



TESIS - KS185411

MODEL HYBRID GSTARX-JORDAN RNN UNTUK PERAMALAN DATA SPACE-TIME DENGAN EFEK VARIASI KALENDER

(Studi Kasus: Data Inflow dan Outflow Bank Indonesia di
Jawa Timur)

FAUZAH HIKMAWATI
06211850010009

Dosen Pembimbing
Dr. Suhartono, M.Sc
Dr.rer.pol. Dedy Dwi Prastyo, M.Si

Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
2020



TESIS - KS185411

**MODEL HYBRID GSTARX-JORDAN RNN UNTUK
PERAMALAN DATA SPACE-TIME DENGAN EFEK
VARIASI KALENDER**

**(Studi Kasus: Data *Inflow* dan *Outflow* Bank Indonesia di
Jawa Timur)**

Fauzah Hikmawati
NRP. 062118 5001 0009

DOSEN PEMBIMBING
Dr. Suhartono, S.Si., M.Sc.
Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

PROGRAM MAGISTER
DEPARTEMEN STATISTIKA
FAKULTAS SAINS DAN ANALITIKA DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
2020



THESIS - KS185411

**A HYBRID GSTARX-JORDAN RNN MODEL FOR
FORECASTING SPACE-TIME DATA WITH CALENDAR
VARIATION EFFECT**

**(Case study: Inflow and Outflow Data of Bank Indonesia in
East Java)**

Fauzah Hikmawati
NRP. 062118 5001 0009

SUPERVISOR
Dr. Suhartono, S.Si., M.Sc.
Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

MAGISTER PROGRAM
DEPARTEMENT OF STATISTICS
FACULTY OF SCIENCE AND DATA ANALYTICS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
2020

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Statistika (M.Stat)

di

Institut Teknologi Sepuluh Nopember

Oleh:

FAUZAH HIKMAWATI

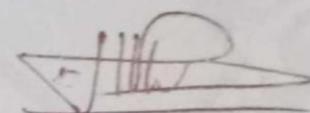
NRP: 06211850010009

Tanggal Ujian: 24 Januari 2020

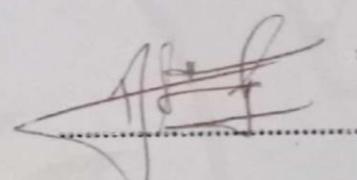
Periode Wisuda: Maret 2020

Disediakan oleh:

Pembimbing:

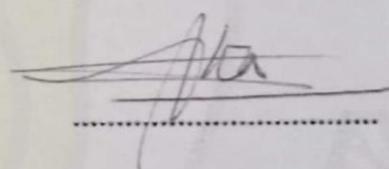


1. Dr. Suhartono, M.Sc
NIP: 19710929 199512 1 001

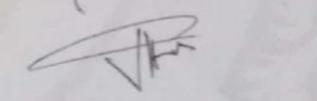


2. Dr.rer.pol. Dedy Dwi Prastyo, M.Si
NIP: 19831204 200812 1 002

Penguji:



1. Dr. Ir. Setiawan, MS
NIP: 19601030 198701 1 001



2. Dr.Purhadi, M.Sc
NIP: 19620204 198701 1 001



**Model *Hybrid GSTARX-Jordan RNN* untuk Peramalan Data *Space-Time*
dengan Efek Variasi Kalender**

(Studi Kasus: Data *Inflow* dan *Outflow* Bank Indonesia di Jawa Timur)

Nama Mahasiswa : Fauzah Hikmawati
NRP : 062118 5001 0009
Pembimbing : Dr. Suhartono, S.Si., M.Sc.
Co-pembimbing : Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

ABSTRAK

Salah satu metode untuk memodelkan data *space-time* adalah *Generalized Space-Time Autoregressive* (GSTAR). Model GSTARX merupakan model GSTAR dengan variabel eksogen. Model ini mampu menangkap komponen tren, musiman, dan variasi kalender pada suatu data *time series* multivariat. Model GSTARX memiliki keterbatasan dalam menangkap pola data yang nonlinier. Penelitian ini bertujuan untuk membentuk model *hybrid GSTARX-Jordan RNN* dengan GSTARX sebagai komponen linier dan Jordan RNN sebagai komponen nonlinier untuk meramalkan data *time series* yang memiliki komponen tren, musiman, dan variasi kalender dengan residual yang mengikuti model nonlinier. Penelitian ini terdiri dari kajian simulasi dan kajian terapan. Kajian simulasi dilakukan untuk mengetahui kebaikan model *hybrid GSTARX-Jordan RNN* dengan membangkitkan data dalam dua skenario, yaitu skenario dengan residual mengikuti model linier dan residual mengikuti model nonlinier. Hasil kajian simulasi menunjukkan bahwa model *hybrid GSTARX-FFNN*, *GSTARX-DLNN*, dan *GSTARX-Jordan RNN* memberikan hasil yang lebih baik dalam meramalkan data simulasi dengan residual mengikuti model linier dan nonlinier. Kajian terapan dilakukan dengan memodelkan data *inflow* dan *outflow* per pecahan dan total di Kantor Perwakilan Bank Indonesia (KP BI) Provinsi Jawa Timur. Hasil dari kajian terapan menunjukkan bahwa model *hybrid GSTARX-Jordan RNN* memberikan hasil yang tidak lebih baik daripada model *hybrid* lainnya. Secara umum, model terbaik untuk memodelkan data *inflow* dan *outflow* total dan uang pecahan besar adalah model *hybrid* dan ini sesuai dengan hasil M4-*Competition*, yaitu model *hybrid* mampu meningkatkan akurasi peramalan dibandingkan dengan model individu.

Kata Kunci: GSTAR, *Hybrid GSTARX-Jordan RNN*, *Inflow*, *Outflow*, *Space-Time*, Variasi Kalender

(Halaman ini sengaja dikosongkan)

A Hybrid GSTARX-Jordan RNN Model for Forecasting Space-Time Data with Calendar Variation Effect

(Case Study: Inflow and Outflow Data of Bank Indonesia in East Java)

Name	:	Fauzah Hikmawati
Student Identity Number	:	062118 5001 0009
Supervisor	:	Dr. Suhartono, S.Si., M.Sc.
Co-Supervisor	:	Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si.

ABSTRACT

One method for modeling space-time data is Generalized Space-Time Autoregressive (GSTAR). The GSTARX is a GSTAR model with an exogenous variable. This model can capture the trend, seasonal, and calendar variation components in a time series data. However, the GSTARX model has the limitation of not being able to capture nonlinear patterns at the data structures. This research aims to modeling the hybrid GSTARX-Jordan RNN model, whereas GSTARX as a linear component and Jordan RNN as a nonlinear component. The results of simulation study show that the hybrid model namely GSTARX-FFNN, GSTARX-DLNN, and GSTARX-Jordan RNN give good results in forecasting simulation data containing the residual following linear and nonlinear patterns. The applied study is conducted by modeling the inflow and outflow data per fraction and total in the Bank Indonesia Regional Office of East Java Province. The results of the applied study show that the hybrid GSTARX-Jordan RNN model gives no better results than other hybrid models. In general, the best model for modeling total inflow and outflow data and large fractional money are hybrid models and this corresponds to the results of the M4-Competition which is the hybrid model tend to produces better forecasting results than individual models.

Keywords: Calendar Variation, East Java, Hybrid GSTARX-Jordan RNN, Inflow, Outflow, Space-Time.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur kehadirat Allah SWT, penulis dapat menyelesaikan penyusunan tesis yang berjudul “**MODEL HYBRID GSTARX-JORDAN RNN UNTUK PERAMALAN DATA SPACE-TIME DENGAN EFEK VARIASI KALENDER**”. Dalam penyusunan tesis ini tidak terlepas dari bantuan dan dukungan dari berbagai pihak. Sehingga, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Mama dan Aba atas segala doa yang tak pernah henti dipanjatkan, kasih sayang, pengorbanan, dan dukungan yang tak terhingga.
2. Bapak Dr. Suhartono, M.Sc selaku dosen pembimbing yang telah banyak memberikan bimbingan dan pengarahan, serta Bapak Dr. rer. pol. Dedy Dwi Prastyo, M.Si selaku dosen pembimbing dan Kepala Program Studi Pascasarjana yang telah banyak memberikan bimbingan dan fasilitas untuk kelancaran penyelesaian tesis.
3. Bapak Dr. Ir. Setiawan, MS dan Bapak Dr. Purhadi. M.Sc selaku dosen penguji yang telah memberikan banyak kritikan serta nasehat.
4. Ibu Dr. Kartika Fithriasari, M.Si selaku Kepala Departemen Statistika Fakultas Sains dan Analitika Data Institut Teknologi Sepuluh Nopember Surabaya.
5. Teman-teman S2 Statistika angkatan 2018 genap yang khususnya Lutfia, Endah, Vania, dan Mbak Mita yang selalu memberikan dukungan.

Berakhiran penyusunan laporan tesis ini, diharapkan agar laporan ini dapat memberikan manfaat kepada berbagai pihak terkait sebagai tambahan informasi. Penulisan laporan ini masih jauh dari sempurna. Oleh karena itu, peneliti mengharap terdapat perbaikan dalam penulisan laporan di masa yang akan datang.

Surabaya, Januari 2020

Penulis

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
TITLE PAGE	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxiii
DAFTAR LAMPIRAN	xxvii
DAFTAR NOTASI	xxix
BAB 1 PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Perumusan Masalah	7
1.3. Tujuan Penelitian	7
1.4. Manfaat Penelitian	7
1.5. Batasan Masalah	8
BAB 2 TINJAUAN PUSTAKA	9
2.1. Model Naïve	9
2.2. Regresi <i>Time Series</i>	10
2.3. Model <i>Autoregressive Integrated Moving Average with Exogenous Variable</i> (ARIMAX)	11
2.4. Variasi Kalender	18
2.5. <i>Time Series Multivariat</i>	18
2.5.1. <i>Vector Autoregressive</i> (VAR)	18
2.5.2. Model <i>Generalized Space-Time Autoregressive</i> (GSTAR)	22
2.6. Uji Terasvirta	34
2.7. <i>Artificial Neural Network</i> (ANN)	35
2.7.1. <i>Feedforward Neural Network</i> (FFNN)	36

2.7.2. <i>Deep Learning Neural Network</i> (DLNN)	39
2.7.3. <i>Recurrent Neural Network</i> (RNN)	42
2.8. Model <i>Hybrid GSTARX-ANN</i>	45
2.9. Pemilihan Model Terbaik	46
2.10. <i>Inflow</i> dan <i>Outflow</i> Uang Kartal Bank Indonesia	46
BAB 3 METODOLOGI PENELITIAN	49
3.1. Kajian Simulasi	49
3.2. Kajian terapan	54
3.2.1 Sumber Data.....	54
3.2.2 Variabel Penelitian	55
3.2.3 Struktur Data	58
3.2.4 Langkah Analisis.....	61
BAB 4 ANALISIS DAN PEMBAHASAN	69
4.1. Kajian Simulasi	69
4.1.1. Pemodelan <i>Time Series Regression</i> (TSR) Pada Data Simulasi	73
4.1.2. Pemodelan GSTAR pada Data Simulasi.....	83
4.1.3. Pemodelan Jordan RNN pada Data Simulasi.....	95
4.1.4. Pemodelan <i>Hybrid GSTARX-FFNN</i> pada Data Simulasi	99
4.1.5. Pemodelan <i>Hybrid GSTARX-DLNN</i> Pada Data Simulasi	105
4.1.6. Pemodelan <i>Hybrid GSTARX-Jordan RNN</i> pada Data Simulasi	113
4.1.7. Pemilihan Model Terbaik pada Data Simulasi.....	119
4.2. Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> di Jawa Timur.....	122
4.2.1. Karakteristik Data <i>Inflow</i> dan <i>Outflow</i> di KP BI Jawa Timur	122
4.2.2. Pemodelan Naïve Musiman pada Data <i>Inflow</i> dan <i>Outflow</i>	128
4.2.3. Pemodelan <i>Time Series Regression</i> Data <i>Inflow</i> dan <i>Outflow</i>	132
4.2.4. Pemodelan ARIMAX Pada Data <i>Inflow</i> dan <i>Outflow</i>	145
4.2.5. Pemodelan GSTARX Pada Data <i>Inflow</i> dan <i>Outflow</i>	150
4.2.6. Pemodelan <i>Hybrid GSTARX-FFNN</i> Pada Data <i>Inflow</i> dan <i>Outflow</i>	158
4.2.7. Pemodelan <i>Hybrid GSTARX-DLNN</i> pada Data <i>Inflow</i> dan <i>Outflow</i>	167

4.2.8. Pemodelan <i>Hybrid GSTARX-Jordan RNN</i> Pada Data <i>Inflow</i> dan <i>Outflow</i>	172
4.2.9. Pemilihan Model Terbaik untuk Meramalkan Data <i>Inflow</i> dan <i>Outflow</i> di Provinsi Jawa Timur.....	179
4.2.10. Peramalan Data <i>Inflow</i> dan <i>Outflow</i> di KP BI Jawa Timur.....	186
BAB 5 KESIMPULAN DAN SARAN.....	195
5.1. Kesimpulan	195
5.2. Saran	196
DAFTAR PUSTAKA	197

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Peta Lokasi dan Wilayah Kantor Bank Indonesia Wilayah Jawa Timur	25
Gambar 2.2 Arsitektur Model FFNN dengan Satu <i>Hidden Layer</i>	37
Gambar 2.3 Arsitektur Model DLNN dengan Dua <i>Hidden Layer</i>	40
Gambar 2.4 Arsitektur <i>Recurrent Neural Network</i> (RNN) Sederhana	43
Gambar 2.5 Arsitektur Model Jordan RNN	44
Gambar 2.6 Arsitektur Model Jordan RNN dengan Satu <i>Neuron</i> pada <i>Hidden Layer</i>	45
Gambar 2.7 Diagram Alir Siklus Peredaran Uang di Indonesia	47
Gambar 2.8 Jaringan Pendistribusian Uang	48
Gambar 3. 1 <i>Time Series Plot</i> Komponen Tren	50
Gambar 3. 2 <i>Time Series Plot</i> Komponen Musiman.....	51
Gambar 3. 3 <i>Time Series Plot</i> Komponen Variasi Kalender.....	52
Gambar 3. 4 Pola Hubungan Komponen N_t dengan N_{t-1} pada Data Skenario 1 dan Skenario 2.....	54
Gambar 3. 5 Diagram Alir Pemodelan ARIMAX.....	62
Gambar 3. 6 Diagram Alir Tahapan Pemodelan <i>hybrid</i> GSTARX-FFNN	65
Gambar 3. 7 Diagram Alir Tahapan Pemodelan <i>hybrid</i> GSTARX-DLNN	66
Gambar 3. 8 Diagram Alir Tahapan Pemodelan GSTARX-Jordan RNN.....	67
Gambar 3. 9 Diagram Alir Tahapan Pemodelan Secara Keseluruhan	68
Gambar 4. 1 Plot Komponen Tren (a) dan Musiman (b)	69
Gambar 4. 2 Plot Komponen Variasi kalender.....	70
Gambar 4. 3 Matriks Plot Residual Skenario 1 (a) dan Skenario 2 (b) di Empat Lokasi	71
Gambar 4. 4 Plot <i>Time Series</i> Data Simulasi 1 Skenario 1 di Empat Lokasi.....	72
Gambar 4. 5 Plot <i>Time Series</i> Data Simulasi 1 Skenario 2 di Empat Lokasi.....	72
Gambar 4. 6 <i>Time Series Plot</i> Data Aktual dan Hasil Ramalan Model TSR Simulasi 1 Skenario 1	82

Gambar 4. 7	<i>Time Series Plot</i> Data Aktual dan Ramalan Model TSR Data Simulasi 1 Skenario 2	83
Gambar 4. 8	<i>Time Series Plot</i> Residual Pemodelan Tahap Pertama Data Simulasi 1 Skenario 1	84
Gambar 4. 9	<i>Time Series Plot</i> Residual Pemodelan Tahap Pertama Data Simulasi 1 Skenario 2	84
Gambar 4. 10.	Representasi Skematik MCCF Residual Data Simulasi 1 Skenario I dan 2	85
Gambar 4. 11	Representasi Skematik MPCCF Residual Data Simulasi 1 Skenario I.....	85
Gambar 4. 12	<i>Time Series Plot</i> Data Aktual dan <i>Forecast</i> Model GSTARX Data Simulasi 1 Skenario 1	88
Gambar 4. 13	<i>Time Series Plot</i> Data Aktual dan <i>Forecast</i> Model GSTARX Data Simulasi 1 Skenario 2	89
Gambar 4. 14	<i>Time Series Plot</i> Data Aktual dan <i>Forecast</i> Model GSTAR Data Simulasi 1 Skenario 1	93
Gambar 4. 15	<i>Time Series Plot</i> Data Aktual dan <i>Forecast</i> Model GSTAR Data Simulasi 1 Skenario 2	94
Gambar 4. 16	Arsitekur Model Jordan RNN dengan 4 <i>Input</i> , 1 <i>Hidden Layer</i>	95
Gambar 4. 17	<i>Time Series Plot</i> Data Aktual dan Ramalan Model Jordan RNN Simulasi 1 Skenario 1 (lanjutan)	97
Gambar 4. 18	<i>Time Series Plot</i> Data Aktual dan Ramalan Model Jordan RNN Simulasi 1 Skenario 2	97
Gambar 4. 19	Arsitekur GSTAR-FFNN dengan Satu <i>Hidden Layer</i>	100
Gambar 4. 20	<i>Time Series Plot</i> Data Aktual dan Ramalan <i>Hybrid</i> GSTARX-FFNN Simulasi 1 Skenario 1.....	102
Gambar 4. 21	<i>Time Series Plot</i> Data Aktual dan Ramalan <i>Hybrid</i> GSTARX-FFNN Simulasi 1 Skenario 2.....	103
Gambar 4. 22	<i>Line Plot</i> Rata-rata Nilai RMSE <i>In Sample</i> dan <i>Out Sample</i> Model <i>Hybrid</i> GSTARX-FFNN Skenario 1(a) dan Skenario 2(b)	104

Gambar 4. 23 Arsitekur GSTAR-DLNN dengan 8 <i>Input</i> dan 16 Input dengan 2 <i>Hidden Layer</i>	106
Gambar 4. 24 <i>Time Series Plot</i> Data Aktual dan Ramalan Model <i>Hybrid</i> GSTARX-DLNN Simulasi 1 Skenario 1	110
Gambar 4. 25 <i>Time Series Plot</i> Data Aktual dan Ramalan Model <i>Hybrid</i> GSTARX-DLNN Simulasi 1 Skenario 2	111
Gambar 4. 26 Arsitekur GSTAR-Jordan RNN dengan 8 Input dan 16 input dan 1 <i>Hidden Layer</i>	113
Gambar 4. 27 <i>Time Series Plot</i> Data Aktual dan Ramalan Model <i>Hybrid</i> GSTARX-Jordan RNN Simulasi 1 Skenario 1	115
Gambar 4. 28 <i>Time Series Plot</i> Data Aktual dan Ramalan Model <i>Hybrid</i> GSTARX-Jordan RNN Simulasi 1 Skenario 2	117
Gambar 4. 29 Diagram Batang Jumlah RMSE Terkecil Pada Setiap Metode....	120
Gambar 4. 30 <i>Line Plot</i> Rata-rata RMSE Model <i>Hybrid</i> pada setiap replikasi di Skenario 2.....	120
Gambar 4. 31 Diagram Batang Perkembangan Total <i>Inflow</i> dan <i>Outflow</i> Setiap Tahun di KP BI Jawa Timur.....	123
Gambar 4. 32 <i>Time Series Plot</i> Data <i>Inflow</i> Total di KP BI Wilayah Jawa Timur	124
Gambar 4. 33. <i>Time Series Plot</i> Data <i>Outflow</i> Total dan Uang Pecahan Besar di KP BI Jawa Timur.....	125
Gambar 4. 34 <i>Time Series Plot</i> Data <i>Outflow</i> Total dan Uang Pecahan Kecil di KP BI Jawa Timur.....	126
Gambar 4. 35 <i>Time Series Plot</i> Data Aktual <i>Inflow</i> Total dan Ramalan Menggunakan Model Naïve Musiman	129
Gambar 4. 36 <i>Time Series Plot</i> Data Aktual <i>Outflow</i> Total dan Ramalan Menggunakan Model Naïve Musiman	130
Gambar 4. 37 <i>Time Series Plot</i> Data Aktual dan Ramalan <i>Inflow</i> Total dari Model TSR	143
Gambar 4. 38 <i>Time Series Plot</i> Data <i>Inflow</i> dan Hasil Ramalan Menggunakan Model ARIMAX	148

Gambar 4. 39 <i>Time Series Plot</i> Residual Model TSR Data <i>Inflow</i> dan <i>Outflow</i>	
Total di KP BI Jawa Timur	152
Gambar 4. 40 Plot MCCF Residual Model TSR Data <i>inflow</i> dan <i>Outflow</i>	
Total.....	153
Gambar 4. 41 Plot MPCC Residual Model TSR Data <i>Inflow</i> dan <i>Outflow</i>	
Total.....	153
Gambar 4. 42 <i>Time Series Plot</i> Data Aktual <i>Inflow</i> Total dengan Hasil	
Ramalan Model GSTARX	157
Gambar 4. 43 Arsitektur Model <i>Hybrid</i> GSTAR-FFNN(8,4,1)	164
Gambar 4. 44 <i>Time Series Plot</i> Perbandingan Data Aktual <i>Inflow</i> Total	
dengan Ramalan Model <i>Hybrid</i> GSTARX-FFNN	165
Gambar 4. 45 Arsitektur Model <i>Hybrid</i> GSTAR-DLNN(8,4,3,1) Data <i>Inflow</i>	
Total.....	168
Gambar 4. 46 <i>Time Series Plot</i> Data <i>Inflow</i> Total dan Hasil Ramalan Model	
<i>Hybrid</i> GSTARX-DLNN di KP BI Jawa Timur	170
Gambar 4. 47 Arsitektur Model <i>Hybrid</i> GSTAR-Jordan RNN(8,10,1).....	175
Gambar 4. 48 <i>Time Series Plot</i> Data <i>inflow</i> Total dan Hasil Ramalan	
Menggunakan Model <i>Hybrid</i> GSTARX-Jordan RNN	177
Gambar 4. 49 Nilai sMAPE Setiap Langkah Peramalan Data <i>Out Sample</i>	
Total <i>Inflow</i>	183
Gambar 4. 50 Nilai sMAPE Setiap Langkah Peramalan Data <i>Out Sample</i>	
Total <i>Outflow</i>	183
Gambar 4. 51 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Total di KP BI	
Jawa Timur	186
Gambar 4. 52 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Total di KP BI	
Jawa Timur	187
Gambar 4. 53 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 100.000,- di	
KP BI Jawa Timur	187
Gambar 4. 54 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 100.000,- di	
KP BI Jawa Timur	188
Gambar 4. 55 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 50.000,- di	
KP BI Jawa Timur	188

Gambar 4. 56 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 50.000,- di KP BI Jawa Timur	189
Gambar 4. 57 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 20.000,- di KP BI Jawa Timur	189
Gambar 4. 58 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 20.000,- di KP BI Jawa Timur	190
Gambar 4. 59 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 10.000,- di KP BI Jawa Timur	190
Gambar 4. 60 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 10.000,- di KP BI Jawa Timur	191
Gambar 4. 61 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 5.000,- di KP BI Jawa Timur	191
Gambar 4. 62 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 5.000,- di KP BI Jawa Timur	192
Gambar 4. 63 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 2.000,- di KP BI Jawa Timur	192
Gambar 4. 64 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 5.000,- di KP BI Jawa Timur	193
Gambar 4. 65 <i>Time Series Plot</i> Hasil Ramalan Data <i>Inflow</i> Rp. 1.000,- di KP BI Jawa Timur	193
Gambar 4. 66 <i>Time Series Plot</i> Hasil Ramalan Data <i>Outflow</i> Rp. 1.000,- di KP BI Jawa Timur	194

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2. 1 Karakteristik Pola ACF dan PACF secara Teoritis	14
Tabel 2. 2 Jarak antar Kantor Bank Indonesia Wilayah Jawa Timur (km)	26
Tabel 2. 3 Wilayah Kerja Bank Indonesia Jawa Timur	48
Tabel 3. 1 Variabel Penelitian (dalam miliar rupiah)	55
Tabel 3. 2 Ketentuan Minggu Berdasarkan Peraturan Bank Indonesia	57
Tabel 3. 3 Jadwal Terjadinya Hari Raya Idul Fitri Tahun 2000-2021	57
Tabel 4. 1 Koefisien Parameter Tahap I pada Data Simulasi 1.....	73
Tabel 4. 2 Hasil Estimasi Parameter Tahap I Data Simulasi 1 Skenario 2	77
Tabel 4. 3 Koefisien Parameter Model GSTARX Simulasi 1 Skenario 1 dan 2.	86
Tabel 4. 4 Nilai Kebaikan Model GSTARX pada Skenario 1	90
Tabel 4. 5 Koefisien Parameter Model GSTARIMA(1 ₁ ,[1,12],0)	91
Tabel 4. 6 Nilai Kebaikan Model GSTARIMA(1 ₁ ,[1,12],0) Skenario 1 dan 2...	92
Tabel 4. 7 Nilai Kebaikan Model Jordan RNN Data Simulasi 1 Skenario 1 dan 2	95
Tabel 4. 8 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-FFNN pada Skenario I	99
Tabel 4. 9 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-FFNN Data Simulasi 1 Skenario 1 dan 2	101
Tabel 4. 10 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-FFNN pada Skenario 1 dan 2	105
Tabel 4. 11 Nilai Kebaikan Model <i>hybrid</i> GSTARX-DLNN Data Simulasi 1 Skenario 1	108
Tabel 4. 12 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-DLNN pada Skenario I dan 2	112
Tabel 4. 13 Nilai Kebaikan Model <i>hybrid</i> GSTAR-Jordan RNN Data Simulasi 1 Skenario 1 dan 2	115
Tabel 4. 14 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-Jordan RNN pada Skenario I dan 2	118
Tabel 4. 15 Rasio Rata-rata RMSE Terhadap Model TSR	121
Tabel 4. 16 Deskriptif Statistik Data <i>Inflow</i>	127

Tabel 4. 17 Deskriptif Statistik Data <i>Outflow</i>	128
Tabel 4. 18 RMSE dari Model Naïve Musiman	131
Tabel 4. 19 Nilai sMAPE dari Model Naïve Musiman.....	132
Tabel 4. 20 Estimasi Parameter Model TSR Data <i>Inflow</i> Total KP BI Provinsi Jawa Timur.....	133
Tabel 4. 21 Hasil Estimasi Parameter Model TSR Data <i>Outflow</i> Total KP BI di Jawa Timur.....	137
Tabel 4. 22 Nilai RMSE Hasil Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> Menggunakan Model TSR	144
Tabel 4. 23 Nilai sMAPE Hasil Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> Menggunakan Model TSR	144
Tabel 4. 24 Hasil Uji <i>Ljung Box</i> Data Residual TSR <i>Inflow</i> dan <i>Outflow</i> di KP BI Jawa Timur.....	145
Tabel 4. 25 Model ARIMAX Data <i>Inflow</i> KP BI Jawa Timur	146
Tabel 4. 26 Model ARIMAX Data <i>Outflow</i> KP BI Jawa Timur	147
Tabel 4. 27 Nilai RMSE Hasil Pemodelan ARIMAX Data <i>Inflow</i> dan <i>Outflow</i> KP BI Jawa Timur.....	149
Tabel 4. 28 Nilai sMAPE Hasil Pemodelan ARIMAX Data <i>Inflow</i> dan <i>Outflow</i> KP BI Jawa Timur.....	150
Tabel 4. 29 Koefisien Korelasi Masing-masing Data <i>Inflow</i> dan <i>Outflow</i>	151
Tabel 4. 30 Model GSTARX Pada Data <i>Inflow</i> dan <i>Outflow</i> di KP BI Jawa Timur.....	154
Tabel 4. 31 Bobot Lokasi Terbaik Model GSTARX Data <i>Inflow</i>	155
Tabel 4. 32 Estimasi Parameter Model GSTARX Data <i>Inflow</i> Total dengan Bobot Biner	155
Tabel 4. 33 Estimasi Parameter Model GSTARX Data <i>Outflow</i> Total dengan Bobot KS	156
Tabel 4. 34 Hasil Uji Terasvirta Data <i>Outflow</i> di KP BI Jawa Timur	159
Tabel 4. 35 Hasil Uji Terasvirta Data <i>Inflow</i> di KP Bi Jawa Timur	160
Tabel 4. 36 Nilai RMSE Model <i>Hybrid</i> GSTARX-FFNN Data Total <i>Inflow</i> di KP BI Jawa Timur.....	161

Tabel 4. 37 Nilai sMAPE Model <i>Hybrid GSTARX-FFNN</i> Data <i>Inflow</i> Total di KP BI Jawa Timur.....	162
Tabel 4. 38 Hasil Estimasi Parameter Model <i>Hybrid GSTARX-FFNN(8,4,1)</i> Data <i>Inflow</i> Total.....	163
Tabel 4. 39 Nilai RMSE Model Terbaik GSTARX-FFNN Data <i>Inflow</i> di KP BI Jawa Timur.....	166
Tabel 4. 40 Nilai sMAPE Model Terbaik GSTARX-FFNN Data <i>Inflow</i> di KP BI Jawa Timur.....	167
Tabel 4. 41 Nilai RMSE dan sMAPE Model <i>Hybrid GSTARX-DLNN</i> Data <i>Inflow</i> Total	168
Tabel 4. 42 Hasil Estimasi Parameter Model <i>Hybrid GSTARX-DLNN(8,4,3,1)</i> Data <i>Inflow</i> Total.....	169
Tabel 4. 43 Nilai RMSE Model Terbaik GSTARX-DLNN Data <i>Inflow</i> di KP BI Jawa Timur.....	171
Tabel 4. 44 Nilai sMAPE Model Terbaik GSTARX-DLNN Data <i>Inflow</i> di KP BI Jawa Timur.....	172
Tabel 4. 45 Nilai RMSE Pemodelan Data <i>inflow</i> Total Menggunakan Model <i>Hybrid GSTARX-Jordan RNN</i>	173
Tabel 4. 46 Nilai sMAPE Pemodelan Data <i>Inflow</i> Total Menggunakan Model <i>Hybrid GSTARX-Jordan RNN</i>	174
Tabel 4. 47 Hasil Estimasi Koefisien Model GSTARX-Jordan RNN(8,10,1) Data <i>Inflow</i> Total.....	175
Tabel 4. 48 Nilai RMSE Model Terbaik dari Model GSTARX-Jordan RNN....	178
Tabel 4. 49 Nilai sMAPE Model Terbaik dari Model GSTARX-Jordan RNN..	178
Tabel 4. 50 Rata-rata Nilai sMAPE Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> di KP BI Jawa Timur.....	180
Tabel 4. 51 Model Terbaik Data <i>Inflow</i> dan <i>Outflow</i> di KP BI Jawa Timur	181
Tabel 4. 52 Rasio Rata-rata sMAPE dari Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> . 182	
Tabel 4. 53 Model Terbaik Data <i>Inflow</i> dan <i>Outflow</i> Masing-masing KP BI Jawa Timur	185

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1.	<i>Data Inflow dan Outflow Wilayah KP BI Jawa Timur (dalam miliar rupiah)</i>	203
Lampiran 2.	<i>Output SAS Pemodelan TSR data Simulasi 1 Skenario 1.....</i>	211
Lampiran 3.	<i>Output SAS Pemodelan TSR data Simulasi 2 Skenario 1.....</i>	213
Lampiran 4.	<i>Output SAS Pemodelan TSR data Simulasi 4 Skenario 1.....</i>	217
Lampiran 5.	<i>Output SAS Pemodelan TSR data Simulasi 5 Skenario 1.....</i>	219
Lampiran 6.	<i>Output SAS Pemodelan TSR data Simulasi 6 Skenario 1.....</i>	221
Lampiran 7.	<i>Output SAS Pemodelan TSR data Simulasi 7 Skenario 1.....</i>	223
Lampiran 8.	<i>Output SAS Pemodelan TSR data Simulasi 8 Skenario 1.....</i>	225
Lampiran 9.	<i>Output SAS Pemodelan TSR data Simulasi 9 Skenario 1.....</i>	227
Lampiran 10.	<i>Output SAS Pemodelan TSR data Simulasi 10 Skenario 1.....</i>	229
Lampiran 11.	<i>Output SAS Pemodelan TSR data Simulasi 1 Skenario 2.....</i>	231
Lampiran 12.	<i>Output SAS Pemodelan TSR data Simulasi 2 Skenario 2.....</i>	233
Lampiran 13.	<i>Output SAS Pemodelan TSR data Simulasi 3 Skenario 2.....</i>	235
Lampiran 14.	<i>Output SAS Pemodelan TSR data Simulasi 4 Skenario 2.....</i>	237
Lampiran 15.	<i>Output SAS Pemodelan TSR data Simulasi 5 Skenario 2.....</i>	239
Lampiran 16.	<i>Output SAS Pemodelan TSR data Simulasi 6 Skenario 2.....</i>	241
Lampiran 17.	<i>Output SAS Pemodelan TSR data Simulasi 7 Skenario 2.....</i>	243
Lampiran 18.	<i>Output SAS Pemodelan TSR data Simulasi 8 Skenario 2.....</i>	245
Lampiran 19.	<i>Output SAS Pemodelan TSR data Simulasi 9 Skenario 2.....</i>	247
Lampiran 20.	<i>Output SAS Pemodelan TSR data Simulasi 10 Skenario 2.....</i>	249
Lampiran 21.	<i>Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 1</i>	251
Lampiran 22.	<i>Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 2</i>	256
Lampiran 23.	<i>Output SAS Pemodelan GSTARX pada Residual Model TSR Data Simulasi Skenario 1</i>	261
Lampiran 24.	<i>Output SAS Pemodelan GSTARX pada Residual Model TSR Data Simulasi Skenario 2</i>	263
Lampiran 25.	<i>Output SAS Pemodelan GSTAR Data Simulasi Skenario 1</i>	267

Lampiran 26. <i>Output</i> SAS Pemodelan GSTAR Data Simulasi Skenario 2	269
Lampiran 27. <i>Output</i> Model Terbaik Jordan RNN Data Simulasi Skenario 1 ..	271
Lampiran 28. <i>Output</i> Model Terbaik Jordan RNN Data Simulasi Skenario 2 ..	277
Lampiran 29. Nilai sMAPE Model Terbaik Data Simulasi Skenario 1 dan 2 ...	282
Lampiran 30. <i>Output</i> Pemodelan <i>Time Series Regression</i> Data <i>Inflow</i>	283
Lampiran 31. <i>Output</i> Pemodelan <i>Time Series Regression</i> Data <i>Outflow</i>	297
Lampiran 32. <i>Output</i> Hasil Pengujian Asumsi <i>White Noise</i> Pada Residual Model TSR Data <i>Inflow</i>	311
Lampiran 33. <i>Output</i> Hasil Pengujian Asumsi <i>White Noise</i> Pada Residual Model TSR Data <i>Outflow</i>	313
Lampiran 34. Gambar Plot ACF dan PACF Pemodelan ARIMAX	315
Lampiran 35. <i>Output</i> Hasil Pemodelan ARIMAX Data <i>Inflow</i>	331
Lampiran 36. <i>Output</i> Hasil Pemodelan ARIMAX Data <i>Outflow</i>	335
Lampiran 37. <i>Output</i> Hasil Uji Asumsi <i>White Noise</i> Residual Model ARIMAX Data <i>Inflow</i>	339
Lampiran 38. <i>Output</i> Hasil Uji Asumsi <i>White Noise</i> Residual Model ARIMAX Data <i>Outflow</i>	341
Lampiran 39. <i>Output</i> Hasil Uji Distribusi Normal Residual Model ARIMAX Data <i>Inflow</i>	343
Lampiran 40. <i>Output</i> Hasil Uji Distribusi Normal Residual Model ARIMAX Data <i>Outflow</i>	347
Lampiran 41. <i>Output</i> SAS MCCF dan MPCCF Residual Model TSR Data <i>Inflow</i>	351
Lampiran 42. <i>Output</i> SAS MCCF dan MPCCF Residual Model TSR Data <i>Outflow</i>	354
Lampiran 43. <i>Output</i> Hasil Estimasi Koefisien Model GSTARX Data <i>Inflow</i> .	357
Lampiran 44. <i>Output</i> Hasil Estimasi Koefisien Model GSTARX Data <i>Outflow</i>	359
Lampiran 45. Koefisien Model <i>Hybrid</i> Terbaik Data <i>Inflow</i>	361
Lampiran 46. Koefisien Model <i>Hybrid</i> Terbaik Data <i>Outflow</i>	364

DAFTAR NOTASI

Y_t	:	Data <i>time series</i> pada waktu ke- t
n	:	Panjang <i>series</i> data, $t = 1, 2, \dots, n$
R	:	Jumlah yang akan diramalkan
m	:	Periode musiman
δ	:	Koefisien komponen tren
ψ	:	Koefisien komponen variasi kalender
γ	:	Koefisien komponen musiman
$\hat{\rho}_k$:	Fungsi autokorelasi (ACF) sampel pada <i>lag</i> ke- k
$\phi_{k,k}$:	Fungsi autokorelasi parsial (PACF) sampel pada <i>lag</i> ke- k
$\hat{\rho}_{ij}(k)$:	Estimasi korelasi silang (MCCF) untuk sampel komponen series ke- i dan ke- j pada <i>lag</i> ke- k
$\mathbf{P}(k)$:	Matriks fungsi korelasi parsial (MPCCF) pada lag ke- k
$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$:	Koefisien model <i>Autoregressive</i> (AR) dengan orde p
$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$:	Koefisien model <i>Moving Average</i> (MA) dengan orde q
$(1 - B)^d$:	Operator <i>differencing</i> untuk orde d
a_t	:	<i>Error</i> pada waktu ke- t yang sudah <i>white noise</i>
$e_t^{(i)}$:	<i>Error</i> pada waktu ke- t lokasi ke- i yang berkorelasi antar lokasi
z	:	Jumlah lokasi dalam model GSTAR
Z	:	Jumlah variabel dalam model SUR
$\lambda_1, \lambda_2, \dots, \lambda_p$:	Orde spasial Model GSTAR
$\Phi_{k0} = \text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^n)$:	Matriks parameter waktu model GSTAR dari n lokasi

$\Phi_{kl} = \text{diag}(\phi_{kl}^1, \dots, \phi_{kl}^n)$: Matriks parameter spasial model GSTAR dari n lokasi
$\omega^{(l)}$: matriks bobot model GSTAR berukuran $(z \times z)$ untuk <i>lag</i> spasial $l = 0, 1, \dots, \lambda_p$
\mathbf{a}_t	: Vektor residual berukuran $(n \times 1)$ yang independen, identik, berdistribusi normal multivariat dengan <i>mean</i> nol dan matriks varians-kovarians $\sigma^2 \mathbf{I}_z$
Φ_{k0}^s	: Matriks parameter waktu musiman s model GSTAR dari n lokasi
Φ_{kl}^s	: Matriks parameter spasial musiman s model GSTAR dari n lokasi
J_{ij}	: Jarak lokasi ke- i dengan lokasi ke- j
ω_{ij}	: Bobot antara lokasi ke- i dan lokasi ke- j
$X_{i,t}$: Variabel input sebanyak K , ($i = 1, 2, \dots, K$) pada model <i>Neural Network</i>
g	: Jumlah <i>neuron</i> pada <i>hidden layer</i> model FFNN
$g1$: Jumlah <i>neuron</i> pada <i>hidden layer</i> pertama model DLNN
$g2$: Jumlah <i>neuron</i> pada <i>hidden layer</i> kedua model DLNN
M	: Jumlah variabel input pada model <i>neural network</i>
w_{ji}^h	: Bobot dari <i>input</i> ke- i yang menuju <i>neuron</i> ke- j pada <i>hidden layer</i>
b_j^h	: Bias pada <i>neuron</i> ke- j pada <i>hidden layer</i>
f_j^h	: Fungsi aktifasi di <i>neuron</i> ke- j pada <i>hidden layer</i>
w_j^o	: Bobot dari <i>neuron</i> ke- j di <i>hidden layer</i> yang menuju <i>neuron</i> pada <i>output layer</i>
b^o	: Bias pada <i>neuron</i> di <i>output layer</i>

f^o	: Fungsi aktifasi pada <i>neuron</i> di lapis <i>output layer</i>
C_t	: <i>Context layer</i> pada model Jordan-RNN
G_t	: Komponen linier pada model <i>hybrid</i>
H_t	: Komponen nonlinier pada model <i>hybrid</i>
$T_t^{(i)}$: Komponen tren ke- t pada lokasi ke- i
$\delta^{(i)}$: Koefisien tren pada lokasi ke- i
$S_t^{(i)}$: Komponen musiman ke- t pada lokasi ke- i
$\gamma_m^{(i)}$: Koefisien musiman ke- m pada lokasi ke- i
$V_{j,t}^{(i)}$: Efek variasi kalender Idul Fitri pada minggu ke- j lokasi ke- i bulan ke- t
$V_{j,t+1}^{(i)}$: Efek variasi kalender bulan sesudah Idul Fitri $(t+1)$ pada minggu ke- j lokasi ke- i
$V_{j,t-1}^{(i)}$: Efek variasi kalender bulan sebelum Idul Fitri $(t-1)$ pada minggu ke- j lokasi ke- i
$\psi^{(i)}$: Koefisien variasi kalender terjadinya Idul Fitri pada lokasi ke- i
$N_t^{(i)}$: Residual pada waktu ke- t lokasi ke- i

(Halaman ini sengaja dikosongkan)

BAB 1

PENDAHULUAN

1.1. Latar Belakang

Kemajuan ilmu teknologi terutama dalam bidang komputasi beberapa tahun terakhir ini menyebabkan banyak dilakukan penelitian terkait peramalan data *time series* yang tidak hanya secara univariat, namun sudah mulai diterapkan metode peramalan pada data *time series* secara multivariat (Chatfield, 1997). Data *time series* merupakan data yang mengandung urutan pengamatan yang telah dikumpulkan dari waktu ke waktu (Hyndman dan Athanasopoulos, 2014). Terdapat kemajuan teoritis yang cukup besar terkait peramalan data *time series* multivariat, namun belum banyak diterapkan dan dikembangkan secara luas. Hal ini disebabkan karena kurangnya penelitian empiris tentang algorithma peramalan yang kuat untuk memodelkan data *time series* multivariat (Gooijer dan Hyndman, 2006).

Box, Jenkins, dan Reinsel (2008) telah mengembangkan metode peramalan data *time series* univariat yang mengandung komponen tren dan musiman, yaitu model *Autoregressive Integrated Moving Average* (ARIMA). Sedangkan salah satu model *time series* multivariat yang sudah sering digunakan adalah *Vector Autoregressive* (VAR), model tersebut ditemukan oleh Quenouille (1957) dalam Gooijer dan Hyndman (2006) dan saat ini sudah mengalami banyak perkembangan. Beberapa penelitian terkait peramalan data *time series* menggunakan VAR telah dilakukan sebelumnya, diantaranya dilakukan oleh Clements dan Galvao (2013) untuk meramalkan tingkat inflasi, serta telah dilakukan juga oleh Kelikume dan Salami (2014) membandingkan model VAR dan VARIMA untuk inflasi di Nigeria.

Data *time series* multivariat adalah data *time series* yang tidak hanya memiliki hubungan antar waktu tetapi juga memiliki ketergantungan atau hubungan antar lokasi, data seperti ini biasa disebut dengan data *space-time*. Pfeifer dan Deutsh (1980a, 1980b) memperkenalkan model *space time* yang disebut model *Space Time Autoregressive* (STAR). Model STAR mengasumsikan bahwa setiap lokasi adalah homogen atau setiap lokasi memiliki parameter *autoregressive* (AR) dengan variasi yang sama, sedangkan pada kenyataannya antar lokasi memiliki

variasi nilai parameter yang heterogen. Ruchjana (2002) mengembangkan model STAR menjadi *Generalized Space Time Autoregressive* (GSTAR) yang mampu mengatasi kelemahan pada model STAR, yaitu memungkinkan parameter *autoregressive* (AR) setiap lokasi memiliki variasi yang berbeda atau mampu mengatasi lokasi yang heterogen. Model GSTAR lebih realistik karena pada kenyatannya lebih banyak ditemui model dengan parameter *autoregressive* (AR) berbeda untuk lokasi yang berbeda. Kajian teoritis berkaitan dengan sifat asimtotis dari parameter model GSTAR dan penentuan bobot antar lokasi diberikan oleh Lopuhaa & Borovkova (2008) dan Suhartono dan Subanar (2006 & 2007). Penelitian sebelumnya tentang GSTAR telah dilakukan oleh Wutsqa dan Suhartono (2010) untuk meramalkan data pariwisata di Yogyakarta dan Bali, yang menghasilkan kesimpulan bahwa model VAR-GSTAR lebih akurat dibandingkan model VARIMA. Suhartono dan Atok (2005) juga melakukan perbandingan model VARMA dan GSTAR dan hasilnya menunjukkan bahwa peramalan dengan model GSTAR lebih akurat.

