ACF dan PACF dari residual pada model regresi *dummy* yang telah diperoleh.

4.4.1 Peramalan *Inflow* dengan ARIMAX

Berikut adalah plot ACF dan PACF dari residual pada regresi *dummy*.



Gambar 4.11 ACF dan PACF untuk Residual Regresi *Dummy* Data *Inflow*

Berdasarkan ACF dan PACF residual model regresi *dummy* pada *inflow* diduga model ARIMA yang terbentuk merupakan model ARIMA musiman. Karena setiap kelipatan lag 12, lag-lag dari ACF maupun PACF selalu tinggi dibandingkan lag yang berada di lag-lag kelipatan 12 tersebut. Sehingga untuk menebak orde ARIMA diperlukan orde non musiman dan orde musiman. Orde non musiman dapat ditebak berdasarkan pola ACF dan PACF sebelum lag 12. Sedangkan orde musiman dapat ditebak berdasarkan ACF dan PACF lag-lag pada kelipatan 12. Orde non musiman, ACF dan PACF membentuk pola *cut off after* lag 1. Pada data *inflow* orde musiman membentuk pola *cut off after* lag 24,36, dan 48 untuk ACF, sedangkan untuk PACF hanya pada lag 24. Berdasarkan ACF dan PACF tersebut tebakan model ARIMA seperti pada Tabel 4.11.

Tabel 4.11 Model ARIMA *Inflow* Uang Kartal Berdasarkan Plot ACF dan PACF Regresi *Dummy*

Variabel	Model ARIMA
<i>Inflow</i>	ARIMA(1,0,0)(2,0,0) ¹²
	ARIMA(0,0,1)(3,0,0) ¹²
	ARIMA(0,0,[1,10])(3,0,0) ¹²
	ARIMA(0,0,[1,13])(3,0,0) ¹²
	ARIMA(0,0,1)(4,0,0) ¹²
	ARIMA(1,0,0)(4,0,1) ¹²
	ARIMA(1,0,0)(4,0,2) ¹²

Model ARIMA yang diperoleh kemudian ditambahkan dengan regresi *dummy*, selanjutnya dilakukan estimasi secara simultan. Akan dilakukan pemeriksaan diagnostik yang mencakup residual memenuhi asumsi *white noise* dan berdistribusi normal. Berikut adalah cek diagnostik untuk model ARIMAX(0,0,[1,13])(3,0,0)¹². Hasil pengujian asumsi *white noise* ada pada Tabel 4.12.

Tabel 4.12 Hasil Uji *White Noise* Residual Model ARIMAX(0,0,[1,13])(3,0,0)¹² untuk *Inflow* Uang Kartal

Lag	χ^2_{hitung}	Df	p-value
6	6,72	3	0,081
12	13,58	9	0,138
18	19,72	15	0,183
24	24,56	21	0,267
30	27,74	27	0,424
36	32,36	33	0,499

Residual dikatakan *white noise* apabila statistik uji chi-square lebih kecil dari nilai $\chi^2_{0,05,df}$ atau $p\text{-value} > \alpha (0,05)$, sehingga asumsi *white noise* terpenuhi. Selanjutnya dilakukan pengujian normalitas dari residual. Untuk uji residual distribusi normal menggunakan uji Kolmogorov-Smirnov. Berdasarkan uji KS didapatkan nilai 0,104 dengan $p\text{-value} < 0,05$ yang berarti residual belum berdistribusi normal. Tidak normalnya residual ini disebabkan adanya *outlier* dalam data. Keberadaan *outlier* yang menyebabkan tidak normalnya residual model ini diatasi dengan memasukkan data *outlier* tersebut ke dalam model peramalan. Data *outlier* yang dimasukkan dalam model adalah additive 98, 97, dan 85. Setelah *outlier* dimasukan dalam model maka residual berdistribusi normal.

Tabel 4.13 Hasil Uji Normalitas Residual

Variabel	Keterangan	Statistik	
		Komogorov-Smirnov	p-value
Inflow	Sebelum penambahan <i>outlier</i>	0,104	0,010
	Sesudah penambahan <i>outlier</i>	0,058	0,150

Pada Tabel 4.14 adalah estimasi parameter ARIMAX pada *inflow* dengan penambahan ARIMA(0,0,[1,3])(3,0,0)¹² pada regresi *dummy* dengan parameter-parameter yang signifikan.

Tabel 4.14 Uji Signifikansi Parameter Model ARIMAX(0,0,[1,3])(3,0,0)¹² untuk *Inflow* Uang Kartal

Variabel	Parameter	Estimasi	Standar error	t _{hitung}	p-value
ε_{t-1}	θ_1	-0,279	0,087	-3,200	0,0018
ε_{t-13}	θ_{13}	-0,315	0,093	-3,370	0,0010
$Z_{1,t-36}$	Φ_{36}	-0,303	0,104	-2,910	0,0044
t	δ	0,009	0,001	6,760	0,0001
$M_{1,t}$	β_1	6,051	0,146	41,340	0,0001
$M_{2,t}$	β_2	5,624	0,143	39,220	0,0001
$M_{3,t}$	β_3	4,904	0,141	34,730	0,0001
$M_{4,t}$	β_4	4,864	0,142	34,300	0,0001
$M_{5,t}$	β_5	4,672	0,142	32,790	0,0001
$M_{6,t}$	β_6	4,705	0,143	32,870	0,0001
$M_{7,t}$	β_7	4,748	0,144	33,020	0,0001
$M_{8,t}$	β_8	4,795	0,148	32,330	0,0001
$M_{9,t}$	β_9	4,757	0,156	30,510	0,0001
$M_{10,t}$	β_{10}	4,923	0,161	30,590	0,0001
$M_{11,t}$	β_{11}	4,726	0,163	28,950	0,0001
$M_{12,t}$	β_{12}	4,553	0,150	30,280	0,0001
D_t	α_1	0,297	0,143	2,070	0,0406
D_{t+1}	α_3	0,489	0,146	3,340	0,0011
$K_{2,t}$	ω_1	-1,697	0,113	-15,070	0,0001

Tabel 4. 14 (Lanjutan)

AO^{98}	γ_{98}	-2,162	0,435	-4,970	0,0001
AO^{97}	γ_{97}	-3,836	0,420	-9,140	0,0001
AO^{85}	γ_{85}	1,078	0,434	2,490	0,0144

Berdasarkan Tabel 4.14 diatas diperoleh parameter-parameter model ARIMAX(0,0,[1,13])(3,0,0)¹² yang signifikan dengan taraf alfa 5%. Cek diagnostik yang sama dilakukan juga untuk semua model pada Tabel 4.10 tetapi tidak semua model memenuhi asumsi *wite noise* dan berdistribusi normal. Pada Tabel 4.15 adalah model ARIMAX yang memenuhi asumsi beserta dengan nilai sMAPE.

Tabel 4.15 Model ARIMAX *Inflow* Uang Kartal

Variabel	Model ARIMAX	sMAPE
<i>Inflow</i>	ARIMAX(0,0,1)(4,0,0) ¹²	0,5081
	ARIMAX(1,0,0)(4,0,2) ¹²	0,5510
	ARIMAX(0,0,[1,10])(3,0,0) ¹²	0,6255
	ARIMAX(0,0,[1,13])(3,0,0) ¹²	0,2209

Berdasarkan nilai sMAPE diperoleh model ARIMAX terbaik untuk data *inflow* adalah ARIMAX(0,0,[1,13])(3,0,0)¹², dengan persamaan yang hanya melibatkan parameter-parameter yang signifikan adalah.

$$\begin{aligned}
Z_{1,t}^* = & (0,009t + 6,051M_{1,t} + 5,624M_{2,t} + 4,904M_{3,t} + 4,864M_{4,t} + \\
& 4,672M_{5,t} + 4,705M_{6,t} + 4,748M_{7,t} + 4,7954M_{8,t} + 4,757M_{9,t} + \\
& 4,923M_{10,t} + 4,726M_{11,t} + 4,553M_{12,t} + 0,297D_t + 0,489D_{t+1} - \\
& 1,697K_{2t} - 2,162AO^{98} - 3,836AO^{97} + 1,078AO^{85}) + \\
& \frac{(1+0,279B+0,315B^3)}{(1+0,303B^{36})} \varepsilon_t
\end{aligned} \tag{4.5}$$

$$\begin{aligned}
Z_{1,t}^* = & -0,303Z_{1,t-36} + 0,009t + 0,002t_{t-36} + 6,051M_{1,t} + 1,833M_{1,t-36} + \\
& 5,624M_{2,t} + 1,704M_{2,t-36} + 4,904M_{3,t} + 1,485M_{3,t-36} + 4,864M_{4,t} + \\
& 1,473M_{4,t-36} + 4,672M_{5,t} + 1,415M_{5,t-36} + 4,705M_{6,t} + 1,425M_{6,t-36} + \\
& 4,748M_{7,t} + 1,438M_{7,t-36} + 4,795M_{8,t} + 1,452M_{8,t-36} + 4,757M_{9,t} + \\
& 1,441M_{9,t-36} + 4,923M_{10,t} + 1,491M_{10,t-36} + 4,726M_{11,t} + 1,431M_{11,t-36} +
\end{aligned} \tag{4.6}$$

$$\begin{aligned}
& 4,553M_{12,t} + 1,379M_{12,t-36} + 0,297D_t + 0,089D_{t-36} + 0,489D_{t+1} + \\
& 0,148D_{(t+1)-36} - 1,697K_{2,t} - 0,514K_{2,t-36} - 2,162AO^{98} - 0,655AO_{t-36}^{98} - \\
& 3,836AO^{97} - 1,162AO_{t-36}^{97} + 1,078AO^{85} + 0,326AO_{t-36}^{85} + \varepsilon_t + 0,279\varepsilon_{t-1} + \\
& 0,315\varepsilon_{t-3}
\end{aligned}$$

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


$$\hat{Z}_{1,t} = \exp(\hat{Z}_{1,t}^*)$$

4.4.2 Peramalan *Outflow* dengan ARIMAX

Peramalan *outflow* Selain menggunakan *dummy* variasi kalender D_{t-1}, D_t dan D_{t+1} juga akan dilakukan peramalan dengan menggunakan penambahan *dummy* variasi kalender berdasarkan minggu terjadinya Idul Fitri.

4.4.2.1 Peramalan Testing 12 Bulan (Tahun 2014) Sebelum Penambahan Variabel *Dummy* Mingguan.

Berikut merupakan peramalan dengan menggunakan transformasi Z^λ . Penentuan orde didasarkan pada *lag* yang signifikan terhadap plot ACF dan PACF. Berikut adalah plot ACF dan PACF dari residual pada model regresi *dummy* deret *outflow*.



Gambar 4.12 ACF dan PACF untuk Residual Regresi *Dummy* Data *Outflow* Uang Kartal

Berdasarkan ACF dan PACF residual model regresi *dummy* pada *outflow* diduga model ARIMA yang terbentuk merupakan model ARIMA musiman. Pada data *outflow* orde musiman membentuk pola *cut off after lag 12* dan *48* untuk ACF, sedangkan untuk PACF hanya pada lag 12,36, dan 48. Berdasarkan ACF dan PACF tersebut tebakan model ARIMA seperti pada Tabel 4.16.

Tabel 4.16 Model ARIMA *Outflow* Uang Kartal Berdasarkan Plot ACF dan PACF Regresi *Dummy*

Variabel	Model ARIMA
<i>Outflow</i>	ARIMA(0,0,0)(0,0,1) ¹²
	ARIMA(0,0,1)(0,0,[1,2]) ¹²
	ARIMA(0,0,1)(0,0,1) ¹²
	ARIMA(1,0,1)(3,0,1) ¹²
	ARIMA(0,0,1)(4,0,1) ¹²
	ARIMA(0,0,0)(0,0,1) ¹²
	ARIMA(3,0,1)(0,0,1) ¹²

Model ARIMA yang diperoleh kemudian ditambahkan dengan regresi *dummy*, selanjutnya dilakukan estimasi secara simultan. Akan dilakukan pemeriksaan diagnostik yang mencakup residual memenuhi asumsi *white noise* dan berdistribusi normal. Berikut adalah cek diagnostik untuk model ARIMAX (3,0,1)(0,0,1)¹². Hasil pengujian asumsi *white noise* ada pada Tabel 4.17

Tabel 4.17 Hasil Uji *White Noise* Residual Model ARIMAX(3,0,1)(0,0,1)¹² untuk *Outflow* Uang Kartal

Lag	χ^2_{hitung}	df	p-value
6	1.49	1	0,223
12	4.53	7	0,717
18	10.57	13	0,647
24	19.99	19	0,395
30	28.51	25	0,285
36	34.99	31	0,284

Residual dikatakan *white noise* apabila statistik uji *chi-square* lebih kecil dari nilai $\chi^2_{0,05;df}$ atau *p-value* > α (0,05), dari Tabel 4.17 nilai *chi-square* < $\chi^2_{0,05;df}$ dan *p-value* > (0,05) sehingga asumsi *white noise* terpenuhi. Selanjutnya dilakukan pengujian normalitas dari residual. Untuk uji residual distribusi normal menggunakan uji Kolmogorov-Smirnov. Berdasarkan uji KS didapatkan nilai 0,094 dengan *p-value* < 0,05 yang berarti residual belum berdistribusi normal. Tidak normalnya residual ini disebabkan adanya *outlier* dalam data. Keberadaan *outlier* yang menyebabkan tidak normalnya residual model ini diatasi dengan memasukkan data *outlier* tersebut ke dalam model peramalan. Data *outlier* yang dimasukkan dalam model adalah additive 70, 62. Setelah *outlier* dimasukkan dalam model maka residual berdistribusi normal seperti pada Tabel 4.18.