Pola dari suatu data *time series* sesungguhnya tidak hanya dipengaruhi oleh waktu sebelumnya atau keterkaitan antar lokasi, namun juga dipengaruhi oleh peristiwa eksternal tertentu seperti liburan, promosi penjualan, perubahan kebijakan dan lain sebagainya (Wei, 2006, hal. 382). Sehingga dalam meramalkan atau mendapatkan suatu model peramalan dalam kasus data univariat maupun multivariat perlu melibatkan variabel eksogen. Model *time series* univariat dengan variabel eksogen dikenal dengan ARIMAX, dimana variabel eksogen dapat berskala metrik atau nonmetrik, dan VARX atau GSTARX dikenal sebagai model *time series* multivariat dengan variabel eksogen. Model ARIMAX dengan variabel eksogen berupa skala metrik dikenal dengan istilah model fungsi transfer (Wei, 2006, hal. 322) sedangkan untuk variabel eksogen dengan skala nonmetrik dikenal dengan istilah model intervensi (Bowerman dan O'Connell, 1993) dan model variasi kalender (Liu, 2006).

Pemodelan *space time* yang mengandung variabel eksogen sudah cukup berkembang dan digunakan dalam beberapa penelitian sebelumnya. Suhartono, Wahyuningrum, Setiawan, dan Akbar (2016) meramalkan inflasi di beberapa daerah di Indonesia dengan variabel prediktor berskala nonmetrik menggunakan

model GSTARX-GLS, diperoleh hasil bahwa model GSTARX-GLS lebih akurat daripada model VARIMAX. Untuk mengestimasi parameter model GSTARX digunakan metode *Generalized Least Square* (GLS) karena metode ini menghasilkan estimator yang lebih efisien daripada metode *Ordinary Least Square* (OLS). Metode OLS mengasumsikan bahwa residual model memenuhi kondisi *white noise* dan berdistribusi normal, hal ini berarti residual antar lokasi tidak memiliki korelasi, sedangkan residual model GSTAR cenderung memiliki korelasi antar lokasi.

Suatu data *time series* tidak menutup kemungkinan bahwa data tersebut mengandung komponen struktur data yang linier dan nonlinier (Zhang, 2003). Model GSTAR memiliki keterbatasan dalam memodelkan data yang mengandung struktur linier dan nonlinier. Metode yang mampu memodelkan data yang mengandung komponen residual yang mengikuti pola linier dan nonlinier secara bersamaan adalah model *hybrid*, yang telah menunjukkan kemampuan yang sesuai karena gabungan komponen tersebut ada pada sebagian besar data di dunia nyata (Hajirahimi dan Khashei, 2019). Zhang (2003) memperkenalkan model *hybrid* dengan mengkombinasikan model ARIMA dan *Artificial Neural Network* (ANN). Model ARIMA sebagai komponen linier dan model ANN sebagai komponen nonlinier. Penelitian yang dilakukan Zhang menghasilkan kesimpulan bahwa model *hybrid* ARIMA-ANN dapat meningkatkan akurasi peramalan dibandingkan dengan model ARIMA dan ANN secara terpisah. Sehingga model *hybrid* juga dapat diterapkan pada GSTAR untuk mengatasi struktur data yang mengandung komponen linier dan nonlinier secara bersamaan.

ANN merupakan model *time series* nonlinier yang telah dikembangkan oleh Tong (1990), Granger dan Terasvirta (1993), serta Franses dan Dijk (2000). Model ANN adalah pendekatan matematis yang memberikan solusi berdasarkan konsep organisasi transmisi sinyal dalam sistem saraf manusia. Datilo, Ismail, dan Dare (2019) melakukan peninjauan peramalan *epidemics* menggunakan ANN, dan didapatkan hasil bahwa model *hybrid* ANN memiliki hasil prediksi yang lebih baik dibandingkan dengan model lain. Kelebihan dalam menggunakan model ANN adalah tidak perlu menentukan bentuk model tertentu karena modelnya dibentuk secara adaptif berdasarkan fitur yang disajikan dari data (Zhang dan Berardi, 1998).

Terdapat beberapa macam model ANN yang dibedakan berdasarkan kedalaman arsitektur. Arsitektur ini juga berperan dalam meminimumkan *error* suatu model peramalan. Semakin dalam atau semakin kompleks suatu arsitektur maka akan menghasilkan akurasi peramalan yang semakin tinggi. Bengio, Lamblin, Popovici, dan Larochelle (2007) melakukan suatu kajian teoritis bahwa arsitektur yang lebih dalam mungkin diperlukan pada fungsi yang cukup rumit dan dapat mengatasi abstraksi fungsi tingkat tinggi. Kedalaman suatu arsitektur model ANN dilihat berdasarkan jumlah *hidden layer*, model ANN dengan satu *hidden layer* dikenal dengan *Feed Forward Neural Network* (FFNN). Peramalan menggunakan FFNN sebelumnya telah dilakukan oleh Dumitru dan Gligor (2017) dalam meramalkan rata-rata kekuatan angin harian di bagian tenggara Eropa. Model ANN dengan *hidden layer* lebih dari satu dikenal sebagai *Deep Learning Neural Network* (DLNN), dan *Recurrent Neural Network* (RNN) juga termasuk dalam *deep learning* yang dikembangkan dari metode FFNN dengan rangkaian arsitektur yang lebih kompleks.

RNN mampu mengidentifikasi sistem dinamis dalam bentuk dimensi tinggi (*nonlinear state-space models*). Dibandingkan dengan FFNN model RNN merupakan model NN yang lebih fleksibel. Model RNN dikatakan fleksibel karena *output* jaringan dijadikan sebagai input untuk mendapatkan *output* berikutnya (Trapletti, 2000). Terdapat dua tipe dalam model RNN yaitu Elman RNN dan Jordan RNN, yang akan dikembangkan dalam penelitian ini adalah tipe Jordan RNN.

Studi kasus yang digunakan pada penelitian ini adalah data *inflow* dan *outflow* di Bank Indonesia. Bank Indonesia memiliki tujuan tunggal yakni mencapai dan memelihara kestabilan nilai Rupiah. Kestabilan nilai Rupiah diukur dari dua aspek yaitu kestabilan nilai uang terhadap barang dan Rupiah terhadap mata uang negara lain (Bank Indonesia, 2018). Uang beredar yang menjadi salah satu alat ukur kestabilan nilai rupiah merupakan salah satu indikator penting dalam proses pengambilan kebijakan ekonomi (Solikin dan Suseno, 2002a). Uang kartal merupakan salah satu bagian dari uang beredar. Dalam kehidupan sehari hari uang kartal yang juga disebut sebagai uang tunai 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 (Solikin dan Suseno, 2002b). Walaupun saat ini sistem pembayaran non tunai berkembang dengan cepat seiring dengan perkembangan teknologi dan inovasi di pasar uang, keberadaan uang kertas dan uang logam yang disebut dengan uang kartal masih memegang peranan penting dalam perekonomian (Sigalingging, Setiawan, dan Sihalolo, 2004).

Perlu disadari bahwa pengedaran uang harus dikelola sedemikian rupa dengan baik sehingga jumlah uang beredar sesuai dengan jumlah uang yang dibutuhkan masyarakat. Jumlah uang yang melampaui permintaan akan mengakibatkan kenaikan harga-harga (inflasi) dan sebaliknya apabila jumlah uang lebih sedikit dari permintaan dapat mengakibatkan melambatnya kegiatan perekonomian. Rencana Distribusi Uang (RDU) adalah penetapan jumlah dan komposisi pecahan uang yang akan dikirim untuk memenuhi kebutuhan kas setiap kantor Bank Indonesia selama satu tahun. Dalam penyusunan RDU salah satu faktor yang menjadi pertimbangan adalah jumlah setoran (*inflow*) dan jumlah bayaran (*outflow*).

Data *inflow* dan *outflow* yang digunakan adalah data di Bank Indonesia wilayah Provinsi Jawa Timur yang mencakup empat kantor perwakilan (KP) yaitu Surabaya, Malang, Kediri, dan Jember. Pertumbuhan ekonomi Jawa Timur pada triwulan II 2019 mencapai 5,7% (yoY), lebih tinggi dibandingkan triwulan sebelumnya. Dibandingkan dengan provinsi lain di Pulau Jawa, kinerja perekonomian Jawa Timur pada periode ini tumbuh lebih tinggi dibandingkan DKI Jakarta sebagai ibu kota Indonesia (Bank Indonesia, 2019). Hal ini menyebabkan tingginya angka *inflow* dan *outflow* di Bank Indonesia wilayah Jawa Timur. Perkembangan *inflow* dan *outflow* di Jawa Timur dengan mayoritas penduduknya adalah muslim menyebabkan memiliki pola musiman yang dipengaruhi oleh dua jenis kalender, yaitu kalender masehi dan kalender Islam. Efek kalender masehi menyebabkan *inflow* dan *outflow* tinggi atau rendah pada bulan tertentu, sedangkan kalender Islam mempengaruhi *inflow* dan *outflow* di sekitar bulan hari idul fitri. Efek hari raya idul fitri tidak bisa dianggap sebagai pola musiman pada data, karena hari raya idul fitri terjadi pada tanggal dan bulan yang berbeda di setiap tahunnya. Sehingga perlu ditambahkan variabel eksogen pada pemodelan GSTAR

yang kemudian disebut dengan GSTARX. penelitian terkait model GSTARX dimana variabel eksogenanya adalah variasi kalender pernah dilakukan oleh Wulansari dkk., (2014), dan didapatkan hasil bahwa penambahan variabel eksogen variasi kalender mampu meningkatkan akurasi model peramalan.

Pemodelan data *inflow* dan *outflow* sudah pernah dilakukan sebelumnya oleh Apriliadara, Suhartono, dan Prastyo (2016), diperoleh hasil bahwa data *inflow* dan *outflow* di seluruh KP Bank Indonesia mengandung komponen linier dan nonlinier. Berdasarkan hasil tersebut, memungkinkan untuk menggunakan model *hybrid* dalam melakukan pemodelan data *inflow* dan *outflow*. Pemodelan *hybrid* pada data *inflow* dan *outflow* sebelumnya telah dilakukan oleh Suhartono dkk., (2019), menggunakan *hybrid* GSTARX-ANN, dengan tipe arsitektur yang digunakan adalah FFNN dan DLNN. Hasil dari penelitian tersebut menyatakan bahwa model *hybrid* GSTARX-DLNN menghasilkan akurasi yang lebih tinggi daripada model GSTARX dan model *hybrid* GSTARX-FFNN.

Sampai saat ini belum ada pemodelan data *inflow* dan *outflow* dengan menggunakan Jordan RNN untuk mengatasi komponen nonlinier. Sehingga pada penelitian ini akan dilakukan pemodelan data *inflow* dan *outflow* dengan mengkombinasikan model GSTARX sebagai komponen linier, dan model Jordan RNN sebagai komponen nonlinier yang dapat disebut dengan model *hybrid* GSTARX-Jordan RNN. Untuk mengetahui pengaruh dari kedalaman arsitektur model Jordan RNN terhadap tingkat akurasi peramalan data *inflow* dan *outflow*, maka akan dilakukan perbandingan tingkat akurasi peramalan model *hybrid* GSTARX-FFNN, GSTARX-DLNN, dan GSTARX-Jordan RNN. Evaluasi kebaikan model-model tersebut dilakukan dengan kajian simulasi data yang mengandung variabel eksogen sama seperti data *inflow* dan *ouflow*. Sehingga dalam penelitian ini pemodelan GSTARX dan *hybrid* dilakukan pada kajian simulasi dan kajian terapan.

1.2. Perumusan Masalah

Setelah diuraikan latar belakang dari penelitian ini, maka didapatkan rumusan masalah yang akan dibahas yaitu:

1. Bagaimana kebaikan model *hybrid GSTARX-Jordan RNN* dalam memodelkan data *time series* yang mengandung komponen tren, musiman, variasi kalender, serta residual yang mengikuti pola linier dan nonlinier?
2. Bagaimana kebaikan model *hybrid GSTARX-Jordan RNN* dalam memodelkan data *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia wilayah Provinsi Jawa Timur?
3. Bagaimana hasil peramalan data *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia wilayah Provinsi Jawa Timur dengan menggunakan model terbaik yang terpilih?

1.3. Tujuan Penelitian

Berdasarkan dari rumusan masalah yang sudah disusun pada sub bab sebelumnya, maka ditentukan tujuan penelitian sebagai berikut:

1. Melakukan kajian simulasi untuk mengetahui kebaikan model *hybrid GSTARX-Jordan RNN*.
2. Mengetahui kebaikan model *hybrid GSTARX-Jordan RNN* dalam memodelkan data *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia wilayah Provinsi Jawa Timur.
3. Mendapatkan hasil peramalan data *inflow* dan *outflow* uang kartal di Kantor Perwakilan Bank Indonesia wilayah Provinsi Jawa Timur menggunakan model terbaik.

1.4. Manfaat Penelitian

Berdasarkan uraian dan tujuan dari penelitian ini, maka dari hasil penelitian ini akan didapatkan manfaat sebagai berikut:

1. Bagi pihak Bank Indonesia khususnya KPw Jawa Timur, diharapkan hasil penelitian diperoleh hasil ramalan *inflow* dan *outflow* uang kartal yang sesuai untuk masing-masing lokasi di Provinsi Jawa Timur, juga bisa digunakan

sebagai referensi dalam merencanakan pendistribusian uang kartal di wilayah Jawa Timur.

2. Hasil penelitian ini diharapkan dapat menambah wawasan keilmuan statistika khususnya di bidang *forecasting* dengan menerapkan model *hybrid GSTARX-Jordan RNN* yang dimungkinkan memiliki akurasi tinggi dan masih bisa menjelaskan efek variasi kalender hari raya idul fitri.

1.5. Batasan Masalah

Beberapa masalah yang dibatasi dalam penelitian diantaranya adalah:

1. Data *inflow* dan *outflow* yang digunakan adalah pecahan uang kertas Rp. 100.000,00; Rp. 50.000,00; Rp. 20.000,00; Rp. 10.000,00; Rp. 5.000,00; Rp. 2.000,00; dan Rp. 1.000,00, serta total uang kertas.
2. Pemodelan data *inflow* dan *outflow* uang kartal di Bank Indonesia khusus wilaya Jawa Timur yang terdiri dari empat wilayah KPw, yaitu Surabaya, Malang, Kediri, dan jember.
3. Variabel eksogen yang digunakan pada model GSTARX berskala nonmetrik yaitu efek variasi kalender hari raya idul fitri.
4. Metode estimasi parameter pada model GSTAR menggunakan GLS, dikarenakan metode GLS mampu mengatasi residual model yang memiliki korelasi antar lokasi.
5. Orde spasial yang digunakan adalah orde satu karena wilayah kerja masing-masing KPw Bank Indonesia wilayah Jawa Timur berdekatan secara langsung.
6. Jumlah *neuron* yang digunakan dalam *hidden layer* model FFNN dan Jordan RNN adalah 1, 2, 3, 4, 5, 10, dan 15. Namun pada model DLNN jumlah *neuron* yang digunakan pada *hidden layer* pertama sama dengan jumlah neuron pada model FFNN dan Jordan RNN, sedangkan jumlah *neuron* yang digunakan pada *hidden layer* kedua adalah 1, 2, 3, 4, dan 5.

BAB 2

TINJAUAN PUSTAKA

Bab ini akan menjelaskan teori-teori yang digunakan dalam penelitian ini yang memuat model *naïve*, model ARIMA, regresi *time series*, model GSTAR, model ANN yang terdiri dari FFNN, DLNN, dan Jordan RNN, model variasi kalender, serta model *hybrid*.

2.1. Model Naïve

Model naive yang paling sederhana mengasumsikan bahwa data periode terakhir adalah prediksi terbaik untuk data masa depan. Model naive yang paling sederhana adalah

$$\hat{Y}_{t+R} = Y_t \quad (2.1)$$

dengan \hat{Y}_{t+R} adalah ramalan untuk waktu ke-($t+R$).

Ketika nilai data meningkat seiring waktu, maka data dikatakan memiliki pola tren. Jika Persamaan (2.1) digunakan, maka hasil ramalan akan memiliki konsistensi yang rendah. Teknik yang dapat digunakan untuk mengatasi data dengan pola tren adalah dengan menambahkan selisih data periode saat ini dan periode sebelumnya. Sehingga model naive untuk data dengan pola tren adalah

$$\hat{Y}_{t+R} = Y_t + (Y_t - Y_{t-R}) \quad (2.2)$$

Beberapa kasus data dengan pola tren dengan beberapa tujuan, laju atau rasio perubahan mungkin lebih tepat digunakan daripada selisih data periode saat ini dan periode sebelumnya, sehingga modelnya adalah sebagai berikut

$$\hat{Y}_{t+R} = Y_t \frac{Y_t}{Y_{t-R}} \quad (2.3)$$

Jika suatu data *time series* memiliki pola musiman maka model naive yang digunakan untuk peramalan adalah sebagai berikut

$$\hat{Y}_{t+R} = Y_{t+R-m} \quad (2.4)$$

dengan m adalah periode ramalan yang ditentukan (Hanke & Reitsch, 1995, hal. 147-150).

2.2. Regresi Time Series

Data *time series* memiliki beberapa pola komponen didalamnya. Komponen-komponen tersebut seperti tren, musiman, variasi kalender, dan fluktuasi yang tidak teratur (Bowerman, O'Connell, dan Koehler, 2005). Regresi dalam *time series* memiliki bentuk yang sama dengan bentuk umum regresi linier, yaitu dengan mengasumsikan *output* atau variabel dependen, Y_t , $t = 1, 2, \dots, n$ dipengaruhi oleh kumpulan *input* yang diduga mempengaruhi atau variabel independent. *Input* atau variabel independen tersebut bersifat *fixed* dan diketahui, hubungan ini dapat diartikan sebagai model regresi linier (Shumway dan Stoffer, 2006). Jika terdapat komponen tren pada data, maka persamaan regresi dituliskan sebagai berikut

$$Y_t = \delta t + \varepsilon_t \quad (2.5)$$

dengan ε_t adalah komponen *error* yang belum tentu memenuhi asumsi *white noise*.

Jika data mengandung komponen musiman $S_{1,t}, S_{2,t}, \dots, S_{m,t}$, maka persamaannya adalah

$$Y_t = \gamma_1 S_{1,t} + \gamma_2 S_{2,t} + \dots + \gamma_m S_{m,t} + \varepsilon_t \quad (2.6)$$

dengan $S_{1,t}, S_{2,t}, \dots, S_{m,t}$ adalah variabel *dummy* untuk pola musiman. Misalnya pola musimannya adalah bulanan makan akan ada 12 variabel *dummy*.

Data yang mengandung komponen variasi kalender juga dapat dimodelkan menggunakan regresi, dengan persamaan regresi dapat dituliskan sebagai berikut

$$Y_t = \psi_1 V_{1,t} + \psi_2 V_{2,t} + \dots + \psi_u V_{u,t} + \varepsilon_t \quad (2.7)$$

dengan $V_{u,t}$ adalah variabel *dummy* untuk efek variasi kalender ke- u . Jumlah efek kalender variasi dapat diidentifikasi berdasarkan pola dari data tersebut.

Jika data *time series* mengandung tiga komponen tersebut, yaitu tren, musiman, dan variasi kalender, maka persamaannya dapat dituliskan sebagai berikut

$$Y_t = \delta t + \gamma_1 S_{1,t} + \gamma_2 S_{2,t} + \dots + \gamma_m S_{m,t} + \psi_1 V_{1,t} + \psi_2 V_{2,t} + \dots + \psi_u V_{u,t} + \varepsilon_t \quad (2.8)$$

dengan, ψ adalah koefisien dari efek variasi kalender, δ adalah koefisien komponen tren, dan γ adalah koefisien komponen musiman.

2.3. Model Autoregressive Integrated Moving Average with Exogenous Variable (ARIMAX)

Model ARIMA adalah salah satu dari model *time series* univariat dan termasuk dalam kelompok model yang linier. Model ini digunakan untuk meramalkan data *time series* yang memiliki pola tren dan musiman atau hanya memiliki pola tren saja. Sedangkan model ARIMAX merupakan model ARIMA dengan penambahan variabel eksogen (Cryer dan Chan, 2008). Lee, Suhartono, dan Hamzah, (2010) menyatakan penambahan variabel eksogen pada model ARIMA berupa variasi kalender dapat dilakukan dengan variabel *dummy* sebagai efek variasi kalender. Model ARIMA secara umum dapat dituliskan sebagai berikut

$$\varepsilon_t = \frac{\theta_q(B)}{\phi_p(B)(1-B)^d} a_t \quad (2.9)$$

dengan a_t adalah *error* yang sudah memenuhi asumsi *white noise* dengan *mean* 0 dan varians konstan. Pembentukan model ARIMAX diawali dengan melakukan pemodelan regresi *time series*, jika *error* dari model regresi *time series* (ε_t) tidak memenuhi asumsi *white noise* maka residual dari model regresi *time series* dimodelkan menggunakan model ARIMA. Secara umum model ARIMAX dapat dituliskan seperti pada persamaan berikut ini

$$Y_t = \delta t + \gamma_1 S_{1,t} + \gamma_2 S_{2,t} + \dots + \gamma_m S_{m,t} + \psi_1 V_{1,t} + \psi_2 V_{2,t} + \dots + \psi_u V_{u,t} + \frac{\theta_q(B)}{\phi_p(B)(1-B)^d} a_t \quad . \quad (2.10)$$

Berikut ini adalah bagian-bagian dari model ARIMA (Wei, 2006)

1. Model Autoregressive (AR)

Model AR merepresentasikan sebuah proses Y_t yang berhubungan dengan Y pada waktu ke- t sebelumnya (Y_{t-k}) ditambah *error* (a_t). Berikut ini adalah persamaan umum untuk model AR(p) (Wei, 2006, hal. 45)

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \dot{Y}_t = a_t \quad (2.11)$$

atau

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \phi_2 \dot{Y}_{t-2} + \dots + \phi_p \dot{Y}_{t-p} + a_t \quad (2.12)$$

dengan,

$$\dot{Y}_t = Y_t - \mu. \quad (2.13)$$

2. Model *Moving Average* (MA)

Model MA adalah representasi dari proses Y_t dengan nilai *error* a_t pada waktu t sebelumnya. Persamaan secara umum untuk model MA(q) adalah sebagai berikut (Wei, 2006, hal. 47)

$$\dot{Y}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.14)$$

atau

$$\dot{Y}_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t. \quad (2.15)$$

3. Model *Autoregressive Moving Average* (ARMA)

Model ARMA adalah gabungan dari model AR dan MA, sehingga persamaannya adalah sebagai berikut (Wei, 2006, hal. 57)

$$\phi_p(B) \dot{Y}_t = \theta_q(B) a_t \quad (2.16)$$

atau

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \dots + \phi_p \dot{Y}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.17)$$

dengan,

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (2.18)$$

dan

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q. \quad (2.19)$$

4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA juga merupakan gabungan dari model AR dan MA dengan *differencing*. *Differencing* ini dilakukan untuk mengatasi data *time series* yang belum stasioner. Persamaan model ARIMA (p,d,q) adalah (Wei, 2006, hal. 72)

$$\phi_p(B)(1-B)^d = \theta_0 + \theta_q(B)a_t \quad (2.20)$$

dengan, (p): orde model AR, (d): order *differencing*, (q): order model MA. $\phi_p(B)$ adalah operator stasioner AR seperti pada Persamaan (2.18) dan $\theta_q(B)$ adalah operator *invertible* MA seperti pada Persamaan (2.19).

Model ARIMA dilakukan melalui tiga tahapan, yaitu identifikasi, estimasi, dan pengujian signifikansi parameter. Berikut ini adalah tahapan-tahapan yang harus dilakukan dalam pembentukan model ARIMA (Wei, 2006).

1. Identifikasi Model

Identifikasi model dilakukan untuk mengetahui kestasioneran data dalam *mean* dan varians dengan melihat *time series plot*, plot *Autorcorrelation Function* (ACF) dan plot *Partial Autorcorrelation Function* (PACF) dari data. Serta Pengujian stasioneritas dalam *mean* dapat dilakukan dengan *Augmented Dickey-Fuller Test* dan melihat plot ACF, sedangkan pendekripsi terhadap stasioneritas dalam variansi dapat dilakukan dengan menggunakan transformasi *Box-Cox*. Jika data belum stasioner dalam *mean* maka perlu dilakukan proses *differencing*.

ACF adalah fungsi yang digunakan untuk menjelaskan korelasi antara Y_t dan Y_{t+k} . Persamaan ACF adalah sebagai diberikan (Wei, 2006, hal. 20-21)

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, k = 1, 2, \dots \quad (2.21)$$

dengan $\bar{Y} = \left(\sum_{t=1}^n Y_t \right) / n$ adalah rata-rata dari sampel dan k adalah *lag* dari data.

Karena ρ_k dengan $k = 1, 2, \dots, K$ tidak diketahui sehingga diganti dengan estimasi dari sampel yaitu $\hat{\rho}_k$ dan berikut ini didapatkan persamaan untuk standar *error* atau batas dari nilai ACF pada pengujian stasioneritas adalah sebagai berikut

$$S_{\hat{\rho}_k} = \sqrt{\frac{1}{n} (1 + 2\hat{\rho}_1^2 + \dots + \hat{\rho}_K^2)}. \quad (2.22)$$

PACF digunakan untuk mengukur korelasi antara Y_t dan Y_{t+k} setelah pengaruh variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ dihilangkan. Korelasi kondisional untuk PACF dalam *time series* dapat dituliskan pada persamaan berikut ini

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.23)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{k,j} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, j = 1, 2, \dots, k. \quad (2.24)$$

Batas dari PACF yang digunakan pada pengujian stasioneritas adalah $\pm 2/\sqrt{n}$.

Pendugaan order AR dan MA juga dapat dilakukan berdasarkan karakteristik ACF dan PACF secara teoritis yang dijelaskan pada Tabel 2.1.

Tabel 2.1. Karakteristik Pola ACF dan PACF secara Teoritis

Proses	ACF	PACF
AR(p)	<i>Dies down</i> (turun cepat) secara eksponensial atau berpola sinusoidal	<i>Cuts off</i> setelah lag p
MA(q)	<i>Cuts off</i> setelah lag q	<i>Dies down</i> (turun cepat) secara eksponensial atau berpola sinusoidal
ARMA(p,q)	<i>Dies down</i> setelah lag $(q-p)$	<i>Dies down</i> setelah lag $(p-q)$

2. Estimasi dan Pengujian Signifikansi Parameter

Estimasi dari model dugaan yang diperoleh melalui ACF dan PACF yang telah dihitung sebelumnya dapat menggunakan *Maximum Likelihood Estimation* (MLE). Terdapat beberapa alternatif estimasi parameter menggunakan parameter, yang digunakan dalam penelitian ini adalah *Conditional Maximum Likelihood Estimation* atau MLE bersyarat (Wei, 2006, hal. 138). Persamaan model ARMA (p,q) secara umum adalah

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \dots + \phi_p \dot{Y}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}. \quad (2.25)$$

atau

$$a_t = \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} - \dot{Y}_t - \phi_1 \dot{Y}_{t-1} - \dots - \phi_p \dot{Y}_{t-p} \quad (2.26)$$

dengan $\dot{Y}_t = Y_t - \mu$, maka

$$\begin{aligned} a_t &= \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} - (Y_t - \mu) - \phi_1 (Y_{t-1} - \mu) - \dots - \phi_p (Y_{t-p} - \mu) \\ &= \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} - Y_t + \mu - \phi_1 Y_{t-1} + \phi_1 \mu - \dots - \phi_p Y_{t-p} + \phi_p \mu \end{aligned} \quad (2.27)$$

dan $a_t \sim iid N(0, \sigma_a^2)$ atau telah *white noise*. *Joint probability density* dari

$\mathbf{a} = (a_1, a_2, \dots, a_n)'$ diberikan sebagai berikut (Wei, 2006, hal. 139)

$$P(\mathbf{a} | \boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_a^2) = (2\pi\sigma_a^2)^{-n/2} \exp\left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2\right]. \quad (2.28)$$

fungsi *likelihood* dari parameter $(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_a^2)$ dapat dituliskan dengan diberikan deret waktu $\mathbf{Y} = (Y_1, Y_2, \dots, Y_n)'$ dan *initial conditions* $\mathbf{Y}_* = (Y_1, Y_2, \dots, Y_n)'$ dan $\mathbf{a} = (a_1, a_2, \dots, a_n)'$ diasumsikan telah diketahui.

Fungsi dari *log-likelihood* bersyarat adalah sebagai berikut

$$L_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_a^2) = -\frac{n}{2} \ln 2\pi\sigma_a^2 - \frac{S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})}{2\sigma_a^2} \quad (2.29)$$

dengan

$$S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}) = \sum_{t=1}^n a_t^2 (\boldsymbol{\phi}, \mu, \boldsymbol{\theta} | Y_*, a_*, Y) \quad (2.30)$$

adalah fungsi jumlah kuadrat bersyarat. Jumlah dari $\hat{\boldsymbol{\phi}}$, $\hat{\mu}$, dan $\hat{\boldsymbol{\theta}}$ yang memaksimumkan fungsi pada Persamaan (2.28) disebut estimator *Maximum Likelihood* bersyarat. Karena $\ln L_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_a^2)$ hanya melibatkan data pada $S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})$, estimator tersebut sama dengan estimator *least square* bersyarat yang diperoleh dari meminimumkan fungsi jumlah kuadrat bersyarat $S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})$ yang kita ketahui tida mengandung parameter σ_a^2 .

Beberapa alternatif untuk menentukan *initial conditions* \mathbf{Y}_* dan \mathbf{a}_* . Berdasarkan asumsi bahwa Y_t stasioner dan $a_t \sim iid N(0, \sigma_a^2)$ dan variabel *random*, maka Y_t yang tidak diketahui dapat diganti dengan rata-rata sample \bar{Y} dan a_t di ekspektasikan sama dengan 0. Model pada Persamaan (2.25) dapat diasumsikan $a_p = a_{p-1} = \dots = a_{p+1-q} = 0$ dan untuk a_t saat $t \geq (p+1)$ menggunakan Persamaan (2.26). Fungsi jumlah kuadrat bersyarat pada Persamaan (2.29) akan menjadi

$$S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}) = \sum_{t=1}^n a_t^2 (\boldsymbol{\phi}, \mu, \boldsymbol{\theta} | Y) \quad (2.31)$$

Setelah memperoleh estimasi parameter $\hat{\phi}, \hat{\mu}$, dan $\hat{\theta}$, estimasi untuk σ_a^2 adalah $\hat{\sigma}_a^2$ yang didapatkan dari persamaan berikut ini

$$\hat{\sigma}_a^2 = \frac{S_*(\phi, \mu, \theta)}{\text{d.f}} \quad (2.32)$$

dengan $\text{d.f} = n - (2p + q + 1)$.

Tahapan selanjutnya adalah melakukan uji signifikansi parameter. Diberikan $\alpha = (\phi, \mu, \theta)$, $\hat{\alpha}$ adalah estimasi dari α . Estimasi varians kovarians $\hat{V}(\hat{\alpha})$ dari $\hat{\alpha}$ adalah

$$\begin{aligned} \hat{V}(\hat{\alpha}) &= \sigma_a^2 (\bar{\underline{X}}_{\hat{\alpha}}' \bar{\underline{X}}_{\hat{\alpha}})^{-1} \\ &= (\hat{\sigma}_{\hat{\alpha}_i \hat{\alpha}_j}^2) \Big|_{i,j=1,2,\dots,p} \end{aligned} \quad (2.33)$$

dengan $i = 1, 2, \dots, p$, $\bar{\underline{X}}$ merupakan matriks variabel independen, dan estimasi $\hat{\sigma}_a^2$ dapat dilihat pada Persamaan (2.31). Sehingga untuk melakukan uji hipotesis signifikansi parameter digunakan statistik uji t dengan persamaan sebagai berikut (Wei, 2006, hal.145-148)

$$t_{\text{hitung}} = \frac{\hat{\alpha}_j - \alpha_{j0}}{\sqrt{\hat{\sigma}_{\hat{\alpha}_j \hat{\alpha}_j}^2}} \quad (2.34)$$

Misalkan untuk menguji signifikansi parameter model AR(p) dengan hipotesis yang digunakan adalah

$$H_0 : \phi_j = 0$$

$$H_0 : \phi_j \neq 0, \text{ dengan } j = 1, 2, \dots, p$$

Statistik uji yang digunakan adalah

$$t_{\text{hitung}} = \frac{\hat{\phi}_j}{SE(\hat{\phi}_j)} \quad (2.35)$$

$SE(\hat{\phi}_j)$ adalah *standard error* dari parameter model AR. H_0 ditolak jika nilai

$|t_{\text{hitung}}| > t_{\alpha/2, (n-n_p)}$ dengan n merupakan banyaknya pengamatan dan n_p adalah jumlah parameter yang diestimasi. Sedangkan hipotesis yang digunakan untuk melakukan uji signifikansi parameter untuk model MA adalah sebagai berikut

$$H_0 : \theta_j = 0$$

$$H_0 : \theta_j \neq 0, \text{ dengan } j = 1, 2, \dots, p$$

Statistik uji yang digunakan adalah

$$t_{hitung} = \frac{\hat{\theta}_j}{SE(\hat{\theta}_j)} \quad (2.36)$$

$SE(\hat{\theta}_j)$ adalah *standard error* dari parameter model MA. H_0 ditolak jika nilai $|t_{hitung}| > t_{\alpha/2, (n-n_q)}$ dengan n merupakan banyaknya pengamatan dan n_q adalah jumlah parameter yang diestimasi.

3. Cek Diagnostik

Setelah dilakukan estimasi dan pengujian signifikansi parameter, langkah selanjutnya adalah menilai kecukupan model dengan melakukan pengecekan apakah asumsi dari model telah terpenuhi. Asumsi mendasar yang harus dipenuhi adalah bahwa a_t telah bersifat *white noise*, serta residual tidak berkorelasi satu dengan lainnya dan dengan *mean 0* dan varians yang konstan. Terdapat beberapa cara dalam mengevaluasi apakah residual telah *white noise*, salah satunya adalah uji Ljung-Box. Pengujian ini menggunakan semua nilai ACF dari residual sampel dengan hipotesis sebagai berikut (Wei, 2006, hal. 152-153)

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (residual Independen)}$$

$$H_1 : \text{minimal ada satu nilai } \rho_k \neq 0, k = 1, 2, \dots, K \text{ (residual tidak independen)}$$

persamaan statistik uji χ^2_{hitung} adalah

$$\chi^2_{hitung} = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}. \quad (2.37)$$

H_0 ditolak jika nilai $\chi^2_{hitung} > \chi^2_{\alpha, K-p-q}$ dengan $\hat{\rho}_k$ adalah autokorelasi dari residual, nilai p adalah jumlah parameter AR dan q adalah jumlah parameter MA, n adalah banyaknya observasi, dan α adalah taraf signifikansi yang digunakan.

2.4. Variasi Kalender

Efek variasi kalender pada analisis *time series* telah mulai di teliti pada banyak penelitian sejak tahun 1980. Diantaranya adalah Liu (1980) dan Cleveland dan Devlin (1980) sebagai peneliti pertama yang mempelajari pengaruh dari efek variasi kalender. Liu (1980) mempelajari efek variasi liburan pada identifikasi dan estimasi model ARIMA. Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Di Indonesia yang sebagian besar penduduknya adalah muslim, data *series* ekonomi akan dipengaruhi oleh efek hari kerja dan efek liburan atau efek hari raya idul fitri. Karena komposisi hari dalam seminggu bervariasi dari bulan ke bulan dan tahun ke tahun. Hal ini yang mendasari terjadinya efek variasi kalender pada data *time series* (Lee, Suhartono, dan Hamzah, 2010). Persamaan model variasi kalender seperti yang sudah dituliskan pada Persamaan (2.7).

2.5. Time Series Multivariat

Time series multivariat merupakan analisis pada data *time series* yang memiliki lebih dari satu *series* data. Dalam *time series* multivariat, stasioneritas suatu data dilihat berdasarkan plot dari *matrix cross correlation function* (MCCF) dan *matrix partial cross correlation function* (MPCCF). Untuk mengidentifikasi stasioneritas suatu data diketahui bahwa, jika plot MCCF turun secara lambat, maka diindikasikan bahwa data belum stasioner dalam rata-rata dan perlu dilakukan proses *differencing* (Wei, 2006).

2.5.1. Vector Autoregressive (VAR)

Model VAR adalah pengembangan dari model AR yang diterapkan pada data *time series* multivariat. Model VAR dapat menjelaskan hubungan linier antara pengamatan pada variabel yang sama pada waktu yang berbeda (disebut dengan autokorelasi), dan juga hubungan linier antara pengamatan pada variabel yang berbeda pada waktu yang berbeda (disebut dengan korelasi silang). Jika diberikan $Y_{i,t}$ dengan $t = 1, 2, \dots, n$ merupakan indeks waktu, sedangkan $i = 1, 2, \dots, z$ adalah indeks dari variabel, maka model VAR dapat dituliskan sebagai berikut (Wei, 2006, hal. 387-388)

$$\Phi_p(B)\dot{Y}_t = \mathbf{a}_t \quad (2.38)$$

dengan

$$\Phi_p(B) = \Phi_0 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p$$

adalah matriks AR polinomial dari order p , Φ_0 adalah matriks $n \times n$ nonsingular, dan \mathbf{a}_t adalah dimensi dari n yang telah *white noise* dengan vektor rata-rata $\mathbf{0}$ dan kovarians Σ . Untuk melakukan identifikasi model pada model VAR digunakan *time series plot*, MCCF, dan MPCCF.

a) *Matrix Cross Correlation Function* (MCCF)

MCCF digunakan untuk mengidentifikasi stasioneritas data dalam *mean*. Suatu vektor data *time series* dengan jumlah observasi sebanyak n , Y_1, Y_2, \dots, Y_n maka persamaan MCCF dapat dituliskan sebagai berikut (Wei, 2006, hal. 401-402)

$$\hat{\mathbf{p}}(k) = [\hat{\rho}_{ij}(k)] \quad (2.39)$$

dengan, $\hat{\rho}_{ij}(k)$ adalah korelasi silang untuk komponen *series* ke- i dan ke- j pada *lag* ke- k yang dinyatakan dalam persamaan berikut :

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\sqrt{\sum_{t=1}^n (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^n (Y_{j,t} - \bar{Y}_j)^2}} \quad (2.40)$$

dengan, \bar{Y}_i dan \bar{Y}_j merupakan rata-rata sampel dari komponen *series* yang bersesuaian. Untuk stasioneritas vektor, Hannan (1970) dan Wei (2006) menunjukkan bahwa $\hat{\mathbf{p}}(k)$ merupakan matriks estimator yang konstan dan berdistribusi normal asimtotis. Bartlett (1966) dalam Wei (2006) telah memperoleh turunan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Berdasarkan hipotesis bahwa dua data *time series* Y_i dan Y_j tidak berkorelasi dan merupakan deret yang *white noise*

$$\text{cov}[\hat{\rho}_{ij}(k), \hat{\rho}_{ij}(k+s)] \approx \frac{1}{n-k} \quad (2.41)$$

dan

$$\text{var}[\hat{\rho}_{ij}(k)] \approx \frac{1}{n-k} \quad (2.42)$$

untuk ukuran sampel yang besar, $(n-k)$ dalam Persamaan (2.39) digantikan dengan n .

MCCF digunakan untuk menentukan order model MA(q). Dalam hal ini, bentuk matriks akan semakin kompleks seiring dengan bertambahnya dimensi vektor. Sehingga Tiao dan Box (1981) memperkenalkan metode yang lebih mudah dalam menjelaskan hasil korelasi sampel dengan menggunakan symbol (+), (-), dan (.) pada baris ke- i dan kolom ke- j pada matriks sampel korelasi. Simbol (+) menunjukkan nilai sampel korelasi $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali nilai estimasi *standar error* dan terdapat korelasi yang positif. Simbol (-) menunjukkan nilai sampel korelasi $\hat{\rho}_{ij}(k)$ kurang dari -2 kali estimasi *standar error* ada terdapat korelasi negatif, sedangkan simbol (.) menotasikan nilai yang berada diantara ±2 kali estimasi *standard error* dan tidak terdapat korelasi.

b) Matrix Partial Cross Correlation Function (MPCCF)

Pada analisis *time series* univariat, fungsi autokorelasi parsial (PACF) digunakan untuk menentukan order model AR (p). Generalisasi dari konsep PACF ke dalam bentuk vektor *time series* dilakukan oleh Tiao dan Box (1981) dalam Wei (2006, hal. 402-404), yang didefinisikan sebagai sebuah matriks autoregresi parsial pada *lag p* sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses VAR dari orde p . Notasi $\Phi_{p,p}$ dalam regresi linier multivariat dituliskan sebagai berikut :

$$\mathbf{Y}_{t+p} = \Phi_{p,1} \mathbf{Y}_{t+p+1} + \Phi_{p,2} \mathbf{Y}_{t+p+2} + \dots + \Phi_{p,p} \mathbf{Y}_t + \mathbf{a}_{p,t+p} \quad (2.43)$$

dengan $\mathbf{a}_{p,t+p}$ adalah komponen *error*.

Hesye dan Wei (1985a, 1985b) dalam Wei (2006) memperluas definisi parsial autokorelasi univariat menjadi vektor *time series* dan memperoleh matriks korelasi antara \mathbf{Y}_t dan \mathbf{Y}_{t+p} setelah menghilangkan dependensi linier dan masing-masing $\mathbf{Y}_{t+1}, \mathbf{Y}_{t+2}, \dots, \mathbf{Y}_{t+p-1}$. Matriks korelasi yang didefinisikan sebagai korelasi antar vektor residual memiliki persamaan sebagai berikut

$$\begin{aligned}\mathbf{u}_{p-1,t+p} &= \mathbf{Y}_{t+p} - \boldsymbol{\alpha}_{p-1,1} \mathbf{Y}_{t+p-1} - \dots - \boldsymbol{\alpha}_{p-1,p-1} \mathbf{Y}_{t+1} \\ &= \begin{cases} \mathbf{Y}_{t+p} - \sum_{k=1}^{p-1} \boldsymbol{\alpha}_{p-1,k} \mathbf{Y}_{t+p-k}, & p \geq 2, \\ \mathbf{Y}_{t+1}, & p = 1, \end{cases} \quad (2.44)\end{aligned}$$

$$\begin{aligned}\mathbf{v}_{p-1,t} &= \mathbf{Y}_t - \boldsymbol{\beta}_{p-1,1} Y_{t+1} - \dots - \boldsymbol{\beta}_{p-1,p-1} Y_{t+p-1} \\ &= \begin{cases} \mathbf{Y}_t - \sum_{k=1}^{p-1} \boldsymbol{\beta}_{p-1,k} \mathbf{Y}_{t+k}, & p \geq 2, \\ \mathbf{Y}_t, & p = 1. \end{cases} \quad (2.45)\end{aligned}$$

Meminimalisasi matriks koefisien regresi linier multivariat $\boldsymbol{\alpha}_{p-1,l}$ dan $\boldsymbol{\beta}_{p-1,k}$ menjadi

$$E\left[\left|\mathbf{u}_{p-1,t+p}\right|^2\right] = E\left[\left(\mathbf{Y}_{t+p} - \boldsymbol{\alpha}(p)\mathbf{Y}_t(p)\right)\left(\mathbf{Y}_{t+p} - \boldsymbol{\alpha}(p)\mathbf{Y}_t(p)\right)'\right] \quad (2.46)$$

dan

$$E\left[\left|\mathbf{v}_{p-1,t}\right|^2\right] = E\left[\left(\mathbf{Y}_t - \boldsymbol{\beta}(p)\mathbf{Y}_t\right)\left(\mathbf{Y}_t - \boldsymbol{\beta}(p)\mathbf{Y}_t\right)'\right]. \quad (2.47)$$

Minimum dari persamaan diatas untuk generalisasi multivariat didapat persamaan

$$\begin{aligned}\mathbf{A}_p \boldsymbol{\alpha}'_p &= \mathbf{c}_p \\ \mathbf{A}_p \boldsymbol{\beta}'_p &= \mathbf{b}_p\end{aligned} \quad (2.48)$$

$$\begin{bmatrix} \Gamma_0 & \Gamma'_0 & \cdots & \Gamma'_{p-2} \\ \Gamma_1 & \Gamma_0 & \cdots & \Gamma'_{p-3} \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma_{p-2} & \Gamma_{p-3} & \cdots & \Gamma'_0 \end{bmatrix} \begin{bmatrix} \boldsymbol{\alpha}'_{p-1,1} \\ \boldsymbol{\alpha}'_{p-1,2} \\ \vdots \\ \boldsymbol{\alpha}'_{p-1,p-1} \end{bmatrix} = \begin{bmatrix} \Gamma_1 \\ \Gamma_2 \\ \vdots \\ \Gamma_{p-1} \end{bmatrix} \quad (2.49)$$

untuk $p \geq 2$, didapatkan nilai \mathbf{A}_p , \mathbf{b}_p , dan \mathbf{c}_p adalah sebagai berikut

$$\begin{aligned}\mathbf{A}_p &= \begin{bmatrix} \Gamma_0 & \Gamma'_0 & \cdots & \Gamma'_0 \\ \Gamma_1 & \Gamma_0 & \cdots & \Gamma'_{p-3} \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma_{p-2} & \Gamma_{p-3} & \cdots & \Gamma'_0 \end{bmatrix}, \quad \mathbf{b}_p = \begin{bmatrix} \Gamma'_{p-1} \\ \Gamma'_{p-2} \\ \vdots \\ \Gamma'_1 \end{bmatrix}, \quad \mathbf{c}_p = \begin{bmatrix} \Gamma_1 \\ \Gamma_2 \\ \vdots \\ \Gamma_{p-1} \end{bmatrix} \\ \boldsymbol{\alpha}_p &= \begin{bmatrix} \boldsymbol{\alpha}'_{p-1,1} \\ \boldsymbol{\alpha}'_{p-1,2} \\ \vdots \\ \boldsymbol{\alpha}'_{p-1,p-1} \end{bmatrix}, \quad \boldsymbol{\beta}'_p = \begin{bmatrix} \boldsymbol{\beta}'_{p-1,p-1} \\ \boldsymbol{\beta}'_{p-1,p-2} \\ \vdots \\ \boldsymbol{\beta}'_{p-1,1} \end{bmatrix}\end{aligned}$$

sehingga, $\text{var}(\mathbf{u}_{p-1,t+p})$ dapat ditulis sebagai $\mathbf{V}_{\mathbf{u},p}$, $\text{var}(\mathbf{v}_{p-1,t})$ adalah $\mathbf{V}_{\mathbf{v},p}$ dan $\text{cov}(\mathbf{v}_{p-1,t}, \mathbf{u}_{p-1,t+p})$ sebagai $\mathbf{V}_{\mathbf{vu},p}$. Kemudian Hesye dan Wei (1985a, 1985b) dalam Wei (2006) mendapatkan persamaan untuk matriks autokorelasi *lag* parsial pada *lag p* sebagai berikut

$$\mathbf{P}(p) = [\mathbf{D}_v(p)]^{-1} \mathbf{V}_{vu}(p) [\mathbf{D}_v(p)]^{-1} \quad (2.50)$$

dengan $\mathbf{D}_v(p)$ adalah matriks diagonal elemen ke-*i* merupakan akar dari elemen diagonal ke-*i* dari $\mathbf{V}_v(p)$ dan $\mathbf{D}_u(p)$ didefinisikan sama untuk $\mathbf{V}_u(p)$. Elemen matriks estimasi $\hat{\mathbf{P}}_{ij}(p)$ dinotasikan dengan simbol (+), (-), dan (.). Simbol (+) artinya nilai lebih besar dari $2/\sqrt{T}$, simbol (-) artinya nilai kurang dari $-2/\sqrt{T}$, dan tanda (.) untuk nilai yang berada diantara $-2/\sqrt{T}$ dan $2/\sqrt{T}$ (Tiao dan Box, 1981) dalam Wei (2006).

2.5.2. Model Generalized Space-Time Autoregressive (GSTAR)

Model *Generalized Space Time Autoregressive* (GSTAR) merupakan suatu model yang dapat mengatasi asumsi yang menyatakan lokasi-lokasi penelitian yang bersifat heterogen, sehingga parameter untuk setiap lokasi berbeda. Model GSTAR merupakan pengembangan dari model *space time autoregressive* (STAR), dimana model STAR hanya dapat digunakan jika lokasi penelitian bersifat homogen, hal ini menyebabkan model GSTAR lebih fleksibel dari model STAR yang juga merupakan spesifikasi dari model *vector autoregressive* (VAR) (Borovkova, Lopuhua, dan Ruchjana, 2002).

Jika sebuah deret $\mathbf{Y}_t : t = 0, \pm 1, \pm 2, \dots$ adalah sebuah deret waktu multivariat dari *z* komponen, maka model GSTAR dengan order *autoregressive p* dan order spasial $\lambda_1, \lambda_2, \dots, \lambda_p$, atau disebut sebagai GSTAR $(p; \lambda_1, \lambda_2, \dots, \lambda_p)$ dalam notasi matriks dapat ditulis sebagai berikut (Wutsqa, Suhartono, dan Sutijo, 2010)

$$\begin{aligned} \mathbf{Y}_t &= \sum_{k=1}^p \left(\boldsymbol{\Phi}_{k0} \mathbf{Y}_{t-k} + \sum_{l=1}^{\lambda_k} \boldsymbol{\Phi}_{kl} \boldsymbol{\omega}^{(l)} \mathbf{Y}_{t-k} \right) + \mathbf{a}_t \\ &= \sum_{k=1}^p \left(\boldsymbol{\Phi}_{k0} + \sum_{l=1}^{\lambda_k} \boldsymbol{\Phi}_{kl} \boldsymbol{\omega}^{(l)} \right) \mathbf{Y}_{t-k} + \mathbf{a}_t \end{aligned} \quad (2.51)$$

dengan $\Phi_{k0} = \text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^z)$, $\Phi_{kl} = \text{diag}(\phi_{kl}^1, \dots, \phi_{kl}^z)$, \mathbf{a}_t merupakan vektor *error* berukuran $(z \times 1)$ yang independen, identik, dan berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarians $\sigma^2 \mathbf{I}_z$, $\boldsymbol{\omega}^{(l)}$ merupakan matriks bobot berukuran $(z \times z)$ untuk *lag* spasial $l = 0, 1, \dots, \lambda_p$ dan nilai pembobot yang dipilih memenuhi syarat $\omega_{ii}^{(l)} = 0$ dan $\sum_{i=1}^z \sum_{j=1}^z \omega_{ij}^{(l)} = 1$ untuk semua i dan j .

Sebagai contoh persamaan model GSTAR untuk order waktu dan order spasial satu, GSTAR(11) dengan menggunakan empat lokasi yang berbeda seperti persamaan berikut,

$$\mathbf{Y}_t = \Phi_{10} \mathbf{Y}_{t-1} + \Phi_{11} \boldsymbol{\omega}^{(1)} \mathbf{Y}_{t-1} + \mathbf{a}_t \quad (2.52)$$

dalam bentuk matriks, Persamaan (2.49) dapat ditulis sebagai berikut

$$\begin{pmatrix} Y_{1,t} \\ Y_{2,t} \\ Y_{3,t} \\ Y_{4,t} \end{pmatrix} = \begin{pmatrix} \phi_{10} & 0 & 0 & 0 \\ 0 & \phi_{20} & 0 & 0 \\ 0 & 0 & \phi_{30} & 0 \\ 0 & 0 & 0 & \phi_{40} \end{pmatrix} + \begin{pmatrix} \phi_{11} & 0 & 0 & 0 \\ 0 & \phi_{21} & 0 & 0 \\ 0 & 0 & \phi_{31} & 0 \\ 0 & 0 & 0 & \phi_{41} \end{pmatrix} \begin{pmatrix} 0 & \omega_{12} & \omega_{13} & \omega_{14} \\ \omega_{21} & 0 & \omega_{23} & \omega_{24} \\ \omega_{31} & \omega_{32} & 0 & \omega_{34} \\ \omega_{41} & \omega_{42} & \omega_{43} & 0 \end{pmatrix} \begin{pmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \\ Y_{4,t-1} \end{pmatrix} + \begin{pmatrix} a_{1,t} \\ a_{2,t} \\ a_{3,t} \\ a_{4,t} \end{pmatrix}.$$

Order model GSTAR pada umumnya order spasial dibatasi pada order satu karena order yang lebih tinggi akan sulit diinterpretasikan (Wutsqa, Suhartono, dan Sutijo, 2010). Order waktu (*autoregressive*) ditentukan dengan menggunakan AIC (Tsay, 2002). Akan tetapi penentuan order model berdasarkan nilai AIC tidak dapat menangkap pola-pola musiman, maka dari itu penentuan order model juga dapat dilakukan berdasarkan plot MCCF dan MPCCF yang terbentuk.

Jika data mengandung komponen musiman, maka model GSTAR yang digunakan adalah model umum GSTAR $(p, \lambda_1, \lambda_2, \dots, \lambda_p)^s$ untuk pola data musiman adalah sebagai berikut

$$\mathbf{Y}_t = \sum_{k=1}^p \left[\Phi_{k0}^s \mathbf{Y}_{t-s} + \sum_{l=1}^{\lambda_k} \Phi_{kl}^s \boldsymbol{\omega}^{(l)} \mathbf{Y}_{t-s} \right] + \mathbf{a}_t \quad (2.53)$$

dengan,

$\Phi_{k0}^s : \text{diag}(\phi_{k0}^{(1)}, \dots, \phi_{k0}^{(z)})$ merupakan matriks parameter waktu musiman s ,

$\Phi_{kl}^s : diag \left(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(z)} \right)$ merupakan matriks parameter spasial musiman s ,
 $\mathbf{a}_{(t)}$: vektor *error* berukuran $(z \times 1)$ yang independen, identik, berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarian $\sigma^2 \mathbf{I}_z$.

Nilai pembobot dipilih sedemikian hingga, sampai memenuhi syarat $\omega_i^{(l)} = 0$ dan $\sum_{j \neq i} \omega_{ij}^{(l)} = 1$. Misal, pada model GSTAR musiman dengan order musiman 1 dan periode musiman 12 ($s = 12$) dan orde spasial 1 adalah sebagai berikut

$$\mathbf{Y}_t = \left[\mathbf{\Phi}_{10}^{12} \mathbf{Y}_{t-12} + \mathbf{\Phi}_{11}^{12} \omega^{(l)} \mathbf{Y}_{t-12} \right] + \mathbf{a}_t \quad (2.54)$$

Generalized Space Time Autoregressive dengan variabel eksogen disebut dengan GSTARX. GSTARX adalah pengembangan dari model GSTAR dengan penambahan variabel eksogen dalam model. Pembentukan model GSTARX diawali dengan melakukan pemodelan regresi *time series*, selanjutnya residual dari pemodelan regresi *time series* dimodelkan menggunakan model GSTAR.

a. Penentuan Bobot Lokasi Model GSTAR

Terdapat beberapa cara dalam menentukan bobot lokasi pada model GSTAR, diantaranya adalah menggunakan bobot seragam, bobot biner, bobot *vers* jarak, bobot normalisasi korelasi silang, dan bobot normalisasi inferensi parsial korelasi silang (Borovkova, Lopuhua, dan Ruchjana, 2002; Ruchjana, 2002; Suhartono dan Atok, 2006; Suhartono dan Subanar, 2006). Sebagai ilustrasi, berikut ini disajikan peta empat lokasi Kantor Perwakilan Bank Indonesia di Wilayah Jawa Timur, yaitu Kota Surabaya, Kota Malang, Kota Kediri, dan Kabupaten Jember.



Gambar 2.1. Peta Lokasi dan Wilayah Kantor Bank Indonesia Wilayah Jawa Timur

(Sumber : maps.google.co.id)

1. Bobot Seragam (*Uniform*)

Bobot lokasi seragam memberikan nilai bobot yang sama untuk setiap lokasi (mengasumsikan bahwa lokasi-lokasi yang digunakan dalam penelitian bersifat homogen). Penentuan nilai bobot dalam bobot lokasi seragam adalah sebagai berikut

$$\omega_{ij} = \frac{1}{z-1} \quad (2.55)$$

Dengan $i \neq j$ dan z adalah banyaknya lokasi. Sehingga untuk ilustrasi lokasi pada Gambar 2.1, matriks pembobotnya adalah

$$\mathbf{\omega} = \begin{bmatrix} 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & 0 & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & 0 & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 \end{bmatrix}.$$

2. Bobot Biner

Metode dengan pembobot biner hanya bergantung pada keadaan yang terbatas. Pembobotan dengan metode biner memiliki pembobot dengan $\omega_{ij} = 0$ atau 1 . Misal, ilustrasi lokasi pada Gambar 2.1, matriks pembobotnya adalah sebagai berikut

$$\boldsymbol{\omega} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}.$$

3. Bobot Invers Jarak

Pembobotan dengan metode *invers* jarak dilakukan berdasarkan jarak sebenarnya antar lokasi di lapangan. Perhitungan bobot dengan metode *invers* jarak diperoleh dari normalisasi hasil *invers* jarak sebenarnya. Pada ilustrasi Gambar 2.1, perhitungan bobot jarak dari Kantor Bank Indonesia Wilayah Jawa Timur adalah berdasarkan pada jarak antar lokasi masing-masing Kantor Bank Indonesia Wilayah Jawa Timur (km).

Tabel 2.2. Jarak antar Kantor Bank Indonesia Wilayah Jawa Timur (km)

Kantor BI	Lokasi			
	Surabaya	Kediri	Malang	Jember
Surabaya	0	$J_{SK} = 123$	$J_{SM} = 89$	$J_{SJ} = 197$
Kediri	$J_{SK} = 123$	0	$J_{KM} = 100$	$J_{KJ} = 299$
Malang	$J_{SM} = 89$	$J_{KM} = 100$	0	$J_{MJ} = 192$
Jember	$J_{SJ} = 197$	$J_{KJ} = 299$	$d_{MJ} = 192$	0

Indeks pada Tabel 2.2 merupakan huruf pertama lokasi Kantor Bank Indonesia. Berikut ini adalah persamaan yang digunakan untuk menghitung bobot antar lokasi

$$\omega_{ij} = \frac{1/J_{ij}}{\sum_{j=1}^z 1/J_{ij}}, \quad j \neq i. \quad (2.56)$$

Didapatkan bobot antar lokasi Kantor Bank Indonesia wilayah Jawa Timur adalah sebagai berikut

$$\omega_{SK} = \frac{1/J_{SK}}{1/J_{SK} + 1/J_{SM} + 1/J_{SJ}} = \frac{1/123}{1/123 + 1/89 + 1/197} = 0,460$$

$$\omega_{SM} = \frac{1/J_{SM}}{1/J_{SK} + 1/J_{SM} + 1/J_{SJ}} = \frac{1/89}{1/123 + 1/89 + 1/197} = 0,333$$

$$\omega_{SJ} = \frac{1/J_{SJ}}{1/J_{SK} + 1/J_{SM} + 1/J_{SJ}} = \frac{1/197}{1/123 + 1/89 + 1/197} = 0,208; \text{ dst.}$$

Sehingga didapatkan matriks pembobot dengan metode *invers jarak* adalah

$$\mathbf{\Omega} = \begin{bmatrix} 0 & 0,460 & 0,333 & 0,208 \\ 0,425 & 0 & 0,378 & 0,197 \\ 0,377 & 0,464 & 0 & 0,159 \\ 0,370 & 0,380 & 0,250 & 0 \end{bmatrix}.$$

4. Bobot Normalisasi Korelasi Silang

Pembobotan dengan metode normalisasi korelasi silang adalah menggunakan hasil normalisasi korelasi silang antar lokasi pada *lag* yang bersesuaian yang pertama kali diperkenalkan oleh Suhartono dan Atok (2006). Secara umum korelasi silang antara lokasi ke-*i* dan ke-*j* pada *lag* waktu ke-*k*, $\text{corr}[Y_i(t), Y_j(t-k)]$, didefinisikan sebagai berikut

$$\rho_{ij}(k) = \frac{\kappa_{ij}(k)}{\sigma_i \sigma_j}, k = 0, \pm 1, \pm 2, \dots \quad (2.57)$$

dengan $\kappa_{ij}(k)$ merupakan kovarians silang antara kejadian di lokasi ke-*i* dan ke-*j*, pada *lag* waktu ke-*k*, σ_i dan σ_j adalah standar deviasi dari kejadian di lokasi ke-*i* dan ke-*j*. Taksiran dari korelasi silang ini pada data sampel dapat dihitung dengan persamaan berikut,

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=k+1}^n [Y_{i,t} - \bar{Y}_i][Y_{j,t-k} - \bar{Y}_j]}{\sqrt{\left(\sum_{t=k+1}^n [Y_{i,t} - \bar{Y}_i]^2 \right) \left(\sum_{t=k+1}^n [Y_{j,t} - \bar{Y}_j]^2 \right)}} \quad (2.58)$$

Penentuan bobot lokasi dapat dilakukan melalui normalisasi dari hasil besaran-besaran korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR(1₁) seperti pada persamaan berikut,

$$\omega_{ij} = \frac{\hat{\rho}_{ij}(1)}{\sum_{j=1}^z |\hat{\rho}_{ij}(1)|}, \quad (2.59)$$

dengan $i \neq j$ dan $\sum_{j \neq i} |\omega_{ij}| = 1$.

5. Bobot Normalisasi Inferensi Korelasi Silang (NIKS)

Pembobotan menggunakan NIKS tidak jauh berbeda dengan pembobotan normalisasi. Secara umum korelasi silang antara lokasi ke- i dan ke- j pada *lag* waktu ke- k , $\text{corr}[Y_{i,t}, Y_{j,t-k}]$, didefinisikan seperti pada persamaan (2.57). Taksiran dari persamaan korelasi silang data sampel dapat dilihat pada persamaan (2.58). Bartlett (1955) dalam Wei (2006) telah menurunkan varians dan kovarians dari korelasi silang yang diestimasi berdasarkan data sampel. Berdasarkan hipotesis, dua data *time series*, Y_i dan Y_j tidak berkorelasi yang ditunjukkan oleh persamaan,

$$\text{var}[\hat{\rho}_{ij}(k)] \approx \frac{1}{n-k} \left[1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s) \right] \quad (2.60)$$

Ketika Y_i dan Y_j adalah merupakan deret yang *white noise* maka diperoleh,

$$\text{var}[\hat{\rho}_{ij}(k)] \approx \frac{1}{n-k}, \quad (2.61)$$

untuk ukuran sampel besar, $(n-k)$ pada Persamaan (2.61) bisa diganti dengan n . Nilai-nilai korelasi silang pada sampel ini dapat diuji apakah sama atau berbeda dengan nol karena diasumsikan berdistribusi normal. Proses inferensi statistik dilakukan dengan taksiran interval seperti pada persamaan berikut

$$\hat{\rho}_{ij}(k) \pm \left[t_{\alpha/2; df} \frac{1}{\sqrt{n}} \right], \text{ dengan } df = n - k - 2 \quad (2.62)$$

Penentuan bobot lokasi dapat dilakukan dengan melakukan normalisasi dari hasil nilai korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR(1₁) seperti pada Persamaan (2.53). Bobot-bobot lokasi dengan menggunakan normalisasi dari hasil inferensi statistik terhadap korelasi silang antar lokasi pada *lag* waktu yang bersesuaian ini memungkinkan semua bentuk kemungkinan hubungan antar lokasi. Dengan demikian, tidak ada lagi batasan yang kaku tentang besarnya bobot,

terutama yang bergantung dari jarak antar lokasi. Bobot ini juga memberikan fleksibilitas pada besar dan tanda hubungan antar lokasi yang bisa berlainan (positif dan negatif) (Suhartono dan Atok, 2006).

b. Estimasi Parameter Model GSTAR

Metode OLS adalah metode estimasi parameter dengan meminimumkan jumlah kuadrat *error* (Borovkova, Lopuhaa, dan Ruchjana, 2008). Namun, metode OLS tidak dapat digunakan dalam mengestimasi parameter model GSTAR, karena diduga terdapat korelasi antar residual masing-masing lokasi estimasi metode OLS menjadi tidak efisien. Sehingga digunakan metode *Generalized Least Square* (GLS). GLS adalah penduga parameter regresi yang memperhatikan adanya korelasi dari residual antar persamaan, dengan nilai residual diperoleh dari penaksiran OLS.

Ordinary Least Square (OLS)

Jika diketahui parameter regresi waktu Φ_{10} dan spasial Φ_{11} seperti pada persamaan (2.54), dengan $\omega^{(1)}$ menyatakan bobot lokasi, maka model GSTAR(1₁) dapat dinyatakan dalam matriks sebagai berikut,

$$\mathbf{Y}_t = \mathbf{A}\mathbf{Y}_{t-1} + \mathbf{a}_t, \quad (2.63)$$

Dengan $\mathbf{A} = \Phi_0 + \Phi_1\omega$, Φ_0 dan Φ_1 merupakan matriks diagonal parameter autoregresi untuk waktu dan lokasi, dan ω merupakan matriks pembobot. Metode OLS sering digunakan dalam melakukan penaksiran parameter terhadap suatu model linier. Metode ini juga diterapkan pada model GSTAR(1₁) yang dapat dituliskan dalam bentuk linier sebagai berikut,

$$\begin{pmatrix} Y_1^{(1)} \\ Y_2^{(1)} \\ \vdots \\ Y_n^{(1)} \\ \vdots \\ Y_1^{(z)} \\ Y_2^{(z)} \\ \vdots \\ Y_n^{(z)} \end{pmatrix} = 1 \begin{pmatrix} Y_0^{(1)} & F_0^{(1)} & \dots & 0 & 0 \\ Y_1^{(1)} & F_1^{(1)} & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ Y_{n-1}^{(1)} & F_{n-1}^{(1)} & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & Y_0^{(z)} & F_0^{(z)} \\ 0 & 0 & \dots & Y_1^{(z)} & F_1^{(z)} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & Y_{n-1}^{(z)} & F_{n-1}^{(z)} \end{pmatrix} \begin{pmatrix} \phi_{01} \\ \phi_{11} \\ \vdots \\ \phi_{0z} \\ \phi_{1z} \\ \vdots \\ \phi_{nz} \end{pmatrix} + \begin{pmatrix} a_1^{(1)} \\ a_2^{(1)} \\ \vdots \\ a_n^{(1)} \\ \vdots \\ a_1^{(z)} \\ a_2^{(z)} \\ \vdots \\ a_n^{(z)} \end{pmatrix} \quad (2.64)$$

dengan $F_{i,t} = \sum_{j \neq i} \omega_{ij} Y_{j,t}$. Secara umum dapat ditulis sebagai $\mathbf{Y} = \mathbf{X}\beta + \mathbf{a}$, dengan

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}^{(1)} \\ \mathbf{Y}^{(2)} \\ \vdots \\ \mathbf{Y}^{(z)} \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} \mathbf{X}^{(1)} & 0 & \dots & 0 \\ 0 & \mathbf{X}^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}^{(z)} \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta^{(1)} \\ \beta^{(2)} \\ \vdots \\ \beta^{(z)} \end{pmatrix}, \quad \mathbf{a} = \begin{pmatrix} a^{(1)} \\ a^{(2)} \\ \vdots \\ a^{(z)} \end{pmatrix}, \quad (2.65)$$

dengan $i = 1, 2, \dots, z$, sehingga struktur model linier dari GSTAR(p_1) adalah

$$\mathbf{Y}^{(i)} = \begin{pmatrix} Y_p^{(i)} \\ Y_{p+1}^{(i)} \\ \vdots \\ Y_n^{(i)} \end{pmatrix}, \quad \mathbf{X}^{(i)} = \begin{pmatrix} Y_p^{(i)} & \dots & Y_1^{(i)} & F_p^{(i)} & \dots & F_1^{(i)} \\ Y_{p+1}^{(i)} & \dots & Y_2^{(i)} & F_{p+1}^{(i)} & \dots & F_2^{(i)} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ Y_{n-1}^{(i)} & \dots & Y_{n-p}^{(i)} & F_{n-1}^{(i)} & \dots & F_{n-p}^{(i)} \end{pmatrix}, \quad \beta^{(i)} = \begin{pmatrix} \phi_{10}^{(i)} \\ \vdots \\ \phi_{p0}^{(i)} \\ \phi_{11}^{(i)} \\ \vdots \\ \phi_{p1}^{(i)} \end{pmatrix}.$$

hal ini berarti estimator *least square* untuk $\beta^{(i)}$ dapat dihitung secara terpisah pada masing-masing lokasi namun tetap bergantung pada nilai \mathbf{Y}_t di lokasi yang lain dan untuk struktur model linier dari GSTAR(1_1) menjadi $\mathbf{Y}^{(i)} = \mathbf{X}^{(i)}\beta^{(i)} + \mathbf{a}^{(i)}$,

$$\mathbf{Y}^{(i)} = \begin{pmatrix} Y_1^{(i)} \\ Y_2^{(i)} \\ \vdots \\ Y_n^{(i)} \end{pmatrix}, \quad \mathbf{X}^{(i)} = \begin{pmatrix} Y_0^{(i)} & F_0^{(i)} \\ Y_1^{(i)} & F_1^{(i)} \\ \vdots & \vdots \\ Y_{n-1}^{(i)} & F_{n-1}^{(i)} \end{pmatrix}, \quad \beta_i = \begin{pmatrix} \phi_{i0} \\ \phi_{i1} \end{pmatrix}, \quad \text{dan } \mathbf{a}^{(i)} = \begin{pmatrix} a_1^{(i)} \\ a_2^{(i)} \\ \vdots \\ a_n^{(i)} \end{pmatrix},$$

dengan $F_t^{(i)} = \sum_{j \neq i} \omega_{ij} Y_j^{(i)}$.

Berdasarkan matriks yang telah diuraikan di atas, nilai taksiran untuk $\beta = (\phi_{10}, \phi_{11}, \phi_{20}, \phi_{21}, \dots, \phi_{z0}, \phi_{z1})'$ dengan n mendekati tak hingga (∞), dapat dihitung menggunakan estimator *least square* menjadi $\hat{\beta}_n = (\hat{\phi}_{10}, \hat{\phi}_{11}, \hat{\phi}_{20}, \hat{\phi}_{21}, \dots, \hat{\phi}_{z0}, \hat{\phi}_{z1})'$ sehingga

$$\mathbf{X}'\mathbf{X}\hat{\beta}_n = \mathbf{X}'\mathbf{Y} = \mathbf{X}'(\mathbf{X}\beta + \mathbf{a}) = \mathbf{X}'\mathbf{X}\beta + \mathbf{X}'\mathbf{a} \quad (2.66)$$

secara tidak langsung menyatakan $\mathbf{X}'\mathbf{X}(\hat{\beta}_n - \beta) = \mathbf{X}'\mathbf{a}$. Elemen-elemen dari matriks $\mathbf{X}'\mathbf{X}$ adalah

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} \mathbf{X}^{(1)'}\mathbf{X}^{(1)} & 0 & \dots & 0 \\ 0 & \mathbf{X}^{(2)'}\mathbf{X}^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}^{(z)'}\mathbf{X}^{(z)} \end{pmatrix}, \text{ dengan}$$

$$\mathbf{X}^{(i)'}\mathbf{X}^{(i)} = \begin{pmatrix} \sum_{t=0}^{n-1} (Y_t^{(i)})^2 & \sum_{t=0}^{n-1} Y_t^{(i)} F_t^{(i)} \\ \sum_{t=0}^{n-1} Y_t^{(i)} F_t^{(i)} & \sum_{t=0}^{n-1} (F_t^{(i)})^2 \end{pmatrix} \text{ dan } F_t^{(i)} = \sum_{j \neq i} \omega_{ij} Y_t^{(i)}.$$

Metode *least square* pada estimasi parameter model dapat dilakukan dengan meminimumkan fungsi

$$\mathbf{a}'\mathbf{a} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}), \quad (2.67)$$

dengan demikian hasil estimator $\boldsymbol{\beta}$ didapat sebagai berikut

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}, \quad (2.68)$$

untuk vektor parameter ϕ_{i0} dan ϕ_{i1} , $i = 1, 2, \dots, z$ adalah

$$\hat{\phi}_i = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}^{(i)}. \quad (2.69)$$

Generalized Least Square (GLS)

GLS sering digunakan di dalam model *Seemingly Unrelated Regression* (SUR). Model SUR merupakan suatu metode estimasi model yang terdiri dari beberapa persamaan dan variabel-variabelnya tidak bersifat dua arah, akan tetapi terdapat korelasi antar persamaan-persamaan tersebut, sehingga terjadi korelasi antara kesalahan-kesalahan persamaan tersebut (Zellner, 1962). Suhartono dkk., (2016) membandingkan metode estimasi menggunakan GLS dan OLS dari data simulasi antar lokasi yang saling berkorelasi atau tidak semua saling berkorelasi, menyimpulkan bahwa nilai *standard error* untuk model GSTARX-GLS lebih kecil dibandingkan model GSTARX-OLS. Hal ini berarti bahwa estimasi parameter dengan model GSTARX-GLS lebih efisien dibandingkan dengan model GSTARX-OLS. Secara umum model SUR dituliskan sebagai berikut,

$$\begin{aligned}
Y_t^{(1)} &= \beta_{10} + \beta_{11} X_{1t,1} + \beta_{12} X_{1t,2} + \cdots + \beta_{1Z_1} X_{1t,Z_1} + e_t^{(1)} \\
Y_t^{(2)} &= \beta_{20} + \beta_{21} X_{2t,1} + \beta_{22} X_{2t,2} + \cdots + \beta_{2Z_2} X_{2t,Z_2} + e_t^{(2)} \\
&\vdots \\
Y_t^{(z)} &= \beta_{z0} + \beta_{z1} X_{zt,1} + \beta_{z2} X_{zt,2} + \cdots + \beta_{zZ_z} X_{zt,Z_z} + e_t^{(z)}
\end{aligned} \tag{2. 70}$$

dengan $t = 1, 2, \dots, n$, dan n merupakan jumlah pengamatan, Z adalah jumlah variabel bebas, z menyatakan jumlah persamaan dalam sistem, dan $e_t^{(1)}, e_t^{(2)}, \dots, e_t^{(z)}$ saling berkorelasi. Model SUR dengan z variabel dependen dinyatakan dengan persamaan sebagai berikut

$$\mathbf{Y}^{(i)} = \mathbf{X}^{(i)} \boldsymbol{\beta}^{(i)} + \mathbf{e}^{(i)} \tag{2. 71}$$

Dengan $i = 1, 2, \dots, z$. $\mathbf{Y}^{(i)}$ adalah vektor pengamatan terurut berukuran $n \times 1$ pada variabel dependen, $\mathbf{X}^{(i)}$ merupakan matriks pengamatan berukuran $n \times k$ pada variabel independen, $\boldsymbol{\beta}^{(i)}$ adalah vektor parameter berukuran $k \times 1$, dan $\mathbf{e}^{(i)}$ adalah vektor residual berukuran $n \times 1$. Persamaan (2.70) dapat ditulis dalam bentuk matriks sebagai berikut,

$$\begin{pmatrix} \mathbf{Y}_{(n \times 1)}^{(1)} \\ \mathbf{Y}_{(n \times 1)}^{(2)} \\ \vdots \\ \mathbf{Y}_{(n \times 1)}^{(z)} \end{pmatrix} = \begin{pmatrix} \mathbf{X}_{(n \times k)}^{(1)} & 0 & \cdots & 0 \\ 0 & \mathbf{X}_{(n \times k)}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{X}_{(n \times k)}^{(z)} \end{pmatrix} \begin{pmatrix} \boldsymbol{\beta}_{(k \times 1)}^{(1)} \\ \boldsymbol{\beta}_{(k \times 1)}^{(2)} \\ \vdots \\ \boldsymbol{\beta}_{(k \times 1)}^{(z)} \end{pmatrix} + \begin{pmatrix} \mathbf{e}_{(n \times 1)}^{(1)} \\ \mathbf{e}_{(n \times 1)}^{(2)} \\ \vdots \\ \mathbf{e}_{(n \times 1)}^{(z)} \end{pmatrix} \tag{2. 72}$$

atau $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$. Asumsi yang harus dipenuhi dalam persamaan model SUR adalah $E(\mathbf{e}) = 0$ dan $E(\mathbf{e}^{(i)} \mathbf{e}^{(j)\prime})$. Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR diberikan dengan

$$E[\mathbf{e}^{(i)} \mathbf{e}^{(j)\prime}] = \begin{bmatrix} e^{(1)} \\ e^{(2)} \\ \vdots \\ e^{(z)} \end{bmatrix} \begin{bmatrix} e^{(1)} & e^{(2)} & \cdots & e^{(z)} \end{bmatrix}, \tag{2. 73}$$

dari Persamaan (2.73) dapat diuraikan menjadi

$$E[\mathbf{e}^{(i)}\mathbf{e}^{(j)\prime}] = \begin{bmatrix} E(e^{(1)}e^{(1)}) & E(e^{(1)}e^{(2)}) & \cdots & E(e^{(1)}e^{(z)}) \\ E(e^{(2)}e^{(1)}) & E(e^{(2)}e^{(2)}) & \cdots & E(e^{(2)}e^{(z)}) \\ \vdots & \vdots & \ddots & \vdots \\ E(e^{(z)}e^{(1)}) & E(e^{(z)}e^{(2)}) & \cdots & E(e^{(z)}e^{(z)}) \end{bmatrix}. \quad (2.74)$$

Karena $E(\mathbf{e}_i\mathbf{e}'_j) = \sigma_{ij}\mathbf{I}$ sehingga dapat dituliskan

$$E[\mathbf{e}^{(i)}\mathbf{e}^{(j)\prime}] = \begin{pmatrix} \sigma_{11}\mathbf{I} & \sigma_{12}\mathbf{I} & \cdots & \sigma_{1z}\mathbf{I} \\ \sigma_{21}\mathbf{I} & \sigma_{22}\mathbf{I} & \cdots & \sigma_{2z}\mathbf{I} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{z1}\mathbf{I} & \sigma_{z2}\mathbf{I} & \cdots & \sigma_{zz}\mathbf{I} \end{pmatrix}. \quad (2.75)$$

Persamaan (2.75) apabila diuraikan menggunakan perkalian Kronecker (\otimes) maka akan didapatkan

$$\begin{aligned} E[\mathbf{e}^{(i)}\mathbf{e}^{(j)\prime}] &= \begin{pmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1z} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2z} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{z1} & \sigma_{z2} & \cdots & \sigma_{zz} \end{pmatrix} \otimes \mathbf{I} \\ &= \Sigma \otimes \mathbf{I} \\ &= \Omega, \end{aligned} \quad (2.76)$$

$$\text{dengan } \Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1z} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2z} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{z1} & \sigma_{z2} & \cdots & \sigma_{zz} \end{bmatrix} \text{ dan } \mathbf{I} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}.$$

Σ merupakan matriks varians-kovarians dari *error* yang berukuran $(z \times z)$ dan \mathbf{I} merupakan matriks identitas berukuran $(z \times z)$.

Pendekatan yang dapat digunakan untuk mengestimasi parameter dari model SUR adalah metode GLS (Baltagi, 1980), yang merupakan pengembangan dari OLS. Jika proses estimasi parameter pada OLS dilakukan dengan cara meminimumkan fungsi persamaan berikut ini,

$$\mathbf{e}'\mathbf{e} = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta), \quad (2.77)$$

maka untuk GLS dapat dikembangkan dengan cara meminimumkan fungsi $\mathbf{e}'\Omega^{-1}\mathbf{e} = (\mathbf{Y} - \mathbf{X}\beta)' \Omega^{-1} (\mathbf{Y} - \mathbf{X}\beta)$. Sehingga estimator untuk β diperoleh dengan rumus sebagai berikut

$$\hat{\beta} = (\mathbf{X}' \boldsymbol{\Omega}^{-1} \mathbf{X})^{-1} \mathbf{X}' \boldsymbol{\Omega}^{-1} \mathbf{Y} \quad (2.78)$$

Menurut Ruchjana (2002) model GSTAR khususnya GSTAR(1₁) merupakan versi yang terbatas dari model VAR. Oleh karena itu, kondisi stasioner model GSTAR dapat diperoleh dari kondisi stasioner model VAR. Sehingga, model GSTAR(1₁), $\mathbf{Y}_t = [\Phi_{10} + \Phi_{11}\boldsymbol{\omega}^{(1)}] \mathbf{Y}_{t-1} + \mathbf{e}_t$ dapat diwakili dengan model VAR(1),

$\mathbf{Y}_t = \Phi_1 \mathbf{Y}_{t-1} + \mathbf{e}_t$, dengan

$$\Phi_1 = [\Phi_{10} + \Phi_{11}\boldsymbol{\omega}^{(1)}] \quad (2.79)$$

secara umum model GSTAR yang merupakan proses stasioner adalah jika semua *eigenvalue* dari matriks $[\Phi_{10} + \Phi_{11}\boldsymbol{\omega}^{(1)}]$ memenuhi syarat $|\lambda| < 1$.

Suhartono dan Subanar (2007) menyatakan bahwa kondisi stasioner pada model GSTAR, khususnya untuk parameter pada model GSTAR(1₁) dapat menggunakan syarat < 1 yang disajikan dalam model VAR(1). Oleh karena itu, untuk mengetahui kondisi stasioneritas parameter model GSTAR(1₁) harus disajikan dalam bentuk VAR(1) terlebih dahulu. Bentuk umum peramalan model GSTAR dapat ditulis seperti persamaan berikut,

$$\hat{\mathbf{Y}}_t = \sum_{k=1}^p \left[\Phi_{k0} \mathbf{Y}_{t-s} + \sum_{l=1}^{\lambda_k} \Phi_{kl} \boldsymbol{\omega}^{(l)} \mathbf{Y}_{t-s} \right]. \quad (2.80)$$

2.6. Uji Terasvirta

Sebelum melakukan pemodelan *time series* nonlinier terlebih dahulu dilakukan uji linieritas pada data *time series*. Ada beberapa uji nonlinieritas, salah satunya adalah uji Terasvirta, yang dikembangkan oleh Terasvirta dkk., (1993). Uji Terasvirta merupakan uji yang dikembangkan dari model *neural networks* dan termasuk dalam kelompok uji tipe Lagrange Multiplier (LM) yang dikembangkan dengan ekspansi Taylor. Implementasi praktis uji Terasvirta dapat dilakukan melalui dua statistik uji, yaitu uji χ^2 atau uji *F*. Prosedur untuk mendapatkan uji *F* adalah sebagai berikut,

1. Meregresikan Y_t pada $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ kemudian hitung nilai residual $\hat{u}_t = Y_t - \hat{Y}_t$ serta jumlah kuadrat residual $SSR_0 = \sum_{t=1}^n \hat{u}_t^2$.
2. Meregresikan \hat{u}_t pada $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ dan D prediktor tambahan adalah suku kuadratik dan kubik yang merupakan hasil pendekatan ekspansi taylor, kemudian hitung nilai residual $\hat{v}_t = \hat{u}_t - \hat{\hat{u}}_t$ serta jumlah kuadrat residual $SSR_1 = \sum_{t=1}^n \hat{v}_t^2$.

Berikut ini adalah persamaan untuk statistik uji Terasvirta

$$F = \frac{(SSR_0 - SSR_1) / D}{SSR_1 / (n - p - 1 - D)} \quad (2.81)$$

dengan n adalah banyaknya pengamatan yang digunakan. Tolak H_0 apabila $F_{hitung} > F_{(\alpha; D, (n - p - 1 - D))}$ atau $P\text{-value}$ kurang dari taraf signifikan (α), hal ini berarti suatu model linier dikatakan sebagai *neglected nonlinearity*. Pada kondisi ini perlu dibangun model nonlinier untuk estimasi model yang lebih sesuai.

2.7. Artificial Neural Network (ANN)

ANN atau jaringan saraf tiruan merupakan suatu sistem pemrosesan informasi yang memiliki karakteristik performa tertentu dalam jaringan saraf biologis, dalam penelitian ini ANN dipandang sebagai suatu obyek matematika atau secara khusus sebagai suatu model *time series*, dengan asumsi sebagai berikut

- i. Pemrosesan informasi terjadi pada *simple element* yang disebut *neuron*.
- ii. Sinyal dilewatkan di antara neuron di atas *connection links*.
- iii. Masing-masing *connection link* memiliki bobot yang dikalikan dengan sinyal yang ditransmisi.
- iv. Masing-masing *neuron* menggunakan fungsi aktivasi pada *net input* (jumlahan sinyal input terboboti) untuk menentukan sinyal *output*.

Sebuah neural network digolongkan berdasarkan pola *connection* di antara neuron (disebut juga arsitektur), metode dalam mentukan bobot dari *connection* (disebut *training*, *learning*, atau *algoritma*), dan fungsi aktivasi (Fausett, 1994). Sebelum melakukan pemodelan menggunakan ANN, dilakukan pengujian linieritas pada

data yang akan dianalisis. Pengujian linieritas yang digunakan pada penelitian ini menggunakan uji Terasvirta. Apabila terdapat pola nonlinieritas pada data, maka model ANN dapat digunakan. Terdapat beberapa jenis desain arsitektur ANN, diantaranya *back-propagation (feedforward)*, *recurrent network*, *self-organizing map*, *radial basis function network*, dan sebagainya. Metode ANN yang banyak digunakan dalam peramalan adalah *feedforward neural network* (FFNN) dan yang akan digunakan dalam penelitian ini adalah FFNN dan *Recurrent Neural Network* (RNN), RNN termasuk dalam *Deep Learning Neural Network* (DLNN) yang saat ini sudah mulai banyak digunakan.