Tabel 4.18 Hasil Uji Normalitas Residual

Variabel	Keterangan	Statistik	
		Komogorov-Smirnov	p-value
Outflow	Sebelum penambahan outlier	0,094	0,010
	Sesudah penambahan outlier	0,052	0,150

Pada Tabel 4.19 adalah estimasi parameter ARIMAX pada deret *outflow* dengan penambahan ARIMAX(3,0,1)(0,0,1)¹² pada regresi *dummy* dengan parameter-parameter yang signifikan.

Tabel 4.19 Uji Signifikansi Parameter Model ARIMAX(3,0,1)(0,0,1)¹² untuk *Outflow* Uang Kartal

Variabel	Parameter	Estimasi	Standar error	t _{hitung}	p-value
ε_{t-1}	θ_1	0,715	0,241	2,97	0,0037
ε_{t-12}	Θ_{12}	-0,473	0,093	-5,08	0,0001
$Z_{2,t-1}$	ϕ_1	1,156	0,239	4,83	0,0001
$Z_{2,t-2}$	ϕ_2	-0,608	0,157	-3,88	0,0002
$Z_{2,t-3}$	ϕ_3	0,314	0,096	3,28	0,0014
t	δ	0,005	0,001	4,24	0,0001
$M_{1,t}$	β_1	1,722	0,074	23,38	0,0001
$M_{2,t}$	β_2	1,660	0,077	21,54	0,0001
$M_{3,t}$	β_3	1,887	0,077	24,56	0,0001
$M_{4,t}$	β_4	1,979	0,077	25,77	0,0001
$M_{5,t}$	β_5	1,995	0,077	25,81	0,0001
$M_{6,t}$	β_6	2,066	0,078	26,45	0,0001
$M_{7,t}$	β_7	2,084	0,078	26,55	0,0001
$M_{8,t}$	β_8	2,060	0,078	26,28	0,0001
$M_{9,t}$	β_9	2,091	0,080	26,27	0,0001
$M_{10,t}$	β_{10}	2,082	0,080	26,03	0,0001
$M_{11,t}$	β_{11}	2,177	0,082	26,60	0,0001
$M_{12,t}$	β_{12}	2,559	0,079	32,30	0,0001
D_{t+1}	α_3	-0,099	0,042	-2,35	0,0205

Tabel 4. 19 (Lanjutan)

$K_{2,t}$	ω_1	-0,292	0,070	-4,17	0,0001
$tK_{2,t}$	ω_3	-0,272	0,111	-2,46	0,0156
AO^{70}	γ_{70}	-0,433	0,105	-4,13	0,0001
AO^{62}	γ_{62}	-0,425	0,106	-4,00	0,0001

Berdasarkan Tabel 4.19 diperoleh parameter-parameter model ARIMAX (3,0,1)(0,0,1)¹² yang signifikan dengan taraf alfa 5%. Cek diagnostik yang sama dilakukan juga untuk semua model pada Tabel 4.15 tetapi tidak semua model memenuhi asumsi *wite noise* dan berdistribusi normal. Pada Tabel 4.20 adalah model-model ARIMAX yang memenuhi asumsi beserta dengan nilai sMAPE.

Tabel 4.20 Model ARIMAX *Outflow* Uang Kartal

Variabel	Model ARIMAX	sMAPE
<i>Outflow</i>	ARIMAX(3,0,1)(0,0,1) ¹²	0,3042
	ARIMAX(0,0,1)(0,0,[1,2]) ¹²	0,3110
	ARIMAX(0,0,1)(0,0,1) ¹²	0,3140
	ARIMAX(0,0,1)(4,0,1) ¹²	0,3067
	ARIMAX(0,0,1)(1,0,0) ¹²	0,3056

Berdasarkan nilai sMAPE diperoleh model ARIMAX terbaik untuk data *outflow* adalah model ARIMAX(3,0,1)(0,0,1)¹², dengan persamaan yang hanya melibatkan parameter-parameter yang signifikan adalah

$$\begin{aligned}
Z_{2,t}^* = & 0,005t + 1,722M_{1,t} + 1,660M_{2,t} + 1,887M_{3,t} + 1,979M_{4,t} + \\
& 1,995M_{5,t} + 2,066M_{6,t} + 2,084M_{7,t} + 2,060M_{8,t} + 2,091M_{9,t} + \\
& 2,082M_{10,t} + 2,177M_{11,t} + 2,559M_{12,t} - 0,099D_{t+1} - 0,292K_{2t} - \\
& 0,272tK_{2t} - 0,433AO^{61} - 0,425AO^{A70} + \frac{(1-0,715B)(1+0,473B^{12})}{(1-1,156B+0,608B^2-0,314B^3)} \varepsilon_t
\end{aligned} \tag{4.7}$$

$$\begin{aligned}
Z_{2,t}^* = & 1,156Z_{2,t-1} - 0,608Z_{2,t-2} + 0,314Z_{2,t-3} + 0,005t - 0,006(t-1) + \\
& 0,003(t-2) - 0,001(t-3) + 1,722M_{1,t} - 1,991M_{1,t-1} + 1,046M_{1,t-2} - \\
& 0,540M_{1,t-3} + 1,660M_{2,t} - 1,918M_{2,t-1} + 1,009M_{2,t-2} - 0,521M_{2,t-3} + \\
& 0,887M_{3,t} - 2,181M_{3,t-1} + 1,147M_{3,t-2} - 0,592M_{3,t-3} + 1,979M_{4,t} - \\
& 2,287M_{4,t-1} + 1203M_{4,t-2} - 0,621M_{4,t-3} + 1,995M_{5,t} - 2,306M_{5,t-1} + \\
& 1,212M_{5,t-2} - 0,626M_{5,t-3} + 2,066M_{6,t} - 2,388M_{6,t-1} + 1,256M_{6,t-2} - \\
& 0,648M_{6,t-3} + 2,084M_{7,t} - 2,409M_{7,t-1} + 1,267M_{7,t-2} - 0,654M_{7,t-3} +
\end{aligned} \tag{4.8}$$

$$\begin{aligned}
& 2,060M_{8,t} - 2,381M_{8,t-1} + 1,252M_{8,t-2} - 0,646M_{8,t-3} + 2,091M_{9,t} - \\
& 2,417M_{9,t-1} + 1,271M_{9,t-2} - 0,656M_{9,t-3} + 2,082M_{10,t} - 2,406M_{10,t-1} + \\
& 1,265M_{10,t-2} - 0,653M_{10,t-3} + 2,177M_{11,t} - 2,516M_{11,t-1} + 1,323M_{11,t-2} - \\
& 0,683M_{11,t-3} + 2,559M_{12,t} - 2,958M_{12,t-1} + 1,555M_{12,t-2} - 0,803M_{12,t-3} - \\
& 0,099D_{t+1} + 0,114D_{(t+1)-1} - 0,060D_{(t+1)-2} + 0,031D_{(t+1)-3} - 0,292K_{2,t} + \\
& 0,337K_{2,t-1} - 0,177K_{2,t-2} + 0,091K_{2,t-3} - 0,272tK_{2,t} + 0,314tK_{2,t-1} - \\
& 0,165tK_{2,t-2} + 0,085tK_{2,t-3} - 0,433AO_t^{70} + 0,501AO_{t-1}^{70} - 0,263AO_{t-2}^{70} + \\
& 0,135AO_{t-3}^{70} - 0,425AO_t^{62} + 0,491AO_{t-1}^{62} - 0,258AO_{t-2}^{62} + 0,133AO_{t-3}^{62} + \\
& \varepsilon_t + 0,473\varepsilon_{t-12} - 0,715\varepsilon_{t-1} - 0,338\varepsilon_{t-13}
\end{aligned}$$

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

$$\hat{Z}_{2,t} = (\hat{Z}_{2,t}^*)^{(1/0.1329999)}$$

Peramalan *outflow* dilakukan juga dengan menggunakan data transformasi *ln*. Dengan tahapan yang sama seperti diatas, diperoleh model terbaik yaitu ARIMAX ([10],0,1)(1,0,0)¹². Berikut adalah cek diagnostik untuk model ARIMAX([10],0,1)(1,0,0)¹².

Tabel 4.21 Hasil Uji *White Noise Residual Model* ARIMAX([10],0,1)(1,0,0)¹² untuk *Outflow* Uang Kartal

<i>Lag</i>	χ^2_{hitung}	<i>df</i>	<i>p-value</i>
6	2,19	3	0,5341
12	4,93	9	0,8404
18	11,87	15	0,6891
24	24,89	21	0,2519
30	27,31	27	0,4472
36	35,65	33	0,3449

Residual dikatakan *white noise* apabila statistik uji *chi-square* lebih kecil dari nilai $\chi^2_{0.05;df}$ atau *p-value* > α (0,05), dari Tabel 4.21 nilai *chi-square* < $\chi^2_{0.05;df}$ dan *p-value* > (0,05) sehingga asumsi *white noise* terpenuhi. Selanjutnya dilakukan pengujian normalitas dari residual. Untuk uji residual distribusi normal menggunakan uji Kolmogorov-Smirnov. Berdasarkan uji KS didapatkan nilai 0,139 dengan *p-value* < 0,05 yang berarti residual belum berdistribusi normal. Tidak normalnya residual ini disebabkan adanya *outlier* dalam data. Keberadaan *outlier* yang menyebabkan tidak normalnya residual model ini diatasi dengan

memasukkan data *outlier* tersebut ke dalam model peramalan. Data *outlier* yang dimasukkan dalam model adalah additive 73, 62, 70, 110. Setelah *outlier* dimasukkan dalam model maka residual berdistribusi normal seperti pada Tabel 4.22.

Tabel 4.22 Hasil Uji Normalitas Residual

Variabel	Keterangan	Statistik	
		Komogorov-Smirnov	p-value
Outflow	Sebelum penambahan outlier	0,139	0,010
	Sesudah penambahan outlier	0,075	0,061

Pada Tabel 4.23 adalah estimasi parameter ARIMAX pada deret *outflow* dengan penambahan ARIMAX([10],0,1)(1,0,0)¹² pada regresi *dummy* dengan parameter-parameter yang signifikan.

Tabel 4.23 Uji Signifikansi Parameter Model ARIMAX([10],0,1)(1,0,0)¹² untuk *Outflow* Uang Kartal

Variabel	Parameter	Estimasi	Standar error	t _{hitung}	p-value
ε_{t-1}	θ_1	-0,454	0,091	-5,00	0,0001
$Z_{2,t-10}$	ϕ_{10}	-0,236	0,097	-2,44	0,0164
$Z_{2,t-12}$	Φ_{12}	0,555	0,085	6,50	0,0001
t	δ	0,009	0,002	4,72	0,0001
$M_{1,t}$	β_1	4,533	0,295	15,37	0,0001
$M_{2,t}$	β_2	4,017	0,311	12,93	0,0001
$M_{3,t}$	β_3	4,848	0,308	15,72	0,0001
$M_{4,t}$	β_4	5,226	0,308	16,94	0,0001
$M_{5,t}$	β_5	5,376	0,308	17,43	0,0001
$M_{6,t}$	β_6	5,594	0,310	18,06	0,0001
$M_{7,t}$	β_7	5,616	0,310	18,11	0,0001
$M_{8,t}$	β_8	5,532	0,311	17,78	0,0001
$M_{9,t}$	β_9	5,594	0,312	17,94	0,0001
$M_{10,t}$	β_{10}	5,631	0,315	17,90	0,0001
$M_{11,t}$	β_{11}	5,890	0,316	18,63	0,0001

Tabel 4.23 (Lanjutan)

$M_{12,t}$	β_{12}	7,043	0,300	23,46	0,0001
$K_{2,t}$	ω_1	-0,735	0,129	-5,70	0,0001
AO^{73}	γ_{73}	-2,449	0,363	-6,74	0,0001
AO^{62}	γ_{62}	-1,966	0,355	-5,53	0,0001
AO^{70}	γ_{70}	-1,764	0,350	-5,04	0,0001
AO^{110}	γ_{110}	1,042	0,352	2,96	0,0038