2.7.1. Feedforward Neural Network (FFNN)

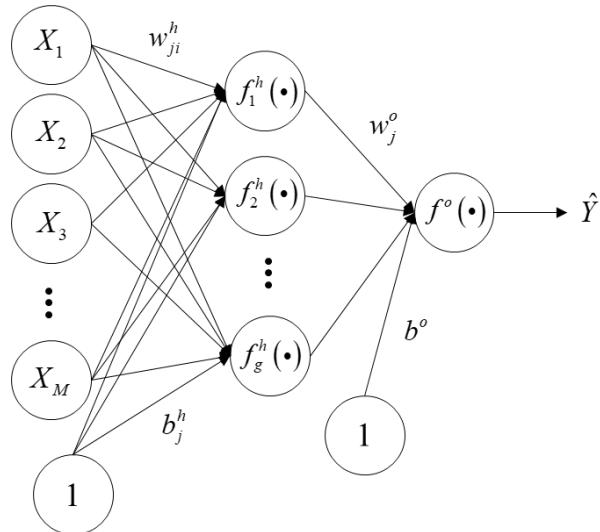
FFNN memiliki beberapa lapisan, yaitu lapisan *input (input layer)*, satu atau lebih lapisan tersembunyi (*hidden layers*) dan lapisan *output (output layer)*. Proses dimulai dari *input* yang diterima oleh *neuron*, dimana *neuron-neuron* ini dikelompokkan dalam *layer*. Informasi yang diterima dari *input layer* dilanjutkan ke *hidden layer* dalam FFNN secara berurutan hingga mencapai *layer output*. Setiap *neuron* akan menerima informasi hanya dari *neuron* pada *layer* sebelumnya dimana *input neuron* berasal dari bobot *Output* pada *layer* sebelumnya (Chong & Zak, 2001). Model FFNN dalam pemodelan statistik untuk peramalan runtun waktu dapat dipandang sebagai suatu model *nonlinear autoregressive*. Bentuk ini mempunyai keterbatasan, yaitu hanya dapat menangkap dan menjelaskan efek *autoregressive* (AR) pada data *time series* (Suhartono, 2007). Model NN telah banyak digunakan untuk menyelesaikan berbagai masalah terapan lain peramalan runtun waktu, *pattern recognition*, *signal processing*, dan proses kontrol yang dilakukan oleh Suhartono, (2007). Bentuk arsitektur NN yang secara umum paling banyak digunakan dalam aplikasi bidang teknik atau rekayasa adalah *Multilayer Perceptrons* (MLP) yang juga dikenal dengan FFNN. Bentuk umum dari FFNN adalah sebagai berikut.

$$\hat{Y}_t = f^0 \left[\sum_{j=1}^g \left[w_j^0 f_j^h \left(\sum_{i=1}^M w_{ji}^h X_{i,t} + b_j^h \right) + b^0 \right] \right] \quad (2.82)$$

dengan

- $X_{i,t}$: variabel *input* sebanyak M , ($i=1,2,\dots,M$)
 \hat{Y}_t : nilai dugaan dari variabel *output*
 t : indeks pasangan data *input-target* ($X_{i,t}, Y_t$), $t = 1, 2, \dots, n$
 w_{ji}^h : bobot dari *input* ke- i yang menuju *neuron* ke- j pada *hidden layer*, dengan $j = 1, 2, \dots, g$
 b_j^h : bias *neuron* ke- j pada *hidden layer*, ($j = 1, 2, \dots, g$)
 f_j^h : fungsi aktivasi di *neuron* ke- j pada *hidden layer*
 w_j^o : bobot dari *neuron* ke- j pada *hidden layer* yang menuju ke *neuron* pada *output layer*
 b^o : bias pada *neuron* di *output layer*
 f^o : fungsi aktivasi pada *neuron* di *output layer*

Berikut ini ditunjukkan bentuk arsitektur dari model FFNN



Gambar 2.2. Arsitektur Model FFNN dengan Satu *Hidden Layer*

Gambar 2.2 menunjukkan arsitektur model FFNN dengan satu *hidden layer*, M unit neuron pada *input layer*, g unit neuron pada *hidden layer*, serta satu unit neuron pada *output layer*. Fungsi aktivasi yang digunakan pada *hidden layer* adalah fungsi *hyperbolic tangent* (\tanh), dengan persamaan berikut ini

$$f^h(x) = \tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} = \frac{1 - \exp(-2x)}{1 + \exp(-2x)} \quad (2.83)$$

Parameter ANN disebut bobot, yang biasanya diestimasi dengan *supervised learning algorithm*. Terdapat beberapa macam algoritma dalam ANN, salah satunya adalah algoritma *backpropagation*. Berikut ini merupakan urutan langkah-langkah dalam algoritma *backpropagation* secara detail (Fausett, 1994).

Langkah 1: Inisiasi bobot.

Langkah 2: Selama kondisi berhenti salah, kerjakan langkah 3 sampai dengan 8.

Langkah 3: Tiap unit *input* ($X_i, i=1, 2, \dots, M$) menerima isyarat masukan X dan diteruskan ke unit-unit *hidden layer*.

Langkah 4: Tiap *hidden layer* ($y_j, j=1, 2, \dots, g$) menjumlahkan bobot sinyal *input*.

$$y_in_j = w_{0j} + \sum_{i=1}^M X_i w_{ij}. \quad (2.84)$$

Dengan menerapkan fungsi aktivasi hitung sebagai berikut

$$y_j = f(y_in_j). \quad (2.85)$$

Apabila fungsi aktivasi yang digunakan adalah *hyperbolic tangent*, maka hasil keluaran yang didapat pada *hidden layer* seperti persamaan berikut

$$y_j = \tanh(y_in_j). \quad (2.86)$$

Kemudian mengirimkan isyarat ini pada unit *output*.

Langkah 5: Unit *output* (y) menjumlahkan isyarat masukan berbobot.

$$y_in = v_0 + \sum_{j=1}^g z_j v_j. \quad (2.87)$$

Dengan menerapkan fungsi aktivasi hitung sebagai berikut

$$y = f(y_in). \quad (2.88)$$

Langkah 6: Unit *output* (y) menerima pola pelatihan masukannya dan menghitung *error* informasinya, dengan t merupakan *output target*

$$\eta = (t - y) f'(y_in). \quad (2.89)$$

Hitung koreksi bobot dan biasnya.

$$\Delta v_j = \alpha \eta z_j \quad (2.90)$$

$$\Delta v_0 = \alpha \eta \quad (2.91)$$

Langkah 7: Tiap *hidden layer* ($z_j, j=1,2,\dots,g$) menghitung delta masukannya (dari unit-unit yang berada pada lapisan atasnya).

$$\eta_{in_j} = \eta v_j \quad (2.92)$$

Hitung *error* informasinya.

$$\eta_j = \eta_{in_j} f'(z_{in_j}) \quad (2.93)$$

Hitung koreksi bobot dan biasnya.

$$\Delta w_{ij} = \alpha \eta_j X_i \quad (2.94)$$

Langkah 8: Unit keluaran (y) memperbarui bobot dan bias.

$$v_0(new) = v_0(old) + \Delta v_0 \quad (2.95)$$

$$v_k(new) = v_k(old) + \Delta v_k \quad (2.96)$$

Tiap *hidden layer* ($y_j, j=1,2,\dots,J$) memperbarui bobot dan biasnya.

$$v_{ik}(new) = v_{ik}(old) + \Delta v_{ik} \quad (2.97)$$

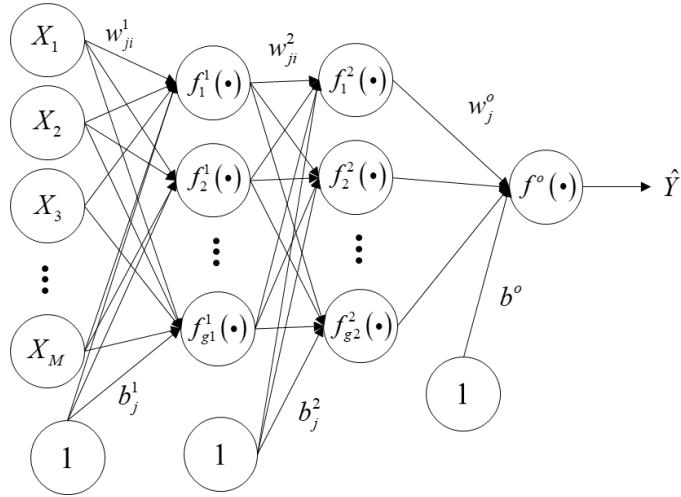
Langkah 9: Uji syarat berhenti.

Langkah 3, 4, dan 5 merupakan langkah *feedforward*, langkah 6 dan 7 termasuk *backpropagation*, sedangkan langkah 8 dan 9 adalah untuk memperbaiki bobot dan bias. Algoritma *backpropagation* dapat melakukan *learning* hingga didapatkan hasil yang paling optimum. Cara algoritma *backpropagation* memaksimalkan hasil *learning* adalah dengan meminimalkan besar *error* yang terjadi. Pada algoritma ini, *error* diminimalisir dengan cara memodifikasi pembobot yang digunakan dalam perhitungan. Ketika ditemukan bobot baru, proses pelatihan akan dilakukan kembali. Proses ini akan dilakukan secara berulang-ulang dan akan berhenti pada saat didapatkan *error* yang telah memenuhi uji syarat berhenti.

2.7.2. Deep Learning Neural Network (DLNN)

DLNN merupakan tipe arsitektur ANN yang juga sering digunakan, DLNN memiliki model arsitektur yang serupa dengan model arsitektur FFNN namun dengan jumlah *hidden layer* yang berbeda. DLNN memiliki dua *hidden layer*, dan FFNN hanya memiliki satu *hidden layer*. Arsitektur DLNN dengan duan *hidden layer* merupakan model arsitektur yang lebih dalam dibandingkan model FFNN,

sehingga model DLNN mampu memodelkan fungsi yang rumit dengan lebih efisien (Dalto, Matsuko, & Vasak, 2015).



Gambar 2.3. Arsitektur Model DLNN dengan Dua *Hidden Layer*

Berikut ini adalah persamaan untuk nilai *output* \hat{Y}_t

$$\hat{Y}_t = f^0 \left(b^0 + \sum_{j=1}^{g2} w_j^0 f_j^2 \left(b_j^2 + \sum_{j=1}^{g1} w_j^2 f_j^1 \left(b_j^1 + \sum_{i=1}^M w_{ji}^1 x_i \right) \right) \right) \quad (2.98)$$

dengan

- \hat{Y}_t : nilai dugaan dari variabel *output*
- X_i : Variabel *input* sebanyak M ($i = 1, 2, \dots, M$)
- t : indeks pasangan data *input-target* $(X_{i,t}, Y_t), t = 1, 2, \dots, n$
- w_j^2 : bobot *neuron* ke- j dari *hidden layer* pertama menuju *hidden layer* kedua, dengan $j = 1, 2, \dots, g2$
- w_{ji}^1 : bobot dari *input* ke- i yang menuju *neuron* ke- j pada *hidden layer* pertama, dengan $j = 1, 2, \dots, g1$
- b_j^2 : bias *neuron* ke- j pada *hidden layer* kedua, ($j = 1, 2, \dots, g2$)
- b_j^1 : bias *neuron* ke- j pada *hidden layer* pertama, ($j = 1, 2, \dots, g1$)
- f_j^2 : fungsi aktivasi di *neuron* ke- j pada *hidden layer* kedua
- f_j^1 : fungsi aktivasi di *neuron* ke- j pada *hidden layer* pertama
- w_j^o : bobot dari *neuron* ke- j pada *hidden layer* kedua yang menuju ke *neuron* pada *output layer*

b^o : bias pada *neuron* di *output layer*

f^o : fungsi aktivasi pada *neuron* di *output layer*

Setelah proses penjumlahan *input* dan bobot pada *hidden layer* pertama pada *neuron* ke- j digunakan v_j^1 untuk menyatakan suatu vektor nilai-nilai dengan persamaan berikut ini

$$v_j^1 = b_j^1 + \sum_{i=1}^M w_{ji}^1 X_i \quad (2.99)$$

Output pada *hidden layer* pertama *neuron* ke- j disimbolkan a_j^1 dengan persamaan sebagai berikut

$$a_j^1 = f_j^1 \left(b_j^1 + \sum_{i=1}^M w_{ji}^1 X_i \right). \quad (2.100)$$

Suatu vector nilai-nilai setelah proses penjumlahan *input* dan bobot pada *hidden layer* kedua *neuron* ke- j dinyatakan sebagai v_j^2 dengan persamaan berikut ini

$$v_j^2 = b_j^2 + \sum_{i=1}^{g^1} w_{ji}^2 a_j^1. \quad (2.101)$$

Output pada *hidden layer* kedua *neuron* ke- j dinyatakan sebagai a_j^2 , dengan persamaan berikut ini

$$a_j^2 = f_j^2 (v_j^2). \quad (2.102)$$

Sehingga didapatkan notasi dari penjumlahan *input* dan bobot pada *output layer* adalah sebagai berikut

$$v_j^o = b_j^o + \sum_{j=1}^{g^2} w_{ji}^o a_j^2 \quad (2.103)$$

$$\hat{Y}_i = f^o (v^o). \quad (2.104)$$

Persamaan yang menunjukkan hubungan antara *input* $X_i, i=1, 2, \dots, M$, dengan *output* \hat{Y}_i dapat dituliskan sebagaimana Persamaan (2.104).

Algoritma yang digunakan pada model DLNN sama dengan algoritma pada model FFNN, menggunakan algoritma *backpropagation*. Bobot pada model DLNN diperbarui menggunakan formula *gradient descent*. Tahapan dalam mengestimasi nilai dari $b^o, w_j^o, b_j^2, w_{ji}^2, b_j^1$, dan w_{ji}^1 adalah sama dengan tahapan pada model FFNN.

Pembaharuan bobot dan bias pada model DLNN ini menggunakan persamaan-persamaan berikut ini:

Persamaan pada *output layer*

$$w_j^{o(h+1)} = w_j^{o(h)} + \eta \sum_{t=1}^n \tau_t^{o(h)} a_j^{2(h)} \quad (2. 105)$$

$$b^{o(h+1)} = b^{o(h)} + \eta \sum_{t=1}^n \tau_t^{o(h)} \quad (2. 106)$$

dengan

$$\tau_t^o = (Y_t - \hat{Y}_t) f^{o'} \left(b^o + \sum_{j=1}^{g^2} w_t^o a_j^2 \right) \quad (2. 107)$$

Persamaan pada *hidden layer* kedua

$$w_{ji}^{2(h+1)} = w_{ji}^{2(h)} + \eta \sum_{t=1}^n \tau_t^{2(h)} a_j^{1(h)} \quad (2. 108)$$

$$b_j^{2(h+1)} = b_j^{2(h)} + \eta \sum_{t=1}^n \tau_t^{2(s)} \quad (2. 109)$$

dengan

$$\tau_t^2 = \tau_t^o w_j^o f_j^2 \left(b_j^2 + \sum_{j=1}^{g^1} w_{ji}^2 a_j^1 \right) \quad (2. 110)$$

Persamaan pada *hidden layer* pertama

$$w_{ji}^{1(h+1)} = w_{ji}^{1(h)} + \eta \sum_{t=1}^n \tau_t^{1(h)} x_i \quad (2. 111)$$

$$b_j^{1(h+1)} = b_j^{1(h)} + \eta \sum_{t=1}^n \tau_t^{1(s)} \quad (2. 112)$$

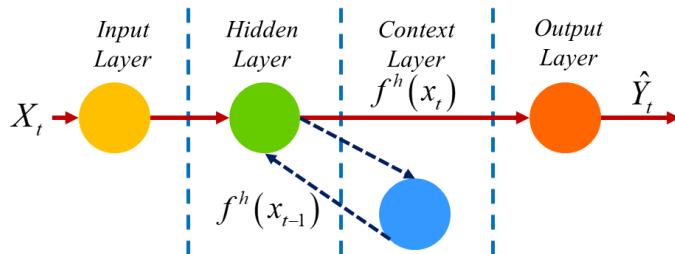
dengan

$$\tau_t^1 = \tau_t^o \tau_t^2 w_{ji}^o f_j^1 \left(b_j^1 + \sum_{i=1}^n w_{ji}^1 X_i \right) \quad (2. 113)$$

2.7.3. Recurrent Neural Network (RNN)

RNN merupakan pengembangan jaringan *perceptron multilayer* yang termasuk *input layer*, *hidden layer*, dan *output layer*. Dalam RNN, semua *neuron* terkoneksi dengan *neuron* yang lain, aliran informasi yang terjadi adalah multidireksional, jadi aktivasi dari setiap *neuron* dapat terjadi secara memutar

dalam sistem *loop* (Lewis, 2016). Perbedaan RNN dengan FFNN adalah FFNN hanya dapat memetakan *input* ke vektor *output* (pemetaan satu ke satu). Sedangkan RNN dapat memetakan dari *history input* sebelumnya ke setiap *output* atau pemetaan urutan-ke-urutan (Li & Cao, 2017). RNN adalah salah satu bentuk NN yang lebih fleksibel daripada FFNN. Model RNN dikatakan fleksibel karena *output* jaringan dijadikan sebagai input untuk mendapatkan *output* berikutnya. Model RNN juga disebut dengan *Autoregressive Moving Average Neural Network* (ARMA-NN), karena selain himpunan beberapa *lag* variabel respon atau target sebagai input, juga melibatkan *lag-lag* dari selisih prediksi target dengan nilai aktual target atau yang dikenal dengan *lag-lag error* (Trapletti, 2000). Secara umum bentuk arsitektur model RNN sama dengan model ARMA(p,q). Hal yang membedakan adalah fungsi runtun waktu bersifat nonlinier pada model RNN dan linier pada model ARMA(p,d,q). Sehingga model RNN dikatakan sebagai model *autoregressive moving average* yang nonlinier. Gambar 2.4. menunjukkan arsitektur RNN sederhana.

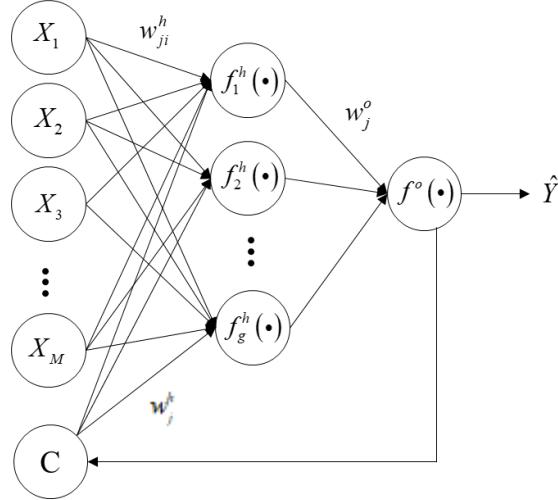


Gambar 2.4. Arsitektur *Recurrent Neural Network* (RNN) Sederhana

Gambar 2.4 di atas menunjukkan arsitektur sederhana dari RNN. Perbedaan arsitektur RNN dan FFNN adalah pada RNN terdapat sebuah *layer* baru yang diberi nama *context layer* yang berisi *delay neuron*. *Delay neuron* ini adalah *neuron* yang menyimpan memori yang berada pada nilai-nilai aktivasi pada langkah sebelumnya, kemudian *neuron* ini juga yang akan melepaskan nilai-nilai yang telah disimpan tadi kembali pada jaringan pada langkah waktu selanjutnya.

Jordan Neural Networks merupakan bagian dari RNN dengan pola kerja yang sama dengan *Elman Neural Networks*, akan tetapi perbedaan antara *Jordan RNN* dengan *Elman RNN* adalah pada *Jordan RNN neuron* pada *context layer* dialiri informasi melalui *output layer* bukan *hidden layer* seperti layaknya pada

Elman RNN (Lewis, 2016). Gambar 2.5 berikut ini menunjukkan arsitektur Jordan RNN dengan sebanyak M input.



Gambar 2.5. Arsitektur Model Jordan RNN

Berdasarkan Gambar 2.5 tersebut dapat diketahui bahwa *context layer* tersebut terkoneksi dengan *output layer*. Berdasarkan Gambar 2.5 dapat diperoleh fungsi dari *output* adalah sebagai berikut

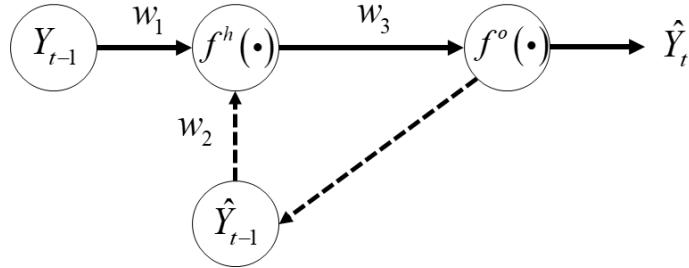
$$\hat{Y}_t = f^o \left[\sum_{j=1}^g \left[w_j^o f_j^h \left(\sum_{i=1}^M w_{ji}^h X_{i,t} + w_j^h C_t \right) \right] \right] \quad (2.114)$$

dengan

- $C_t = \hat{Y}_{t-1}$: *Context layer* yang selanjutnya menjadi *input*
- $X_{i,t}$: variabel *input* sebanyak M , ($i = 1, 2, \dots, M$)
- \hat{Y}_t : nilai dugaan dari variabel *output*
- t : indeks pasangan data *input-target* $(X_{i,t}, Y_t)$, $t = 1, 2, \dots, n$
- w_{ji}^h : bobot dari *input* ke- i yang menuju *neuron* ke- j pada *hidden layer*, dengan $j = 1, 2, \dots, g$
- f_j^h : fungsi aktivasi di *neuron* ke- j pada *hidden layer*
- w_j^o : bobot dari *neuron* ke- j pada *hidden layer* yang menuju ke *neuron* pada *output layer*
- w_j^h : bobot dari *neuron* pada *context layer* menuju *hidden layer* ke- j
- b^o : bias pada *neuron* di *output layer*

f^o : fungsi aktivasi pada *neuron* di *output layer*

Contoh pemodelan menggunakan Jordan RNN dengan satu *neuron* pada *hidden layer* dan satu *input* yaitu *lag* ke-1 maka arsitektur yang terbentuk dijelaskan pada Gambar 2.6.



Gambar 2.6. Arsitektur Model Jordan RNN dengan Satu *Neuron* pada *Hidden Layer*

Berdasarkan arsitektur pada Gambar 2.6. dapat dituliskan model Jordan RNN yang terbentuk dapat ditulis

$$\hat{Y}_t = f^o \left(w_3 f^h \left(w_1 Y_{t-1} + w_2 \hat{Y}_{t-1} \right) \right) \quad (2.115)$$

dengan $Y_{t-1} = \hat{Y}_{t-1} + a_{t-1}$ maka $Y_{t-1} - a_{t-1} = \hat{Y}_{t-1}$, sehingga persamaan (2.112) menjadi

$$\hat{Y}_t = f^o \left(w_3 f^h \left(w_1 Y_{t-1} + w_2 (\hat{Y}_{t-1} - a_{t-1}) \right) \right) \quad (2.116)$$

Selanjutnya diperoleh persamaan berikut ini

$$\hat{Y}_t = f^o \left(w_3 f^h \left((w_1 + w_2) Y_{t-1} - w_2 (a_{t-1}) \right) \right). \quad (2.117)$$

2.8. Model *Hybrid GSTARX-ANN*

Model *hybrid* pertama kali diperkenalkan oleh Zhang (2003) dengan tujuan untuk menambah keakuratan ramalan. Model *hybrid* mengombinasikan komponen linier dan nonlinier yang secara matematis dapat dituliskan seperti persamaan berikut

$$Y_t = Y_t^{Linier} + Y_t^{Nonlinier} + e_t, \quad (2.118)$$

dengan Y_t^{Linier} merupakan komponen linier dan $Y_t^{Nonlinier}$ merupakan komponen nonlinier. Dalam penelitian ini, pemodelan *hybrid* dilakukan secara dua tahap. Tahap pertama yaitu memodelkan pola tren, musiman, dan variasi kalender menggunakan model TSR sebagai komponen linier. Tahap kedua yaitu memodelkan residual tahap pertama dengan GSTAR-ANN. Model GSTAR-ANN

yang yang digunakan terdiri dari GSTAR-FFNN dengan satu *hidden layer*, GSTAR-DLNN dengan dua *hidden layer* dan GSTAR-Jordan RNN.

2.9. Pemilihan Model Terbaik

Kriteria pemilihan model terbaik yang digunakan adalah nilai RMSE (*Root Mean Square Error*) dan sMAPE (*Symmetric Mean Absolute Percentage Error*) untuk kriteria pada data *in sample* dan *out sample*. Model terbaik dinyatakan dengan nilai RMSE terkecil. Berikut ini adalah persamaan untuk mendapatkan nilai RMSE (Wei, 2006, hal. 181).

$$MSE = \frac{1}{R} \sum_{r=1}^R (Y_{n+r} - \hat{Y}_n(r))^2 \quad (2. 119)$$

$$RMSE = \sqrt{MSE}. \quad (2. 120)$$

Sedangkan sMAPE merupakan bentuk simetrik dari MAPE dengan persamaan berikut ini (Gooijer dan Hyndman, 2006)

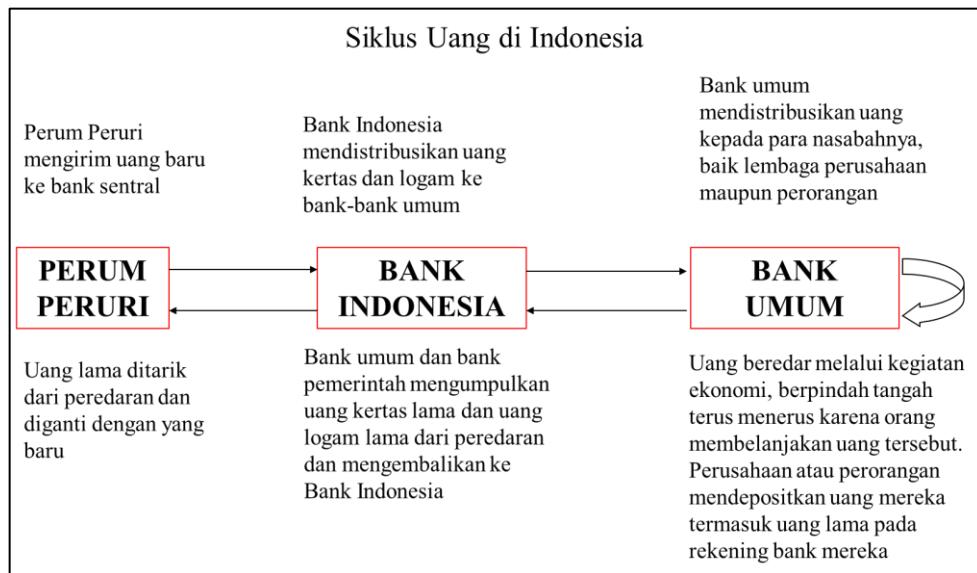
$$sMAPE = \left(\frac{1}{R} \sum_{r=1}^R \frac{2|Y_{n+r} - \hat{Y}_n(r)|}{|Y_{n+r} + \hat{Y}_n(r)|} \right) \times 100\% \quad (2. 121)$$

dengan R adalah banyaknya ramalan atau panjang data *out sample*.

2.10. *Inflow* dan *Outflow* Uang Kartal Bank Indonesia

Dalam penyusunan Rencana Distribusi Uang (RDU) terdapat beberapa faktor yang dijadikan pertimbangan, yaitu : (i) jumlah setoran (*inflow*) dan bayaran (*outflow*) ; (ii) uang yang dimusnahkan (PTTB) ; (iii) jumlah posisi kas; dan (iv) kondisi ekonomi serta geografis daerah secara spesifik. Perkembangan *outflow* dan *inflow* di setiap daerah sesungguhnya mencerminkan suatu pola pergerakan permintaan uang kartal yang dipengaruhi oleh faktor pertumbuhan ekonomi, perkembangan inflasi, perbandingan jumlah kredit dan dana, jumlah kantor bank & jaringan ATM, perkembangan suatu daerah (termasuk otonomi daerah), faktor musiman, tingkat usia edar uang dan jarak antar suatu daerah. Perkembangan *outflow* dan *inflow* di setiap daerah mencerminkan suatu pola pergerakan permintaan uang kartal yang dipengaruhi oleh faktor pertumbuhan ekonomi, perkembangan inflasi, perkembangan suatu daerah (termasuk otonomi daerah), faktor musiman, dan lain sebagainya. Faktor musiman dalam perkembangan *inflow*

dan *outflow* mencakup faktor musiman harian, mingguan, atau bulanan serta faktor yang dipengaruhi oleh sosial budaya disuatu daerah tertentu, seperti hari raya suatu agama, adat istiadat dan sebagainya (Sigalingging dkk., 2004). Berikut ini adalah diagram aliran peredaran uang di Indonesia

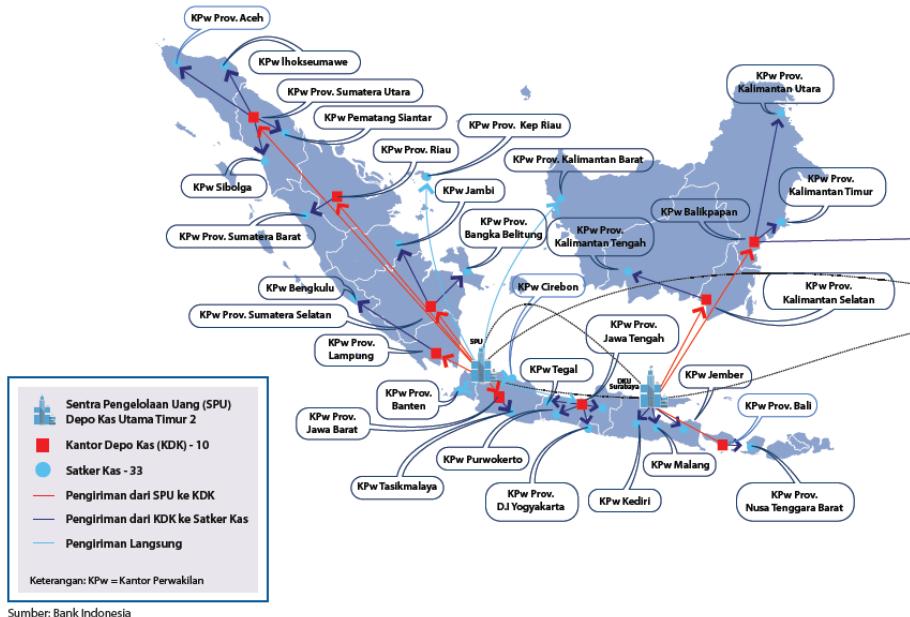


Gambar 2. 7. Diagram Alir Siklus Peredaran Uang di Indonesia

Pertumbuhan ekonomi di Jawa Timur pada triwulan II 2019 mencapai 5,7% (yoy), lebih tinggi dibandingkan triwulan sebelumnya sebesar 5,6% (yoy). Dibandingkan dengan provinsi di Pulau Jawa, kinerja perekonomian Jawa Timur pada periode ini tumbuh lebih tinggi dibandingkan DKI Jakarta, Jawa Barat, Jawa tengah, serta Banten. Pada triwulan II 2019 pergerakan *inflow* dan *outflow* di Jawa Timur dalam posisi *net outflow* sebesar Rp 2,8 triliun. Hal ini sejalan dengan peningkatan kebutuhan masyarakat selama bulan Ramadhan dan perayaan hari raya idul fitri, serta sejalan dengan peningkatan PDRB Jawa Timur. Peningkatan *outflow* di Jawa Timur disebabkan oleh peningkatan kebutuhan uang kartal dan logam di masyarakat baik dalam bentuk Uang Pecahan Kecil (UPK) maupun Uang Pecahan Besar (UPB) untuk belanja kebutuhan bulan Ramadhan dan hari raya idul fitri.

Secara spasial *outflow* terbesar pada triwulan II 2019 terjadi di BI Provinsi Jawa Timur sebesar Rp. 17,3 triliun, disusul BI Kediri sebesar Rp. 7,8 triliun, BI Malang Rp. 5,6 triliun dan BI Jember Rp. 5,3 triliun. Gambar 2.8 menunjukkan bahwa Kantor Bank Indonesia Surabaya merupakan Sentra Pengelolaan Uang (SPU) Depo Kas Utama (DKU) Timur 2. Sehingga, KP BI Surabaya ini juga disebut

DKU Surabaya, selain bertugas mendistribusikan uang ke BI Malang, BI Kediri, dan BI Jember, DKU Surabaya juga bertugas mendistribusikan uang ke Kantor Depo Kas (DKK) Kalimantan dan Bali.



Gambar 2. 8 Peta Jaringan Pendistribusian Uang

Tabel 2. 3. Wilayah Kerja Bank Indonesia Jawa Timur

Wilayah Kerja	Area
Kantor Perwakilan Bank Indonesia Provinsi Jawa Timur (BI Jawa Timur)	Kota Surabaya, Kota Mojokerto, Kabupaten Gresik, Kabupaten Sidoarjo, Kabupaten Mojokerto, Kabupaten Jombang, Kabupaten Sampang, Kabupaten Pamekasan, Kabupaten Sumenep, Kabupaten Bangkalan, Kabupaten Bojonegoro, Kabupaten Tuban, dan Kabupaten Lamongan
Kantor Perwakilan Bank Indonesia Malang (BI Malang)	Kota Malang, Kota Batu, Kota Pasuruan, Kota Probolinggo, Kabupaten Malang, Kabupaten Pasuruan dan Kabupaten Probolinggo
Kantor Perwakilan Bank Indonesia Kediri (BI Kediri)	Kota Kediri, Kota Blitar, Kota Madiun, Kabupaten Kediri, Kabupaten Ngawi, Kabupaten Magetan, Kabupaten Nganjuk, Kabupaten Tulungagung, Kabupaten Ponorogo, Kabupaten Madiun, Kabupaten Blitar, Kabupaten Trenggalek, dan Kabupaten Pacitan
Kantor Perwakilan Bank Indonesia Jember (BI Jember)	Kabupaten Jember, Kabupaten Lumajang, Kabupaten Bondowoso, Kabupaten Situbondo, Kabupaten Banyuwangi

BAB 3

METODOLOGI PENELITIAN

Pada bab ini akan dibahas tahapan penelitian yang meliputi studi simulasi dan kajian terapan menggunakan metode GSTARX dan *hybrid* GSTARX-Jordan RNN. Data simulasi mengandung komponen tren, musiman, variasi kalender, dan residual yang mengikuti pola linier maupun nonlinier. Sedangkan kajian terapan menggunakan data *inflow* dan *outflow* uang kartal di Kota Surabaya, Malang, Kediri dan Jember.

3.1. Kajian Simulasi

Kajian simulasi dilakukan untuk mengetahui kebaikan model *hybrid* GSTARX-Jordan RNN dalam memodelkan data *time series* yang memiliki efek komponen tren, musiman, variasi kalender, dan residual yang mengikuti pola linier maupun nonlinier. Tahapan-tahapan dalam melakukan studi simulasi adalah sebagai berikut:

- a. Membangkitkan data yang memiliki efek komponen tren, musiman, variasi kalender (efek hari raya Idul Fitri) dengan persamaan sebagai berikut,

$$Y_t^{(i)} = T_t^{(i)} + S_t^{(i)} + V_t^{(i)} + N_t^{(i)} \quad (3.1)$$

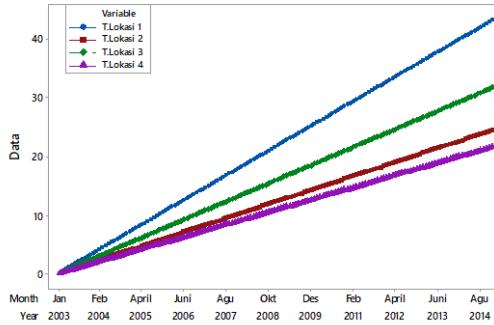
$i = 1,2,3,4$ yang menyatakan lokasi dengan,

- i. Komponen tren yang digunakan merupakan komponen linier dengan persamaan sebagai berikut,

$$T_t^{(i)} = \delta^{(i)} t \quad (3.2)$$

Koefisien untuk tren yang digunakan dalam seluruh skenario adalah sama, yaitu $\delta^{(1)} = 0,3$ $\delta^{(2)} = 0,17$ $\delta^{(3)} = 0,22$ $\delta^{(4)} = 0,15$.

Berikut ini adalah hasil pembangkitan data komponen tren memiliki pola seperti pada gambar berikut ini untuk masing-masing lokasi



Gambar 3. 1. Time Series Plot Komponen Tren

- ii. Komponen musiman diperoleh dengan persamaan sebagai berikut,

$$S_t^{(i)} = \gamma_1^{(i)} S_{1,t} + \gamma_2^{(i)} S_{2,t} + \dots + \gamma_{12}^{(i)} S_{12,t} \quad (3.3)$$

Koefisien pada data komponen musiman dibangkitkan menggunakan persamaan *sinus* berikut ini

$$\gamma_t^{(i)} = c^{(i)} + d^{(i)} \sin\left(\frac{2\pi t}{12}\right) \quad (3.4)$$

dengan

$$\gamma_1^{(i)} = \gamma_t^{(i)}; \text{ untuk } t = 1, 13, \dots, 133$$

$$\gamma_2^{(i)} = \gamma_t^{(i)}; \text{ untuk } t = 2, 14, \dots, 134$$

$$\gamma_3^{(i)} = \gamma_t^{(i)}; \text{ untuk } t = 3, 15, \dots, 135$$

:

$$\gamma_{12}^{(i)} = \gamma_t^{(i)}; \text{ untuk } t = 12, 24, \dots, 144$$

Konstanta yang digunakan untuk koefisien $c^{(i)} = 12$ dan $d^{(1)} = 9$, $d^{(2)} = 4$, $d^{(3)} = 7$, dan $d^{(4)} = 5$. Koefisien $c^{(i)}$ dan $d^{(i)}$ ini ditentukan berdasarkan data acuan pembangkitan data, dan koefisien tersebut menentukan tinggi rendah fluktuasi musiman pada setiap lokasi. Sehingga didapatkan koefisien pada persamaan untuk komponen musiman di masing-masing lokasi adalah sebagai berikut:

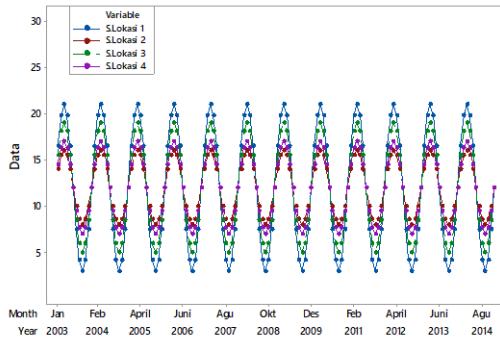
$$S_t^{(1)} = 16,5S_{1,t} + 19,79S_{2,t} + 21S_{3,t} + 19,79S_{4,t} + 16,5S_{5,t} + 12S_{6,t} + 7,5S_{7,t} + 4,21S_{8,t} + 3S_{9,t} + 4,21S_{10,t} + 7,5S_{11,t} + 12S_{12,t}$$

$$S_t^{(2)} = 14S_{1,t} + 15,46S_{2,t} + 16S_{3,t} + 15,46S_{4,t} + 14S_{5,t} + 12S_{6,t} + 10S_{7,t} + 8,54S_{8,t} + 8S_{9,t} + 8,54S_{10,t} + 10S_{11,t} + 12S_{12,t}$$

$$S_t^{(3)} = 15,5S_{1,t} + 18,1S_{2,t} + 19S_{3,t} + 18,1S_{4,t} + 15,5S_{5,t} + 12S_{6,t} + 8,5S_{7,t} + 5,9S_{8,t} + 5S_{9,t} + 5,9S_{10,t} + 8,5S_{11,t} + 12S_{12,t}$$

$$S_t^{(4)} = 14,5S_{1,t} + 16,3S_{2,t} + 17S_{3,t} + 16,3S_{4,t} + 14,5S_{5,t} + 12S_{6,t} + 9,5S_{7,t} + 7,7S_{8,t} + 7S_{9,t} + 7,7S_{10,t} + 9,5S_{11,t} + 12S_{12,t}$$

Berikut ini adalah *time series plot* untuk komponen musiman



Gambar 3. 2. Time Series Plot Komponen Musiman

- iii. Komponen untuk variasi kalender pada studi simulasi ini hanya menggunakan model simulasi data *outflow*, sehingga efek variasi kalender yang digunakan adalah pada saat terjadinya Hari raya Idul Fitri dan satu bulan sebelum Hari raya Idul Fitri, dengan persamaan sebagai berikut,

$$V_t^{(i)} = \psi_{i,1} V_{1,t} + \dots + \psi_{i,4} V_{4,t} + \psi_{i,1} V_{1,t-1} + \dots + \psi_{i,4} V_{4,t-1} \quad (3.5)$$

dengan

Efek satu bulan sebelum hari raya idul fitri, yaitu

$$V_{1,t-1} = \begin{cases} 1, & \text{satu bulan sebelum idul fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

⋮

$$V_{4,t-1} = \begin{cases} 1, & \text{satu bulan sebelum idul fitri yang terjadi pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Efek pada bulan saat hari raya idul fitri, yaitu

$$V_{1,t} = \begin{cases} 1, & \text{bulan saat idul fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

⋮

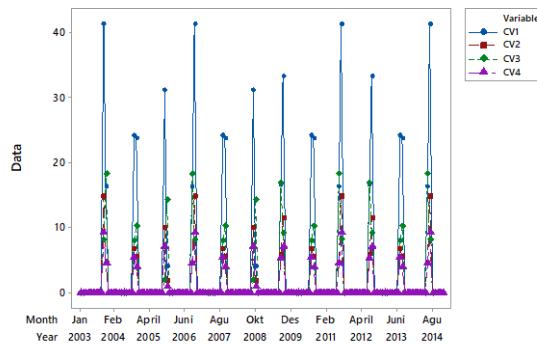
$$V_{4,t} = \begin{cases} 1, & \text{bulan saat idul fitri yang terjadi pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Koefisien yang digunakan berdasarkan data *outflow* total di KP BI Jawa Timur periode Januari 2003 hingga Desember 2014, dengan menghitung rata-rata nilai *outflow* total pada setiap minggu di bulan terjadinya hari raya

dan satu bulan sebelum terjadi hari raya. Sehingga diperoleh persamaan untuk masing-masing lokasi adalah sebagai berikut

$$\begin{aligned}
 V_t^{(1)} &= 8,13V_{1,t} + 47,46V_{2,t} + 66,5V_{3,t} + 82,38V_{4,t} + 62,29V_{1,t-1} + 48,21V_{2,t-1} + \\
 &\quad 33,07V_{3,t-1} + 32,42V_{4,t-1} \\
 V_t^{(2)} &= 3,9V_{1,t} + 11,14V_{2,t} + 22,84V_{3,t} + 29,59V_{4,t} + 19,77V_{1,t-1} + 13,39V_{2,t-1} + \\
 &\quad 11,6V_{3,t-1} + 9,05V_{4,t-1} \\
 V_t^{(3)} &= 3,74V_{1,t} + 15,99V_{2,t} + 33,78V_{3,t} + 36,4V_{4,t} + 28,7V_{1,t-1} + 20,46V_{2,t-1} + \\
 &\quad 18,39V_{3,t-1} + 16,12V_{4,t-1} \\
 V_t^{(4)} &= 1,73V_{1,t} + 7,87V_{2,t} + 14,21V_{3,t} + 18,48V_{4,t} + 14,21V_{1,t-1} + 10,67V_{2,t-1} + \\
 &\quad 10,43V_{3,t-1} + 8,85V_{4,t-1}
 \end{aligned}$$

Berikut ini adalah *time series plot* hasil pembangkitan data komponen variasi kalender pada masing-masing lokasi



Gambar 3. 3. Time Series Plot Komponen Variasi Kalender

- iv. Komponen untuk residual yang digunakan dalam studi simulasi ini terdiri dari residual yang mengikuti pola linier dan nonlinier dengan masing-masing persamaan adalah sebagai berikut,
Komponen residual yang mengikuti pola linier

$$N_t^{(i)} = \phi_1^{(i)} N_{1,t-1} + \phi_2^{(i)} N_{2,t-1} + \phi_3^{(i)} N_{3,t-1} + \phi_4^{(i)} N_{4,t-1} + e_t \quad (3. 6)$$

dengan koefisien yang digunakan untuk parameter model GSTAR(1₁) sesuai syarat stasioneritas data yaitu nilai *eigen* < 1. Berikut ini adalah koefisien parameter model GSTAR(1₁)

$$\Phi = \begin{bmatrix} 0,4 & 0,18 & 0,18 & 0,18 \\ 0,19 & 0,37 & 0,19 & 0,19 \\ 0,2 & 0,2 & 0,35 & 0,2 \\ 0,21 & 0,21 & 0,21 & 0,33 \end{bmatrix}$$

Berdasarkan matriks diatas didapatkan nilai *eigen* yang telah memenuhi syarat stasioneritas model GSTAR yaitu $\lambda_1 = 0,95$, $\lambda_2 = 0,21$, $\lambda_3 = 0,17$, $\lambda_4 = 0,13$, sehingga didapatkan persamaan dari koefisien pada matriks Φ adalah sebagai berikut

$$\begin{aligned} N_t^{(1)} &= 0,4N_{1,t-1} + 0,18N_{2,t-1} + 0,18N_{3,t-1} + 0,18N_{4,t-1} + a_t^{(1)} \\ N_t^{(2)} &= 0,19N_{1,t-1} + 0,37N_{2,t-1} + 0,19N_{3,t-1} + 0,19N_{4,t-1} + a_t^{(2)} \\ N_t^{(3)} &= 0,2N_{1,t-1} + 0,2N_{2,t-1} + 0,35N_{3,t-1} + 0,2N_{4,t-1} + a_t^{(3)} \\ N_t^{(4)} &= 0,21N_{1,t-1} + 0,21N_{2,t-1} + 0,21N_{3,t-1} + 0,33N_{4,t-1} + a_t^{(4)}. \end{aligned}$$

Berikut ini adalah persamaan residual yang mengikuti pola nonlinier

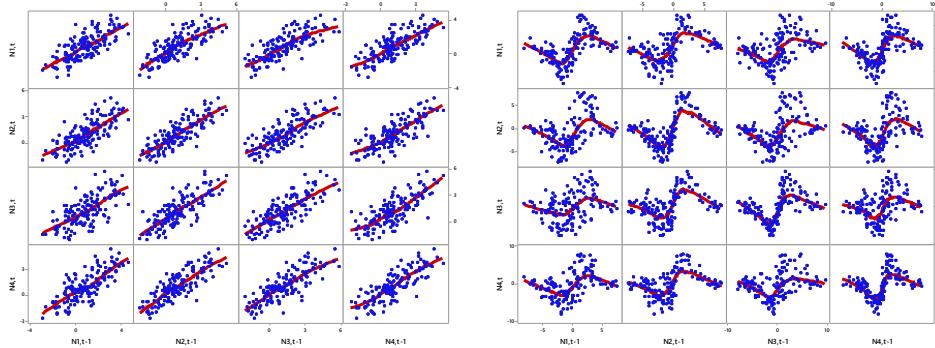
$$\begin{aligned} N_t^{(1)} &= 3,5N_{1,t-1} \times \exp(-0,2N_{1,t-1}^2) + 0,9N_{2,t-1} \times \exp(-0,2N_{2,t-1}^2) + \\ &\quad 1,5N_{3,t-1} \times \exp(-0,2N_{3,t-1}^2) + 2N_{4,t-1} \times \exp(-0,2N_{4,t-1}^2) + a_t^{(1)} \\ N_t^{(2)} &= 1,8N_{1,t-1} \times \exp(-0,2N_{1,t-1}^2) + 4N_{2,t-1} \times \exp(-0,2N_{2,t-1}^2) + \\ &\quad 1,1N_{3,t-1} \times \exp(-0,2N_{3,t-1}^2) + 1,5N_{4,t-1} \times \exp(-0,2N_{4,t-1}^2) + a_t^{(2)} \\ N_t^{(3)} &= 1,2N_{1,t-1} \times \exp(-0,2N_{1,t-1}^2) + 2,3N_{2,t-1} \times \exp(-0,2N_{2,t-1}^2) + \\ &\quad 4,5N_{3,t-1} \times \exp(-0,2N_{3,t-1}^2) + 1N_{4,t-1} \times \exp(-0,2N_{4,t-1}^2) + a_t^{(3)} \\ N_t^{(4)} &= 1,9N_{1,t-1} \times \exp(-0,2N_{1,t-1}^2) + 2,1N_{2,t-1} \times \exp(-0,2N_{2,t-1}^2) + \\ &\quad 1,3N_{3,t-1} \times \exp(-0,2N_{3,t-1}^2) + 3,9N_{4,t-1} \times \exp(-0,2N_{4,t-1}^2) + a_t^{(4)} \end{aligned}$$

dengan $a_t \sim MN(\mathbf{0}, \Sigma)$ dan antar lokasi saling berkorelasi, dan

$$\Sigma = \begin{bmatrix} 1 & 0,6 & 0,45 & 0,55 \\ 0,6 & 1 & 0,57 & 0,61 \\ 0,45 & 0,57 & 1 & 0,49 \\ 0,55 & 0,61 & 0,49 & 1 \end{bmatrix}.$$

- b. Mendapatkan data deret waktu $Y_t^{(i)}$, dengan $i = 1, 2, 3, 4$ yang berarti terdapat 4 lokasi dan $t = 1, 2, \dots, 144$, dengan skenario berikut ini
 - i. Skenario 1, residual merupakan deret yang belum *white noise* dan mengikuti pola linier
 - ii. Skenario 2, residual merupakan deret yang belum *white noise* dan mengikuti pola nonlinier

Berikut ini adalah pola hubungan *noise* pada skenario 1 dan skenario 2 dengan waktu sebelumnya ($t - 1$)



Gambar 3.4. Pola Hubungan Komponen \mathbf{N}_t dengan \mathbf{N}_{t-1} pada Data Skenario 1 dan Skenario 2

- c. Melakukan pemodelan menggunakan metode TSR, GSTARX, *hybrid* GSTARX-FFNN, *hybrid* GSTARX-DLNN, dan *hybrid* GSTARX-Jordan RNN pada data $Y_t^{(i)}$ dengan menggunakan bobot seragam sesuai dengan skenario pada tahap (b) dengan replikasi sebanyak 10 kali.
- d. Melakukan perbandingan kebaikan model menggunakan nilai RMSE dari model TSR, GSTARX, *hybrid* GSTARX-FFNN, *hybrid* GSTARX-DLNN, dan *hybrid* GSTARX-Jordan RNN dan menentukan model terbaik dalam meramalkan data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan residual yang mengikuti pola linier maupun nonlinier.

3.2. Kajian terapan

Kajian terapan menggunakan data *inflow* dan *outflow* di empat lokasi Kantor Perwakilan Bank Indonesia (KP BI) Jawa Timur menggunakan model GSTARX, model *hybrid* GSTARX-FFNN, GSTARX-DLNN, dan GSTARX-Jordan RNN dengan variabel prediktor nonmetrik yaitu komponen tren, musiman, dan efek variasi kalender.

3.2.1 Sumber Data

Data yang digunakan dalam kajian terapan merupakan data sekunder yang berupa data bulanan *inflow* dan *outflow* uang kertas per pecahan dan total di KP BI wilayah Provinsi Jawa Timur yang terdiri dari Kota Surabaya, Malang, Kediri dan Jember yang diperoleh dari Bank Indonesia. Periode data yang digunakan dari bulan Januari tahun 2000 hingga bulan Juni tahun 2019, dengan periode data *in sample* yaitu Januari 2000 sampai dengan bulan Desember 2017 untuk data total

dan pecahan kecuali pecahan Rp. 2.000. Periode data *in sample* untuk pecahan Rp.2.000 mulai bulan Januari tahun 2010 hingga Desember tahun 2017. Sedangkan periode data *out sample* mulai bulan Januari 2018 sampai dengan Juni 2019.

3.2.2 Variabel Penelitian

Berikut ini adalah rincian dari variabel penelitian yang digunakan dalam kajian terapan,

Tabel 3. 1. Variabel Penelitian (dalam miliar rupiah)

Data	Variabel $Y_{c,t}^{(i)}$	Keterangan
<i>Inflow</i>	$Y_{1,t}^{(i)}$	total pada waktu ke- t lokasi ke- i
	$Y_{2,t}^{(i)}$	pecahan Rp. 100.000,- pada waktu ke- t lokasi ke- i
	$Y_{3,t}^{(i)}$	pecahan Rp. 50.000,- pada waktu ke- t lokasi ke- i
	$Y_{4,t}^{(i)}$	pecahan Rp. 20.000,- pada waktu ke- t lokasi ke- i
	$Y_{5,t}^{(i)}$	pecahan Rp. 10.000,- pada waktu ke- t lokasi ke- i
	$Y_{6,t}^{(i)}$	pecahan Rp. 5.000,- pada waktu ke- t lokasi ke- i
	$Y_{7,t}^{(i)}$	pecahan Rp. 2.000,- pada waktu ke- t lokasi ke- i
	$Y_{8,t}^{(i)}$	pecahan Rp. 1.000,- pada waktu ke- t lokasi ke- i
<i>Outflow</i>	$Y_{9,t}^{(i)}$	total pada waktu ke- t lokasi ke- i
	$Y_{10,t}^{(i)}$	pecahan Rp. 100.000,- pada waktu ke- t lokasi ke- i
	$Y_{11,t}^{(i)}$	pecahan Rp. 50.000,- pada waktu ke- t lokasi ke- i
	$Y_{12,t}^{(i)}$	pecahan Rp. 20.000,- pada waktu ke- t lokasi ke- i
	$Y_{13,t}^{(i)}$	pecahan Rp. 10.000,- pada waktu ke- t lokasi ke- i
	$Y_{14,t}^{(i)}$	pecahan Rp. 5.000,- pada waktu ke- t lokasi ke- i
	$Y_{15,t}^{(i)}$	pecahan Rp. 2.000,- pada waktu ke- t lokasi ke- i
	$Y_{16,t}^{(i)}$	pecahan Rp. 1.000,- pada waktu ke- t lokasi ke- i

$Y_{c,t}^{(i)}$ dengan $c = 1, 2, \dots, 8$ merupakan data *inflow* masing-masing pecahan dan total sedangkan $c = 9, 10, \dots, 16$ merupakan data *outflow* masing-masing pecahan dan total.

Selanjutnya, untuk variabel prediktor yang digunakan dalam pemodelan terdiri dari beberapa variabel *dummy* yaitu:

1. Variabel untuk *dummy* tren dan kebijakan Bank Indonesia

t : tren kenaikan *inflow* atau *outflow* uang kartal dengan $t = 1, 2, \dots, n$.

$D_{i,t}$: *dummy* kebijakan Bank Indonesia yaitu kebijakan periode pertama bulan Januari 2007 hingga Desember 2010, kebijakan periode kedua bulan Januari 2011 hingga Desember 2014.

$tD_{i,t}$: tren dan kebijakan Bank Indonesia pada periode ke- i .

2. Variabel *dummy* untuk pola musiman (bulan)

$$S_{1,t} = \begin{cases} 1, & \text{bulan Januari,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

$$S_{2,t} = \begin{cases} 1, & \text{bulan Februari,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

:

$$S_{11,t} = \begin{cases} 1, & \text{bulan November,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

$$S_{12,t} = \begin{cases} 1, & \text{bulan Desember,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

3. Variabel *dummy* hari raya idul fitri

Diasumsikan efek hari raya idul fitri berkaitan dengan minggu terjadinya lebaran idul fitri satu bulan sebelumnya ($t - 1$), bulan terjadinya hari raya idul fitri (t), dan satu bulan setelah hari raya idul fitri ($t + 1$).

Efek satu bulan sebelum hari raya idul fitri, yaitu

$$V_{1,t-1} = \begin{cases} 1, & \text{satu bulan sebelum idul fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

:

$$V_{4,t-1} = \begin{cases} 1, & \text{satu bulan sebelum idul fitri yang terjadi pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Efek pada bulan saat hari raya idul fitri, yaitu

$$V_{1,t} = \begin{cases} 1, & \text{bulan saat idul fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

⋮

$$V_{4,t} = \begin{cases} 1, & \text{bulan saat idul fitri yang terjadi pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Efek satu bulan setelah hari raya idul fitri, yaitu

$$V_{1,t+1} = \begin{cases} 1, & \text{satu bulan sesudah idul fitri apabila pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

⋮

$$V_{4,t+1} = \begin{cases} 1, & \text{satu bulan sesudah idul fitri apabila pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Berikut ini adalah ketentuan minggu berdasarkan peraturan Bank Indonesia yang disajikan pada Tabel 3.2.

Tabel 3. 2. Ketentuan Minggu Berdasarkan Peraturan Bank Indonesia

Minggu ke-	Tanggal
1	1 – 7
2	8 – 15
3	16 – 23
4	24 – tanggal terakhir pada bulan tersebut

Tanggal terjadinya hari raya idul fitri pada tahun 2000 hingga 2021 disajikan pada Tabel 3.3

Tabel 3. 3. Jadwal Terjadinya Hari Raya Idul Fitri Tahun 2000-2021

Tahun	Hari Raya Idul Fitri		
	Tanggal	Bulan	Minggu ke-
2000	8-9	Januari	2
2000	27-28	Desember	4
2001	17-18	Desember	3
2002	6-7	Desember	7
2003	25-26	November	4
2004	14-15	November	2
2005	3-4	November	1
2006	24-25	Oktober	4
2007	12-13	Oktober	2
2008	1-2	Oktober	1
2009	20-21	September	3

Tabel 3. 3. Jadwal Terjadinya Hari Raya Idul Fitri Tahun 2000-2021 (Lanjutan)

Tahun	Hari Raya Idul Fitri		
	Tanggal	Bulan	Minggu ke-
2010	10-11	September	2
2011	30-31	Agustus	4
2012	19-20	Agustus	3
2013	8-9	Agustus	2
2014	28-29	Juli	4
2015	17-18	Juli	3
2016	6-7	Juli	1
2017	26-27	Juni	4
2018	15-16	Juni	2
2019	5-6	Juni	1
2020	24-25	Mei	4
2021	13-14	Mei	2

3.2.3 Struktur Data

Struktur dari data yang digunakan pada penelitian ini disajikan pada Tabel 3.4 untuk data *inflow*, dan Tabel 3.5 untuk data *outflow*. Berdasarkan pengaruh variasi kalender, data *inflow* cenderung tinggi satu bulan setelah hari raya Idul Fitri ($V_{t+1}^{(i)}$) sedangkan nilai *outflow* cenderung tinggi satu bulan sebelum hari raya Idul Fitri ($V_{t-1}^{(i)}$).

Tabel 3.4. Struktur Data Pemodelan Data *Inflow* dengan GSTARX-Jordan RNN

Bulan-Tahun	<i>Inflow</i>				<i>Dummy</i>													
	$Y_{c,t}^{(1)}$	$Y_{c,t}^{(2)}$	$Y_{c,t}^{(3)}$	$Y_{c,t}^{(4)}$	t	$D_{1,t}$	$D_{2,t}$	$tD_{1,t}$	$tD_{2,t}$	$S_{1,t}$...	$S_{12,t}$	$V_{1,t}$...	$V_{4,t}$	$V_{1,t+1}$...	$V_{4,t+1}$
Jan-2000	$Y_{c,1}^{(1)}$	$Y_{c,1}^{(2)}$	$Y_{c,1}^{(3)}$	$Y_{c,1}^{(4)}$	1	0	0	0	0	1	...	0	1	...	0	0	...	0
Feb-2000	$Y_{c,2}^{(1)}$	$Y_{c,2}^{(2)}$	$Y_{c,2}^{(3)}$	$Y_{c,2}^{(4)}$	2	0	0	0	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
Des-2000	$Y_{c,12}^{(1)}$	$Y_{c,12}^{(2)}$	$Y_{c,12}^{(3)}$	$Y_{c,12}^{(4)}$	12	0	0	0	0	0	...	1	1	...	0	0	...	0
Jan-2001	$Y_{c,13}^{(1)}$	$Y_{c,13}^{(2)}$	$Y_{c,13}^{(3)}$	$Y_{c,13}^{(4)}$	13	0	0	0	0	1	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
Jun-2019	$Y_{c,234}^{(1)}$	$Y_{c,234}^{(2)}$	$Y_{c,234}^{(3)}$	$Y_{c,234}^{(4)}$	234	0	234	0	1	0	...	0	1	...	0	0	...	0

Tabel 3.5. Struktur Data Pemodelan Data *Outflow* dengan GSTARX-Jordan RNN

Bulan-Tahun	<i>Outflow</i>				<i>Dummy</i>													
	$Y_{c,t}^{(1)}$	$Y_{c,t}^{(2)}$	$Y_{c,t}^{(3)}$	$Y_{c,t}^{(4)}$	t	D_1	D_2	tD_1	tD_2	$S_{1,t}$...	$S_{12,t}$	$V_{1,t}$...	$V_{4,t}$	$V_{1,t+1}$...	$V_{4,t+1}$
Jan-2000	$Y_{c,1}^{(1)}$	$Y_{c,1}^{(2)}$	$Y_{c,1}^{(3)}$	$Y_{c,1}^{(4)}$	1	0	0	0	0	1	...	0	1	...	0	0	...	0
Feb-2000	$Y_{c,2}^{(1)}$	$Y_{c,2}^{(2)}$	$Y_{c,2}^{(3)}$	$Y_{c,2}^{(4)}$	2	0	0	0	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-2000	$Y_{c,12}^{(1)}$	$Y_{c,12}^{(2)}$	$Y_{c,12}^{(3)}$	$Y_{c,12}^{(4)}$	12	0	0	0	0	0	...	1	1	...	0	0	...	0
Jan-2001	$Y_{c,13}^{(1)}$	$Y_{c,13}^{(2)}$	$Y_{c,13}^{(3)}$	$Y_{c,13}^{(4)}$	13	0	0	0	0	1	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Jun-2019	$Y_{c,234}^{(1)}$	$Y_{c,234}^{(2)}$	$Y_{c,234}^{(3)}$	$Y_{c,234}^{(4)}$	234	0	1	0	234	0	...	0	1	...	0	0	...	0

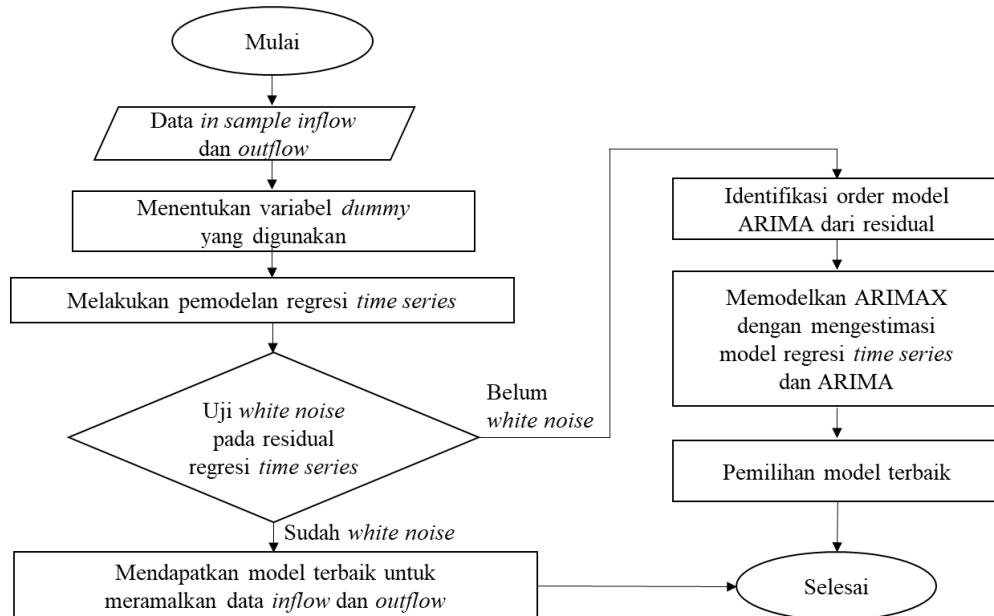
3.2.4 Langkah Analisis

Berikut ini adalah langkah-langkah yang akan digunakan dalam kajian terapan:

1. Membuat statistika deskriptif dan *time series plot* dari data per pecahan dan total dari masing-masing data *inflow* dan *outflow*.
2. Mengidentifikasi pola data *inflow* dan *outflow* pada masing-masing wilayah di kantor Bank Indonesia Provinsi Jawa Timur, serta menentukan variabel *dummy* yang digunakan, yaitu tren, kebijakan Bank Indonesia, musiman, dan variasi kalender.
3. Membagi data *in sample* dan *out sample*
4. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* secara univariat menggunakan model *naïve* musiman dan melakukan peramalan pada data *out sample*.
5. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* secara univariat menggunakan model TSR.
6. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* secara univariat menggunakan model ARIMAX dengan tahapan berikut ini
 - a. Meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy*.
 - b. Melakukan uji *white noise* pada residual model TSR menggunakan uji Ljung-Box. Jika telah memenuhi asumsi maka dilakukan peramalan untuk data *out sample* menggunakan model TSR. Jika belum memenuhi asumsi *white noise*, maka dilanjutkan ke langkah 6c hingga 6e.
 - c. Melakukan pemodelan menggunakan model ARIMA dari residual hasil model TSR yang belum memenuhi asumsi *white noise* pada masing-masing wilayah dengan tahapan berikut ini
 - i. Menentukan order model ARIMA dengan mengidentifikasi plot ACF dan PACF
 - ii. Mendapatkan model dugaan
 - iii. Mengestimasi parameter model dugaan
 - iv. Melakukan uji signifikansi parameter pada model dugaan

- v. Melakukan cek diagnostik pada residual model ARIMA, untuk mengetahui apakah telah memenuhi asumsi *white noise*
- d. Mendapatkan model ARIMAX
- e. Melakukan peramalan untuk data *out sample* menggunakan model ARIMAX yang telah didapatkan.

Berikut ini adalah diagram alir dari proses pembentukan model ARIMAX



Gambar 3.5. Diagram Alir Pemodelan ARIMAX

7. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* secara multivariat menggunakan model GSTAR, berikut ini adalah tahapan-tahapannya:
 - a. Memeriksa stasioneritas data *in sample* dari *inflow* dan *outflow* masing-masing lokasi di Provinsi Jawa Timur menggunakan plot MCCF.
 - b. Jika data belum stasioner, maka dilakukan *differencing* hingga data stasioner
 - c. Melakukan identifikasi order model AR menggunakan plot MPCCF.
 - d. Menentukan nilai pembobot spasial yang digunakan.
 - e. Melakukan estimasi parameter GSTAR(p_1).
 - f. Menguji signifikansi parameter model GSTAR.

$$\mathbf{Y}_t = \sum_{k=1}^p (\boldsymbol{\Phi}_{k0} \mathbf{Y}_{t-k} + \boldsymbol{\Phi}_{k1} \boldsymbol{\Theta}^{(1)} \mathbf{Y}_{t-k}) + \mathbf{a}_t.$$

- g. Mendapatkan model GSTAR dan melakukan peramalan untuk data *out sample*.
- 8. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* di masing-masing wilayah Provinsi Jawa Timur secara multivariat menggunakan model Jordan-RNN dengan tahapan berikut ini:
 - a. Menentukan *lag* data untuk input dalam model Jordan-RNN menggunakan plot MPCCF dari masing-masing lokasi.
 - b. Data disusun dalam bentuk satu vektor
 - c. Melakukan estimasi parameter dengan persamaan pada *output layer* seperti pada Persamaan (2.111).
 - d. Melakukan peramalan data *out sample* dari *inflow* dan *outflow* masing-masing lokasi
 - e. Menentukan *neuron* model terbaik dari Jordan RNN berdasarkan RMSE sMAPE terkecil.
- 9. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* di masing-masing wilayah Provinsi Jawa Timur secara multivariat menggunakan model GSTARX dengan tahapan berikut ini:
 - a. Melakukan pemodelan menggunakan TSR dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan.
 - b. Mengidentifikasi korelasi residual hasil pemodelan TSR antar lokasi pada masing-masing data *inflow* dan *outflow*.
 - c. Melakukan pemodelan residual model TSR menggunakan model GSTAR dengan tahapan pemodelan GSTAR seperti pada langkah 7. Hasil estimasi parameter model GSTAR dari residual model TSR adalah:
$$\boldsymbol{\varepsilon}_t = \sum_{k=1}^p (\boldsymbol{\Phi}_{k0} \boldsymbol{\varepsilon}_{t-k} + \boldsymbol{\Phi}_{k1} \boldsymbol{\omega}^{(1)} \boldsymbol{\varepsilon}_{t-k}) + \mathbf{a}_t.$$
 - d. Mendapatkan model GSTARX yang merupakan penjumlahan dari hasil model TSR dengan model GSTAR dari residual TSR.
 - e. Melakukan peramalan untuk data *out sample* berdasarkan model GSTARX yang sudah didapatkan

10. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* di masing-masing wilayah Provinsi Jawa Timur secara multivariat menggunakan model *hybrid GSTARX-FFNN* dengan tahapan berikut ini :
 - a. Melakukan pemodelan menggunakan TSR dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan.
 - b. Menentukan *lag* data untuk input dalam model FFNN berdasarkan order pada model GSTARX yang sudah didapatkan.
 - c. Melakukan penghitungan bobot GSTAR yang digunakan sebagai input dalam model *hybrid GSTARX-FFNN*.
 - d. Melakukan estimasi parameter dengan persamaan pada *output layer* sebagai berikut

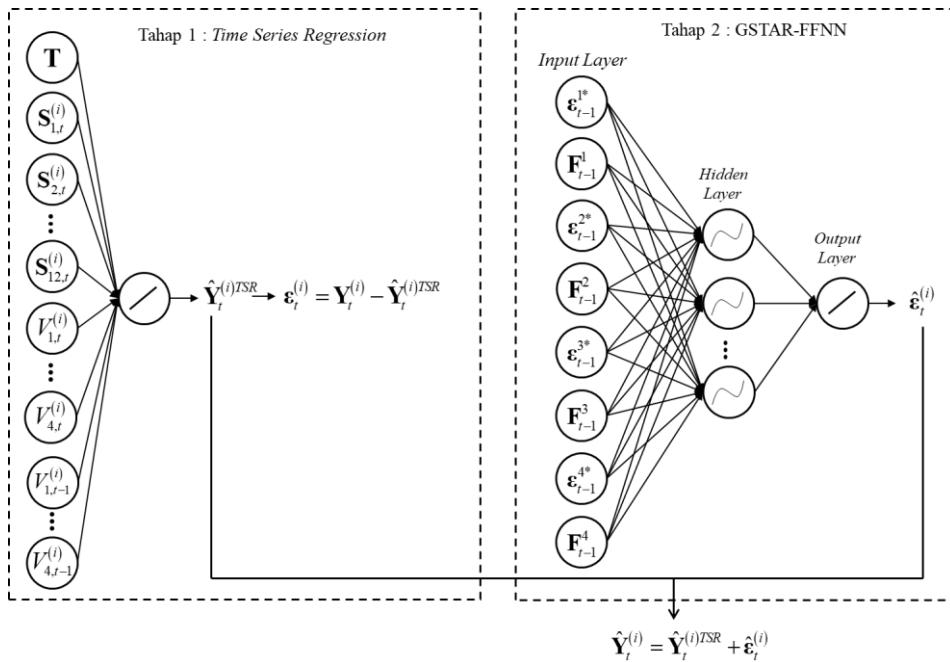
$$\hat{\varepsilon}_t = b^o + \sum_{j=1}^g w_j^o f_j^1(v_j^1)$$

Persamaan untuk *hidden layer* adalah

$$f_j^1(v_j^1) = \tanh(b_i^1 + w_{1i}\varepsilon_{1,t-1} + w_{2i}F_{2,t-1} + \dots + w_{pi}F_{4,t-1})$$

- e. Mendapatkan model *hybrid GSTARX-FFNN* yang merupakan penjumlahan dari model TSR dengan model GSTAR-FFNN dari residual model TSR.
- f. Melakukan peramalan untuk data *out sample* berdasarkan model *hybrid GSTARX-FFNN* yang sudah didapatkan
- g. Menentukan *neuron* model terbaik dari model *hybrid GSTARX-FFNN* berdasarkan RMSE dan sMAPE terkecil.

Berikut ini adalah gambaran diagram alir dari pemodelan *hybrid GSTARX-FFNN*



Gambar 3. 6. Diagram Alir Tahapan Pemodelan *hybrid GSTARX-FFNN*

11. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* di masing-masing wilayah Provinsi Jawa Timur secara multivariat menggunakan model *hybrid GSTARX-DLNN* dengan tahapan berikut ini :
 - a. Melakukan pemodelan menggunakan TSR dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan.
 - b. Menentukan *lag* data untuk input dalam model DLNN berdasarkan order pada model GSTARX yang sudah didapatkan.
 - c. Melakukan penghitungan bobot GSTAR yang digunakan sebagai input dalam model *hybrid GSTARX-DLNN*.
 - d. Melakukan estimasi parameter dengan persamaan pada *output layer* dengan persamaan berikut ini

$$\hat{\varepsilon}_t = b^o + \sum_{j=1}^{g^2} w_j^o f_j^2(v_j^2)$$

Persamaan pada *hidden layer* kedua yaitu

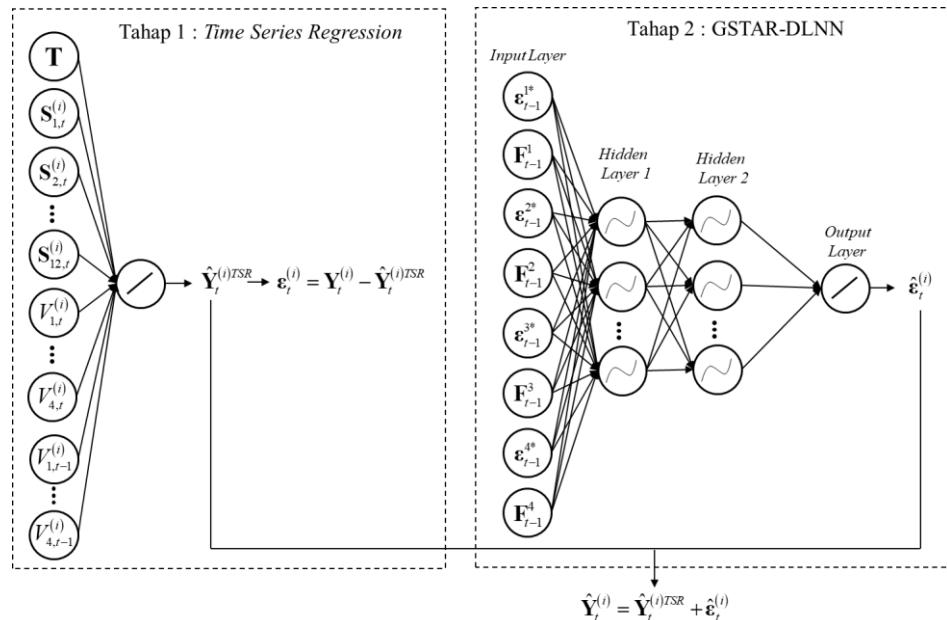
$$f_j^2(v_j^2) = b_j^2 + \sum_{j=1}^{g^1} w_{ji}^2 f_j^1(v_j^1)$$

dan persamaan pada *hidden layer* pertama yaitu

$$f_j^1(v_j^1) = \tanh(b_i^1 + w_{1i}\varepsilon_{1,t-1} + w_{2i}F_{2,t-1} + \dots + w_{pi}F_{4,t-1})$$

- e. Mendapatkan model *hybrid GSTARX-DLNN* yang merupakan penjumlahan dari model TSR dengan model GSTAR-DLNN dari residual.
- f. Melakukan peramalan untuk data *out sample* berdasarkan model *hybrid GSTARX-DLNN* yang sudah didapatkan
- g. Menentukan *neuron* model terbaik dari model *hybrid GSTARX-DLNN* berdasarkan RMSE terkecil

Berikut ini adalah gambaran diagram alir dari pemodelan *hybrid GSTARX-DLNN*

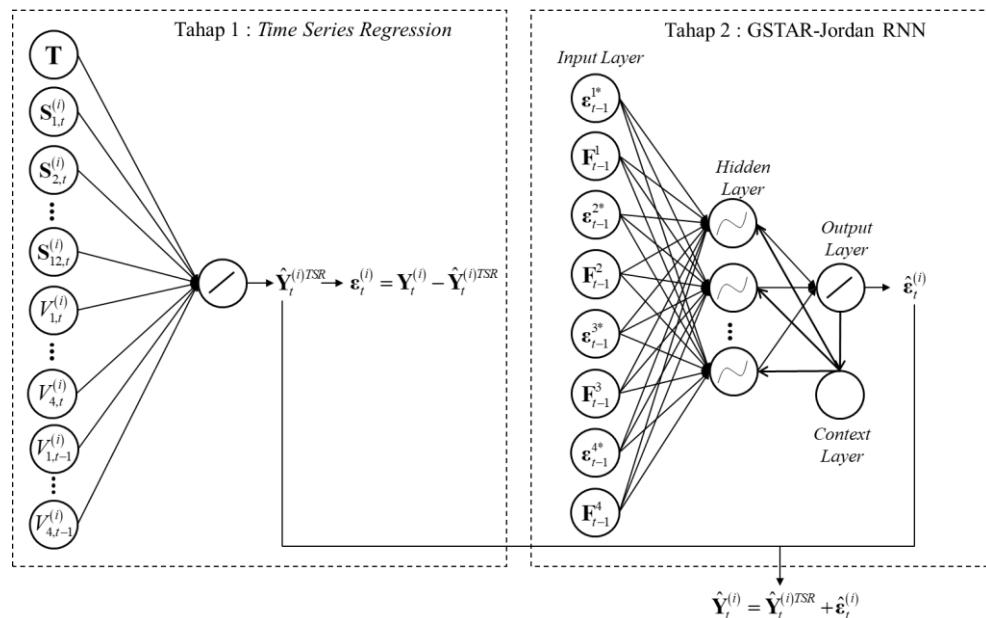


Gambar 3.7. Diagram Alir Tahapan Pemodelan *hybrid GSTARX-DLNN*

- 12. Melakukan pemodelan data *in sample* dari *inflow* dan *outflow* di masing-masing wilayah Provinsi Jawa Timur secara multivariat menggunakan model *hybrid GSTARX-Jordan RNN* dengan tahapan berikut ini :
 - a. Melakukan pemodelan menggunakan TSR dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan.
 - b. Menentukan *lag* data untuk input dalam model Jordan RNN berdasarkan order pada model GSTARX yang sudah didapatkan.
 - c. Melakukan penghitungan bobot GSTAR yang digunakan sebagai input dalam model *hybrid GSTARX-Jordan NN*.

- d. Melakukan estimasi parameter dengan persamaan pada *output layer* seperti pada Persamaan (2.111).
- e. Melakukan peramalan data *out sample* dari *inflow* dan *outflow* masing-masing lokasi
- f. Mendapatkan model *hybrid GSTARX-Jordan RNN* yang merupakan penjumlahan dari model TSR dengan model GSTAR-Jordan RNN dari residual.

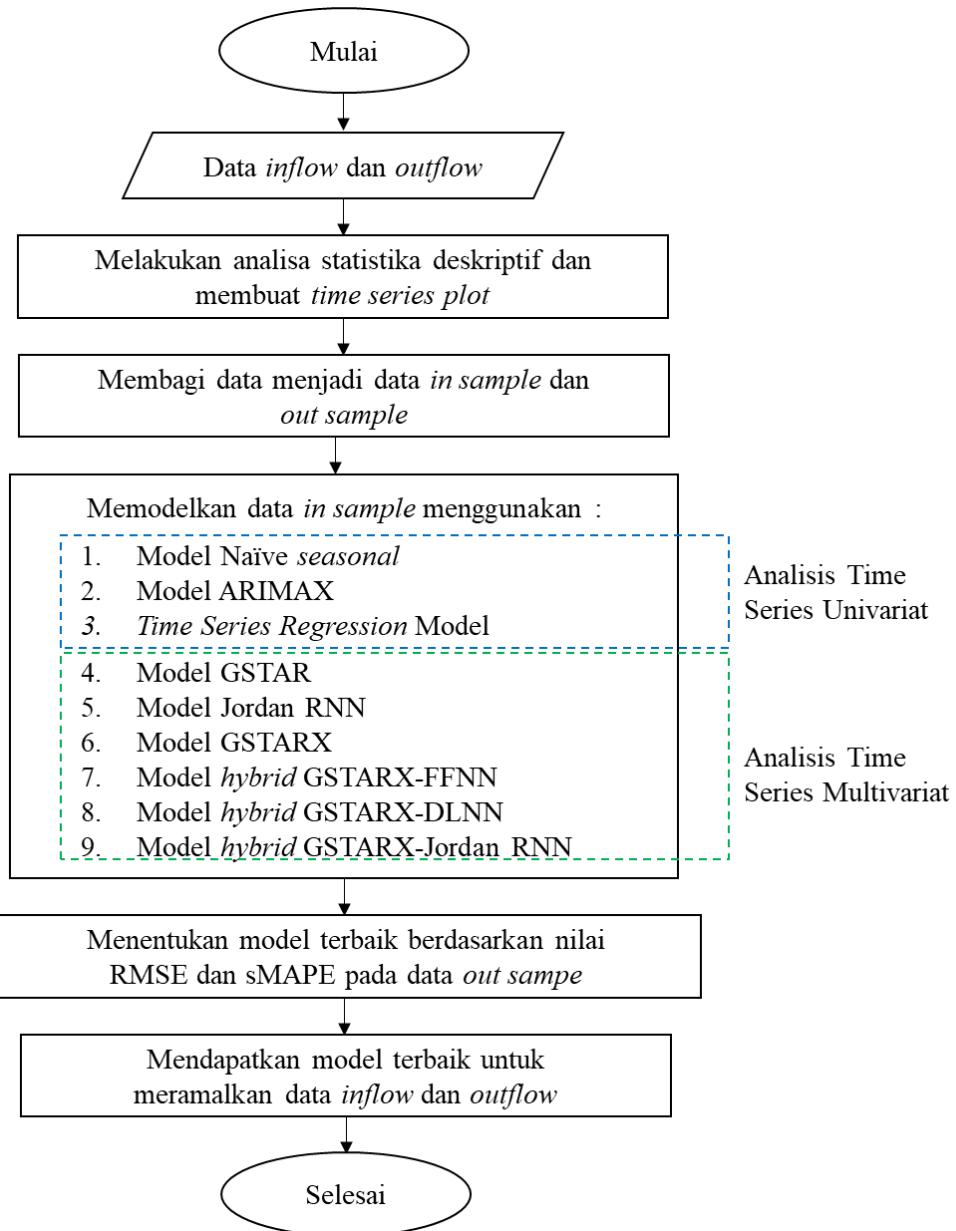
Berikut ini adalah gambaran diagram alir dari pemodelan *hybrid GSTARX-Jordan RNN*



Gambar 3.8. Diagram Alir Tahapan Pemodelan GSTARX-Jordan RNN

- 13. Menghitung nilai RMSE dan sMAPE dari masing-masing pemodelan yang sudah dilakukan pada data *inflow* dan *outflow* untuk data *in sample* dan *out sample*.
- 14. Membandingkan nilai RMSE dan sMAPE yang didapatkan pada masing-masing pemodelan, dan menentukan model yang memiliki *performance* terbaik dalam memodelkan data *inflow* dan *outflow* Bank Indonesia baik per pecahan maupun total di masing-masing wilayah kantor cabang yang ada di Provinsi Jawa Timur.
- 15. Meramalkan data *inflow* dan *outflow* per pecahan dan juga total di masing-masing wilayah kantor cabang yang ada di Provinsi Jawa Timur.

Keseluruhan tahapan penelitian yang sudah diuraikan diatas, dapat digambarkan dalam bentuk diagram alir berikut ini.



Gambar 3. 9. Diagram Alir Tahapan Pemodelan Secara Keseluruhan

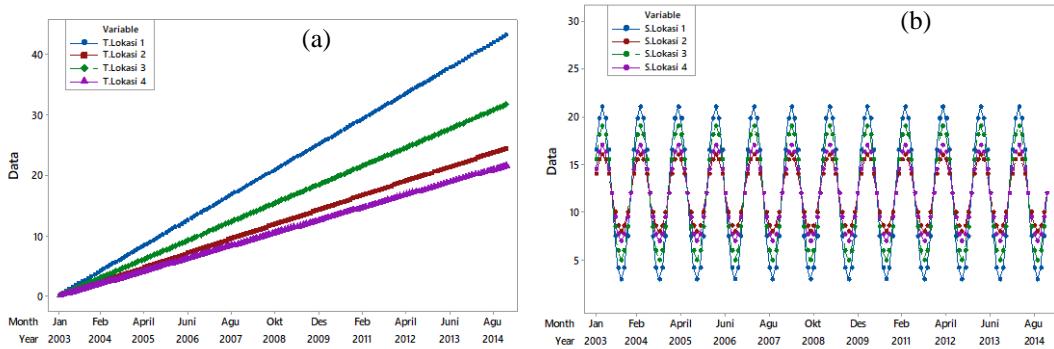
BAB IV

ANALISIS DAN PEMBAHASAN

4.1. Kajian Simulasi

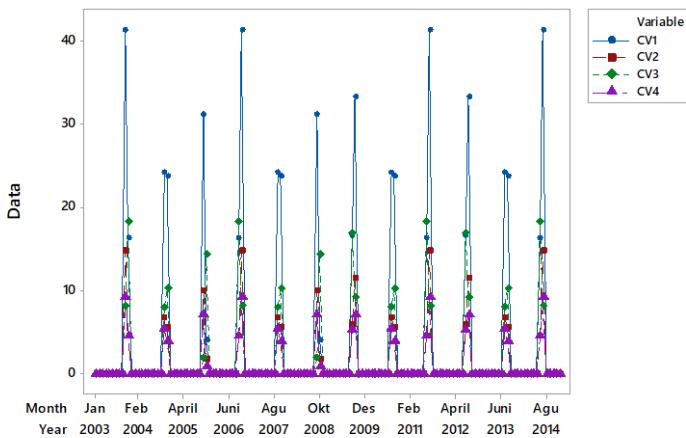
Sebelum dilakukan pemodelan pada data aktual, perlu dilakukan pemodelan terhadap data simulasi yang memiliki pola menyerupai data aktual. Studi simulasi ini dilakukan untuk mengetahui kebaikan model *hybrid GSTARX-Jordan RNN* dalam meramalkan data *space time* yang memiliki pola tren, musiman, dan variasi kalender, serta residual yang mengikuti pola linier dan nonlinier. Adapun kriteria yang digunakan untuk melihat kebaikan model pada studi simulasi ini adalah RMSE. Data yang digunakan adalah simulasi yang dibangkitkan berdasarkan pola data *outflow* mulai bulan Januari 2003 hingga Desember 2013 sebagai data *in sample* dan periode Januari 2014 hingga Desember 2015 sebagai data *out sample*.

Didapatkan data $Y_t^{(i)}$ berdasarkan Persamaan (3.1). Untuk mendapatkan masing-masing komponen sesuai dengan persamaan (3.2) dan (3.3). Berikut adalah plot komponen tren dan musiman.



Gambar 4. 1 Plot Komponen Tren (a) dan Musiman (b)

Gambar 4. 1(a) menunjukkan adanya pola tren yang mengakibatkan kenaikan data dengan seiring bertambahnya waktu. Gambar 4. 1(b) menunjukkan pola musiman yang homogen, ditunjukkan dengan memiliki pola yang sama untuk masing-masing lokasi. Serta data cenderung memiliki nilai yang sama pada bulan yang sama. Efek variasi kalender ditunjukkan pada berikut ini



Gambar 4. 2 Plot Komponen Variasi kalender

Penentuan efek variasi kalender disesuaikan dengan data *outflow* uang kartal di Kantor Bank Indonesia wilayah Jawa Timur. Adapun pada saat Hari Raya Idul Fitri terjadi pada minggu ke-1 atau minggu ke-2, maka *outflow* cenderung tinggi pada satu bulan sebelum terjadi Hari Raya Idul Fitri. Sedangkan, jika hari raya Idul Fitri terjadi pada minggu ke-3 atau menggu ke-4, maka *outflow* tinggi pada bulan terjadinya hari raya Idul Fitri. Studi simulasi pada penelitian ini menggunakan dua skenario. Skenario 1, yaitu residual belum memenuhi asumsi *white noise* dan memiliki pola linier. Skenario 2, yaitu residual yang belum memenuhi asumsi *white noise* dan memiliki pola nonlinier.

Pada pemodelan skenario 1, residual merupakan deret yang belum *white noise* dan mengikuti pola linier dan model GSTAR(1₁). Sedangkan simulasi pada skenario 2, residual yang digunakan merupakan deret yang belum *white noise* dan mengikuti pola nonlinier. Koefisien untuk parameter yang digunakan dalam model GSTAR(1₁) sudah sesuai dengan syarat stasioner parameter GSTAR, yaitu nilai eigen dari parameter harus kurang dari 1, $|\lambda\mathbf{I} - \Phi| = 0$, $|\Phi| = |\lambda\mathbf{I}|$, dengan $|\lambda| < 1$.