Berdasarkan Tabel 4.23 diperoleh parameter-parameter model ARIMAX([10],0,1)(1,0,0)¹² yang signifikan pada taraf alfa 5% dan dengan nilai sMAPE sebesar 0,310. Diperoleh persamaan yang hanya melibatkan parameter-parameter yang signifikan adalah

$$Z_{2,t}^* = 0,009t + 4,532M_{1,t} + 4,017M_{2,t} + 4,848M_{3,t} + 5,226M_{4,t} + 5,375M_{5,t} + 5,594M_{6,t} + 5,615M_{7,t} + 5,531M_{8,t} + 5,594M_{9,t} + 5,631M_{10,t} + 5,890M_{11,t} + 7,042M_{12,t} - 0,734K_{2,t} - 2,448AO^{73} - 1,965AO^{62} - 1,763AO^{70} + 1,041AO^{110} + \frac{(1 + 0,454B)}{(1 + 0,235B^{10} - 0,555B^{12} - 0,130B^{22})} \varepsilon_t \quad (4.9)$$

$$Z_{2,t}^* = -0,235Z_{2,t-10} + 0,555Z_{2,t-12} + 0,130Z_{2,t-22} + 0,009t + 0,002(t-10) - 0,005(t-12) - 0,001(t-22) + 4,533M_{1,t} + 1,065M_{1,t-10} - 2,515M_{1,t-12} - 0,589M_{1,t-22} + 4,017M_{2,t} + 0,943M_{2,t-10} - 2,229M_{2,t-12} - 0,522M_{2,t-22} + 4,848M_{3,t} + 1,139M_{3,t-10} - 2,690M_{3,t-12} - 0,630M_{3,t-22} + 5,226M_{4,t} + 1,228M_{4,t-10} - 2,00M_{4,t-12} - 0,679M_{4,t-22} + 5,376M_{5,t} + 1,263M_{5,t-10} - 2,983M_{5,t-12} - 0,698M_{5,t-22} + 5,594M_{6,t} + 1,314M_{6,t-10} - 3,104M_{6,t-12} - 0,727M_{6,t-22} + 5,616M_{7,t} + 1,319M_{7,t-10} - 3,116M_{7,t-12} - 0,730M_{7,t-22} + 5,532M_{8,t} + 1,300M_{8,t-10} - 3,070M_{8,t-12} - 0,719M_{8,t-22} + 5,594M_{9,t} + 1,314M_{9,t-10} - 3,104M_{9,t-12} - 0,727M_{9,t-22} + 5,631M_{10,t} + 1,323M_{10,t-10} - 3,125M_{10,t-12} - 0,732M_{10,t-22} + 5,890M_{11,t} + 1,384M_{11,t-10} - 3,268M_{11,t-12} - 0,765M_{11,t-22} + 7,043M_{12,t} + 1,655M_{12,t-10} - 3,908M_{12,t-12} - 0,915M_{12,t-22} - 0,735K_{2,t} - 0,172K_{2,t-10} + 0,407K_{2,t-12} + 0,095K_{2,t-22} - 2,449AO_t^{73} - 0,575AO_{t-10}^{73} + 1,359AO_{t-12}^{73} + 0,318AO_{t-22}^{73} - 1,966AO_t^{62} - 0,462AO_{t-10}^{62} + 1,091AO_{t-12}^{62} + 0,255AO_{t-22}^{62} - 1,764AO_t^{70} - 0,414AO_{t-10}^{70} + 0,979AO_{t-12}^{70} + 0,229AO_{t-22}^{70} + 1,042AO_t^{110} + 0,244AO_{t-10}^{110} - 0,578AO_{t-12}^{110} - 0,135AO_{t-22}^{110} + 0,454\varepsilon_{t-1} + \varepsilon_t \quad (4.10)$$

Nilai ramalan yang telah diperoleh akan dikembalikan ke data asli dengan menggunakan rumus $\hat{Z}_{2,t} = \exp(\hat{Z}_{2,t}^*)$. Hasil ramalan dengan menggunakan transformasi \ln memberikan nilai sMAPE sebesar 0,31, sehingga dapat dikatakan berdasarkan kriteria sMAPE pada *out-sample* diperoleh bahwa peramalan dengan menggunakan transformasi Z^λ memberikan hasil yang lebih baik dengan sMAPE sebesar 0,30, maka untuk analisis selanjutnya transformasi yang digunakan adalah transformasi Z^λ .

4.4.2.2 Peramalan Testing 12 Bulan (Tahun 2014) Dengan Penambahan Variabel *Dummy* Mingguan.

Dengan menggunakan model ARIMAX (3,0,1)(0,0,1)¹² akan dilakukan pemeriksaan diagnostik yang mencakup residual memenuhi asumsi *white noise* dan berdistribusi normal. Hasil pengujian asumsi *white noise* pada tabel berikut.

Tabel 4.24 Hasil Uji *White Noise* Residual Model ARIMAX(3,0,1)(0,0,1)¹²

<i>Lag</i>	χ^2_{hitung}	<i>df</i>	<i>p-value</i>
6	0,55	1	0,458
12	0,63	7	0,999
18	6,21	13	0,938
24	13,26	19	0,825
30	22,03	25	0,634
36	36,09	31	0,243

Residual dikatakan *white noise* apabila statistik uji *chi-square* lebih kecil dari nilai $\chi^2_{0,05,df}$ atau *p-value* > α (0,05), dari Tabel 4.24 nilai *chi-square* < $\chi^2_{0,05,df}$ dan *p-value* > (0,05) sehingga asumsi *white noise* terpenuhi. Selanjutnya pengujian distribusi normal. Berdasarkan uji KS didapatkan nilai 0,094 dengan *p-value* < 0,05 yang berarti residual belum berdistribusi normal. Kemudian data additive 73 yang dideteksi sebagai *outlier* dimasukkan kedalam model. Setelah *outlier* dimasukkan dalam model maka residual berdistribusi normal, seperti pada Tabel 4.25.

Tabel 4.25 Hasil Uji Normalitas Residual

Variabel	Keterangan	Statistik <i>Komogorov-Smirnov</i>	<i>p-value</i>
<i>Outflow</i>	Sebelum penambahan outlier	0,104	0,010
	Sesudah penambahan outlier	0,036	0,150

Estimasi parameter-parameter yang signifikan dapat dilihat pada tabel 4.26 berikut.

Tabel 4.26 Uji Signifikansi Parameter Model ARIMAX(3,0,1)(0,0,1)¹² dengan Penambahan *Dummy* Variasi Kalender Mingguan.

Variabel	Parameter	Estimasi	Standar error	t _{hitung}	p-value
ε_{t-1}	θ_1	0,708	0,217	3,26	0,0015
ε_{t-12}	Θ_{12}	-0,672	0,089	-7,54	0,0001
$Z_{2,t-1}$	ϕ_1	1,043	0,217	4,81	0,0001
$Z_{2,t-2}$	ϕ_2	-0,463	0,141	-3,29	0,0014
$Z_{2,t-3}$	ϕ_3	0,289	0,096	3,00	0,0034
t	δ	0,003	0,001	3,80	0,0002
$M_{1,t}$	β_1	1,788	0,072	24,70	0,0001
$M_{2,t}$	β_2	1,674	0,074	22,57	0,0001
$M_{3,t}$	β_3	1,915	0,074	25,91	0,0001
$M_{4,t}$	β_4	2,009	0,074	27,21	0,0001
$M_{5,t}$	β_5	2,016	0,074	27,12	0,0001
$M_{6,t}$	β_6	2,084	0,075	27,80	0,0001
$M_{7,t}$	β_7	2,118	0,075	28,14	0,0001
$M_{8,t}$	β_8	2,087	0,075	27,85	0,0001
$M_{9,t}$	β_9	2,116	0,076	27,89	0,0001
$M_{10,t}$	β_{10}	2,055	0,076	27,12	0,0001
$M_{11,t}$	β_{11}	2,200	0,077	28,63	0,0001
$M_{12,t}$	β_{12}	2,573	0,076	34,07	0,0001
D_{t+1}	α_3	-0,132	0,042	-3,15	0,0021
$D_{1,t-1}$	ν_1	0,173	0,060	2,88	0,0049
$D_{1,t+1}$	ν_3	0,169	0,064	2,63	0,0097
$K_{2,t}$	ω_1	-0,534	0,131	-4,09	0,0001
$tK_{2,t}$	ω_2	0,005	0,002	2,99	0,0035
AO^{73}	γ_{73}	-0,449	0,096	-4,70	0,0001
AO^{62}	γ_{62}	-0,272	0,090	-3,03	0,003

Berdasarkan Tabel 4.26 diperoleh parameter-parameter model ARIMAX (3,0,1)(0,0,1)₁₂ yang signifikan dengan taraf alfa 5%, dengan model sebagai berikut.

$$\begin{aligned}
Z_{2,t}^* = & 0,003t + 1,788M_{1,t} + 1,674M_{2,t} + 1,915M_{3,t} + 2,009M_{4,t} + \\
& 2,016M_{5,t} + 2,084M_{6,t} + 2,118M_{7,t} + 2,087M_{8,t} + 2,116M_{9,t} + \\
& 2,055M_{10,t} + 2,200M_{11,t} + 2,573M_{12,t} - 0,132D_{t+1} + 0,173D_{1,t-1} + \quad (4.11) \\
& 169D_{1,t+1} - 0,534K_{2,t} + 0,005tK_{2,t} - 0,449AO^{73} - 0,272AO^{62} + \\
& \frac{(1 - 0,708B)(1 + 0,672B^{12})}{(1 - 1,043B + 0,463B^2 - 0,289B^3)} \varepsilon_t
\end{aligned}$$

$$\begin{aligned}
Z_{2,t}^* = & 1,043Z_{2,t-1} - 0,463Z_{2,t-2} + 0,288Z_{2,t-3} + 0,003t - 0,003(t-1) + 0,001(t-2) - \\
& 0,0001(t-3) + 1,788M_{1,t} - 1,865M_{1,t-1} + 0,827M_{1,t-2} - 0,516M_{1,t-3} + \\
& 1,673M_{2,t} - 1,747M_{2,t-1} + 0,774M_{2,t-2} - 0,483M_{2,t-3} + 1,915M_{3,t} - \\
& 1,997M_{3,t-1} + 0,886M_{3,t-2} - 0,553M_{3,t-3} + 2,008M_{4,t} - 2,095M_{4,t-1} + \\
& 0,929M_{4,t-2} - 0,580M_{4,t-3} + 2,016M_{5,t} - 2,103M_{5,t-1} + 0,933M_{5,t-2} - \\
& 0,582M_{5,t-3} + 2,083M_{6,t} - 2,173M_{6,t-1} + 0,964M_{6,t-2} - 0,602M_{6,t-3} + \\
& 2,117M_{7,t} - 2,208M_{7,t-1} + 0,980M_{7,t-2} - 0,611M_{7,t-3} + 2,086M_{8,t} - \quad (4.12) \\
& 2,176M_{8,t-1} + 0,965M_{8,t-2} - 0,602M_{8,t-3} + 2,116M_{9,t} - 2,207M_{9,t-1} + \\
& 0,979M_{9,t-2} - 0,611M_{9,t-3} + 2,055M_{10,t} - 2,143M_{10,t-1} + 0,951M_{10,t-2} - \\
& 0,593M_{10,t-3} + 2,199M_{11,t} - 2,294M_{11,t-1} + 1,018M_{11,t-2} - 0,635M_{11,t-3} + \\
& 2,573M_{12,t} - 2,683M_{12,t-1} + 1,190M_{12,t-2} - 0,742M_{12,t-3} - 0,132D_{t+1} + \\
& 0,137D_{(t+1)-1} - 0,061D_{(t+1)-2} + 0,038D_{(t+1)-2} + 0,173D_{1,t-1} - 0,181D_{1,(t-1)-1} + \\
& 0,080D_{1,(t-1)-2} - 0,05D_{1,(t-1)-3} + 0,168D_{1,t+1} - 0,176D_{1,(t+1)-1} + 0,078D_{1,(t+1)-2} - \\
& 0,048D_{1,(t+1)-3} - 0,534K_{2,t} + 0,557K_{2,t-1} - 0,247K_{2,t-2} + 0,154K_{2,t-3} + \\
& 0,005tK_{2,t} - 0,005tK_{2,t-1} + 0,002tK_{2,t-2} - 0,001tK_{2,t-3} - 0,449AO_t^{73} + \\
& 0,468AO_{t-1}^{73} - 0,207AO_{t-2}^{73} + 0,129AO_{t-3}^{73} - 0,271AO^{62} + 0,283AO_{t-1}^{62} - \\
& 0,125AO_{t-2}^{62} + 0,078AO_{t-3}^{62} + \varepsilon_t - 0,708\varepsilon_{t-1} + 0,672\varepsilon_{t-2} - 0,4764\varepsilon_{t-3}
\end{aligned}$$

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

$$\hat{Z}_{2,t} = (\hat{Z}_{2,t}^*)^{(1/0.1329999)}$$

Dari semua parameter yang signifikan pada Tabel 4.19 salah satu parameter yang signifikan adalah variabel *dummy* satu bulan sesudah terjadinya Idul Fitri D_{t+1} , hasil estimasi yang diperoleh bernilai negatif, dimana hal ini

diakibatkan karena penurunan akan permintaan uang terjadi signifikan setelah perayaan Idul Fitri pada beberapa tahun (Gambar 4.3). Untuk memperjelas dugaan tersebut maka dilakukan peramalan dengan menambahkan variabel *dummy* berdasarkan minggu terjadinya Idul Fitri. Hasil yang diperoleh pada Tabel 4.26 menunjukkan bahwa D_{t+1} tetap signifikan terhadap deret *outflow* dengan hasil estimasi bernilai negatif. Dari model persamaan (4.8) dan (4.12) akan digunakan untuk meramalkan 36 bulan kedepan yaitu tahun 2015 sampai 2017.