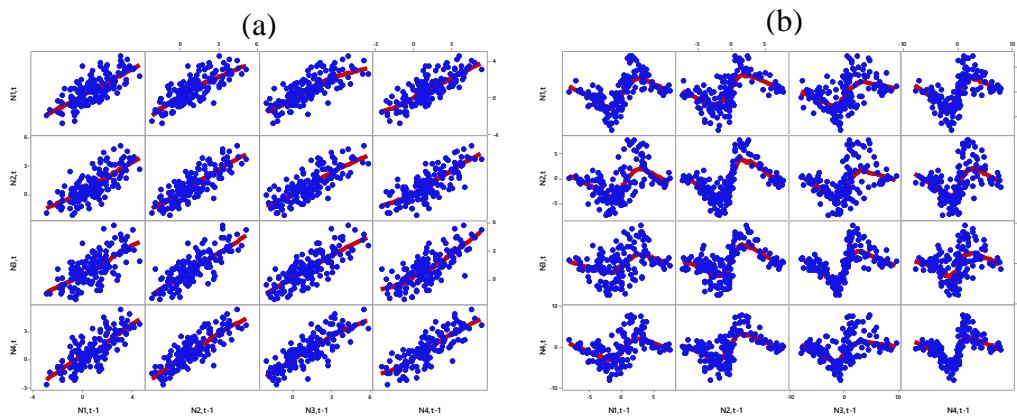
Parameter tersebut disajikan dalam persamaan matriks berikut ini

$$\Phi = \begin{bmatrix} 0,4 & 0,18 & 0,18 & 0,18 \\ 0,19 & 0,37 & 0,19 & 0,19 \\ 0,2 & 0,2 & 0,35 & 0,2 \\ 0,21 & 0,21 & 0,21 & 0,33 \end{bmatrix}$$

Selanjutnya, diketahui bahwa residual antar lokasi saling berkorelasi, dengan matriks varians kovarians adalah Σ dan rata-rata adalah $\mathbf{0}$. Matriks varians kovarians residual pada skenario 1 dan 2 adalah sebagai berikut.

$$\Sigma = \begin{bmatrix} 1 & 0,6 & 0,45 & 0,55 \\ 0,6 & 1 & 0,57 & 0,61 \\ 0,45 & 0,57 & 1 & 0,49 \\ 0,55 & 0,61 & 0,49 & 1 \end{bmatrix},$$

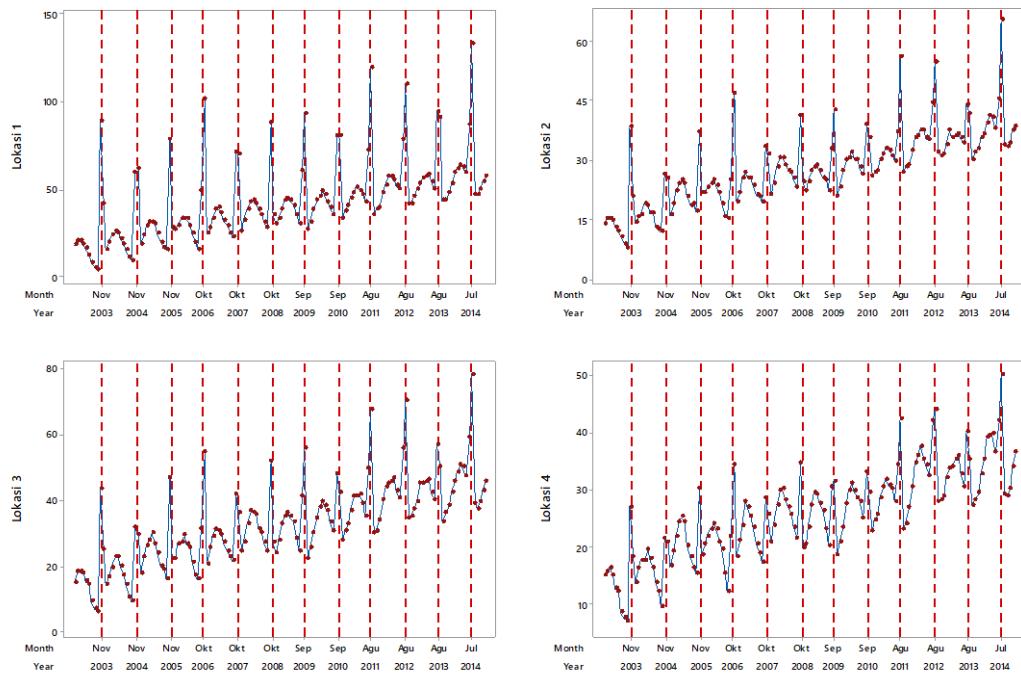
Selanjutnya, ditampilkan identifikasi pola residual melalui matriks plot antara residual pada waktu ke- t dengan residual pada waktu ke-($t-1$) pada empat lokasi yang ditunjukkan pada gambar berikut



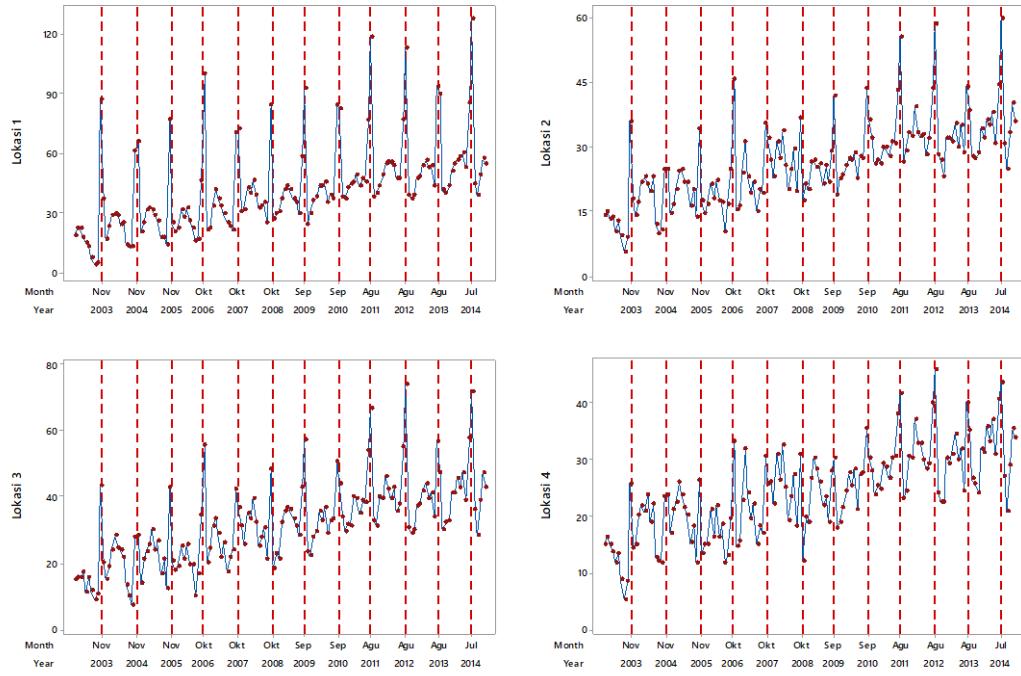
Gambar 4. 3 Matriks Plot Residual Skenario 1 (a) dan Skenario 2 (b) di Empat Lokasi

Berdasarkan matriks plot pada Gambar 4. 3(a), dapat diketahui bahwa hubungan antara residual pada waktu ke- t dengan residual pada waktu ke-($t-1$) antar lokasi berpolai linier, dan pada Gambar 4. 3(b) menunjukkan bahwa residual pada waktu ke- t dengan residual pada waktu ke-($t-1$) antar lokasi berpolai nonlinier. Setelah dilakukan pembangkitan data dengan replikasi sebanyak 10 kali, berikut ini adalah *time series plot* dari data hasil simulasi pada skenario 1 dan skenario 2.

Gambar 4. 4 menunjukkan *time series plot* untuk data simulasi ke-1 pada skenario 1 di empat lokasi, terlihat bahwa pola data di empat lokasi sudah mengandung tren, musiman, variasi kalender, dan residual mengikuti pola linier. Gambar 4. 5 menunjukkan *time series plot* data simulasi 1 pada skenario 2 di empat lokasi. Dari gambar tersebut terlihat bahwa pola data di masing-masing lokasi terlihat mengandung komponen tren, musiman dan variasi kalender, serta terindikasi memiliki residual yang mengikuti pola nonlinier.



Gambar 4. 4 Plot Time Series Data Simulasi 1 Skenario 1 di Empat Lokasi



Gambar 4. 5 Plot Time Series Data Simulasi 1 Skenario 2 di Empat Lokasi

4.1.1. Pemodelan *Time Series Regression* (TSR) Pada Data Simulasi

Tahap pertama dilakukan pemodelan tren, musiman, dan variasi kalender menggunakan *Time Series Regression* dengan metode estimasi *Generalized Least Square* (GLS) dikarenakan residual model cenderung berkorelasi antar lokasi, sehingga jika menggunakan OLS, akan menghasilkan estimator yang tidak efisien. Sebelum dilakukan pemodelan terlebih dahulu data dibagi menjadi data *in sample* dan data *out sample*. Data *in sample* sebanyak 132 data atau periode 11 tahun, dan data *out sample* sebanyak 12 data atau periode 1 tahun. Berikut ini adalah hasil dari estimasi parameter tahap pertama menggunakan model regresi *time series* dapat dilihat pada Tabel 4.1.

Tabel 4.1 Koefisien Parameter Tahap I pada Data Simulasi 1

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	Batas atas	Batas bawah	
	$\delta^{(1)}$	0,3	0,309	0,31	0,29	Benar
	$\gamma_1^{(1)}$	16,50	16,703	17,61	15,39	Benar
	$\gamma_2^{(1)}$	19,79	20,169	20,91	18,68	Benar
	$\gamma_3^{(1)}$	21,00	21,363	22,12	19,88	Benar
	$\gamma_4^{(1)}$	19,79	19,837	20,92	18,67	Benar
	$\gamma_5^{(1)}$	16,50	16,276	17,62	15,38	Benar
	$\gamma_6^{(1)}$	12,00	12,221	13,13	10,87	Benar
	$\gamma_7^{(1)}$	7,50	7,783	8,68	6,32	Benar
	$\gamma_8^{(1)}$	4,21	4,283	5,43	2,98	Benar
	$\gamma_9^{(1)}$	3,00	3,272	4,24	1,76	Benar
1	$\gamma_{10}^{(1)}$	4,21	3,855	5,54	2,87	Benar
	$\gamma_{11}^{(1)}$	7,50	7,323	8,71	6,29	Benar
	$\gamma_{12}^{(1)}$	12,00	12,231	13,15	10,85	Benar
	$\psi_1^{(1)}$	8,13	9,211	10,63	5,62	Benar
	$\psi_2^{(1)}$	47,46	47,402	49,24	45,67	Benar
	$\psi_3^{(1)}$	66,50	66,903	69,01	63,98	Benar
	$\psi_4^{(1)}$	82,38	82,512	84,52	80,24	Benar
	$\psi_1^{(1)}$	62,29	63,241	64,80	59,77	Benar
	$\psi_2^{(1)}$	48,21	48,018	50,00	46,42	Benar
	$\psi_3^{(1)}$	33,07	33,085	35,58	30,57	Benar
	$\psi_4^{(1)}$	32,42	31,418	34,46	30,38	Benar

Tabel 4. 1 Koefisien Parameter Tahap I pada Data Simulasi 1 (lanjutan)

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	Batas atas	Batas bawah	
2	$\delta^{(2)}$	0,17	0,175	0,18	0,16	Benar
	$\gamma_1^{(2)}$	14,00	15,081	15,16	12,84	Benar
	$\gamma_2^{(2)}$	15,46	16,055	16,63	14,30	Benar
	$\gamma_3^{(2)}$	16,00	16,758	17,17	14,83	Benar
	$\gamma_4^{(2)}$	15,46	15,950	16,63	14,30	Benar
	$\gamma_5^{(2)}$	14,00	14,340	15,17	12,83	Benar
	$\gamma_6^{(2)}$	12,00	12,715	13,18	10,82	Benar
	$\gamma_7^{(2)}$	10,00	10,477	11,23	8,77	Benar
	$\gamma_8^{(2)}$	8,54	9,388	9,81	7,26	Benar
	$\gamma_9^{(2)}$	8,00	8,453	9,30	6,70	Benar
	$\gamma_{10}^{(2)}$	8,54	9,113	9,93	7,15	Benar
	$\gamma_{11}^{(2)}$	10,00	10,212	11,26	8,74	Benar
3	$\gamma_{12}^{(2)}$	12,00	12,606	13,20	10,80	Benar
	$\psi_1^{(2)}$	3,39	4,173	6,01	0,78	Benar
	$\psi_2^{(2)}$	11,14	10,842	13,00	9,27	Benar
	$\psi_3^{(2)}$	22,84	22,366	25,46	20,22	Benar
	$\psi_4^{(2)}$	29,59	28,366	31,82	27,36	Benar
	$\psi_5^{(2)}$	19,77	21,345	22,39	17,15	Benar
	$\psi_6^{(2)}$	13,39	13,156	15,25	11,53	Benar
	$\psi_7^{(2)}$	11,60	11,693	14,21	8,99	Benar
	$\psi_8^{(2)}$	9,05	8,537	11,17	6,92	Benar
	$\delta^{(3)}$	0,220	0,228	0,23	0,21	Benar
	$\gamma_1^{(3)}$	15,500	16,501	16,72	14,28	Benar
	$\gamma_2^{(3)}$	18,062	18,644	19,28	16,84	Benar
	$\gamma_3^{(3)}$	19,000	19,358	20,23	17,77	Benar
	$\gamma_4^{(3)}$	18,062	18,803	19,29	16,83	Benar
	$\gamma_5^{(3)}$	15,500	15,874	16,73	14,27	Benar
	$\gamma_6^{(3)}$	12,000	12,819	13,24	10,76	Benar
	$\gamma_7^{(3)}$	8,500	9,457	9,79	7,21	Benar
	$\gamma_8^{(3)}$	5,938	7,284	7,28	4,59	Benar
	$\gamma_9^{(3)}$	5,000	5,612	6,36	3,64	Benar
	$\gamma_{10}^{(3)}$	5,938	6,351	7,40	4,48	Benar

Tabel 4. 1 Koefisien Parameter Tahap I pada Data Simulasi 1 (lanjutan)

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	batas atas	batas bawah	
3	$\gamma_{11}^{(3)}$	8,500	8,746	9,83	7,17	Benar
	$\gamma_{12}^{(3)}$	12,000	12,422	13,26	10,74	Benar
	$\psi_1^{(3)}$	3,737	5,030	6,48	0,99	Benar
	$\psi_2^{(3)}$	15,992	15,234	17,95	14,03	Benar
	$\psi_3^{(3)}$	33,783	33,660	36,54	31,02	Benar
	$\psi_4^{(3)}$	36,396	35,911	38,74	34,05	Benar
	$\psi_1^{(3)}$	28,704	31,344	31,46	25,94	Benar
	$\psi_2^{(3)}$	20,465	20,055	22,43	18,50	Benar
	$\psi_3^{(3)}$	18,387	17,683	21,13	15,64	Benar
	$\psi_4^{(3)}$	16,117	15,053	18,35	13,88	Benar
4	$\delta^{(4)}$	0,15	0,157	0,16	0,14	Benar
	$\gamma_1^{(4)}$	14,50	15,287	15,68	13,32	Benar
	$\gamma_2^{(4)}$	16,33	17,032	17,51	15,15	Benar
	$\gamma_3^{(4)}$	17,00	17,614	18,19	15,81	Benar
	$\gamma_4^{(4)}$	16,33	16,674	17,52	15,14	Benar
	$\gamma_5^{(4)}$	14,50	14,978	15,70	13,30	Benar
	$\gamma_6^{(4)}$	12,00	12,806	13,20	10,80	Benar
	$\gamma_7^{(4)}$	9,50	10,326	10,75	8,25	Benar
	$\gamma_8^{(4)}$	7,67	8,263	8,97	6,37	Benar
	$\gamma_9^{(4)}$	7,00	7,203	8,32	5,68	Benar
	$\gamma_{10}^{(4)}$	7,67	7,742	9,09	6,25	Benar
	$\gamma_{11}^{(4)}$	9,50	9,667	10,79	8,21	Benar
	$\gamma_{12}^{(4)}$	12,00	12,510	13,22	10,78	Benar
	$\psi_1^{(4)}$	1,73	2,085	4,39	-0,93	Benar
	$\psi_2^{(4)}$	7,87	7,603	9,77	5,97	Benar
	$\psi_3^{(4)}$	14,21	14,345	16,88	11,54	Benar
	$\psi_4^{(4)}$	18,48	18,057	20,75	16,20	Benar
	$\psi_1^{(4)}$	14,21	16,778	16,89	11,54	Benar
	$\psi_2^{(4)}$	10,67	10,602	12,57	8,77	Benar
	$\psi_3^{(4)}$	10,43	11,550	13,09	7,77	Benar
	$\psi_4^{(4)}$	8,85	7,239	11,02	6,68	Benar

Berdasarkan hasil estimasi parameter yang dapat dilihat pada Tabel 4.1 dengan *confidence interval* 95%, keseluruhan parameter yang diestimasi telah memberikan hasil yang benar atau telah sesuai dengan nilai parameter yang sebenarnya. Dapat diketahui dari selang kepercayaan 95%, seluruh parameter yang diestimasi telah memuat nilai parameter sebenarnya. Keseluruhan parameter model TSR yang telah diestimasi telah signifikan. Sehingga didapatkan persamaan model TSR adalah sebagai berikut

$$Y_t^{(1)} = 0,309t + 16,703S_{1,t} + 20,176S_{2,t} + 21,363S_{3,t} + 19,837S_{4,t} + 16,276S_{5,t} + 12,221S_{6,t} + 7,783S_{7,t} + 4,283S_{8,t} + 3,272S_{9,t} + 3,855S_{10,t} + 7,323S_{11,t} + 12,231S_{12,t} + 9,211V_{1,t} + 47,402V_{2,t} + 66,903V_{3,t} + 82,512V_{4,t} + 63,241V_{1,t-1} + 48,018V_{2,t-1} + 33,085V_{3,t-1} + 31,418V_{4,t-1} + N_{1,t}.$$

$$Y_t^{(2)} = 0,175t + 15,081S_{1,t} + 16,055S_{2,t} + 16,758S_{3,t} + 15,950S_{4,t} + 14,340S_{5,t} + 12,715S_{6,t} + 10,477S_{7,t} + 9,388S_{8,t} + 8,453S_{9,t} + 9,113S_{10,t} + 10,212S_{11,t} + 12,606S_{12,t} + 4,173V_{1,t} + 10,842V_{2,t} + 22,366V_{3,t} + 28,366V_{4,t} + 21,345V_{1,t-1} + 13,156V_{2,t-1} + 11,693V_{3,t-1} + 8,537V_{4,t-1} + N_{2,t}$$

$$Y_t^{(3)} = 0,228t + 16,501S_{1,t} + 18,644S_{2,t} + 19,358S_{3,t} + 18,803S_{4,t} + 15,874S_{5,t} + 12,819S_{6,t} + 9,457S_{7,t} + 7,284S_{8,t} + 5,612S_{9,t} + 6,351S_{10,t} + 8,746S_{11,t} + 12,422S_{12,t} + 5,030V_{1,t} + 15,234V_{2,t} + 33,660V_{3,t} + 35,911V_{4,t} + 31,344V_{1,t-1} + 20,055V_{2,t-1} + 17,683V_{3,t-1} + 15,053V_{4,t-1} + N_{3,t}.$$

$$Y_t^{(4)} = 0,157t + 15,287S_{1,t} + 17,032S_{2,t} + 17,614S_{3,t} + 16,674S_{4,t} + 14,978S_{5,t} + 12,806S_{6,t} + 10,326S_{7,t} + 8,263S_{8,t} + 7,203S_{9,t} + 7,742S_{10,t} + 9,667S_{11,t} + 12,510S_{12,t} + 2,085V_{1,t} + 7,603V_{2,t} + 14,345V_{3,t} + 18,057V_{4,t} + 16,778V_{1,t-1} + 10,602V_{2,t-1} + 11,550V_{3,t-1} + 7,239V_{4,t-1} + N_{4,t}.$$

Persamaan-persamaan model diatas dapat disajikan dalam bentuk matriks sebagai berikut

$$\begin{aligned}
\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} &= \begin{bmatrix} 0,309 & 0 & 0 & 0 \\ 0 & 0,175 & 0 & 0 \\ 0 & 0 & 0,228 & 0 \\ 0 & 0 & 0 & 0,157 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} 16,703 & 0 & 0 & 0 \\ 0 & 15,081 & 0 & 0 \\ 0 & 0 & 16,501 & 0 \\ 0 & 0 & 0 & 15,287 \end{bmatrix} \\
&\quad \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots + \begin{bmatrix} 33,085 & 0 & 0 & 0 \\ 0 & 11,693 & 0 & 0 \\ 0 & 0 & 17,683 & 0 \\ 0 & 0 & 0 & 11,550 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \\ V_{3,t-1}^{(4)} \end{bmatrix} + \\
&\quad \begin{bmatrix} 31,418 & 0 & 0 & 0 \\ 0 & 8,537 & 0 & 0 \\ 0 & 0 & 15,053 & 0 \\ 0 & 0 & 0 & 7,239 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} \begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix}.
\end{aligned}$$

Selanjutnya akan dilakukan pemodelan data simulasi skenario 1 dan 2 menggunakan model GSTAR, Jordan RNN, *hybrid* GSTARX-FFNN, *hybrid* GSTARX-DLNN, dan *hybrid* GSTARX-Jordan RNN. Selanjutnya adalah pemodelan data simulasi 1 skenario 2 menggunakan model TSR dan berikut ini adalah hasil estimasi parameter yang didapatkan

Tabel 4. 2 Hasil Estimasi Parameter Tahap I Data Simulasi 1 Skenario 2

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	batas atas	batas bawah	
1	$\delta^{(1)}$	0,3	0,287	0,877	-0,303	Benar
	$\gamma_1^{(1)}$	16,50	17,159	53,691	-19,373	Benar
	$\gamma_2^{(1)}$	19,79	21,236	65,928	-23,456	Benar
	$\gamma_3^{(1)}$	21,00	21,792	67,602	-24,019	Benar
	$\gamma_4^{(1)}$	19,79	19,266	60,033	-21,500	Benar
	$\gamma_5^{(1)}$	16,50	15,034	47,343	-17,275	Benar
	$\gamma_6^{(1)}$	12,00	12,856	40,815	-15,104	Benar
	$\gamma_7^{(1)}$	7,50	8,833	28,848	-11,183	Benar
	$\gamma_8^{(1)}$	4,21	5,325	18,419	-7,769	Benar
	$\gamma_9^{(1)}$	3,00	3,669	13,483	-6,145	Benar
	$\gamma_{10}^{(1)}$	4,21	4,511	16,191	-7,168	Benar

Tabel 4. 2 Hasil Estimasi Parameter Tahap I Data Simulasi 1 Skenario 2 (lanjutan)

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	batas atas	batas bawah	
1	$\gamma_{11}^{(1)}$	7,50	7,944	26,248	-10,360	Benar
	$\gamma_{12}^{(1)}$	12,00	12,242	39,018	-14,534	Benar
	$\psi_1^{(1)}$	8,13	4,267	17,795	-9,261	Benar
	$\psi_2^{(1)}$	47,46	50,031	153,658	-53,595	Benar
	$\psi_3^{(1)}$	66,50	69,568	213,716	-74,581	Benar
	$\psi_4^{(1)}$	82,38	81,606	249,084	-85,872	Benar
	$\psi_1^{(1)}$	62,29	61,461	189,399	-66,477	Benar
	$\psi_2^{(1)}$	48,21	50,037	153,674	-53,601	Benar
	$\psi_3^{(1)}$	33,07	32,142	101,417	-37,133	Benar
	$\psi_4^{(1)}$	32,42	30,878	96,696	-34,941	Benar
2	$\delta^{(2)}$	0,17	0,159	0,176	0,142	Benar
	$\gamma_1^{(2)}$	14,00	14,518	16,913	12,123	Benar
	$\gamma_1^{(2)}$	15,46	15,830	18,232	13,428	Benar
	$\gamma_3^{(2)}$	16,00	15,587	17,997	13,178	Benar
	$\gamma_4^{(2)}$	15,46	14,304	16,721	11,887	Benar
	$\gamma_5^{(2)}$	14,00	12,136	14,560	9,711	Benar
	$\gamma_6^{(2)}$	12,00	12,805	15,237	10,373	Benar
	$\gamma_7^{(2)}$	10,00	10,970	13,512	8,427	Benar
	$\gamma_8^{(2)}$	8,54	9,415	12,059	6,772	Benar
	$\gamma_9^{(2)}$	8,00	7,796	10,475	5,117	Benar
	$\gamma_{10}^{(2)}$	8,54	8,853	11,728	5,979	Benar
	$\gamma_{11}^{(2)}$	10,00	9,884	12,498	7,271	Benar
	$\gamma_{12}^{(2)}$	12,00	11,111	13,591	8,632	Benar
	$\psi_1^{(2)}$	3,39	-0,460	4,942	-5,862	Benar
	$\psi_2^{(2)}$	11,14	11,641	15,497	7,785	Benar
	$\psi_3^{(2)}$	22,84	25,688	31,111	20,265	Benar
	$\psi_4^{(2)}$	29,59	27,886	32,502	23,270	Benar
	$\psi_1^{(2)}$	19,77	18,528	23,955	13,101	Benar
	$\psi_2^{(2)}$	13,39	15,655	19,511	11,800	Benar
	$\psi_3^{(2)}$	11,60	10,445	15,843	5,046	Benar
	$\psi_4^{(2)}$	9,05	10,314	14,710	5,918	Benar

Tabel 4.2 Hasil Estimasi Parameter Tahap I Data Simulasi 1 Skenario 2 (lanjutan)

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	batas atas	batas bawah	
3	$\delta^{(3)}$	0,220	0,208	0,226	0,190	Benar
	$\gamma_1^{(3)}$	15,500	15,850	18,470	13,230	Benar
	$\gamma_2^{(3)}$	18,062	18,535	21,163	15,907	Benar
	$\gamma_3^{(3)}$	19,000	18,546	21,182	15,910	Benar
	$\gamma_4^{(3)}$	18,062	17,441	20,085	14,797	Benar
	$\gamma_5^{(3)}$	15,500	14,132	16,785	11,480	Benar
	$\gamma_6^{(3)}$	12,000	13,427	16,087	10,766	Benar
	$\gamma_7^{(3)}$	8,500	10,931	13,713	8,150	Benar
	$\gamma_8^{(3)}$	5,938	8,888	11,779	5,996	Salah
	$\gamma_9^{(3)}$	5,000	6,571	9,502	3,641	Benar
	$\gamma_{10}^{(3)}$	5,938	6,818	9,962	3,674	Benar
	$\gamma_{11}^{(3)}$	8,500	9,134	11,993	6,275	Benar
	$\gamma_{12}^{(3)}$	12,000	11,615	14,327	8,902	Benar
	$\psi_1^{(3)}$	3,737	0,317	6,227	-5,592	Benar
4	$\psi_2^{(3)}$	15,992	15,110	19,328	10,892	Benar
	$\psi_3^{(3)}$	33,783	37,177	43,109	31,244	Benar
	$\psi_4^{(3)}$	36,396	36,205	41,255	31,156	Benar
	$\psi_1^{(3)}$	28,704	27,859	33,796	21,922	Benar
	$\psi_2^{(3)}$	20,465	20,205	24,423	15,987	Benar
	$\psi_3^{(3)}$	18,387	18,266	24,172	12,361	Benar
	$\psi_4^{(3)}$	16,117	15,998	20,807	11,189	Benar
	$\delta^{(4)}$	0,15	0,136	0,152	0,120	Benar
	$\gamma_1^{(4)}$	14,50	15,852	18,096	13,607	Benar
	$\gamma_2^{(4)}$	16,33	17,833	20,084	15,581	Benar
4	$\gamma_3^{(4)}$	17,00	17,109	19,367	14,850	Benar
	$\gamma_4^{(4)}$	16,33	15,560	17,825	13,294	Benar
	$\gamma_5^{(4)}$	14,50	13,159	15,431	10,887	Benar
	$\gamma_6^{(4)}$	12,00	13,355	15,634	11,075	Benar
	$\gamma_7^{(4)}$	9,50	11,523	13,906	9,140	Benar
	$\gamma_8^{(4)}$	7,67	9,069	11,547	6,592	Benar
	$\gamma_9^{(4)}$	7,00	7,555	10,066	5,044	Benar

Tabel 4. 2 Hasil Estimasi Parameter Tahap I Data Simulasi 1 Skenario 2 (lanjutan)

Lokasi	Parameter	Koefisien		CI 95%		Keterangan
		Nilai Sebenarnya	Estimasi	batas atas	batas bawah	
4	$\gamma_{10}^{(4)}$	7,67	9,069	11,547	6,592	Benar
	$\gamma_{11}^{(4)}$	9,50	10,085	12,534	7,635	Benar
	$\gamma_{12}^{(4)}$	12,00	12,101	14,425	9,777	Salah
	$\psi_1^{(4)}$	1,73	-3,849	1,215	-8,912	Benar
	$\psi_2^{(4)}$	7,87	9,471	13,085	5,857	Benar
	$\psi_3^{(4)}$	14,21	16,070	21,154	10,987	Benar
	$\psi_4^{(4)}$	18,48	17,530	21,856	13,203	Benar
	$\psi_1^{(4)}$	14,21	13,572	18,658	8,485	Benar
	$\psi_2^{(4)}$	10,67	12,907	16,521	9,292	Benar
	$\psi_3^{(4)}$	10,43	10,229	15,289	5,169	Benar
	$\psi_4^{(4)}$	8,851	6,901	11,021	2,780	Benar

Dari hasil estimasi parameter yang didapatkan pada beberapa tabel diatas, terdapat satu parameter yang tidak signifikan pada lokasi 3 dan 4. Berikut ini adalah model persamaan dari koefisien-koefisien yang sudah didapatkan

$$\begin{aligned} Y_t^{(1)} = & 0,287t + 17,159S_{1,t} + 21,236S_{2,t} + 21,792S_{3,t} + 19,266S_{4,t} + 15,034S_{5,t} + 12,856S_{6,t} + \\ & 8,833S_{7,t} + 5,325S_{8,t} + 3,669S_{9,t} + 4,511S_{10,t} + 7,944S_{11,t} + 12,242S_{12,t} + \\ & 4,267V_{1,t} + 50,031V_{2,t} + 69,568V_{3,t} + 81,606V_{4,t} + 61,461V_{1,t-1} + 50,037V_{2,t-1} + \\ & 32,142V_{3,t-1} + 30,878V_{4,t-1} + \varepsilon_{1,t}. \end{aligned}$$

$$\begin{aligned} Y_t^{(2)} = & 0,159t + 14,518S_{1,t} + 15,830S_{2,t} + 15,587S_{3,t} + 14,304S_{4,t} + 12,136S_{5,t} + 12,805S_{6,t} + \\ & 10,970S_{7,t} + 9,415S_{8,t} + 7,796S_{9,t} + 8,853S_{10,t} + 9,884S_{11,t} + 11,111S_{12,t} - \\ & 0,460V_{1,t} + 11,641V_{2,t} + 25,688V_{3,t} + 27,886V_{4,t} + 18,528V_{1,t-1} + 15,655V_{2,t-1} + \\ & 10,445V_{3,t-1} + 10,314V_{4,t-1} + \varepsilon_{2,t}. \end{aligned}$$

$$\begin{aligned} Y_t^{(3)} = & 0,208t + 15,850S_{1,t} + 18,535S_{2,t} + 18,546S_{3,t} + 17,441S_{4,t} + 14,132S_{5,t} + \\ & 13,427S_{6,t} + 10,931S_{7,t} + 8,888S_{8,t} + 6,571S_{9,t} + 6,818S_{10,t} + 9,134S_{11,t} + \\ & 11,615S_{12,t} + 0,317V_{1,t} + 15,110V_{2,t} + 37,177V_{3,t} + 36,205V_{4,t} + 27,859V_{1,t-1} + \\ & 20,205V_{2,t-1} + 18,266V_{3,t-1} + 15,998V_{4,t-1} + \varepsilon_{3,t}. \end{aligned}$$

$$\begin{aligned} Y_t^{(4)} = & 0,136t + 15,852S_{1,t} + 17,833S_{2,t} + 17,109S_{3,t} + 15,560S_{4,t} + 13,159S_{5,t} + 13,355S_{6,t} + \\ & 11,523S_{7,t} + 9,069S_{8,t} + 7,555S_{9,t} + 8,277S_{10,t} + 10,085S_{11,t} + 12,101S_{12,t} - \\ & 3,849V_{1,t} + 9,471V_{2,t} + 16,070V_{3,t} + 17,530V_{4,t} + 13,572V_{1,t-1} + 12,907V_{2,t-1} + \\ & 10,229V_{3,t-1} + 6,901V_{4,t-1} + \varepsilon_{4,t}. \end{aligned}$$

Persamaan diatas dapat disajikan dalam bentuk matriks sebagai berikut

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0.287 & 0 & 0 & 0 \\ 0 & 0.159 & 0 & 0 \\ 0 & 0 & 0.208 & 0 \\ 0 & 0 & 0 & 0.136 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} 17.159 & 0 & 0 & 0 \\ 0 & 14.518 & 0 & 0 \\ 0 & 0 & 15.850 & 0 \\ 0 & 0 & 0 & 15.852 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix}$$

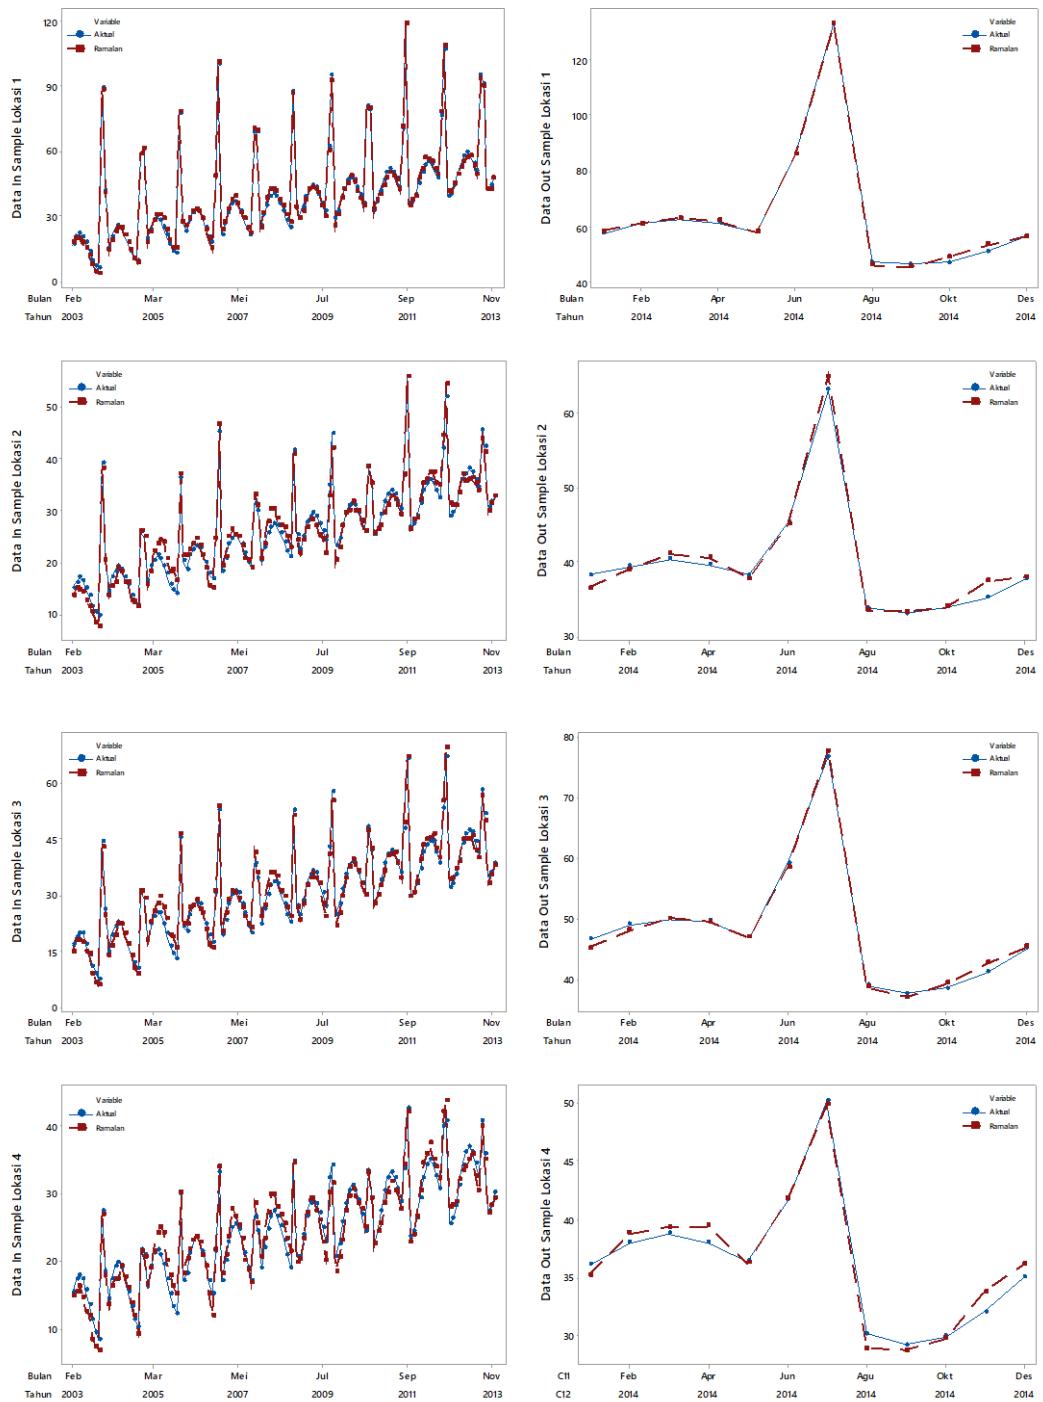
$$+ \dots + \begin{bmatrix} 32.142 & 0 & 0 & 0 \\ 0 & 10.445 & 0 & 0 \\ 0 & 0 & 18.266 & 0 \\ 0 & 0 & 0 & 10.229 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \\ V_{3,t-1}^{(4)} \end{bmatrix} +$$

$$\begin{bmatrix} 30.878 & 0 & 0 & 0 \\ 0 & 10.314 & 0 & 0 \\ 0 & 0 & 15.998 & 0 \\ 0 & 0 & 0 & 6.901 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix}$$

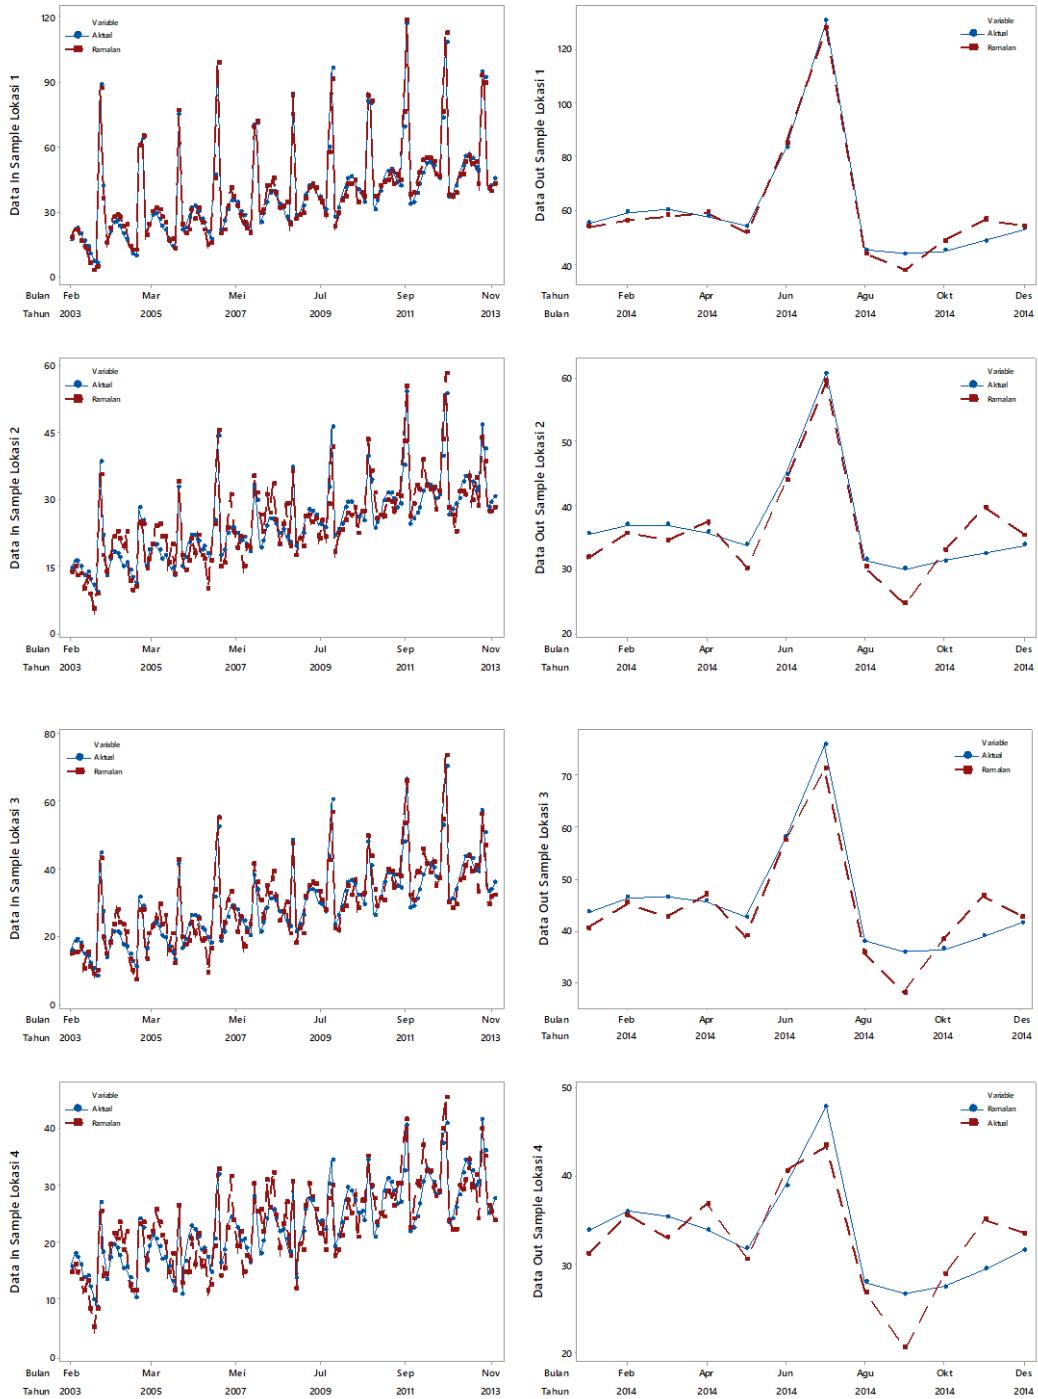
Setelah dilakukan pemodelan pada tahap pertama menggunakan model TSR, maka dilakukan peramalan untuk data *out sample* skenario 1 dan skenario 2 pada masing-masing lokasi yang dapat dilihat pada Gambar 4. 6.

Berdasarkan Gambar 4.6 yang merupakan *time series plot* data aktual dan ramalan pada data *in sample* dan *out sample* hasil pemodelan TSR untuk data simulasi 1 skenario 1. Gambar tersebut menunjukkan bahwa data hasil ramalan telah mengikuti pola data aktual yang mengandung komponen tren, musiman, dan variasi kalender.

Gambar 4. 7 menunjukkan *time series plot* dari data aktual dan data hasil ramalan menggunakan model TSR untuk data simulasi 1 skenario 2. Berdasarkan gambar tersebut dapat diketahui bahwa nilai ramalan pada data *in sample* telah mampu mengikuti pola data aktual yang mengandung komponen tren, musiman, dan variasi kalender, sedangkan pada data *out sample* terlihat bahwa nilai ramalan belum mampu mengikuti pola data aktual secara tepat. Hal ini dikarenakan pada data skenario 2 mengandung komponen residual yang mengikuti pola nonlinier dan belum mampu ditangkap oleh model TSR.



Gambar 4. 6 Time Series Plot Data Aktual dan Hasil Ramalan Model TSR Simulasi 1 Skenario 1

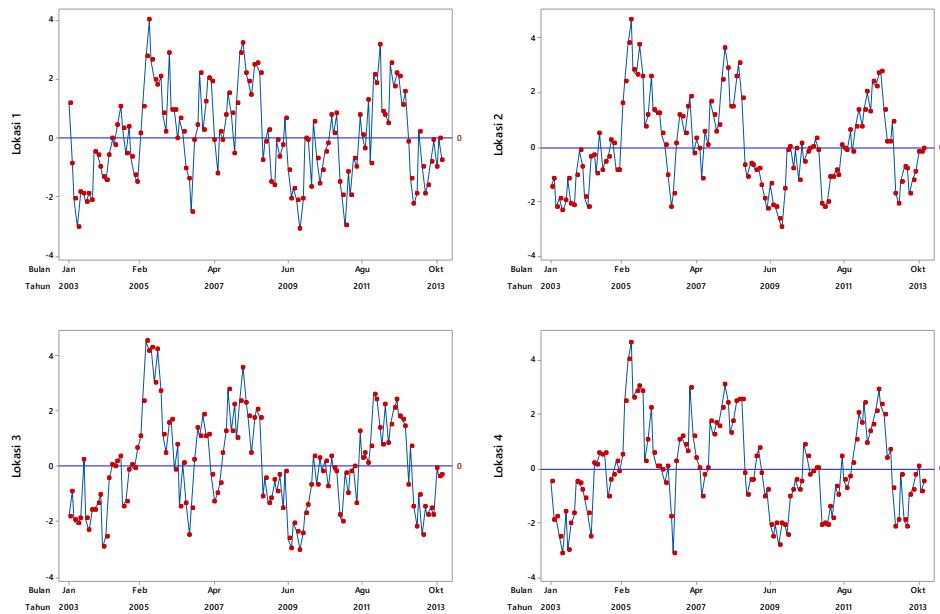


Gambar 4. 7 Time Series Plot Data Aktual dan Ramalan Model TSR Data Simulasi 1 Skenario 2

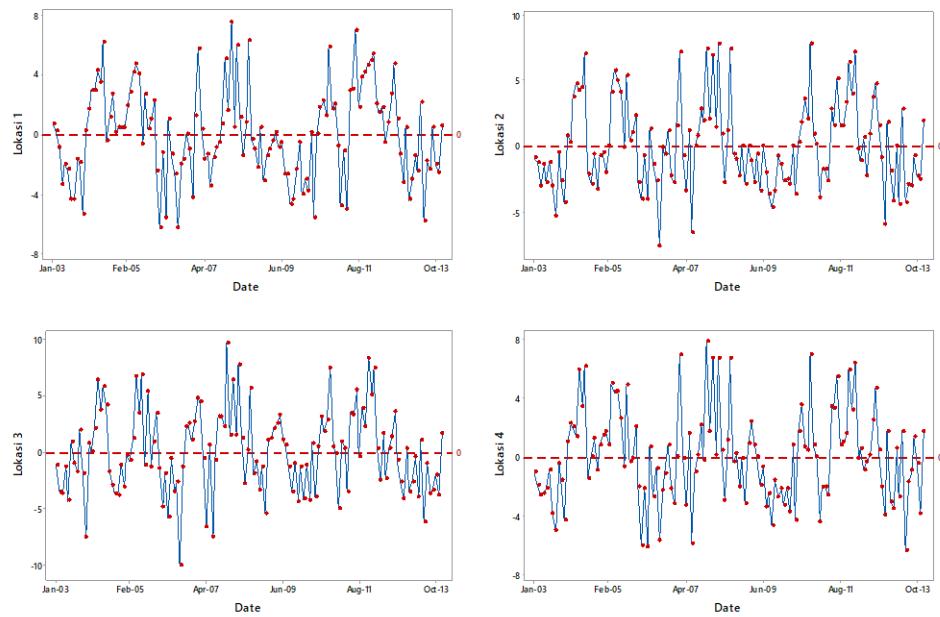
4.1.2. Pemodelan GSTAR pada Data Simulasi

Pada pemodelan tahap ini yang dimodelkan menggunakan GSTAR adalah data aktual dan data residual model TSR yang selanjutnya disebut dengan GSTARX. Berikut ini adalah hasil pemodelan data residual TSR menggunakan

metode GSTARX dengan langkah awal dalam pemodelan adalah melakukan identifikasi stasioneritas data. Proses identifikasi stasioneritas secara visual dilakukan dengan melihat *time series plot* dari residual hasil pemodelan pada tahap pertama, yang ditampilkan pada Gambar 4.8.



Gambar 4. 8 *Time Series Plot* Residual Pemodelan Tahap Pertama Data Simulasi 1 Skenario 1



Gambar 4. 9 *Time Series Plot* Residual Pemodelan Tahap Pertama Data Simulasi 1 Skenario 2

Berdasarkan Gambar 4.8 dan 4.9 dapat diketahui bahwa data residual dari model TSR pada skenario 1 dan 2 telah stasioner karena plot data menyebar acak disekitar 0 dan tidak membentuk pola tertentu. Selain secara visual dari *time series plot* identifikasi stasioneritas juga dapat dilakukan dengan melihat pola dari skematik MCCF yang dapat dilihat pada Gambar 4. 10.

Schematic Representation of Cross Correlations-Skenario 1													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	.	+++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++..
yresid4	++++	++++	++++	++++	++++	++++	++++	++++

+ is $> 2 \times \text{std error}$, - is $< -2 \times \text{std error}$, . is between

Schematic Representation of Cross Correlations-Skenario 2													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++..	++..
yresid2	++++	++++	++++	++..	++..
yresid3	++++	++++	++++	++..	++..	--..
yresid4	++++	++++	++++	++..	++..

+ is $> 2 \times \text{std error}$, - is $< -2 \times \text{std error}$, . is between

Gambar 4. 10. Representasi Skematik MCCF Residual Data Simulasi 1 Skenario I dan 2

Gambar 4. 10 menunjukkan representasi dari skematik MCCF yang menunjukkan bahwa data sudah stasioner baik skenario 1 maupun skenario 2 karena memiliki pola yang cenderung turun cepat. Selanjutnya adalah melakukan identifikasi untuk menentukan orde model dengan melihat skematik MPCCF yang dapat dilihat pada Gambar 4. 11 berikut ini

Schematic Representation of Partial Autoregression-Skenario 1												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	...++	-....	-..
yresid2	.++.
yresid3	.++.	...+
yresid4	.+++	+... ..-

+ is $> 2 \times \text{std error}$, - is $< -2 \times \text{std error}$, . is between

Schematic Representation of Partial Cross Correlations-Skenario 2												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	+...	+...
yresid2	.+..	-..
yresid3	.+..	...+	+..
yresid4	+...	+...	...+	-..	-..

+ is $> 2 \times \text{std error}$, - is $< -2 \times \text{std error}$, . is between

Gambar 4. 11 Representasi Skematik MPCCF Residual Data Simulasi 1 Skenario I

Berdasarkan Gambar 4.11 yang menunjukkan skematik MPCCF, dapat diketahui bahwa *lag* yang signifikan yaitu pada *lag* 1 untuk data simulasi 1 skenario 1, karena keluar dari batas. Sedangkan untuk data simulasi 1 skenario 2 diketahui bahwa *lag* yang keluar dari batas adalah *lag* 1 dan 2. Sehingga model dugaan yang digunakan untuk data skenario 1 adalah GSTARX(1₁) dan untuk data skenario 2 adalah GSTARX(2₁). Bobot yang digunakan dalam pemodelan GSTARX yaitu bobot seragam dengan mengasumsikan bahwa setiap lokasi bersifat homogen. Estimasi parameter yang digunakan dalam pemodelan adalah GLS, sama halnya dengan pemodelan tahap pertama. Hasil estimasi parameter model GSTARX (1₁) dan GSTARX(2₁) adalah berikut ini

Tabel 4. 3 Koefisien Parameter Model GSTARX Simulasi 1 Skenario 1 dan 2

Skenario	Lokasi	Parameter	Estimasi	Batas atas	Batas bawah	P-value
1	1	ϕ_{10}^1	0,208	0,374	0,042	0,0132*
		ϕ_{11}^1	0,600	0,771	0,430	<,0001*
	2	ϕ_{20}^1	0,384	0,556	0,211	<,0001*
		ϕ_{21}^1	0,489	0,679	0,298	<,0001*
	3	ϕ_{30}^1	0,385	0,553	0,216	<,0001*
		ϕ_{31}^1	0,477	0,674	0,281	<,0001*
	4	ϕ_{40}^1	0,261	0,434	0,087	0,0032*
		ϕ_{41}^1	0,648	0,843	0,454	<,0001*
2	1	ϕ_{10}^1	0,218	0,374	0,061	0,006*
		ϕ_{11}^1	0,086	0,265	-0,094	0,342
		ϕ_{10}^2	0,230	0,385	0,075	0,004*
		ϕ_{11}^2	0,177	0,358	-0,003	0,052
	2	ϕ_{20}^1	0,227	0,401	0,052	0,010*
		ϕ_{21}^1	0,024	0,247	-0,199	0,828
		ϕ_{20}^2	0,214	0,387	0,040	0,015*
		ϕ_{21}^2	0,300	0,523	0,077	0,008*
3	3	ϕ_{30}^1	0,224	0,398	0,050	0,011*
		ϕ_{31}^1	0,016	0,257	-0,224	0,892
		ϕ_{30}^2	0,311	0,488	0,134	0,001*
		ϕ_{31}^2	0,199	0,440	-0,042	0,101
	4	ϕ_{40}^1	0,158	0,312	0,004	0,042*
		ϕ_{41}^1	0,074	0,260	-0,112	0,428
		ϕ_{40}^2	0,064	0,219	-0,091	0,411
		ϕ_{41}^2	0,341	0,527	0,154	0,000*

*Signifikansi $\alpha = 0,05$

Tabel 4.3 menunjukkan bahwa hasil estimasi model GSTARX pada skenario 1 keseluruhan parameternya telah signifikan, karena memiliki *P-value* kurang dari 0.05. Sedangkan pada hasil estimasi parameter GSTARX skenario 2, terdapat beberapa parameter yang tidak signifikan. Secara lengkap model GSTARX(1₁) data simulasi 1 skenario 1 dapat dituliskan dalam bentuk matriks sebagai berikut

Persamaan model GSTARX data simulasi 1 skenario 1

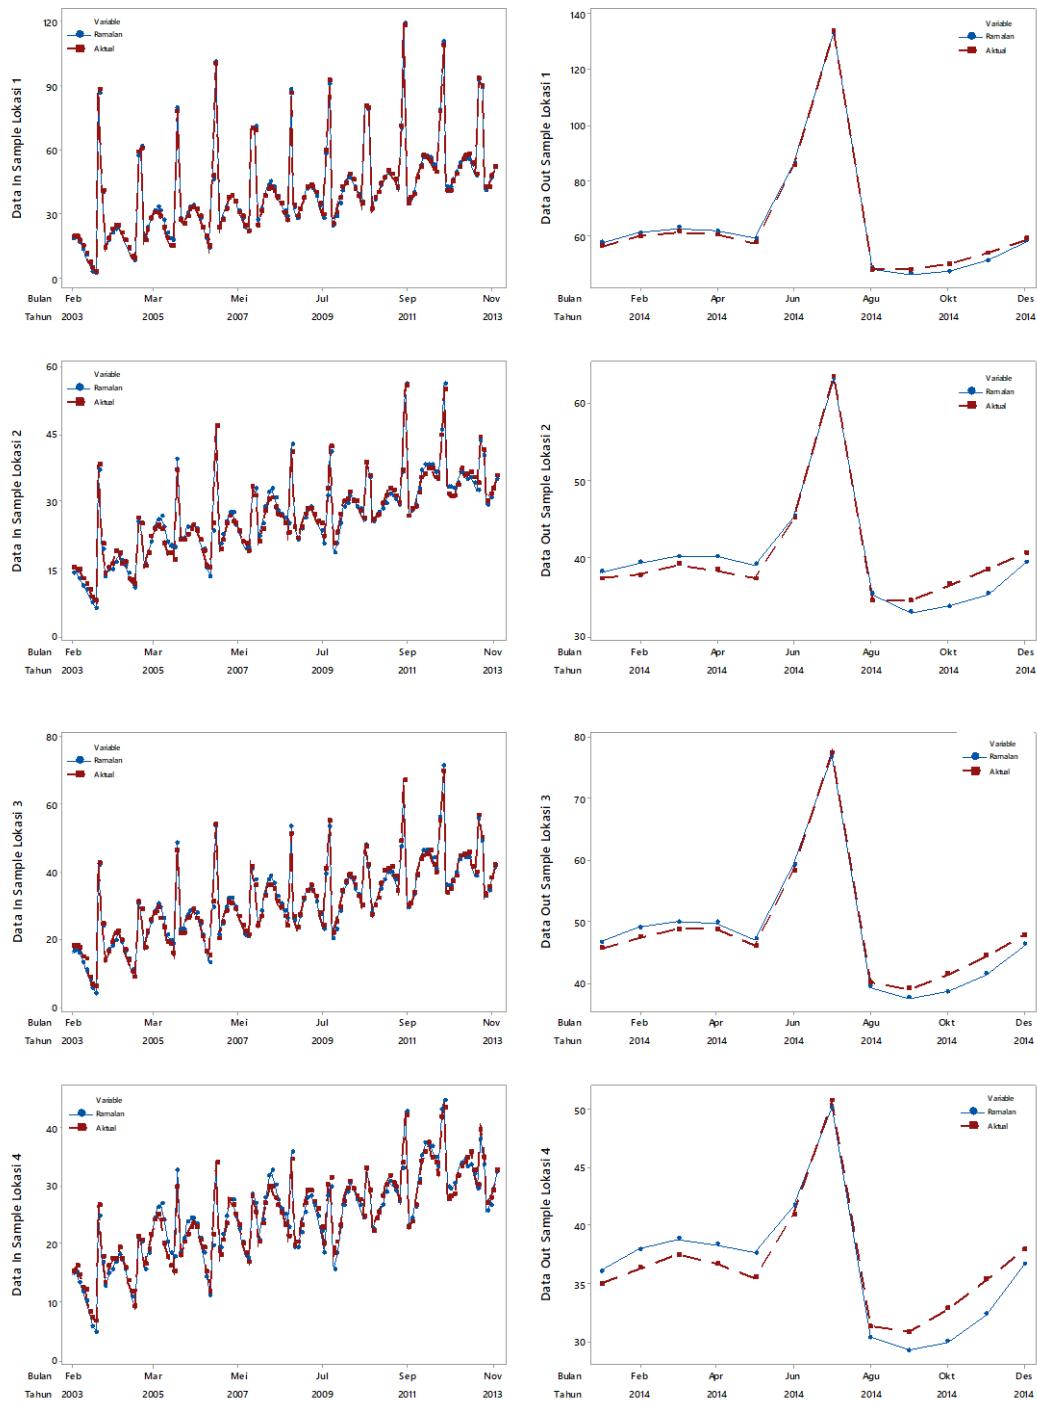
$$\begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,208 & 0,200 & 0,200 & 0,200 \\ 0,163 & 0,348 & 0,163 & 0,163 \\ 0,159 & 0,159 & 0,385 & 0,159 \\ 0,216 & 0,216 & 0,216 & 0,261 \end{bmatrix} \begin{bmatrix} \varepsilon_{t-1}^{(1)} \\ \varepsilon_{t-1}^{(2)} \\ \varepsilon_{t-1}^{(3)} \\ \varepsilon_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}$$

Persamaan model GSTARX data simulasi 1 skenario 2

$$\begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix} = \begin{bmatrix} [0,088 & 0 & 0 & 0] \\ [0 & 0,173 & 0 & 0] \\ [0 & 0 & 0,274 & 0] \\ [0 & 0 & 0 & 0,123] \end{bmatrix} \begin{bmatrix} \varepsilon_{t-1}^{(1)} \\ \varepsilon_{t-1}^{(2)} \\ \varepsilon_{t-1}^{(3)} \\ \varepsilon_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} [0,247 & 0 & 0 & 0] \\ [0 & 0,129 & 0 & 0] \\ [0 & 0 & -0,039 & 0] \\ [0 & 0 & 0 & 0,128] \end{bmatrix} + \dots$$

$$\begin{bmatrix} [0,234 & 0 & 0 & 0] \\ [0 & 0,102 & 0 & 0] \\ [0 & 0 & 0,275 & 0] \\ [0 & 0 & 0 & 0,067] \end{bmatrix} \begin{bmatrix} \varepsilon_{t-2}^{(1)} \\ \varepsilon_{t-2}^{(2)} \\ \varepsilon_{t-2}^{(3)} \\ \varepsilon_{t-2}^{(4)} \end{bmatrix} + \begin{bmatrix} [0,105 & 0 & 0 & 0] \\ [0 & 0,157 & 0 & 0] \\ [0 & 0 & 0,001 & 0] \\ [0 & 0 & 0 & 0,177] \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}$$

Selanjutnya dilakukan peramalan untuk data *out sample* data simulasi 1 di empat lokasi menggunakan model GSTARX(1₁) untuk data skenario 1 dan menggunakan model GSTARX(2₁). Berikut ini adalah *time series plot* hasil ramalan di empat lokasi masing-masing skenario

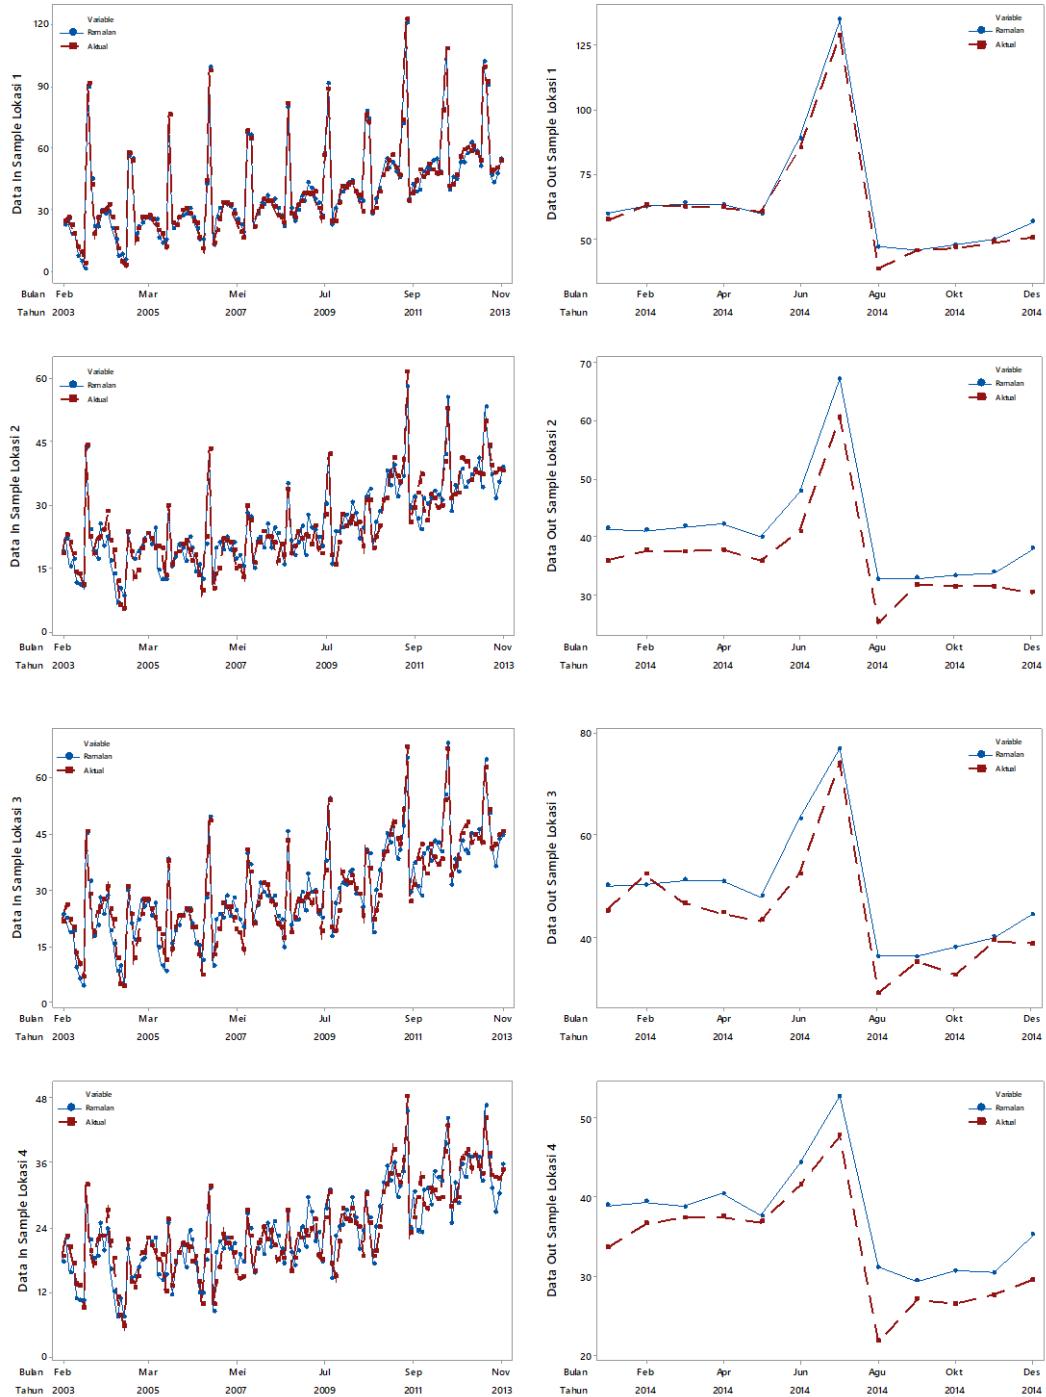


Gambar 4. 12 Time Series Plot Data Aktual dan Forecast Model GSTARX Data Simulasi 1

Skenario 1

Gambar 4. 12 adalah *time series plot* dari ramalan pada data *in sample* dan *out sample* simulasi 1 pada empat lokasi. Gambar tersebut menunjukkan bahwa

pola data hasil ramalan sudah mengikuti pola data simulasi namun masih belum sepenuhnya mengikuti pola data aktual.



**Gambar 4. 13 Time Series Plot Data Aktual dan Forecast Model GSTARX Data Simulasi 1
Skenario 2**

Gambar 4. 13 menunjukkan perbandingan *time series plot* antara data aktual dan data ramalan pada data *in sample* dan *out sample* simulasi 1 skenario 2. Dari gambar tersebut dapat diketahui bahwa hasil ramalan menggunakan model GSTARX(2₁) telah mengikuti pola data aktual namun masih terdapat jarak yang cukup jauh antar titik datanya. Hal ini dikarenakan model GSTARX belum ammpu menangkap pola residual yang nonlinier pada data simulasi skenario 2.

Selanjutnya dilihat nilai kebaikan model GSTARX dalam meramalkan data simulasi pada skenario 1 dan 2 menggunakan nilai RMSE pada data *in sample* dan *out sample*.

Tabel 4. 4 Nilai Kebaikan Model GSTARX pada Skenario 1

Simulasi	RMSE Data <i>In Sample</i>				RMSE Data <i>Out Sample</i>			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1								
1	1,525	1,581	1,649	1,616	1,202	1,178	0,783	0,920
2	1,125	1,339	1,424	1,214	1,312	1,825	2,355	1,626
3	1,459	1,415	1,455	1,568	0,871	0,561	0,886	0,939
4	1,729	2,039	1,935	2,029	1,277	1,561	1,697	1,527
5	1,256	1,594	1,633	1,720	1,117	1,549	2,077	1,646
6	1,557	1,700	1,634	1,841	1,025	0,642	0,764	1,261
7	1,309	1,530	1,604	1,540	1,068	1,172	1,350	1,575
8	1,548	1,673	1,604	1,703	1,429	1,250	1,133	1,443
9	1,671	1,896	1,921	1,882	2,874	3,499	3,317	3,393
10	1,724	2,058	2,050	2,093	0,891	1,021	0,980	1,013
Skenario 2								
1	3,025	3,267	3,470	3,074	3,455	3,151	3,982	3,099
2	3,033	3,423	3,672	3,020	3,864	5,046	5,384	4,361
3	3,420	3,527	3,778	3,254	2,922	2,910	2,866	3,047
4	3,227	3,328	3,493	3,147	3,165	3,213	4,038	3,357
5	3,288	3,568	3,802	3,320	3,031	3,965	3,999	3,945
6	3,062	3,305	3,486	3,098	3,689	3,318	3,926	3,747
7	3,271	3,545	3,481	3,169	4,635	5,481	4,977	5,288
8	3,221	3,456	3,517	3,280	3,248	3,785	3,869	3,894
9	3,233	3,579	3,550	3,264	3,178	4,288	4,265	3,728
10	4,781	5,253	4,950	4,897	5,940	6,811	6,480	5,637

Berdasarkan Tabel 4. 4 dapat diketahui bahwa nilai RMSE pada setiap lokasi pada data *in sample* dan *out sample* skenario 1 memiliki nilai yang lebih rendah dibandingkan nilai RMSE pada data skenario 2. Hal ini dikarenakan model GSTARX belum mampu menangkap pola nonlinier pada data skenario 2 dengan baik.

Selanjutnya dilakukan pemodelan data aktual pada simulasi 1 menggunakan metode GSTAR dengan tahapan yang sama seperti yang telah diuraikan diatas. Karena data aktual belum memenuhi asumsi stasioner maka terlebih dahulu dilakukan *differencing* dan ditentukan orde model yang digunakan adalah GSTARIMA(1₁,[1,12],0) untuk data skenario 1 dan 2. Berikut ini adalah hasil estimasi parameter model GSTARIMA(1₁,[1,12],0) dari data aktual pada simulasi 1 masing-masing skenario

Tabel 4. 5 Koefisien Parameter Model GSTARIMA(1₁,[1,12],0)

Skenario	Lokasi	Parameter	Estimasi	Batas atas	Batas bawah	P-value
1	1	ϕ_{10}^1	-0,227	-0,121	-0,334	0,035*
		ϕ_{11}^1	-0,561	-0,460	-0,661	0,008*
	2	ϕ_{20}^1	-0,583	-0,495	-0,672	<,0001*
		ϕ_{21}^1	-0,523	-0,433	-0,614	0,345
	3	ϕ_{30}^1	-0,868	-0,549	-1,187	<,00018*
		ϕ_{31}^1	0,071	0,146	-0,004	0,360
	4	ϕ_{40}^1	0,086	0,180	-0,008	<,0001*
		ϕ_{41}^1	0,010	0,056	-0,035	0,823
2	1	ϕ_{10}^1	-0,488	-0,305	-0,671	<,0001*
		ϕ_{11}^1	-0,173	0,275	-0,621	0,4428
	2	ϕ_{20}^1	-0,610	-0,460	-0,759	<,0001*
		ϕ_{21}^1	0,044	0,185	-0,098	0,5374
	3	ϕ_{30}^1	-0,496	-0,327	-0,666	<,0001*
		ϕ_{31}^1	-0,101	0,090	-0,291	0,2931
	4	ϕ_{40}^1	-0,440	-0,293	-0,587	<,00018*
		ϕ_{41}^1	-0,093	0,007	-0,192	0,0662

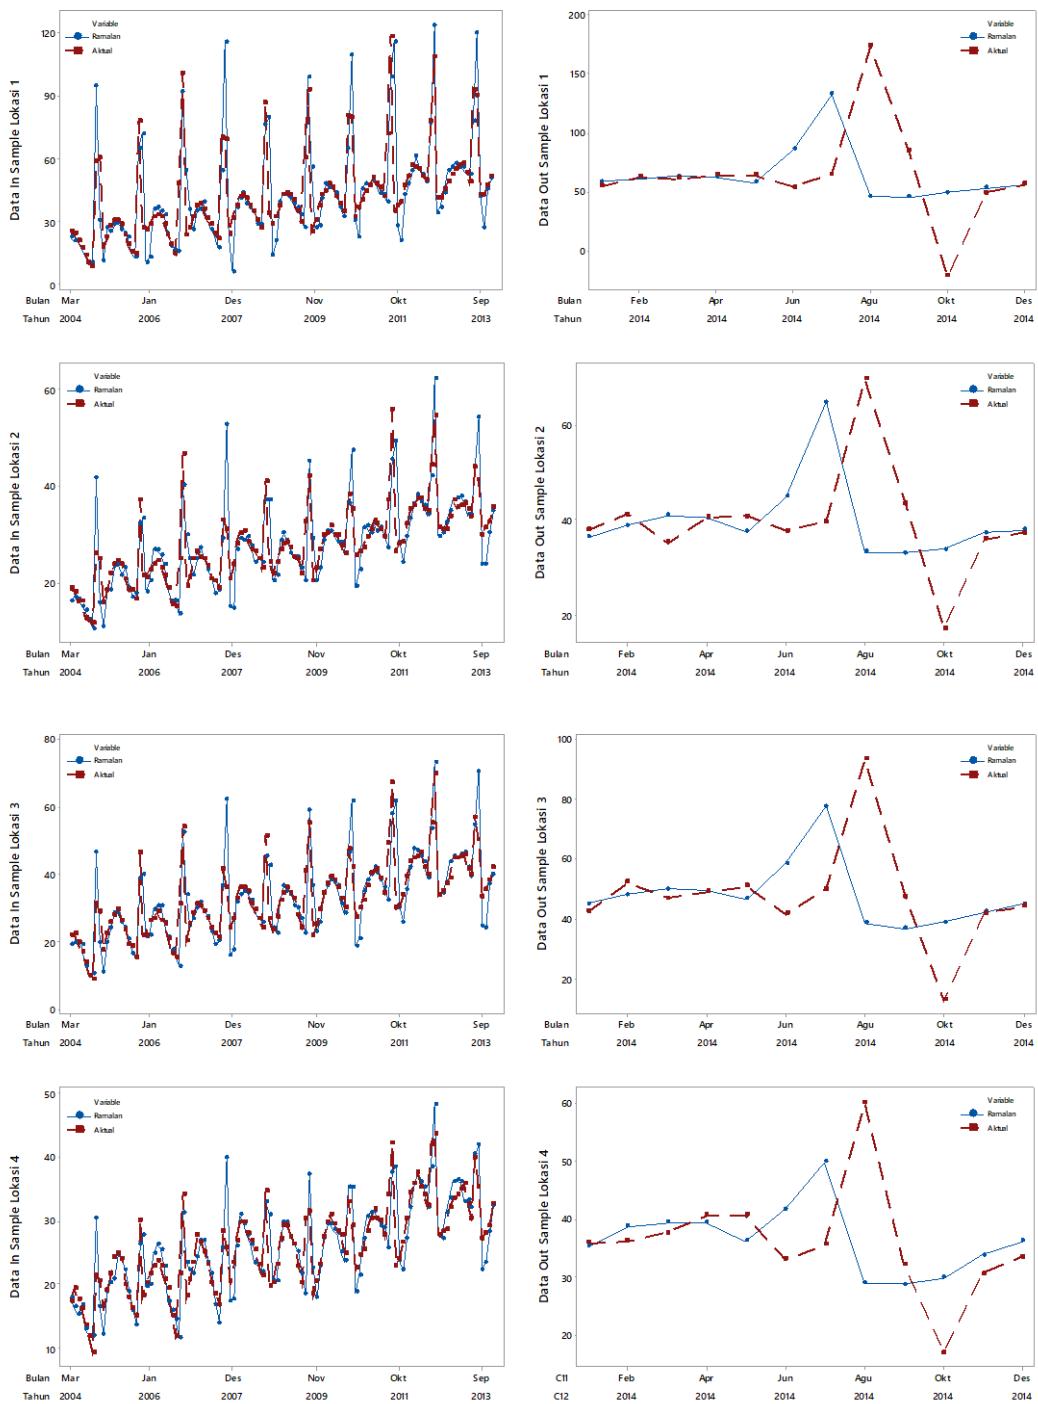
*Signifikansi $\alpha = 0,05$

Tabel 4. 5 menunjukkan bahwa hasil estimasi parameter model GSTAR pada masing-masing skenario terdapat parameter yang tidak signifikan. Pada skenario 1 di lokasi 1 parameter untuk *lag* dan bobot keduanya signifikan, namun pada lokasi lain hanya parameter *lag* saja yang signifikan. Pada skenario 2 parameter *lag* pada masing-masing lokasi telah signifikan, namun parameter bobot pada masing-masing lokasi tidak signifikan. Selanjutnya ditunjukkan nilai kebaikan model yang didapatkan dari pemodelan menggunakan metode GSTAR untuk kedua skenario data simulasi.

Tabel 4. 6 Nilai Kebaikan Model GSTARIMA(1₁,[1,12],0) Skenario 1 dan 2

Simulasi	RMSE In Sample				RMSE Out Sample			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1								
1	15,049	5,293	7,041	3,779	48,651	14,252	20,101	11,077
2	15,021	5,332	6,958	3,459	48,816	15,015	20,418	10,993
3	7,123	2,881	5,713	2,354	23,146	7,496	9,808	4,877
4	15,176	5,588	7,036	3,863	47,108	14,127	19,803	9,113
5	15,001	5,456	7,086	3,722	48,402	14,606	20,189	11,395
6	14,675	5,574	6,976	3,646	47,970	15,230	20,326	10,765
7	14,675	5,574	6,976	3,646	49,117	14,726	20,576	10,399
8	14,712	5,339	6,882	3,446	47,445	14,560	20,005	10,715
9	15,023	5,731	6,948	3,647	46,879	13,913	20,847	9,890
10	15,061	5,445	6,745	3,834	48,702	15,679	21,319	11,264
Skenario 2								
1	15,511	7,085	8,984	5,715	53,575	17,980	24,069	15,020
2	15,036	6,583	8,227	5,036	51,581	19,117	23,517	14,690
3	15,460	7,292	8,512	6,093	52,613	18,897	24,934	12,665
4	15,901	7,206	8,804	5,839	51,240	17,711	23,059	15,047
5	15,195	7,502	9,024	6,472	51,200	17,134	24,475	14,575
6	15,324	7,216	8,568	5,430	47,699	17,293	21,936	12,993
7	15,671	7,147	8,503	5,751	51,022	17,923	23,588	14,499
8	15,153	7,054	8,271	6,079	46,776	14,886	18,683	11,127
9	15,700	7,502	8,360	6,231	47,549	15,732	21,216	13,771
10	15,702	7,151	8,548	6,216	50,310	18,937	23,602	16,119

Tabel 4. 6 menunjukkan nilai kebaikan metode GSTAR dalam memodelkan data pada skenario 1 dan 2 masing-masing simulasi menggunakan model dengan orde GSTARIMA(1₁,[1,12],0). Hasil nilai RMSE yang didapatkan pada kedua skenario masih cukup tinggi, sehingga dapat diambil kesimpulan bahwa data *time series* yang mengandung komponen tren, musiman, dan variasi kalender dengan residual yang mengikuti pola linier dan nonlinier kurang tepat dimodelkan menggunakan model GSTAR. Berikut ini adalah *time series plot* hasil ramalan data simulasi 1 skenario 1 dan 2.

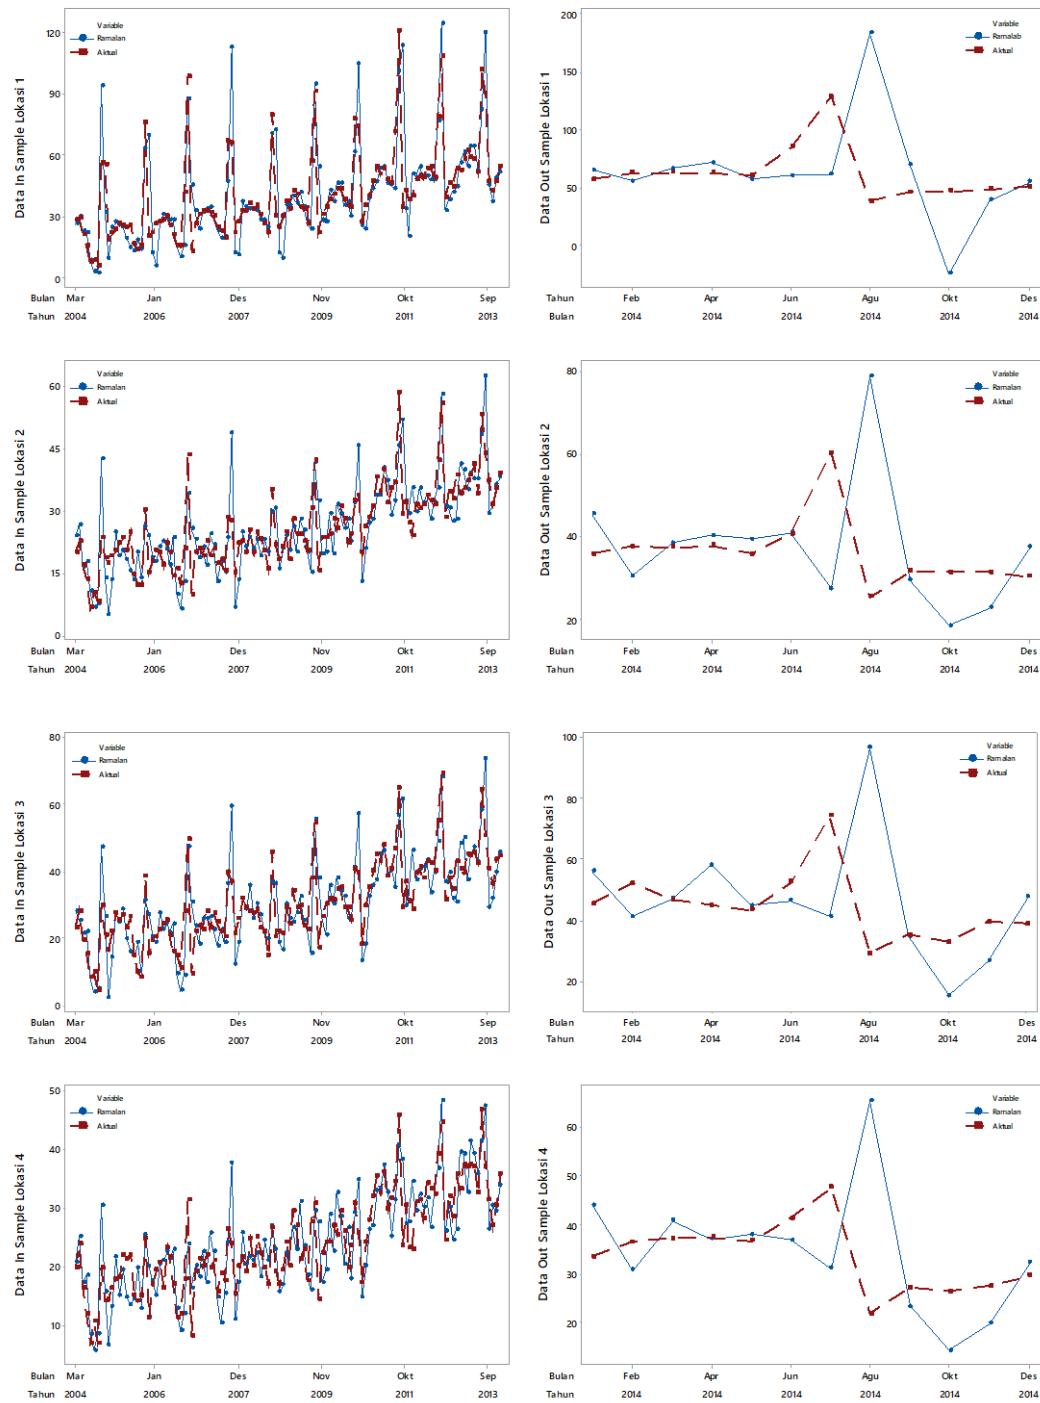


Gambar 4. 14 Time Series Plot Data Aktual dan Forecast Model GSTAR Data Simulasi 1

Skenario 1

Hasil *time series plot* menunjukkan bahwa jika data yang mengandung komponen tren, musiman, dan variasi kalender dimodelkan langsung menggunakan metode GSTAR akan menghasilkan ramalan yang belum bisa mengikuti pola data

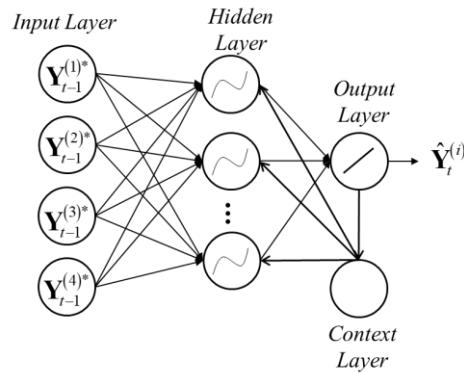
aktual karena model GSTAR belum mampu menangkap pola tren, musiman, dan variasi kalender.



Gambar 4. 15 Time Series Plot Data Aktual dan Forecast Model GSTAR Data Simulasi 1 Skenario 2

4.1.3. Pemodelan Jordan RNN pada Data Simulasi

Pada pemodelan menggunakan metode Jordan RNN, banyaknya *hidden layer* yang digunakan adalah satu *hidden layer*, input yang digunakan adalah data aktual masing-masing lokasi. Sehingga input terdiri dari 4 variabel. Berikut ini adalah arsitektur pemodelan Jordan RNN



Gambar 4. 16 Arsitekur Model Jordan RNN dengan 4 Input, 1 Hidden Layer

Jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *out sample*. Tabel 4. 7 menunjukkan hasil evaluasi model untuk data simulasi 1 menggunakan model Jordan RNN.

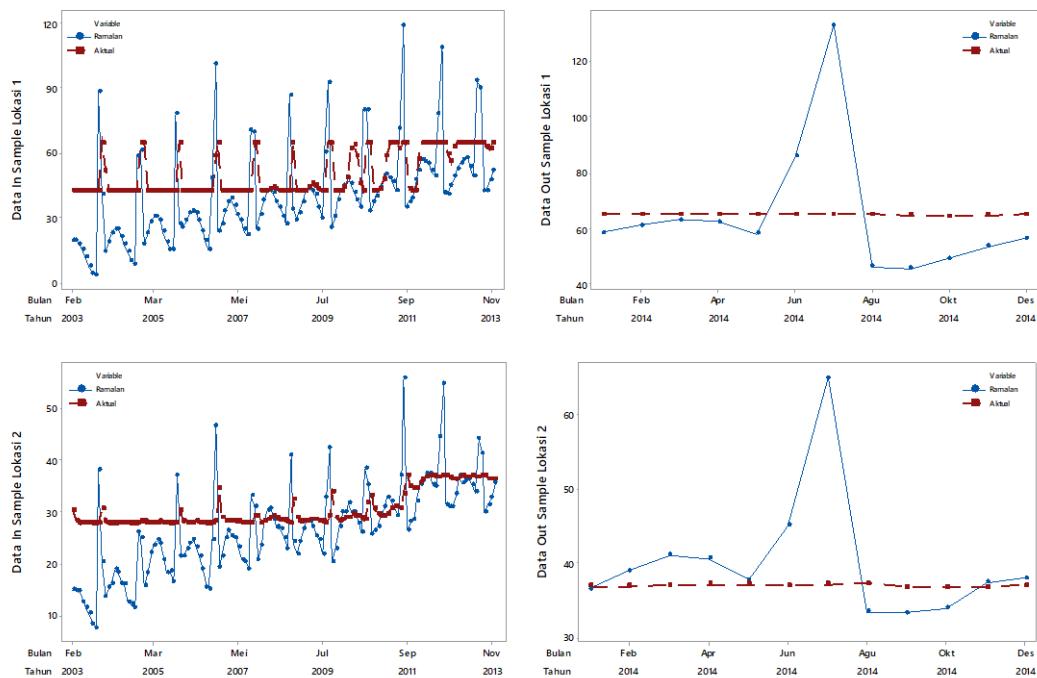
Tabel 4. 7 Nilai Kebaikan Model Jordan RNN Data Simulasi 1 Skenario 1 dan 2

Model Jordan RNN	RMSE <i>in Sample</i>				RMSE <i>out Sample</i>			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1								
Jordan RNN(4,1,1)*	21,249	8,206	11,217	6,702	22,896	8,684	10,942	6,425
Jordan RNN (4,2,1)	18,947	7,059	9,627	5,765	23,185	9,193	11,828	6,554
Jordan RNN (4,3,1)	25,003	11,086	12,736	7,479	47,582	21,974	28,303	18,474
Jordan RNN (4,4,1)	22,726	11,352	12,921	10,087	45,133	22,508	29,010	19,572
Jordan RNN (4,5,1)	31,498	17,349	21,147	12,090	55,802	26,134	32,803	22,535
Jordan RNN (4,10,1)	20,708	8,194	10,993	6,129	28,844	14,227	18,295	10,696
Jordan RNN (4,15,1)	22,590	9,595	13,311	9,435	43,687	19,844	28,811	18,502
Skenario 2								
Jordan RNN (4,1,1)	22.975	8.975	11.401	7.403	23.901	8.577	11.441	7.020
Jordan RNN (4,2,1)*	20.586	8.349	11.188	6.819	22.189	7.915	9.884	5.952
Jordan RNN (4,3,1)	19.094	17.152	22.959	15.016	46.217	6.541	8.045	22.560
Jordan RNN (4,4,1)	25.165	8.874	25.948	11.115	64.241	30.531	40.433	26.860
Jordan RNN (4,5,1)	29.235	13.733	17.507	11.488	51.582	23.739	31.208	20.446
Jordan RNN (4,10,1)	49.052	21.232	27.305	26.477	89.824	40.481	52.238	39.397
Jordan RNN (4,15,1)	24.494	13.856	17.015	9.040	47.075	20.500	26.270	13.542

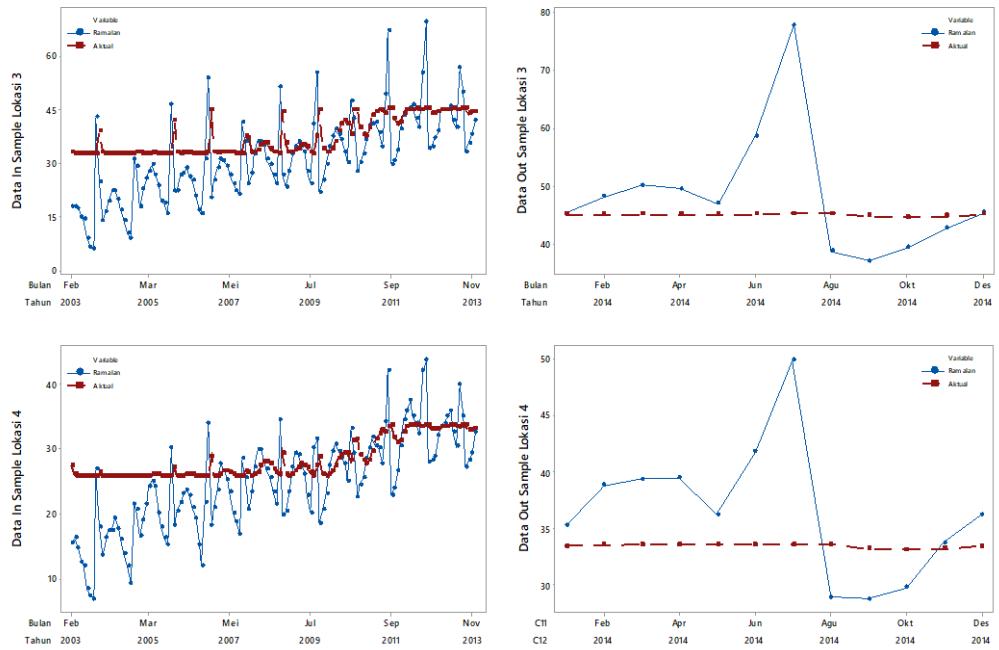
Ket: *model terbaik

Dari Tabel 4. 7 dapat diketahui bahwa nilai RMSE yang dihasilkan dari pemodelan data aktual menggunakan model Jordan RNN masih cukup tinggi baik pada data *in sample* maupun *out sample*. Hal ini menunjukkan bahwa metode Jordan RNN kurang baik dalam memodelkan data *time series* yang mengandung komponen tren, musiman dan variasi kalender. Pemilihan model terbaik dilakukan berdasarkan nilai RMSE terkecil pada data *out sample*. Model terbaik yang terpilih berdasarkan nilai RMSE terkecil pada data simulasi 1 skenario 1 adalah model Jordan RNN(4,1,1) dengan empat input dan satu unit *neuron* pada *hidden layer*. Sedangkan model terbaik yang terpilih pada data simulasi 1 skenario 2 adalah model Jordan RNN(4,2,1) dengan empat input dan dua unit *neuron* pada *hidden layer*.