4.4.2.3 Peramalan 36 Bulan (2015 sampai 2017)

Berikut adalah perhitungan manual untuk peramalan bulan Januari 2015 dengan menggunakan persamaan (4.8) dan (4.12). Sebelum penambahan variabel *dummy* mingguan, berdasarkan persamaan (4.8).

$$\begin{aligned}
 Z_{2,t}^* = & 1,156(2,98521) - 0,608(2,57364) + 0,314(2,54831) + \\
 & 0,005(145) - 0,006(144) + 0,003(143) - 0,001(142) + \\
 & 1,722(1) - 1,991(0) + 1,046(0) - 0,540(0) + 1,660(0) - \\
 & 1,918(0) + 1,009(0) - 0,521(0) + 0,887(0) - 2,181(0) + \\
 & 1,147(0) - 0,592(0) + 1,979(0) - 2,287(0) + 1,203(0) - \\
 & 0,621(0) + 1,995(0) - 2,306(0) + 1,212(0) - 0,626(0) + \\
 & 2,066(0) - 2,388(0) + 1,256(0) - 0,648(0) + 2,084(0) - \\
 & 2,409(0) + 1,267(0) - 0,654(0) + 2,060(0) - 2,381(0) + \\
 & 1,252(0) - 0,646(0) + 2,091(0) - 2,417(0) + 1,271(0) - \\
 & 0,656(0) + 2,082(0) - 2,406(0) + 1,265(0) - 0,653(1) + \\
 & 2,177(0) - 2,516(0) + 1,323(1) - 0,683(0) + 2,559(0) - \\
 & 2,958(1) + 1,555(0) - 0,803(0) - 0,099(0) + 0,114(0) - \\
 & 0,060(0) + 0,031(0) - 0,292(0) + 0,337(0) - 0,177(0) + \\
 & 0,091(0) - 0,272(0) + 0,314(0) - 0,165(0) + 0,085(0) - \\
 & 0,433AO_t^{70} + 0,501AO_{t-1}^{70} - 0,263AO_{t-2}^{70} + 0,135AO_{t-3}^{70} - \\
 & 0,425AO_t^{62} + 0,491AO_{t-1}^{62} - 0,258AO_{t-2}^{62} + 0,133AO_{t-3}^{62} + 0 - \\
 & 0,715(-0,05349) + 0,473(-0,07309) - 0,338(0,042876)
 \end{aligned} \tag{4.13}$$

$$\hat{Z}_{2,t}^* = 2,06605$$

$$\hat{Z}_{2,t} = 234,1466$$

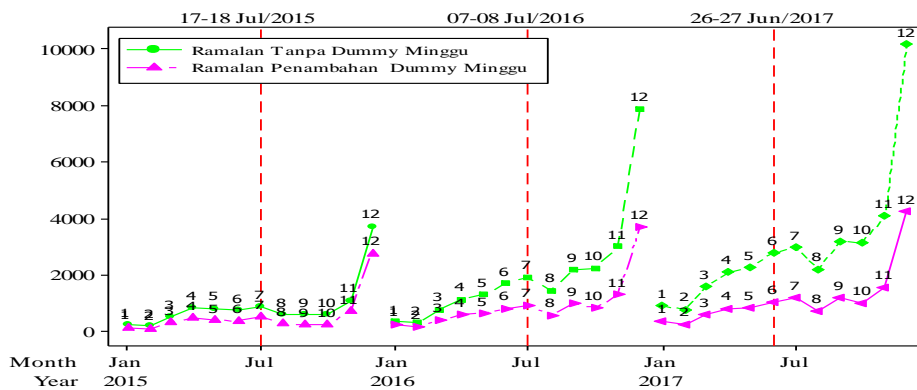
Dengan penambahan variabel *dummy* mingguan, berdasarkan persamaan (4.12).

$$\begin{aligned}
 Z_{2,t}^* = & 1,043(298522) - 0,463(2,57365) + 0,288(2,54831) + 0,003(145) - \\
 & 0,003(144) + 0,001(143) - 0,0001(142) + 1,788(1) - 1,865(0) + \\
 & 0,827(0) - 0,516(0) + 1,673(0) - 1,747(0) + 0,774(0) - 0,483(0) + \\
 & 1,915(0) - 1,997(0) + 0,886(0) - 0,553(0) + 2,008(0) - 2,095(0) + \\
 & 0,929(0) - 0,580(0) + 2,016(0) - 2,103(0) + 0,933(0) - 0,582(0) + \\
 & 2,083(0) - 2,173(0) + 0,964(0) - 0,602(0) + 2,117(0) - 2,208(0) + \\
 & 0,980(0) - 0,611(0) + 2,086(0) - 2,176(0) + 0,965(0) - 0,602(0) + \\
 & 2,116(0) - 2,207(0) + 0,979(0) - 0,611(0) + 2,055(0) - 2,143(0) + \\
 & 0,951(0) - 0,593(1) + 2,199(0) - 2,294(0) + 1,018(1) - 0,635(0) + \\
 & 2,573(0) - 2,683(1) + 1,190(0) - 0,742(0) - 0,132(0) + 0,137(0) - \\
 & 0,061(0) + 0,038(0) + 0,173(0) - 0,181(0) + 0,080(0) - 0,05(0) + \\
 & 0,168(0) - 0,176(0) + 0,078(0) - 0,048(0) - 0,534(0) + 0,557(0) - \\
 & 0,247(0) + 0,154(0) + 0,005(0) - 0,005(0) + 0,002(0) - 0,001(0) - \\
 & 0,449(0) + 0,468(0) - 0,207(0) + 0,129(0) - 0,271(0) + 0,283(0) - \\
 & 0,125(0) + 0,078(0) + 0 - 0,708(0,073296) + 0,672(-0,134252) - \\
 & 0,4764(-0,077040)
 \end{aligned}
 \tag{4.14}$$

$$\hat{Z}_{2,t}^* = 1,945733$$

$$\hat{Z}_{2,t} = 149,1282$$

Plot hasil dari nilai ramalan yang diperoleh pada tahun 2015 sampai 2017 dapat dilihat pada Gambar 4.13



Gambar 4.13. Plot Ramalan 2015 Sampai 2017 Sebelum dan Sesudah penambahan *dummy* Variasi Kalender Berdasarkan Minggu Terjadinya Idul Fitri.

Dari hasil plot pada Gambar 4.13 terlihat bahwa hasil ramalan *outflow* dengan penambahan *dummy* variasi kalender minggu terjadinya Idul Fitri memberikan nilai ramalan yang lebih rendah. Diketahui juga bahwa bulan-bulan terjadinya kenaikan *outflow* cenderung sama. Kenaikan *outflow* tertinggi masih

terjadi pada bulan Desember, bahkan kenaikan *outflow* sudah mulai terjadi pada bulan sebelumnya yaitu November. Seperti tahun-tahun sebelumnya hari raya Idul Fitri juga masih mempengaruhi permintaan uang, hal ini mengakibatkan *outflow* mengalami kenaikan disekitaran bulan saat terjadinya Idul Fitri. Pada tahun 2015 Idul Fitri terjadi pada minggu ke-3 bulan Juli sehingga *outflow* mengalami kenaikan pada bulan Juli saat terjadinya Idul Fitri, sementara pada tahun 2016 meskipun Idul Fitri terjadi pada awal bulan tetapi kenaikan *outflow* masih pada bulan terjadinya Idul Fitri. Pada tahun 2017 Idul Fitri terjadi pada minggu ke-4 bulan Juni tetapi kenaikan *outflow* yang lebih tinggi justru terjadi pada bulan berikutnya yaitu dibulan Juli. Hasil peramalan dapat dilihat pada Tabel 4.27.

Tabel 4.27 Hasil Nilai Ramalan 36 Bulan (2015-2017)

Tanpa <i>Dummy</i> Mingguan			Penambahan <i>Dummy</i> Mingguan		
Tahun 2015	Tahun 2016	Tahun 2017	Tahun 2015	Tahun 2016	Tahun 2017
234,1466	354,0065	911,4913	149,1282	266,0847	379,2980
201,6430	320,8103	782,1140	99,4731	168,7663	259,1897
530,7451	773,1810	1584,8408	330,2112	416,4676	599,5784
829,1154	1141,2215	2102,8899	471,7351	606,4273	817,9497
817,8161	1305,8833	2255,9657	406,4448	650,0172	849,3053
761,6562	1718,8806	2793,6247	378,4924	824,5499	1055,0889
880,3857	1924,6285	2989,8028	526,8544	940,8351	1182,9563
587,4221	1449,4010	2206,5166	277,7863	583,6273	732,0337
594,8311	2196,2984	3172,9037	250,2581	990,4268	1206,2471
588,6669	2248,8054	3162,3295	241,5373	842,8160	1019,0206
1094,4551	3018,2396	4100,6387	721,3318	1323,2306	1567,6024
3722,1318	7891,7582	10168,0081	2764,9716	3691,1929	4247,3827

4.5 Peramalan *Inflow* dan *Outflow* dengan RBFN


Pada peramalan *inflow* dan *outflow* dengan RBFN digunakan tiga node pada *hidden layer*. Berdasarkan plot ACF dan PACF dari *inflow* dan *outflow* uang kartal, maka *lag* yang digunakan sebagai input pada *inflow* adalah *lag* 1($Z_{1,t-1}$), 2($Z_{2,t-1}$), dan 3($Z_{3,t-1}$).

$Z_{1,t-2}$), 12 ($Z_{1,t-12}$) dan pada *outflow* adalah lag 1 ($Z_{1,t-1}$), 3 ($Z_{1,t-3}$), 12 ($Z_{1,t-12}$). Setelah dilakukan perhitungan untuk masing-masing input diperoleh nilai sMAPE *out of sample* pada Tabel 4.28.

Tabel 4.28 Nilai sMAPE untuk setiap input

Variabel	Input	sMAPE
<i>Inflow</i>	$Z_{1,t-1}$ dan $Z_{1,t-2}$	0,65
	$Z_{1,t-1}$ dan $Z_{1,t-12}$	0,54
	$Z_{1,t-1}$, $Z_{1,t-2}$ dan $Z_{1,t-12}$	0,58
<i>Outflow</i>	$Z_{2,t-1}$, $Z_{2,t-3}$ dan $Z_{2,t-12}$	0,34

Berdasarkan nilai sMAPE diperoleh model terbaik untuk *inflow* uang kartal adalah model dengan input $Z_{1,t-1}$ dan $Z_{1,t-12}$. Gambar 4.14 adalah arsitektur RBFN berdasarkan masing-masing input pada *inflow* dan *outflow*.



Gambar 4.14 Arsitektur RBFN *Inflow*(a) dan *Outflow*(b) Uang Kartal

Berikut adalah model RBFN *inflow*.

$$F(x) = 195,69 + 1928,79\phi_1(\mathbf{x}_1 - \mathbf{c}_1) + 525,95\phi_2(\mathbf{x}_2 - \mathbf{c}_2) + 14,66\phi_3(\mathbf{x}_3 - \mathbf{c}_3) \quad (4.15)$$

dengan

$$\begin{aligned} \phi_1(\mathbf{x}_1 - \mathbf{c}_1) &= \exp \left[- \left(\frac{\|Z_{1,t-1} - c_{1,t-1}\|^2}{\sigma_{1,t-1}^2} + \frac{\|Z_{1,t-12} - c_{1,t-12}\|^2}{\sigma_{1,t-12}^2} \right) \right] \\ &= \exp \left[- \left(\frac{\|Z_{1,t-1} - 310,29\|^2}{7560,507} + \frac{\|Z_{1,t-12} - 1086,63\|^2}{8595,59} \right) \right] \end{aligned}$$

$$\begin{aligned}\phi_2(\mathbf{x}_2 - \mathbf{c}_2) &= \exp \left[- \left(\frac{\|Z_{1,t-1} - c_{2,t-1}\|^2}{\sigma_{2,t-1}^2} + \frac{\|Z_{1,t-12} - c_{2,t-12}\|^2}{\sigma_{2,t-12}^2} \right) \right] \\ &= \exp \left[- \left(\frac{\|Z_{1,t-1} - 1013,12\|^2}{159081} + \frac{\|Z_{1,t-12} - 479,39\|^2}{53564,01} \right) \right]\end{aligned}$$

$$\begin{aligned}\phi_3(\mathbf{x}_3 - \mathbf{c}_3) &= \exp \left[- \left(\frac{\|Z_{1,t-1} - c_{3,t-1}\|^2}{\sigma_{3,t-1}^2} + \frac{\|Z_{1,t-12} - c_{3,t-12}\|^2}{\sigma_{3,t-12}^2} \right) \right] \\ &= \exp \left[- \left(\frac{\|Z_{1,t-1} - 206,65\|^2}{23453,46} + \frac{\|Z_{1,t-12} - 184,50\|^2}{18827,97} \right) \right]\end{aligned}$$

Untuk *Outflow* uang kartal model yang diperoleh adalah

$$F(x) = 457,38 - 161,44\phi_1(\mathbf{x}_1 - \mathbf{c}_1) + 4412,14\phi_2(\mathbf{x}_2 - \mathbf{c}_2) - 407,71\phi_3(\mathbf{x}_3 - \mathbf{c}_3) \quad (4.16)$$

$$\begin{aligned}\phi_1(\mathbf{x}_1 - \mathbf{c}_1) &= \exp \left[- \left(\frac{\|Z_{2,t-1} - c_{1,t-1}\|^2}{\sigma_{1,t-1}^2} + \frac{\|Z_{2,t-3} - c_{1,t-3}\|^2}{\sigma_{1,t-3}^2} + \frac{\|Z_{2,t-12} - c_{1,t-12}\|^2}{\sigma_{1,t-12}^2} \right) \right] \\ &= \exp \left[- \left(\frac{\|Z_{2,t-1} - 547,148\|^2}{447179,92} + \frac{\|Z_{2,t-3} - 376,360\|^2}{77342,96} + \frac{\|Z_{2,t-12} - 385,544\|^2}{91162,94} \right) \right]\end{aligned}$$

$$\begin{aligned}\phi_2(\mathbf{x}_2 - \mathbf{c}_2) &= \exp \left[- \left(\frac{\|Z_{2,t-1} - c_{2,t-1}\|^2}{\sigma_{2,t-1}^2} + \frac{\|Z_{2,t-3} - c_{2,t-3}\|^2}{\sigma_{2,t-1}^2} + \frac{\|Z_{2,t-12} - c_{2,t-12}\|^2}{\sigma_{2,t-12}^2} \right) \right] \\ &= \exp \left[- \left(\frac{\|Z_{2,t-1} - 1119,43\|^2}{92703,03} + \frac{\|Z_{2,t-3} - 559,33\|^2}{50518,13} + \frac{\|Z_{2,t-12} - 2514,52\|^2}{1280604,21} \right) \right]\end{aligned}$$

$$\begin{aligned}\phi_3(\mathbf{x}_3 - \mathbf{c}_3) &= \exp \left[- \left(\frac{\|Z_{2,t-1} - c_{2,t-1}\|^2}{\sigma_{3,t-1}^2} + \frac{\|Z_{2,t-3} - c_{2,t-3}\|^2}{\sigma_{3,t-3}^2} + \frac{\|Z_{2,t-12} - c_{2,t-12}\|^2}{\sigma_{3,t-12}^2} \right) \right] \\ &= \exp \left[- \left(\frac{\|Z_{2,t-1} - 221,50\|^2}{75262,36} + \frac{\|Z_{2,t-3} - 2220,59\|^2}{1150273,32} + \frac{\|Z_{2,t-12} - 388,15\|^2}{92617,30} \right) \right]\end{aligned}$$

4.6 Hybrid ARIMAX-RBFN


4.6.1 Pemodelan *Inflow* dengan Model *Hybrid ARIMAX-RBFN*

Pemodelan *hybrid ARIMAX-RBFN* untuk deret *inflow* dimulai dengan pemodelan komponen linear dari deret *inflow* dengan menggunakan ARIMAX.

Bedasarkan nilai sMAPE diperoleh model terbaik adalah ARIMAX(0,0,[1,13])(3,0,0)¹², dengan persamaan pada (4.17).

$$\begin{aligned}
 Z_{1,t}^* = & -0,303Z_{1,t-36} + 0,009t + 0,002t_{t-36} + 6,051M_{1,t} + 1,833M_{1,t-36} + \\
 & 5,624M_{2,t} + 1,704M_{2,t-36} + 4,904M_{3,t} + 1,485M_{3,t-36} + 4,864M_{4,t} + \\
 & 1,473M_{4,t-36} + 4,672M_{5,t} + 1,415M_{5,t-36} + 4,705M_{6,t} + 1,425M_{6,t-36} + \\
 & 4,748M_{7,t} + 1,438M_{7,t-36} + 4,795M_{8,t} + 1,452M_{8,t-36} + 4,757M_{9,t} + \quad (4.17) \\
 & 1,441M_{9,t-36} + 4,923M_{10,t} + 1,491M_{10,t-36} + 4,726M_{11,t} + 1,431M_{11,t-36} + \\
 & 4,553M_{12,t} + 1,379M_{12,t-36} + 0,297D_t + 0,089D_{t-36} + 0,489D_{t+1} + \\
 & 0,148D_{(t+1)-36} - 1,697K_{2,t} - 0,514K_{2,t-36} - 2,162AO^{98} - 0,655AO^{98}_{t-36} - \\
 & 3,836AO^{97} - 1,162AO^{97}_{t-36} + 1,078AO^{85} + 0,326AO^{85}_{t-36} + \varepsilon_t + 0,279\varepsilon_{t-1} + \\
 & 0,315\varepsilon_{t-3}
 \end{aligned}$$

Residual yang diperoleh dari model ARIMAX yaitu $Z_{1,t} = \hat{Z}_{1,t} + e_{1,t}$, dengan residual memenuhi asumsi *white noise* dan berdistribusi normal, dengan parameter-parameter $\delta, \beta_1, \beta_2, \dots, \beta_{12}, \alpha_1, \alpha_3, \omega_1, \gamma_{98}, \gamma_{97}, \gamma_{85}$ dan model ARIMA(0,0,[1,13])(3,0,0)¹², sehingga untuk $e_{1,t-1}$ dan $e_{1,t-13}$ digunakan sebagai input. Input tersebut diperoleh berdasarkan *lag-lag* orde ARIMA pada model ARIMAX untuk target pemodelan RBFN yaitu $e_{1,t}$. Dari peramalan menghasilkan nilai sMAPE *out of sample* sebesar 0,221. Gambar 4.15 adalah arsitektur RBFN berdasarkan input pada *inflow*.



Gambar 4.15 Arsitektur RBFN *Inflow* Uang Kartal

Diperoleh model RBFN adalah

$$e_{1,t} = w_0 + w_1 \exp \left[- \left(\frac{\|Z_{1,t-1} - c_{1,t-1}\|}{\sigma_{1,t-1}} + \frac{\|Z_{1,t-13} - c_{1,t-13}\|}{\sigma_{1,t-13}} \right) \right] +$$

$$\begin{aligned}
& w_2 \exp \left[- \left(\frac{\|Z_{1,t-1} - c_{2,t-1}\|}{\sigma_{2,t-1}} + \frac{\|Z_{1,t-13} - c_{2,t-13}\|}{\sigma_{2,t-13}} \right) \right] + \\
& w_3 \exp \left[- \left(\frac{\|Z_{1,t-1} - c_{3,t-1}\|}{\sigma_{3,t-1}} + \frac{\|Z_{1,t-13} - c_{3,t-13}\|}{\sigma_{3,t-13}} \right) \right] \\
= & 2,56 + 1,29 \exp \left[- \left(\frac{\|Z_{1,t-1} + 5,46\|}{3091,67} + \frac{\|Z_{1,t-13} - 13,37\|}{3008,25} \right) \right] + \\
& 0,24 \exp \left[- \left(\frac{\|Z_{1,t-1} + 162,49\|}{29647,73} + \frac{\|Z_{1,t-13} + 180,76\|}{15529,95} \right) \right] - \\
& 0,02 \exp \left[- \left(\frac{\|Z_{1,t-1} - 144,49\|}{11535,93} + \frac{\|Z_{1,t-13} - 78,32\|}{17029,27} \right) \right]
\end{aligned}$$

Setelah mendapatkan ramalan residual menggunakan metode RBFN, langkah selanjutnya yaitu hasil yang diperoleh dijumlahkan dengan hasil ramalan ARIMAX, sehingga model *hybrid* ARIMAX-RBFN untuk data *inflow* dapat ditulis sebagai berikut

$$Y_{1,t} = \hat{Z}_{1,t} + \hat{e}_{1,t} + \eta_{1,t}$$


4.6.2 Pemodelan *Outflow* dengan Model *Hybrid* ARIMAX-RBFN

Bedasarkan nilai sMAPE diperoleh model terbaik adalah ARIMAX(3,0,1)(0,0,1)¹², dengan persamaan

$$\begin{aligned}
Z_{2,t}^* = & 1,156Z_{2,t-1} - 0,608Z_{2,t-2} + 0,314Z_{2,t-3} + 0,005t - 0,006(t-1) + \\
& 0,003(t-2) - 0,001(t-3) + 1,722M_{1,t} - 1,991M_{1,t-1} + 1,046M_{1,t-2} - \\
& 0,540M_{1,t-3} + 1,660M_{2,t} - 1,918M_{2,t-1} + 1,009M_{2,t-2} - 0,521M_{2,t-3} + \\
& 0,887M_{3,t} - 2,181M_{3,t-1} + 1,147M_{3,t-2} - 0,592M_{3,t-3} + 1,979M_{4,t} - \\
& 2,287M_{4,t-1} + 1,203M_{4,t-2} - 0,621M_{4,t-3} + 1,995M_{5,t} - 2,306M_{5,t-1} + \\
& 1,212M_{5,t-2} - 0,626M_{5,t-3} + 2,066M_{6,t} - 2,388M_{6,t-1} + 1,256M_{6,t-2} - \\
& 0,648M_{6,t-3} + 2,084M_{7,t} - 2,409M_{7,t-1} + 1,267M_{7,t-2} - 0,654M_{7,t-3} + \\
& 2,060M_{8,t} - 2,381M_{8,t-1} + 1,252M_{8,t-2} - 0,646M_{8,t-3} + 2,091M_{9,t} - \\
& 2,417M_{9,t-1} + 1,271M_{9,t-2} - 0,656M_{9,t-3} + 2,082M_{10,t} - 2,406M_{10,t-1} + \\
& 1,265M_{10,t-2} - 0,653M_{10,t-3} + 2,177M_{11,t} - 2,516M_{11,t-1} + 1,323M_{11,t-2} -
\end{aligned} \tag{4.18}$$

$$\begin{aligned}
& 0,683M_{11,t-3} + 2,559M_{12,t} - 2,958M_{12,t-1} + 1,555M_{12,t-2} - 0,803M_{12,t-3} - \\
& 0,099D_{t+1} + 0,114D_{(t+1)-1} - 0,060D_{(t+1)-2} + 0,031D_{(t+1)-3} - 0,292K_{2,t} + \\
& 0,337K_{2,t-1} - 0,177K_{2,t-2} + 0,091K_{2,t-3} - 0,272tK_{2,t} + 0,314tK_{2,t-1} - \\
& 0,165tK_{2,t-2} + 0,085tK_{2,t-3} - 0,433AO_t^{70} + 0,501AO_{t-1}^{70} - 0,263AO_{t-2}^{70} + \\
& 0,135AO_{t-3}^{70} - 0,425AO_t^{62} + 0,491AO_{t-1}^{62} - 0,258AO_{t-2}^{62} + 0,133AO_{t-3}^{62} + \\
& \varepsilon_t + 0,473\varepsilon_{t-12} - 0,715\varepsilon_{t-1} - 0,338\varepsilon_{t-13}
\end{aligned}$$

Residual yang diperoleh dari model ARIMAX yaitu $Z_{2,t} = \hat{Z}_{2,t} + e_{2,t}$, dengan residual memenuhi asumsi *white noise* dan berdistribusi normal, dengan parameter $\delta, \beta_1, \beta_2, L, \beta_{12}, \alpha_3, \omega_1, \omega_3, \gamma_{70}, \gamma_{62}$, dan ARIMA(3,0,1)(0,0,1)¹². Sehingga untuk $e_{2,t-1}, e_{2,t-2}, e_{2,t-3}$ dan $e_{2,t-12}$, digunakan sebagai input. Input tersebut diperoleh berdasarkan *lag-lag* orde ARIMA pada model ARIMAX untuk target pemodelan RBFN yaitu $e_{2,t}$. Dari peramalan menghasilkan nilai sMAPE *out of sample* sebesar 0,3049. Gambar 4.16 adalah arsitektur RBFN berdasarkan input pada *outflow*.



Gambar 4.16 Arsitektur RBFN *Outflow* Uang Kartal

Diperoleh model RBFN adalah

$$\begin{aligned}
e_{2,t} = & w_0 + w_1 \exp \left[- \left(\frac{\|Z_{2,t-1} - c_{1,t-1}\|}{\sigma_{1,t-1}} + \frac{\|Z_{2,t-2} - c_{1,t-2}\|}{\sigma_{1,t-2}} + \frac{\|Z_{2,t-3} - c_{1,t-3}\|}{\sigma_{1,t-3}} + \frac{\|Z_{2,t-12} - c_{1,t-12}\|}{\sigma_{1,t-12}} \right) \right] + \\
& w_2 \exp \left[- \left(\frac{\|Z_{2,t-1} - c_{2,t-1}\|}{\sigma_{2,t-1}} + \frac{\|Z_{2,t-2} - c_{2,t-2}\|}{\sigma_{2,t-2}} + \frac{\|Z_{2,t-3} - c_{2,t-3}\|}{\sigma_{2,t-3}} + \frac{\|Z_{2,t-13} - c_{2,t-13}\|}{\sigma_{2,t-13}} \right) \right] +
\end{aligned}$$

$$\begin{aligned}
& w_3 \exp \left[- \left(\frac{\|Z_{2,t-1} - c_{3,t-1}\|}{\sigma_{3,t-2}} + \frac{\|Z_{2,t-2} - c_{3,t-2}\|}{\sigma_{3,t-2}} + \frac{\|Z_{2,t-3} - c_{3,t-3}\|}{\sigma_{3,t-3}} + \frac{\|Z_{2,t-13} - c_{3,t-13}\|}{\sigma_{3,t-13}} \right) \right] \\
& = 3,13 + 0,11 \exp \left[- \left(\frac{\|Z_{2,t-1} - 65,69\|}{10986,96} + \frac{\|Z_{2,t-2} + 100,63\|}{29765,26} + \frac{\|Z_{2,t-3} - 605,26\|}{165963,3} + \frac{\|Z_{2,t-12} - 127,28\|}{28325,65} \right) \right] + \\
& 0,38 \exp \left[- \left(\frac{\|Z_{2,t-1} - 10,47\|}{139953,8} + \frac{\|Z_{2,t-2} + 50,17\|}{57470,32} + \frac{\|Z_{2,t-3} - 36,41\|}{56577,73} + \frac{\|Z_{2,t-13} - 759,02\|}{211435,9} \right) \right] - \\
& 0,25 \exp \left[- \left(\frac{\|Z_{2,t-1} - 4,37\|}{62165,67} + \frac{\|Z_{2,t-2} - 19,58\|}{62636,73} + \frac{\|Z_{2,t-3} + 33,7\|}{29561,28} + \frac{\|Z_{2,t-13} + 22,89\|}{27230,15} \right) \right]
\end{aligned}$$

Setelah mendapatkan ramalan residual menggunakan metode RBFN, langkah selanjutnya yaitu hasil yang diperoleh dijumlahkan dengan hasil ramalan ARIMAX. sehingga model *hybrid* ARIMAX-RBFN untuk data *outflow* dapat ditulis sebagai berikut

$$Y_{2,t} = \hat{Z}_{2,t} + \hat{e}_{2,t} + \eta_{2,t}$$

4.7 Perbandingan Akurasi Model

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, RBFN dan model *hybrid* ARIMAX-RBFN. Semakin kecil nilai sMAPE dikatakan bahwa model semakin baik. Berdasarkan kriteria *out-sample*, nilai akurasi peramalan dengan menggunakan metode sMAPE dapat dilihat pada tabel 4.31 dan 4.32. Berdasarkan nilai sAPE aditif dan kumulatif pada Tabel 4.31 maka dapat disimpulkan bahwa model terbaik untuk peramalan *inflow* uang kartal di Bank Indonesia Provinsi Papua untuk bulan 2, 5, 6 dan 9 adalah model ARIMAX, kemudian untuk bulan 3, 7 dan 8 adalah model RBFN, sisanya pada model *Hybrid*. Untuk peramalan beberapa bulan kedepan, model ARIMAX merupakan model terbaik untuk meramalkan 2, 3, 5, 6, 7, 8, 9, 10, 11, 12 bulan kedepan, model *Hybrid* untuk meramalkan 1 dan 2 bulan kedepan. Berdasarkan nilai sAPE dan sMAPE pada Tabel 4.32 maka dapat disimpulkan bahwa model terbaik untuk peramalan *inflow* uang kartal di Bank Indonesia Provinsi Papua untuk bulan 2 dan 12 adalah model ARIMAX, kemudian untuk bulan 2, 3, 5, 6, 7, 8, 9 dan 11 adalah

model RBFN, sisanya pada model *Hybrid*. Untuk peramalan beberapa bulan kedepan, model ARIMAX merupakan model terbaik untuk meramalkan 1, 3, 5, 10 dan 12 bulan kedepan, model *Hybrid* untuk meramalkan 1 dan 4 bulan kedepan, sisanya pada model RBFN.

Perbandingan peningkatan nilai akurasi ini juga dapat dilihat dari perbandingan nilai ramalan dan aktual pada Tabel 4.29 dan Tabel 4.30, serta pada Gambar 4.17 dan Gambar 4.18.

Tabel 4.29 Hasil Nilai Ramalan *Inflow* Tiap Metode

Inflow	ARIMAX	RBFN	Hybrid ARIMAX-RBFN
1800,5823	1505,2285	369,0349	1507,7834
691,5094	1031,7380	196,2834	1034,2969
321,0802	505,9309	452,6727	508,4899
435,5443	423,3927	239,5065	426,0789
339,9947	356,8801	260,7132	360,3865
372,5200	403,7920	223,2207	406,9993
227,3899	499,0968	227,5643	502,2637
870,0946	777,5127	800,3586	780,1010
391,7611	454,7283	628,0349	457,2873
446,0392	437,6415	233,4035	440,3477
397,4124	368,8168	237,8636	371,6659
499,7434	343,5044	242,0953	346,6443

Tabel 4.30 Hasil Nilai Ramalan *Outflow* Tiap Metode

Outflow	ARIMAX	RBFN	Hybrid ARIMAX-RBFN
173,9906	262,0273	457,3865	265,1529
234,3643	210,0296	252,0004	213,1569
468,8243	581,0027	404,9471	584,2314
827,0658	728,6864	650,2183	731,6467
442,0682	717,5875	574,5108	720,6891
570,1126	869,9547	623,6481	872,9491
1566,1661	1219,0338	1340,8565	1222,4030
265,4821	649,2606	456,6101	652,3130
675,7433	1121,4325	593,8677	1124,7003
1133,7867	965,4055	377,9620	968,5404
1221,3442	1425,4822	1358,9570	1428,7397
3726,0521	3750,3715	2110,1127	3753,3177


Tabel 4.31 Perbandingan Hasil Ramalan Model ARIMAX, RBFN dan Gabungan ARIMAX-RBFN dengan Data Aktual *Inflow*

t (Bulan)	Nilai Aktual	ARIMAX			Ramalan	RBFN		Gabungan ARIMAX-RBFN		
		Ramalan	Aditif (sAPE)	Kumulatif (sMAPE)		Ramalan	Aditif (sAPE)	Kumulatif (sMAPE)	Ramalan	Aditif (sAPE)
1	1800,58	1505,23	17,87%	17,87%	369,03	131,96%	131,96%	1507,78	17,70%	17,70%
2	691,51	1031,74	39,49%	28,68%	196,28	111,56%	121,76%	1034,30	39,72%	28,71%
3	321,08	505,93	44,70%	34,02%	452,67	34,01%	92,51%	508,49	45,18%	34,20%
4	435,54	423,39	2,83%	26,22%	239,51	58,08%	83,90%	426,08	2,20%	26,20%
5	339,99	356,88	4,85%	21,95%	260,71	26,40%	72,40%	360,39	5,82%	22,12%
6	372,52	403,79	8,06%	19,63%	223,22	50,12%	68,69%	407,00	8,85%	19,91%
7	227,39	499,10	74,80%	27,51%	227,56	0,08%	58,89%	502,26	75,34%	27,83%
8	870,09	777,51	11,24%	25,48%	800,36	8,35%	52,57%	780,10	10,91%	25,72%
9	391,76	454,73	14,88%	24,30%	628,03	46,34%	51,88%	457,29	15,44%	24,57%
10	446,04	437,64	1,90%	22,06%	233,40	62,59%	52,95%	440,35	1,28%	22,24%
11	397,41	368,82	7,46%	20,73%	237,86	50,23%	52,70%	371,67	6,70%	20,83%
12	499,74	343,50	37,06%	22,10%	242,10	69,46%	54,10%	346,64	36,18%	22,11%

Tabel 4.32 Perbandingan Hasil Ramalan Model ARIMAX, RBFN dan Gabungan ARIMAX-RBFN dengan Data Aktual *Outflow*

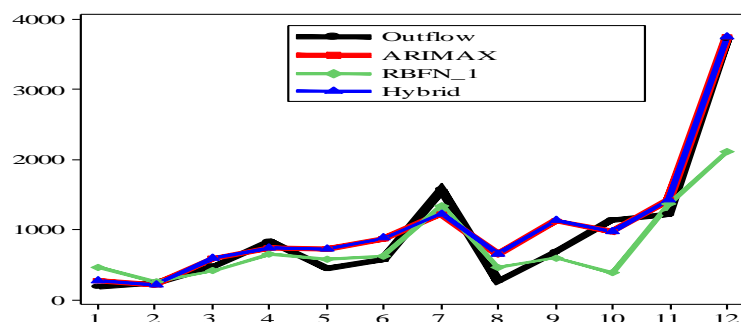
t (Bulan)	Nilai Aktual	ARIMAX			RBFN			Hybrid ARIMAX-RBFN		
		Ramalan	Aditif (sAPE)	Kumulatif (sMAPE)	Ramalan	Aditif (sAPE)	Kumulatif (sMAPE)	Ramalan	Aditif (sAPE)	Kumulatif (sMAPE)
1	173,99	262,0273037	40,38%	40,38%	457,39	89,77%	89,77%	265,15	41,52%	41,52%
2	234,36	210,0296487	10,95%	25,67%	252,00	7,25%	48,51%	213,16	9,48%	25,50%
3	468,82	581,0027219	21,37%	24,23%	404,95	14,62%	37,21%	584,23	21,92%	24,31%
4	827,07	728,6864153	12,65%	21,34%	650,22	23,94%	33,90%	731,65	12,24%	21,29%
5	442,07	717,5874533	47,52%	26,57%	574,51	26,06%	32,33%	720,69	47,92%	26,62%
6	570,11	869,9547299	41,64%	29,09%	623,65	8,97%	28,44%	872,95	41,97%	29,18%
7	1566,17	1219,033809	24,93%	28,49%	1340,86	15,50%	26,59%	1222,40	24,66%	28,53%
8	265,48	649,260575	83,91%	35,42%	456,61	52,94%	29,88%	652,31	84,30%	35,50%
9	675,74	1121,432509	49,60%	36,99%	593,87	12,90%	27,99%	1124,70	49,87%	37,10%
10	1133,79	965,4054512	16,04%	34,90%	377,96	99,99%	35,19%	968,54	15,72%	34,96%
11	1221,34	1425,482215	15,43%	33,13%	1358,96	10,67%	32,96%	1428,74	15,65%	33,20%
12	3726,05	3750,371487	0,65%	30,42%	2110,11	55,38%	34,83%	3753,32	0,73%	30,50%

Perbandingan hasil peramalan setiap bulan periode Januari-Desember 2014 untuk model *inflow* dapat dilihat pada Gambar 4.17. Metode ARIMAX dan *hybrid* ARIMAX-RBFN memberikan hasil yang serupa dalam meramal data aktual. Khusus pada bulan Januari, Agustus dan Desember model ARIMAX dan *hybrid* ARIMAX-RBFN mampu mendekati hasil aktual. Sementara di bulan Januari model RBFN memberikan hasil yang jauh dari data aktual dibandingkan pada bulan lainnya.



Gambar 4.17 Perbandingan Hasil Peramalan tiap Metode pada Model *Inflow*

Perbandingan hasil peramalan setiap bulan periode Januari-Desember 2014 untuk model *outflow* dapat dilihat pada Gambar 4.18. Metode ARIMAX dan *hybrid* ARIMAX-RBFN memberikan hasil yang serupa dalam meramal data aktual. Perbedaan prediksi yang agak jauh dari metode RBFN terjadi pada bulan Oktober dan Desember, sementara pada bulan lainnya menghasilkan nilai peramalan yang mirip dengan kedua metode lainnya. Namun, secara keseluruhan pola pergerakan *outflow* dapat dikatakan sudah mengikuti data aktual.



Gambar 4.18 Perbandingan Hasil Peramalan Tiap Metode pada Model *Outflow*

LAMPIRAN

Lampiran A

Lampiran 1 : Syntax SAS Uji *Augmented Dickey Fuller Inflow*

```

data bi;
input inflow;
datalines;
5.60010
4.77196
4.79835
4.81360
4.72503
.
.
.
.
5.99344
;
proc arima data=bi;
identify var=inflow stationarity=(adf=(12));
run;
    
```

Lampiran 2 : Output SAS Uji *Augmented Dickey Fuller Inflow*

Augmented Dickey-Fuller Unit Root Tests



Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	12	0.1020	0.7049	0.21	0.7456		
Single Mean	12	-3.1473	0.6344	-0.93	0.7752	0.50	0.9512
Trend	12	-3.3857	0.9173	-1.07	0.9297	1.19	0.9383



Lampiran 3 : Output SAS Uji *Augmented Dickey Fuller Outflow*

Augmented Dickey-Fuller Unit Root Tests


Type	Lags	Rho	Pr < Rho	Tau	Pr < Tau	F	Pr > F
Zero Mean	12	0.1786	0.7232	1.55	0.9700		
Single Mean	12	0.5439	0.9776	0.33	0.9791	1.22	0.7603
Trend	12	-1.2894	0.9835	-0.61	0.9765	1.24	0.9296

Lampiran 4 : Plot ACF dan PACF Data *Inflow* dan *Outflow*





Lampiran 5 : Plot Box-Cox *Inflow* dan *Outflow*



Lampiran 6 : Syntax SAS Regresi *Dummy Inflow*

```
data bi;
input inflow inflowtrans t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 Dtm1 Dt Dtp1 K2t tK2t K3t tK3t
;
datalines;
270.452217083 5.60010 1 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
118.150655100 4.77196 2 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
121.309709342 4.79835 3 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
.
.
.
312.759455758 5.74543 131 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 131
400.792318770 5.99344 132 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 132
* * 133 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 133
* * 134 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 134
* * 135 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 135
* * 136 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 136
* * 137 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 1 137
* * 138 0 0 0 0 0 1 0 0 0 0 0 0 0 1 0 0 0 0 1 138
* * 139 0 0 0 0 0 0 1 0 0 0 0 0 0 1 0 0 0 0 1 139
* * 140 0 0 0 0 0 0 0 1 0 0 0 0 0 0 1 0 0 1 140
* * 141 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 1 141
* * 142 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 142
* * 143 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 1 143
* * 144 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 1 144
;

/*input data outlier*/
data bi;
set bi;
if _n_>=36 then S36=1; else S36=0;
if _n_>=41 then S41=1; else S41=0;
if _n_>=47 then S47=1; else S47=0;
if _n_>=48 then S48=1; else S48=0;
run;

/*Proses Identifikasi*/
```

```

proc arima data=bi out=result1;
identify var=inflowtrans
crosscorr=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 Dtm1 Dt Dtp1 K2t tK2t K3t tK3t
A97 A98 A86 A95)
nlag=36;
run;

/*Proses Estimasi*/
estimate
input=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 Dtm1 Dt Dtp1 K2t tK2t K3t tK3t)
p=(0)(0) q=(0)(0)
noconstant;
run;

/*Pendeteksian outlier*/
outlier maxnum=132;
run;

/*uji asumsi normal*/
forecast lead=12 out=fits1;
run;

proc print data=fits1;

proc univariate data=fits1 normal;
var residual;
run;

```

Lampiran 7 : Estimasi Parameter Regresi *Dummy* untuk Deret *Inflow*

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.01842	0.0060609	3.04	0.0030	0	t	0
NUM2	5.67890	0.23051	24.64	<.0001	0	M1	0
NUM3	5.26426	0.23163	22.73	<.0001	0	M2	0
NUM4	4.76885	0.23282	20.48	<.0001	0	M3	0
NUM5	4.73210	0.23408	20.22	<.0001	0	M4	0
NUM6	4.54209	0.23540	19.30	<.0001	0	M5	0
NUM7	4.54420	0.23679	19.19	<.0001	0	M6	0
NUM8	4.61634	0.24423	18.90	<.0001	0	M7	0
NUM9	4.64916	0.25087	18.53	<.0001	0	M8	0
NUM10	4.59981	0.26353	17.45	<.0001	0	M9	0
NUM11	4.78935	0.26537	18.05	<.0001	0	M10	0
NUM12	4.55996	0.26021	17.52	<.0001	0	M11	0
NUM13	4.39495	0.25226	17.42	<.0001	0	M12	0
NUM14	-0.02475	0.21264	-0.12	0.9075	0	Dtm1	0
NUM15	0.27299	0.21564	1.27	0.2082	0	Dt	0
NUM16	0.37849	0.21264	1.78	0.0778	0	Dtp1	0
NUM17	-1.08795	0.47486	-2.29	0.0238	0	K2t	0
NUM18	-0.01602	0.0084660	-1.89	0.0610	0	tK2t	0
NUM19	-3.39996	1.08787	-3.13	0.0023	0	K3t	0
NUM20	0.02080	0.01104	1.88	0.0622	0	tK3t	0

Lampiran 8 : Cek Diagnosa Residual Model Regresi *Dummy Inflow*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	13.85	6	0.0313	0.250	-0.082	0.029	-0.072	-0.123	-0.104
12	16.66	12	0.1629	-0.050	-0.007	0.059	0.104	-0.032	-0.039
18	19.20	18	0.3795	0.089	-0.052	0.005	-0.008	0.074	-0.027
24	29.21	24	0.2125	-0.078	0.010	-0.037	-0.154	-0.084	-0.154
30	32.47	30	0.3458	-0.015	0.125	-0.042	-0.031	-0.011	-0.031
36	42.89	36	0.1997	-0.098	0.013	0.069	0.021	-0.146	-0.145

Lampiran 9 : Estimasi Parameter Regresi *Dummy* untuk Deret *Outflow*

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.0031568	0.0016922	1.87	0.0647	0	t	0
NUM2	1.72862	0.06436	26.86	<.0001	0	M1	0
NUM3	1.64459	0.06468	25.43	<.0001	0	M2	0
NUM4	1.92126	0.06501	29.55	<.0001	0	M3	0
NUM5	2.01014	0.06536	30.76	<.0001	0	M4	0
NUM6	2.02597	0.06573	30.82	<.0001	0	M5	0
NUM7	2.10917	0.06612	31.90	<.0001	0	M6	0
NUM8	2.09165	0.06829	30.63	<.0001	0	M7	0
NUM9	2.09411	0.06923	30.25	<.0001	0	M8	0
NUM10	2.09896	0.07435	28.23	<.0001	0	M9	0
NUM11	2.07947	0.07496	27.74	<.0001	0	M10	0
NUM12	2.24350	0.07451	30.11	<.0001	0	M11	0
NUM13	2.59281	0.07053	36.76	<.0001	0	M12	0
NUM14	0.07430	0.06058	1.23	0.2226	0	Dtm1	0
NUM15	-0.01769	0.06117	-0.29	0.7729	0	Dt	0
NUM16	-0.12095	0.06058	-2.00	0.0483	0	Dtp1	0
NUM17	-0.23996	0.13259	-1.81	0.0730	0	K2t	0
NUM18	-0.0000347	0.0023636	-0.01	0.9883	0	tK2t	0
NUM19	-0.42214	0.30384	-1.39	0.1675	0	K3t	0
NUM20	0.0033850	0.0030829	1.10	0.2746	0	tK3t	0

Lampiran 10 : Cek Diagnosa Residual Model Regresi *Dummy* *Outflow*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.51	6	0.2028	0.187	-0.163	-0.003	-0.033	0.000	0.016
12	40.16	12	<.0001	-0.069	-0.001	-0.074	-0.114	0.166	0.406
18	46.81	18	0.0002	0.055	-0.127	-0.017	-0.091	-0.074	-0.103
24	55.18	24	0.0003	-0.083	0.009	-0.094	-0.123	0.099	0.105
30	61.97	30	0.0005	-0.010	-0.118	-0.123	-0.068	-0.039	-0.069
36	69.96	36	0.0006	-0.118	-0.075	-0.027	-0.052	0.096	-0.111

Lampiran B

Lampiran 1 : Syntax SAS Model ARIMAX (0,0,[1,13])(3,0,0)12 untuk Deret *Inflow*

```

data bi;
input inflow inflowtrans t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 Dtm1 Dt Dtp1 K2t tK2t K3t tK3t
;
datalines;
270.452217083          5.60010  1  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0
118.150655100        4.77196  2  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0
121.309709342        4.79835  3  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0
.
.
.
312.759455758        5.74543 131 0  0  0  0  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  1 131
400.792318770        5.99344 132 0  0  0  0  0  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  1 132
*      * 133 1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 133
*      * 134 0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 134
*      * 135 0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 135
*      * 136 0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 136
*      * 137 0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 137
*      * 138 0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  1 138
*      * 139 0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  1 139
*      * 140 0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  1 140
*      * 141 0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  0  1 141
*      * 142 0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  0  1 142
*      * 143 0  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  0  1 143
*      * 144 0  0  0  0  0  0  0  0  0  0  0  1  0  0  0  0  0  0  0  0  0  0  0  1 144
;

```

```

/*input data outlier*/
data bi;
set bi;

if _n_=85 then A85=1; else A85=0;
if _n_=86 then A86=1; else A86=0;
if _n_=87 then A87=1; else A87=0;
if _n_=89 then A89=1; else A89=0;
if _n_=95 then A95=1; else A95=0;
if _n_=96 then A96=1; else A96=0;
if _n_=97 then A97=1; else A97=0;
if _n_=98 then A98=1; else A98=0;
if _n_=99 then A99=1; else A99=0;

run;

/*Proses Identifikasi*/
proc arima data=bi out=result1;
identify var=inflowtrans
crosscorr=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 Dtm1 Dt Dtp1 K2t tK2t K3t tK3t
A97 A98 A86 A95 A87 A85 A73)
nlag=36;
run;

/*Proses Estimasi*/
estimate
input=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 Dt Dtp1 K2t A98 A97 A85)
p=(0)(36) q=(1,13)(0)
noconstant;
run;

/*Pendeteksian outlier*/
outlier maxnum=132;
run;

/*uji asumsi normal*/
forecast lead=12 out=fits1;
run;

proc print data=fits1;

proc univariate data=fits1 normal;
var residual;
run;

```

Lampiran 2 : Deteksi *Outlier* Awal pada Data *Inflow*

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
97	Additive	-1.27039	22.59	<.0001
98	Additive	-0.82803	8.37	0.0038
87	Additive	-0.58569	5.18	0.0228
73	Additive	0.74603	9.35	0.0022

Lampiran 3 : Estimasi Parameter Model ARIMAX(0,0,[1,13])(3,0,0)¹² untuk Deret *Inflow*

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	-0.27943	0.08723	-3.20	0.0018	1	inflowtrans	0
MA1,2	-0.31461	0.09345	-3.37	0.0010	13	inflowtrans	0
AR1,1	-0.30280	0.10408	-2.91	0.0044	36	inflowtrans	0
NUM1	0.0088436	0.0013087	6.76	<.0001	0	t	0
NUM2	6.05070	0.14636	41.34	<.0001	0	M1	0
NUM3	5.62419	0.14340	39.22	<.0001	0	M2	0
NUM4	4.90404	0.14119	34.73	<.0001	0	M3	0

NUM5	4.86442	0.14182	34.30	<.0001	0	M4	0
NUM6	4.67244	0.14248	32.79	<.0001	0	M5	0
NUM7	4.70543	0.14316	32.87	<.0001	0	M6	0
NUM8	4.74848	0.14383	33.02	<.0001	0	M7	0
NUM9	4.79531	0.14833	32.33	<.0001	0	M8	0
NUM10	4.75704	0.15593	30.51	<.0001	0	M9	0
NUM11	4.92306	0.16095	30.59	<.0001	0	M10	0
NUM12	4.72556	0.16324	28.95	<.0001	0	M11	0
NUM13	4.55337	0.15037	30.28	<.0001	0	M12	0
NUM14	0.29654	0.14310	2.07	0.0406	0	Dt	0
NUM15	0.48855	0.14624	3.34	0.0011	0	Dtp1	0
NUM16	-1.69691	0.11263	-15.07	<.0001	0	K2t	0
NUM17	-2.16179	0.43528	-4.97	<.0001	0	A98	0
NUM18	-3.83570	0.41987	-9.14	<.0001	0	A97	0
NUM19	1.07764	0.43350	2.49	0.0144	0	A85	0

Lampiran 4 : Cek Diagnosa Residual Model ARIMAX(0,0,[1,13])(3,0,0)¹² untuk Deret *Inflow*

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.72	3	0.0814	-0.031	0.108	0.140	-0.091	-0.072	-0.055
12	13.58	9	0.1382	-0.055	-0.014	0.150	0.065	0.096	0.091
18	19.72	15	0.1828	-0.001	-0.141	-0.000	-0.109	0.060	-0.071
24	24.56	21	0.2667	-0.080	0.008	-0.028	-0.108	0.094	-0.049
30	27.74	27	0.4243	0.041	0.090	-0.007	0.019	-0.073	-0.057
36	32.36	33	0.4986	-0.137	-0.053	-0.028	-0.003	-0.059	-0.019

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.983308	Pr < W 0.1058
Kolmogorov-Smirnov	D 0.058202	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.079708	Pr > W-Sq 0.2146
Anderson-Darling	A-Sq 0.615841	Pr > A-Sq 0.1083

Lampiran 5 : Estimasi Parameter Model ARIMAX(3,0,1)(0,0,1)¹² untuk Deret *Outflow*

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	0.71460	0.24079	2.97	0.0037	1	outflowtrans	0
MA2,1	-0.47319	0.09311	-5.08	<.0001	12	outflowtrans	0
AR1,1	1.15620	0.23914	4.83	<.0001	1	outflowtrans	0
AR1,2	-0.60754	0.15677	-3.88	0.0002	2	outflowtrans	0
AR1,3	0.31440	0.09595	3.28	0.0014	3	outflowtrans	0
NUM1	0.0050173	0.0011843	4.24	<.0001	0	t	0
NUM2	1.72206	0.07366	23.38	<.0001	0	M1	0
NUM3	1.65985	0.07706	21.54	<.0001	0	M2	0
NUM4	1.88735	0.07686	24.56	<.0001	0	M3	0
NUM5	1.97892	0.07678	25.77	<.0001	0	M4	0
NUM6	1.99503	0.07730	25.81	<.0001	0	M5	0
NUM7	2.06631	0.07811	26.45	<.0001	0	M6	0
NUM8	2.08365	0.07848	26.55	<.0001	0	M7	0
NUM9	2.05963	0.07838	26.28	<.0001	0	M8	0
NUM10	2.09059	0.07959	26.27	<.0001	0	M9	0
NUM11	2.08182	0.07999	26.03	<.0001	0	M10	0
NUM12	2.17736	0.08186	26.60	<.0001	0	M11	0
NUM13	2.55861	0.07922	32.30	<.0001	0	M12	0
NUM14	-0.09902	0.04212	-2.35	0.0205	0	Dtp1	0
NUM15	-0.29244	0.07015	-4.17	<.0001	0	K2t	0
NUM16	-0.27205	0.11075	-2.46	0.0156	0	K3t	0

NUM17	-0.43324	0.10495	-4.13	<.0001	0	A70	0
NUM18	-0.42497	0.10612	-4.00	0.0001	0	A62	0

Lampiran 6 : Cek Diagnosa Residual Model ARIMAX(3,0,1)(0,0,1)¹² untuk Deret Outflow

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.49	1	0.2227	0.009	-0.028	0.048	-0.055	-0.022	0.064
12	4.53	7	0.7171	-0.062	0.001	0.109	0.021	0.012	0.069
18	10.57	13	0.6471	-0.049	-0.008	0.100	-0.090	-0.048	-0.129
24	19.99	19	0.3951	-0.029	0.026	-0.037	-0.176	0.112	0.109
30	28.51	25	0.2848	0.087	-0.105	-0.122	-0.121	-0.044	-0.025
36	34.99	31	0.2842	-0.046	0.000	0.019	-0.021	0.111	-0.142

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W 0.916791	Pr < W	<0.0001	
Kolmogorov-Smirnov	D 0.052789	Pr > D	>0.1500	
Cramer-von Mises	W-Sq 0.081467	Pr > W-Sq	0.2043	
Anderson-Darling	A-Sq 0.726188	Pr > A-Sq	0.0589	

Lampiran C

Lampiran 1 : Syntax Matlab untuk Model RBFN Inflow dengan Input $Z_{1,t-1}$ dan $Z_{1,t-2}$

```

clc;close All
data=xlsread('D:\DATA\KULIAH_S2\PROPOSAL\JUDUL BARU\Olah DATA
THESIS\RBFN\Inflow\MATLAB\C.xlsx',1);

%ambil semua data
y0=data(:,1);x0=data(:,2:3);
MSD=xlsread('D:\DATA\KULIAH_S2\PROPOSAL\JUDUL BARU\Olah DATA
THESIS\RBFN\Inflow\MATLAB\C.xlsx',2);
M=MSD(:,1:3); SD=MSD(:,4:6);

%ambil data training
Y=y0(1:120);x1=x0(1:120,1);x2=x0(1:120,2);
X=[x1 x2];

%ambil data testing
[a,b]=size(x0);Yt=y0(121:a);
X1t=x0(121:a,1);X2t=x0(121:a,2);
Xt=[X1t X2t];

%peramalan data training
H=rbfDesign(X', M, SD,'b');
lamb=globalRidge(H, Y, 0.05);
W=inv(H'*H+lamb*eye(4))*H'*Y;ft=H*W;e=Y-ft;Jkt=(mean(Y))* (Y-mean(Y));
mpe=mean(abs(e./((Y+ft)/2)));sse=e'*e;MS=sse/50;R2t=1-(sse/Jkt);

% Peramalan Data Testing
Hv=rbfDesign(Xt', M, SD,'b');
ftv=Hv*W;ev=Yt-ftv;Jkv=(Yt-mean(Yt))* (Yt-mean(Yt));
mpev=mean(abs(ev./((Yt+ftv)/2)));ssev=ev'*ev;MSv=ssev/(a-7);R2v=1-(ssev/Jkv);

% Peramalan Seluruh Data

```

```


Hu=rbfDesign(x0',M,SD,'b');lamb=globalRidge(Hu, y0,0.05);
Wu=inv(Hu'*Hu+lamb*eye(4))*Hu'*y0;ftu=Hu*Wu;eu=y0-ftu;
Jku=(y0-mean(y0))'*(y0-mean(y0));
mpeu=mean(abs(eu./((y0+ftu)/2)));sseu=eu'*eu;MSu=sseu/(a-8);R2u=1-(sseu/Jku);

% simpan hasil
MAPE=[mpe mpev mpeu];
SS=[sse ssev sseu];
MSt=[MS MSv MSu];
R2=[R2t R2v R2u];


%Plot
Yh=[ft;ftv];plot(y0,'r');
Hold on;plot(Yh,'b');

```


Lampiran 2 : Output RBFN Plot Hasil Ramalan *Inflow* dengan Input $Z_{1,t-1}$ dan $Z_{1,t-12}$




Lampiran 3 : Output RBFN Plot Hasil Ramalan *Inflow* dengan Input ε_{t-1} dan ε_{t-13}



Lampiran 4 : Output RBFN Plot Hasil Ramalan *Outflow* dengan input $Z_{1,t-1}$, $Z_{1,t-3}$ dan $Z_{1,t-12}$



Lampiran 5 : Output RBFN Plot Hasil Ramalan *Outflow* dengan Input ε_{t-1} , ε_{t-2} , ε_{t-3} dan ε_{t-12}



BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

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

1. Peramalan dengan menggunakan metode ARIMAX diperoleh model terbaik untuk model *inflow* adalah ARIMAX(0,0,[1,13])(3,0,0)¹². Dengan nilai sMAPE *out-sample* untuk deret *inflow* sebesar 0,22.
2. Peramalan dengan menggunakan metode ARIMAX diperoleh model terbaik untuk model *outflow* adalah ARIMAX (3,0,1)(0,0,1)¹². Dengan nilai sMAPE *out-sample* sebesar 0,304
3. Ramalan pada deret *outflow* dilakukan dua kali yaitu tanpa penambahan variabel *dummy* minggu terjadinya Idul Fitri dan dengan penambahan variabel *dummy* minggu terjadinya Idul Fitri. Hasil ramalan yang diperoleh dari tahun 2015 sampai 2017 memberikan hasil dengan pola yang sama, namun dengan penambahan variabel *dummy* mingguan diperoleh nilai ramalan yang lebih rendah untuk ketiga tahun tersebut.
4. Model RBFN diperoleh $F(x) = w_0 + w_1\phi_1(\mathbf{x}_1 - \mathbf{c}_1) + w_2\phi_2(\mathbf{x}_2 - \mathbf{c}_2)$ dengan menggunakan input $Z_{1,t-1}$ dan $Z_{1,t-12}$ untuk *inflow* dan diperoleh model $F(x) = w_0 + w_1\phi_1(\mathbf{x}_1 - \mathbf{c}_1) + w_2\phi_2(\mathbf{x}_2 - \mathbf{c}_2) + w_3\phi_3(\mathbf{x}_3 - \mathbf{c}_3)$ untuk *outflow* dengan input $Z_{1,t-1}, Z_{1,t-3}$ dan $Z_{1,t-12}$. Menghasilkan nilai sMAPE *out-sample* untuk *inflow* dan *outflow* berturut-turut sebesar 0,540 dan 0,340.
5. Dari model *Hybrid* ARIMAX-RBFN diperoleh nilai sMAPE *out-sample* untuk *inflow* sebesar 0,221 dan pada deret *outflow* sebesar 0,304.
6. Perbandingan nilai sMAPE *out-sample* memberikan hasil bahwa model ARIMAX merupakan model terbaik untuk peramalan *inflow* maupun *outflow*.

5.2 Saran

Setelah dilakukan analisis, maka saran yang dapat diberikan adalah perlu untuk mencoba memasukkan faktor-faktor non teknis dalam pemodelan. Faktor-faktor tersebut misalnya faktor sosial dan budaya masyarakat setempat. Dalam penerapannya di Provinsi Papua, 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 tepat.

DAFTAR PUSTAKA

- Anders, U., & Korn., (1999), *Model Selection in Neural Network*, Neural Networks, 12, 309-323.
- Bank Indonesia, (2011), Surat Edaran Perihal Penyetoran dan Penarikan Uang Rupiah oleh Bank Umum di Indonesia, Bank Indonesia.
- Bowerman, B.L., and O'Connell, R.T., (1993), *Forecasting and Time Series: An Applied Approach*. California: Duxbury Press.
- Box, G.E.P., Jenkins, G.M., & Reinsel, G. C., (1994), "*Time Series Analysis forecasting and Control*, 3rd Edition", Prentice-Hall Inc., New Jersey.
- Brenton, C. (1999). *Matering Network Security*, Sybex, San Fransisco.
- Costanzo, S., Trigo, L., Jimenez, L., dan Gonzales, J. (2007), *A Neural Network Model of Venezuelan Economy*. (online). [<http://arxiv.org/abs.>], diakses Jumat, 19 February 2016.
- Cryer , J. D., & Chan, K. S. (2008). *Time Series Analysis with Applications in R (2nd ed.)*. New York:Springer.
- Donald, K. dan Cios, "Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model, *Neurocomputing* 10 (1996) 149-168.
- Fausett, L. (1994), "*Fundamentals of Neural Networks : Architectures, Algorithms, and Applications*", Prentice Hall, Englewood Cliffs, New Jersey.
- Fauziah, L. dan Suhartono., (2012). *Peramalan Jumlah Kedatangan Wisatawan Mancanegara ke Indonesia Melalui Lima Pintu Kedatangan Utama Menggunakan Model hibrida ARIMA-ANFIS*, Makalah Tugas Akhir, Jurusan Statistika FMIPA-ITS, Surabaya.
- Fnegxia, & Shouming. (2011). Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing. *World Academy of Science, Engineering and Technology International Journal of Mathematical, Computational, Physical, Electrical and Computer Engineering* Vol:5, No:3, 2011

- Gde, P. R. (2015). *Peramalan Inflow dan Outflow Uang Kartal Dengan Fungsi Transfer Multi Input dan Hybrid ARIMA-Artificial Neural Network di Provinsi Bali*, Thesis: Institut Teknologi Sepuluh Nopember.
- Hermawan, A. (2006), *Jaringan Saraf Tiruan: Teori dan Aplikasi*. Penerbit ANDI. Jakarta
- Ho, Ping Chun & Yim, John Z., (2006), "Wave Height Forecasting by the Transfer Function Model", *Ocean Engineering* 33 (2006) 1230–1248
- Lee, M. H., Suhartono, & Hamzah, N. A. (2010). Calender Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect. *Proceeding of The Regional Conference on Statistical Sciences 2010 (RCSS'10)*, (pp. 349-361)
- Makridakis, S., Wheelwright, S.C., and McGee, V.E. (1999). *Metode dan Aplikasi Peramalan Edisi Kedua [Terjemahan]*. Jakarta: Erlangga.
- Merh, N., Saxem, V., dan Pardasani, K. (2010), "A Comparison Between Hybrid Approaches of ANN and ARIMA for Indian Stock Trend Forecasting", *Business Intelligence Journal*, vol. 3 no. 2 , hal 23-44.
- Montgomery, D.C., Cheryl L.J., dan Murat K., (2008), *Introduction to Time Series Analysis and Forecasting*, John Wiley & Sons, Kanada.
- Moshiri, S., dan Cameron, N. (2000), "Neural Network versus Econometric Models in Forecasting Inflation", *Journal of Forecasting* 19 , hal. 201-217.
- Khrisnamurti, L., Narayan, J., Raj., S.P., (1989), "Intervention Analysis Using Control Series and Exogenous Variables in A Transfer Function Model: A Case Study", *International Journal of Forecasting* 5 (1989) 21-27
- Kusumaningrum., Suhartono., dan Haryono. (2012), "Peramalan Kebutuhan Bahan Bakar Premium di Depot Ampenan dengan Metode Hibrida Arima-Neural Network untuk Optimasi Persediaan", *Jurnal Sains dan Seni ITS* Vol. 1, No. 1
- Terasyirta., T. Tjostheim, D., & Granger, C.W.J., (1992), *Aspects Of Modelling Nonlinear Time Series*", Research Report 1992:1. Department Of Statistics. University Of Goteborg, Finland.
- Terui, N. and Van Dijk, H.K., 2002, "Combined Forecast from Linear and Nonlinear Time Series Model", *International Journal of Forecasting*, vol.18, no.3, pp 421-438.

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

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

BIODATA PENULIS



Penulis dengan nama lengkap Maya Paembonan dilahirkan pada tanggal 9 Mei 1987 di Kabupaten Moanemani Provinsi Papua. Merupakan anak keempat dari lima bersaudara. Pendidikan formal penulis dimulai dari SD Negeri Sanoba 1 Nabire, SLTP Negeri 4 Nabire, SMA Negeri 1 Nabire. Setelah lulus SMA, penulis diterima di Jurusan Matematika Universitas Negeri Papua melalui jalur SMPTN. Empat tahun kemudian penulis melanjutkan program magister di Jurusan Statistika-Institut Teknologi Sepuluh November.

Bidang minat statistika yang ditekuni penulis adalah 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*: mayapaembonan@gmail.com