Selanjutnya adalah melakukan peramalan data simulasi 1 pada empat lokasi menggunakan model Jordan RNN(4,1,1) untuk skenario 1 dan model Jordan RNN(4,2,1) untuk data skenario 2. Hasil ramalan di keempat lokasi ditampilkan dalam bentuk plot *time series* pada Gambar 4. 17.

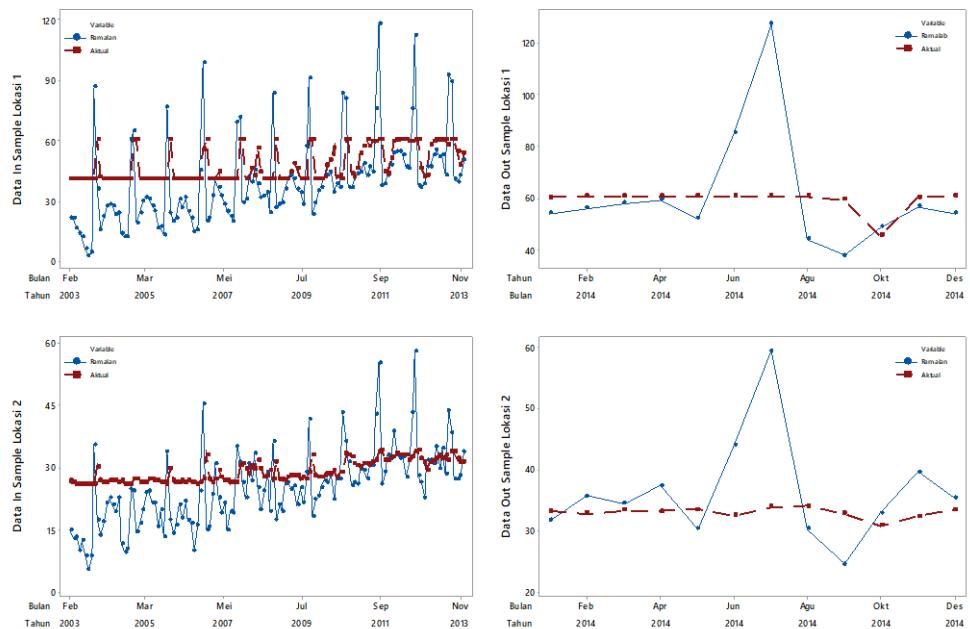


Gambar 4. 17 Time Series Plot Data Aktual dan Ramalan Model Jordan RNN Simulasi 1
Skenario 1

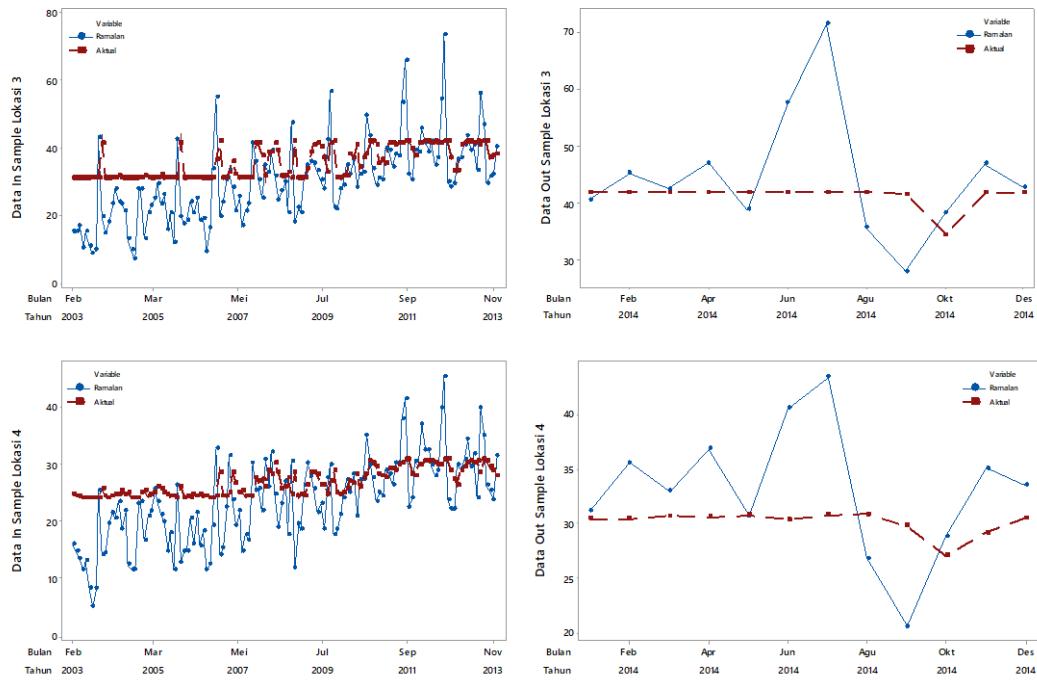


Gambar 4. 17 Time Series Plot Data Aktual dan Ramalan Model Jordan RNN Simulasi 1
Skenario 1 (lanjutan)

Berdasarkan Gambar 4. 17 secara visual dapat diketahui bahwa data ramalan *in sample* dan *out sample* data simulasi 1 skenario 1 belum dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender.



Gambar 4. 18 Time Series Plot Data Aktual dan Ramalan Model Jordan RNN Simulasi 1
Skenario 2



**Gambar 4. 18 Time Series Plot Data Aktual dan Ramalan Model Jordan RNN Simulasi 1
Skenario 2 (lanjutan)**

Hasil ramalan data *in sample* dan *out sample* data simulasi 1 skenario 2 yang dapat dilihat pada Gambar 4. 18 menunjukkan pola yang sama dengan hasil ramalan pada skenario 1. Sehingga dapat disimpulkan bahwa metode Jordan RNN kurang sesuai jika digunakan untuk memodelkan data *time series* yang mengandung komponen pola tren, musiman, dan variasi kalender dengan residual yang mengikuti pola linier maupun nonlinier.

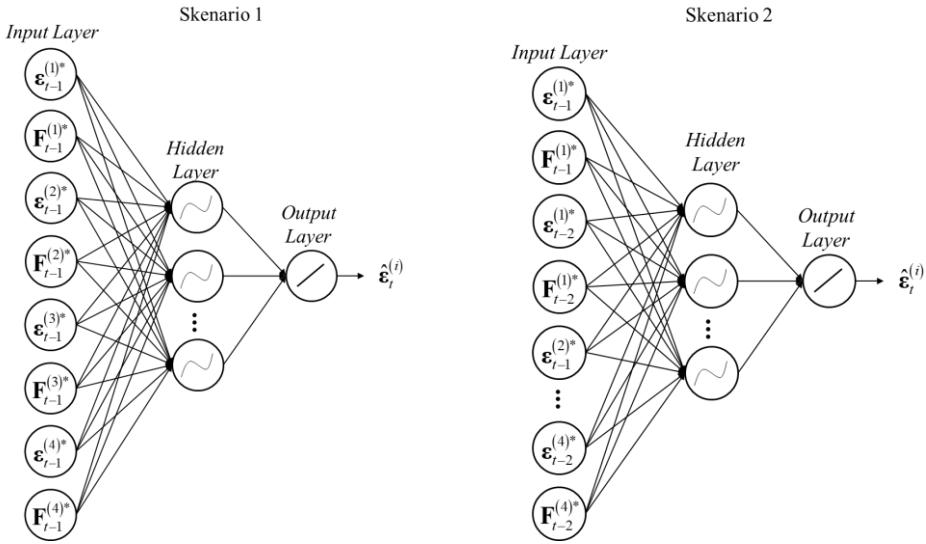
Setelah diperoleh nilai tingkat kesalahan ramalan dan visualisasi perbandingan data aktual dan ramalan untuk masing-masing data simulasi, model Jordan RNN terbaik untuk setiap data simulasi pada kedua skenario dapat dilihat pada Tabel 4. 8. Dari 10 kali replikasi, model Jordan RNN menghasilkan model terbaik dengan jumlah *neuron* yang bervariasi. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* yang digunakan untuk mendapatkan model yang optimum.

Tabel 4. 8 Nilai Kebaikan Model *Hybrid GSTARX-FFNN* pada Skenario I

Data Simulasi	Model Jordan RNN	RMSE <i>in Sample</i>				RMSE <i>out Sample</i>			
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1									
1	Jordan RNN(4,1,1)	21,249	8,206	11,217	6,702	22,896	8,684	10,942	6,425
2	Jordan RNN(4,2,1)	19,505	7,578	10,399	6,271	21,916	8,319	11,181	6,142
3	Jordan RNN(4,4,1)	9,964	4,287	5,040	3,331	12,629	5,790	7,383	4,641
4	Jordan RNN(4,2,1)	19,334	6,569	8,816	5,004	21,413	7,867	9,933	5,208
5	Jordan RNN(4,2,1)	19,317	7,247	9,850	5,647	21,886	7,015	9,976	4,474
6	Jordan RNN(4,3,1)	19,607	6,082	8,315	4,758	19,961	6,969	9,713	5,281
7	Jordan RNN(4,2,1)	19,638	7,503	10,267	6,082	21,910	7,884	10,200	4,859
8	Jordan RNN(4,1,1)	20,454	8,089	10,782	6,413	23,801	10,228	12,690	8,491
9	Jordan RNN(4,2,1)	19,583	7,691	10,500	6,099	22,319	8,692	11,904	6,180
10	Jordan RNN(4,1,1)	22,317	9,439	11,990	7,698	23,089	9,302	11,072	6,585
Skenario 2									
1	Jordan RNN(4,1,1)	19,439	8,247	10,396	6,950	22,276	9,033	11,293	6,114
2	Jordan RNN(4,2,1)	20,586	8,349	11,188	6,819	22,189	7,915	9,884	5,952
3	Jordan RNN(4,4,1)	20,470	8,947	11,603	7,464	21,641	8,172	11,203	4,595
4	Jordan RNN(4,2,1)	19,910	8,833	11,192	7,273	24,109	11,029	14,274	8,311
5	Jordan RNN(4,2,1)	20,802	9,491	11,860	7,611	21,252	8,573	12,031	6,027
6	Jordan RNN(4,3,1)	18,874	7,821	10,143	6,734	24,546	10,878	11,174	7,688
7	Jordan RNN(4,2,1)	18,403	12,750	9,902	9,111	18,552	7,495	11,357	8,450
8	Jordan RNN(4,1,1)	20,625	8,836	11,148	7,305	22,152	9,120	11,356	8,001
9	Jordan RNN(4,2,1)	19,326	8,605	11,060	6,889	23,054	8,490	10,568	6,150
10	Jordan RNN(4,1,1)	21,735	9,476	12,331	8,026	23,587	10,143	12,014	7,450

4.1.4. Pemodelan *Hybrid GSTARX-FFNN* pada Data Simulasi

Pada pemodelan *hybrid GSTARX-FFNN*, pemodelan ini terdiri dari 2 tahapan. Tahap pertama adalah memodelkan data menggunakan model TSR dan tahap kedua adalah memodelkan residual hasil pemodelan TSR dengan residual model TSR yang sudah diboboti menggunakan model FFNN. Bobot yang digunakan bobot seragam, jumlah *hidden layer* yang digunakan adalah satu *hidden layer* yang dikenal dengan sebutan *feedforward neural network* (FFNN), *input* yang digunakan adalah variabel model GSTAR. Sehingga *input* yang digunakan terdiri dari 8 variabel untuk data skenario 1 dan terdiri dari 16 input untuk data skenario 2. Ilustrasi gambar arsitektur pemodelan *hybrid GSTAR-FFNN* dapat dilihat pada Gambar 4. 19.



Gambar 4. 19 Arsitekur GSTAR-FFNN dengan Satu *Hidden Layer*

dengan $\boldsymbol{\varepsilon}_{t-1}^{(i)*}$ merupakan *standardize* dari $\boldsymbol{\varepsilon}_{t-1}^{(i)}$, dan vektor $\mathbf{0}$ berukuran sama dengan vektor $\boldsymbol{\varepsilon}_{t-1}^{(i)}$

$$\boldsymbol{\varepsilon}_{t-1}^{(1)*} = \begin{bmatrix} \boldsymbol{\varepsilon}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(4)} \end{bmatrix},$$

$$\mathbf{F}_{t-1}^{(1)*} = \begin{bmatrix} \omega_{12}\boldsymbol{\varepsilon}_{t-1}^{(2)} + \omega_{13}\boldsymbol{\varepsilon}_{t-1}^{(3)} + \omega_{14}\boldsymbol{\varepsilon}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \omega_{21}\boldsymbol{\varepsilon}_{t-1}^{(1)} + \omega_{23}\boldsymbol{\varepsilon}_{t-1}^{(3)} + \omega_{24}\boldsymbol{\varepsilon}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{F}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \omega_{31}\boldsymbol{\varepsilon}_{t-1}^{(1)} + \omega_{32}\boldsymbol{\varepsilon}_{t-1}^{(2)} + \omega_{34}\boldsymbol{\varepsilon}_{t-1}^{(4)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \omega_{41}\boldsymbol{\varepsilon}_{t-1}^{(1)} + \omega_{42}\boldsymbol{\varepsilon}_{t-1}^{(2)} + \omega_{43}\boldsymbol{\varepsilon}_{t-1}^{(3)} \end{bmatrix}$$

Jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15. Fungsi aktivasi yang digunakan pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi yang digunakan untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *out sample*. Tabel 4. 9 menunjukkan hasil evaluasi model untuk data simulasi 1 menggunakan *hybrid GSTARX-FFNN*.

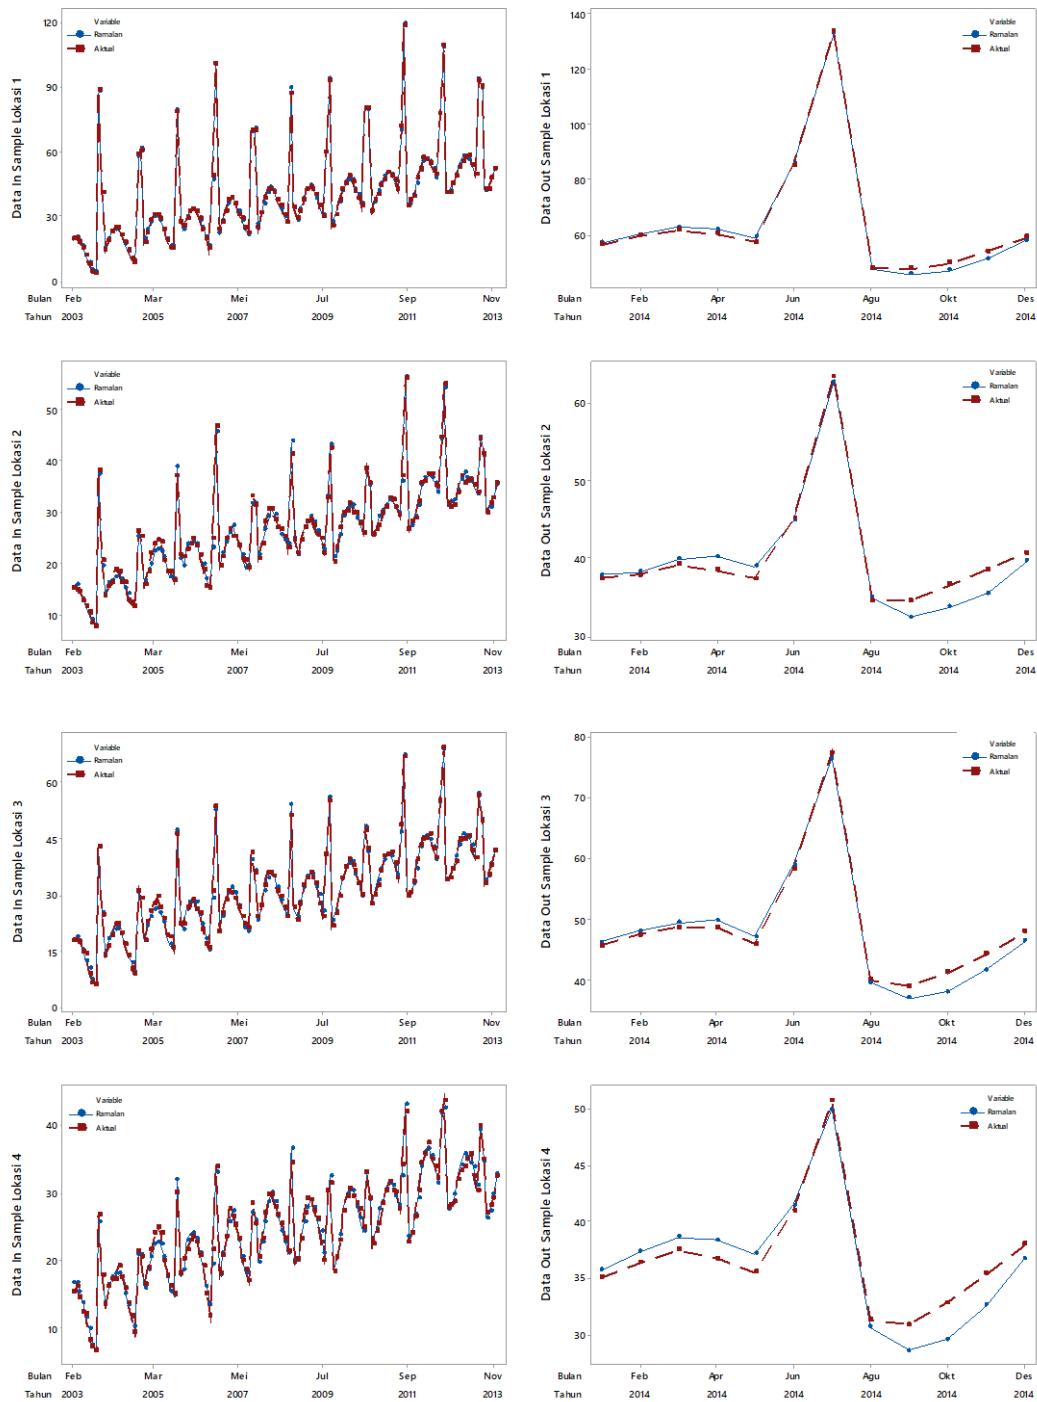
Tabel 4. 9 Nilai Kebaikan Model *hybrid* GSTAR-FFNN Data Simulasi 1 Skenario 1 dan 2

Model GSTARX-FFNN	RMSE in Sample				RMSE out Sample			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1								
GSTARX-FFNN(8,1,1)*	0,912	0,867	1,015	0,871	1,220	1,279	0,792	0,890
GSTARX-FFNN (8,2,1)	0,896	0,848	0,995	0,863	1,362	1,349	0,862	0,887
GSTARX-FFNN (8,3,1)	0,904	0,861	1,006	0,843	1,258	1,252	0,794	0,899
GSTARX-FFNN (8,4,1)	0,871	0,822	0,985	0,839	1,247	1,269	0,787	0,886
GSTARX-FFNN (8,5,1)	0,858	0,796	0,956	0,806	1,297	1,263	0,783	0,960
GSTARX-FFNN (8,10,1)	0,823	0,717	0,869	0,791	1,174	1,680	0,865	1,045
GSTARX-FFNN (8,15,1)	0,740	0,655	0,760	0,652	1,372	1,547	1,224	1,113
Skenario 2								
GSTARX-FFNN(16,1,1)*	0,063	0,077	0,055	0,696	0,060	0,087	0,056	0,074
GSTARX-FFNN(16,2,1)	0,058	0,074	0,063	0,697	0,062	0,088	0,059	0,073
GSTARX-FFNN (16,3,1)	0,069	0,073	0,059	0,696	0,056	0,086	0,076	0,072
GSTARX-FFNN (16,4,1)	0,056	0,073	0,063	0,698	0,066	0,070	0,071	0,096
GSTARX-FFNN (16,5,1)	0,058	0,077	0,069	0,697	0,085	0,084	0,110	0,120
GSTARX-FFNN(16,10,1)	0,055	0,075	0,072	0,697	0,141	0,109	0,131	0,120
GSTARX-FFNN(16,15,1)	0,056	0,074	0,075	0,698	0,087	0,101	0,093	0,210

Ket: *model terbaik

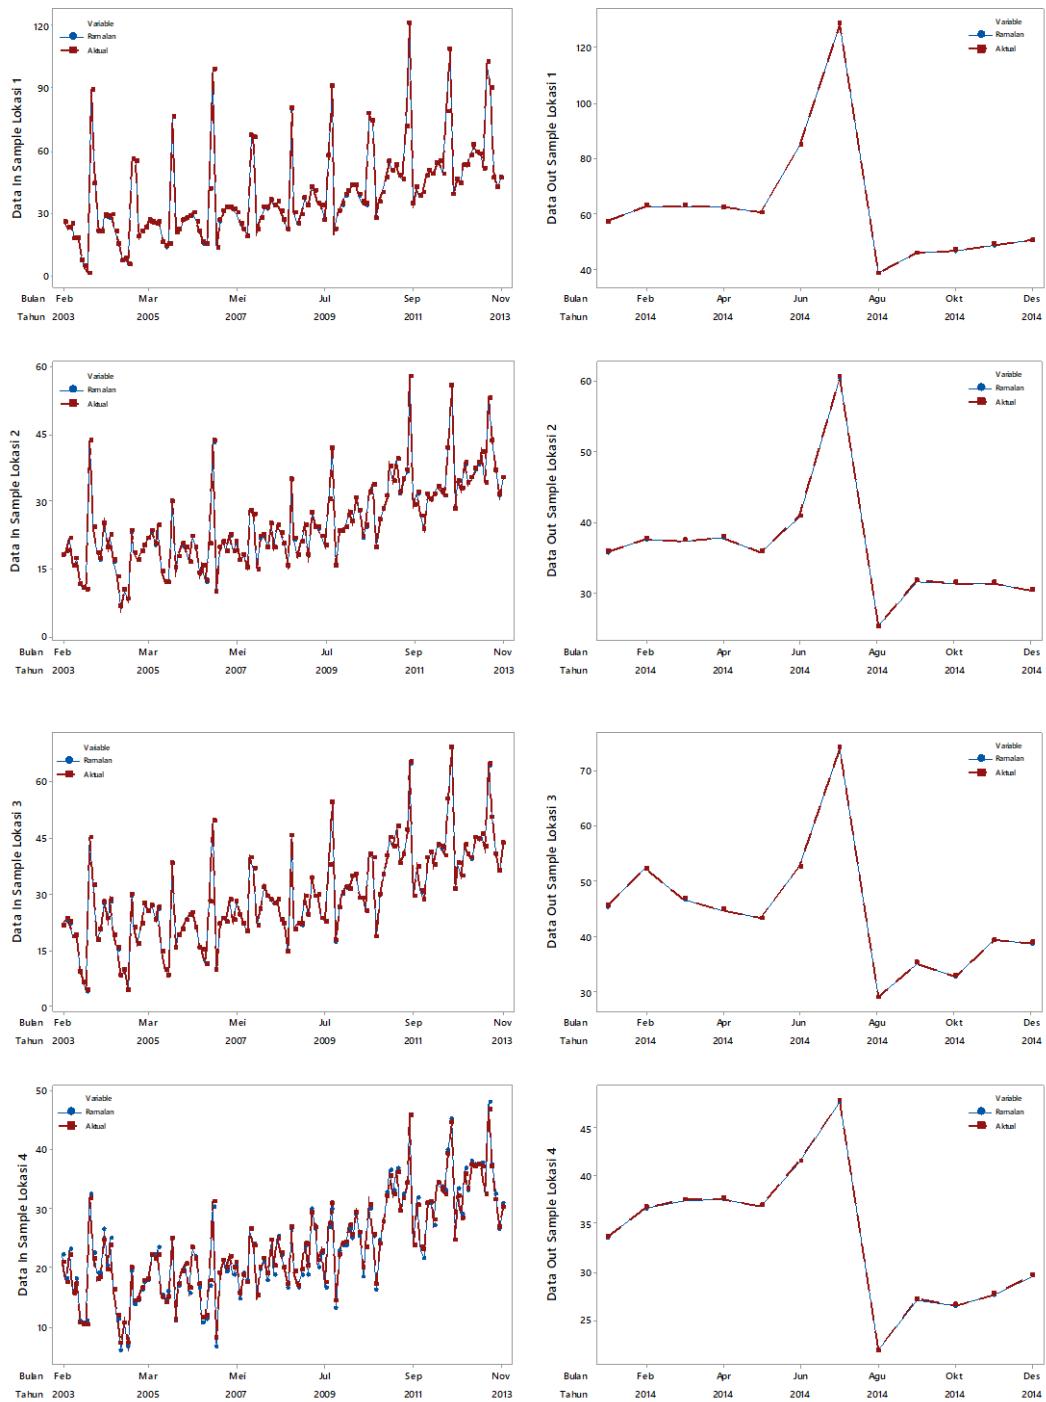
Tabel 4. 9 menunjukkan hasil kebaikan model *hybrid* GSTARX-FFNN menggunakan kriteria nilai RMSE pada masing-masing model. Pemilihan model terbaik dilakukan berdasarkan nilai RMSE terkecil pada data *out sample*. Namun, dapat diketahui bahwa nilai RMSE pada data *out sample* terdapat perbedaan kesimpulan pada setiap lokasi. Model terbaik yang dipilih merupakan model yang memiliki nilai RMSE minimum paling banyak di empat lokasi. Model *hybrid* GSTARX-FFNN dengan delapan *input* dan satu unit *neuron*, yang dinotasikan dalam *hybrid* GSTARX-FFNN(8,1,1) merupakan model terbaik pada data simulasi 1 skenario 1 dan sedangkan model *hybrid* GSTARX-FFNN dengan 16 input dan satu unit *neuron* yang dinotasikan dalam *hybrid* GSTARX-FFNN(16,1,1) merupakan model terbaik pada data simulasi 1 skenario 2 karena memiliki nilai RMSE terkecil.

Selanjutnya adalah melakukan peramalan data simulasi 1 di keempat lokasi menggunakan *hybrid* GSTARX-FFNN(8,1,1) untuk data skenario 1 dan menggunakan *hybrid* GSTARX-FFNN(16,1,1) untuk data skenario 2. Hasil ramalan pada keempat lokasi ditampilkan dalam bentuk *time series* pada Gambar 4. 20.



Gambar 4. 20 Time Series Plot Data Aktual dan Ramalan Hybrid GSTARX-FFNN Simulasi 1
Skenario 1

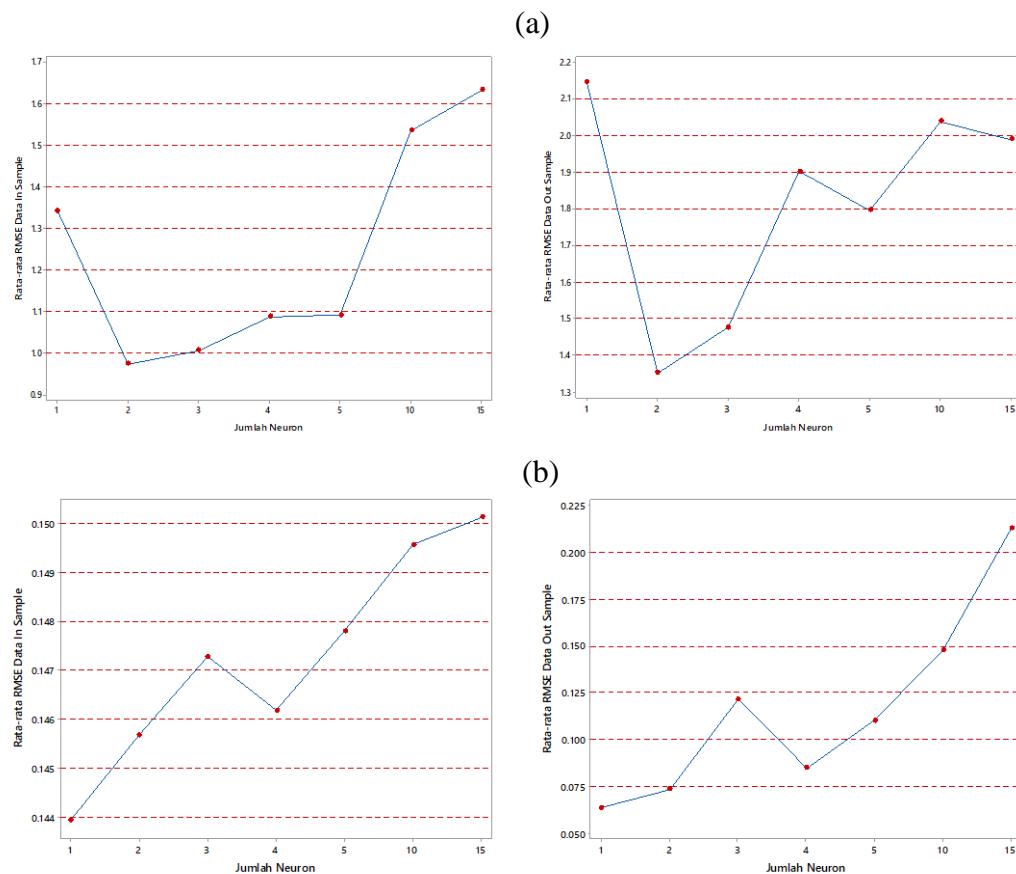
Berdasarkan Gambar 4. 20 dapat diketahui bahwa hasil ramalan data simulasi 1 skenario 1 menggunakan model *hybrid* GSTARX-FFNN mampu mengikuti pola data dengan cukup baik. Berikut ini adalah *time series plot* antara data aktual dan ramalan untuk data skenario 2 simulasi 1



Gambar 4. 21 Time Series Plot Data Aktual dan Ramalan Hybrid GSTARX-FFNN Simulasi 1 Skenario 2

Berdasarkan Gambar 4. 21 dapat diketahui bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender. Selanjutnya dilakukan penghitungan nilai

RMSE untuk data *in sample* dan *out sample* data simulasi pada masing-masing jumlah *neuron* yang digunakan, untuk mengetahui pengaruh jumlah *neuron* terhadap kebaikan model *hybrid GSTARX-FFNN* dalam meramalkan data pada skenario I dengan replikasi sebanyak 10 kali.



Gambar 4. 22 Line Plot Rata-rata Nilai RMSE In Sample dan Out Sample Model Hybrid GSTARX-FFNN Skenario 1(a) dan Skenario 2(b)

Berdasarkan Gambar 4. 22 dapat diketahui bahwa pemodelan data simulasi dengan model *hybrid GSTARX-FFNN* untuk data *in sample* dan *out sample* pada kesua skenario memiliki pola *line plot* rata-rata RMSE yang hampir sama. *Neuron* optimal yang menghasilkan rata-rata RMSE data *in sample* dan *out sample* terkecil pada skenario 1 adalah sebanyak 2 unit *neuron* dan *neuron* optimal yang menghasilkan rata-rata RMSE data *in sample* dan *out sample* terkecil pada skenario 2 adalah satu unit *neuron*. Rata-rata nilai RMSE data *in sample* cenderung lebih tinggi dibandingkan dengan data *out sample*, hal ini terjadi pada kedua skenario data simulasi.

Setelah diperoleh nilai tingkat kesalahan ramalan untuk masing-masing data simulasi, model *hybrid GSTARX-FFNN* terbaik untuk setiap data simulasi pada kedua skenario dapat dilihat pada Tabel 4. 10.

Tabel 4. 10 Nilai Kebaikan Model *Hybrid GSTARX-FFNN* pada Skenario 1 dan 2

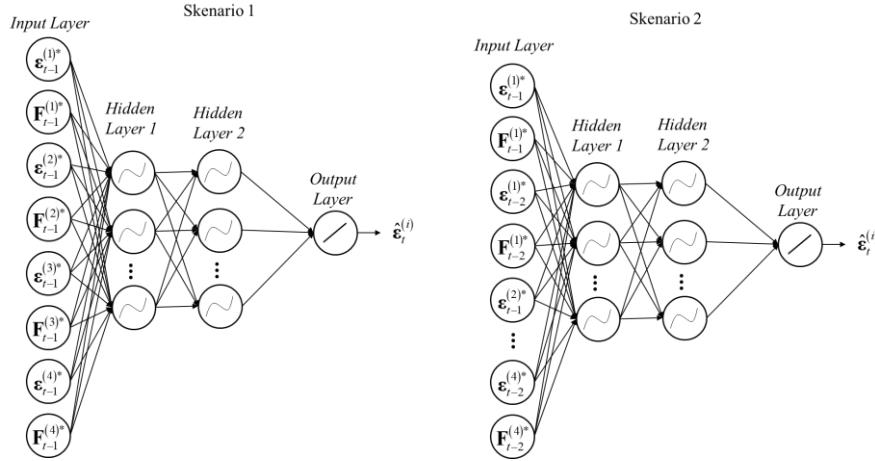
Data Simulasi	Model GSTARX-FFNN	RMSE <i>in Sample</i>				RMSE <i>out Sample</i>			
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1									
1	GSTARX-FFNN(8,1,1)	0,912	0,867	1,015	0,871	1,220	1,279	0,792	0,890
2	GSTARX-FFNN (8,1,1)	0,864	0,965	0,925	0,831	0,917	1,209	1,729	1,077
3	GSTARX-FFNN (8,1,1)	0,973	0,955	0,919	1,048	0,711	0,582	0,799	0,811
4	GSTARX-FFNN (8,3,1)	0,954	0,849	0,968	0,903	1,000	0,714	1,115	1,007
5	GSTARX-FFNN (8,1,1)	0,848	1,012	0,939	1,011	2,228	1,808	1,527	2,011
6	GSTARX-FFNN (8,1,1)	0,963	1,015	0,976	1,028	1,000	0,687	1,197	0,880
7	GSTARX-FFNN (8,2,1)	0,945	0,849	0,821	0,850	0,924	0,949	1,611	1,469
8	GSTARX-FFNN (8,1,1)	0,956	1,004	1,045	1,072	1,526	1,706	1,662	2,072
9	GSTARX-FFNN (8,1,1)	0,864	0,955	0,923	0,850	0,980	1,324	1,100	1,228
10	GSTARX-FFNN (8,1,1)	0,918	0,988	0,977	1,068	0,861	1,012	1,012	1,078
Skenario 2									
1	GSTARX-FFNN (16,1,1)	0,073	0,077	0,086	0,564	0,056	0,070	0,074	0,064
2	GSTARX-FFNN (16,1,1)	0,063	0,077	0,055	0,696	0,060	0,087	0,056	0,074
3	GSTARX-FFNN (16,1,1)	0,039	0,028	0,028	0,525	0,038	0,017	0,021	0,025
4	GSTARX-FFNN (16,1,1)	0,043	0,047	0,068	0,360	0,044	0,053	0,075	0,049
5	GSTARX-FFNN (16,1,1)	0,036	0,061	0,068	0,363	0,031	0,069	0,070	0,088
6	GSTARX-FFNN (16,1,1)	0,091	0,072	0,079	0,465	0,113	0,073	0,095	0,090
7	GSTARX-FFNN (16,1,1)	0,046	0,056	0,032	0,377	0,080	0,076	0,100	0,108
8	GSTARX-FFNN (16,1,1)	0,052	0,054	0,058	0,181	0,058	0,071	0,071	0,075
9	GSTARX-FFNN (16,1,1)	0,053	0,056	0,066	0,399	0,073	0,062	0,089	0,079
10	GSTARX-FFNN (16,1,1)	0,025	0,035	0,018	0,189	0,021	0,031	0,014	0,037

Tabel 4. 10 tersebut menunjukkan bahwa model terbaik yang didapatkan untuk setiap data simulasi pada skenario 1 dengan menggunakan *hybrid GSTARX-FFNN* menghasilkan model dengan jumlah *neuron* yang bervariasi. Model terbaik yang terpilih dari hasil pemodelan menggunakan *hybrid GSTARX-FFNN* pada skenario 2 memiliki jumlah *neuron* yang sama, yaitu dengan 1 unit *neuron*. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* untuk mendapatkan model yang optimum.

4.1.5. Pemodelan *Hybrid GSTARX-DLNN* Pada Data Simulasi

Pada pemodelan *hybrid GSTARX-DLNN* digunakan dua *hidden layer* yang sudah termasuk dalam kelompok *deep learning neural network* (DLNN) dan

jumlah *input* yang digunakan adalah variabel model GSTAR pada data simulasi skenario 1 dan 2. Sehingga *input* terdiri dari 8 variabel untuk skenario 1 dan terdapat 16 input untuk skenario 2. Berikut ini adalah arsitektur pemodelan *hybrid* GSTAR-DLNN



Gambar 4. 23 Arsitekur GSTAR-DLNN dengan 8 *Input* dan 16 Input dengan 2 *Hidden Layer*

dengan $\boldsymbol{\varepsilon}_{t-1}^{(i)}$ merupakan *standardize* dari $\boldsymbol{\varepsilon}_{t-1}^{(i)}$, dan vektor $\mathbf{0}$ berukuran sama dengan vektor $\boldsymbol{\varepsilon}_{t-1}^{(i)}$

$$\begin{aligned}\boldsymbol{\varepsilon}_{t-1}^{(1)*} &= \begin{bmatrix} \boldsymbol{\varepsilon}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(4)} \end{bmatrix}, \\ \mathbf{F}_{t-1}^{(1)*} &= \begin{bmatrix} \omega_{12}\boldsymbol{\varepsilon}_{t-1}^{(2)} + \omega_{13}\boldsymbol{\varepsilon}_{t-1}^{(3)} + \omega_{14}\boldsymbol{\varepsilon}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \omega_{21}\boldsymbol{\varepsilon}_{t-1}^{(1)} + \omega_{23}\boldsymbol{\varepsilon}_{t-1}^{(3)} + \omega_{24}\boldsymbol{\varepsilon}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\ \mathbf{F}_{t-1}^{(3)*} &= \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \omega_{31}\boldsymbol{\varepsilon}_{t-1}^{(1)} + \omega_{32}\boldsymbol{\varepsilon}_{t-1}^{(2)} + \omega_{34}\boldsymbol{\varepsilon}_{t-1}^{(4)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \omega_{41}\boldsymbol{\varepsilon}_{t-1}^{(1)} + \omega_{42}\boldsymbol{\varepsilon}_{t-1}^{(2)} + \omega_{43}\boldsymbol{\varepsilon}_{t-1}^{(3)} \end{bmatrix}, \\ \boldsymbol{\varepsilon}_{t-2}^{(1)*} &= \begin{bmatrix} \boldsymbol{\varepsilon}_{t-2}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-2}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-2}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-2}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-2}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-2}^{(4)} \end{bmatrix},\end{aligned}$$

$$\mathbf{F}_{t-2}^{(1)*} = \begin{bmatrix} \omega_{12}\boldsymbol{\varepsilon}_{t-2}^{(2)} + \omega_{13}\boldsymbol{\varepsilon}_{t-2}^{(3)} + \omega_{14}\boldsymbol{\varepsilon}_{t-2}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-2}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \omega_{21}\boldsymbol{\varepsilon}_{t-2}^{(1)} + \omega_{23}\boldsymbol{\varepsilon}_{t-2}^{(3)} + \omega_{24}\boldsymbol{\varepsilon}_{t-2}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{F}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \omega_{31}\boldsymbol{\varepsilon}_{t-2}^{(1)} + \omega_{32}\boldsymbol{\varepsilon}_{t-2}^{(2)} + \omega_{34}\boldsymbol{\varepsilon}_{t-2}^{(4)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-2}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \omega_{41}\boldsymbol{\varepsilon}_{t-2}^{(1)} + \omega_{42}\boldsymbol{\varepsilon}_{t-2}^{(2)} + \omega_{43}\boldsymbol{\varepsilon}_{t-2}^{(3)} \end{bmatrix}.$$

Banyaknya jumlah *neuron* yang digunakan pada *hidden layer* pertama adalah 1, 2, 3, 4, 5, 10, dan 15, dan banyaknya *neuron* pada *hidden layer* kedua adalah 1, 2, 3, 4, dan 5. Fungsi aktivasi yang digunakan pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi yang digunakan untuk *output layer* adalah linier. *Neuron* optimal yang teroilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *out sample*.

Tabel 4.11 menunjukkan hasil kebaikan model *hybrid GSTARX-DLNN* menggunakan kriteria nilai RMSE pada masing-masing model dalam kedua skenario data. Pemilihan model terbaik dilakukan berdasarkan nilai RMSE terkecil pada data *out sample*. Namun, dapat diketahui bahwa nilai RMSE pada data *out sample* terdapat perbedaan kesimpulan pada setiap lokasi. Dengan demikian, model terbaik yang dipilih merupakan model yang memiliki nilai minimum paling banyak di keempat lokasi. Model *hybrid GSTARX-DLNN* dengan delapan input, 10 unit *neuron* pada *hidden layer* pertama dan 2 unit *neuron* pada *hidden layer* kedua, yang dinotasikan dalam *hybrid GSTARX-DLNN(8,10,2,1)* merupakan model terbaik untuk data simulasi 1 skenario 1 karena memiliki nilai RMSE terkecil. Sedangkan model terbaik yang terpilih untuk memodelkan data simulasi 1 skenario 2 adalah model *hybrid* dengan 16 input, 1 unit *neuron* pada *hidden layer* pertama dan 5 unit *neuron* pada *hidden layer* kedua yang dinotasikan dengan *hybrid GSTARX-DLNN(16,1,5,1)*.

Tabel 4. 11 Nilai Kebaikan Model *hybrid* GSTARX-DLNN Data Simulasi 1 Skenario 1

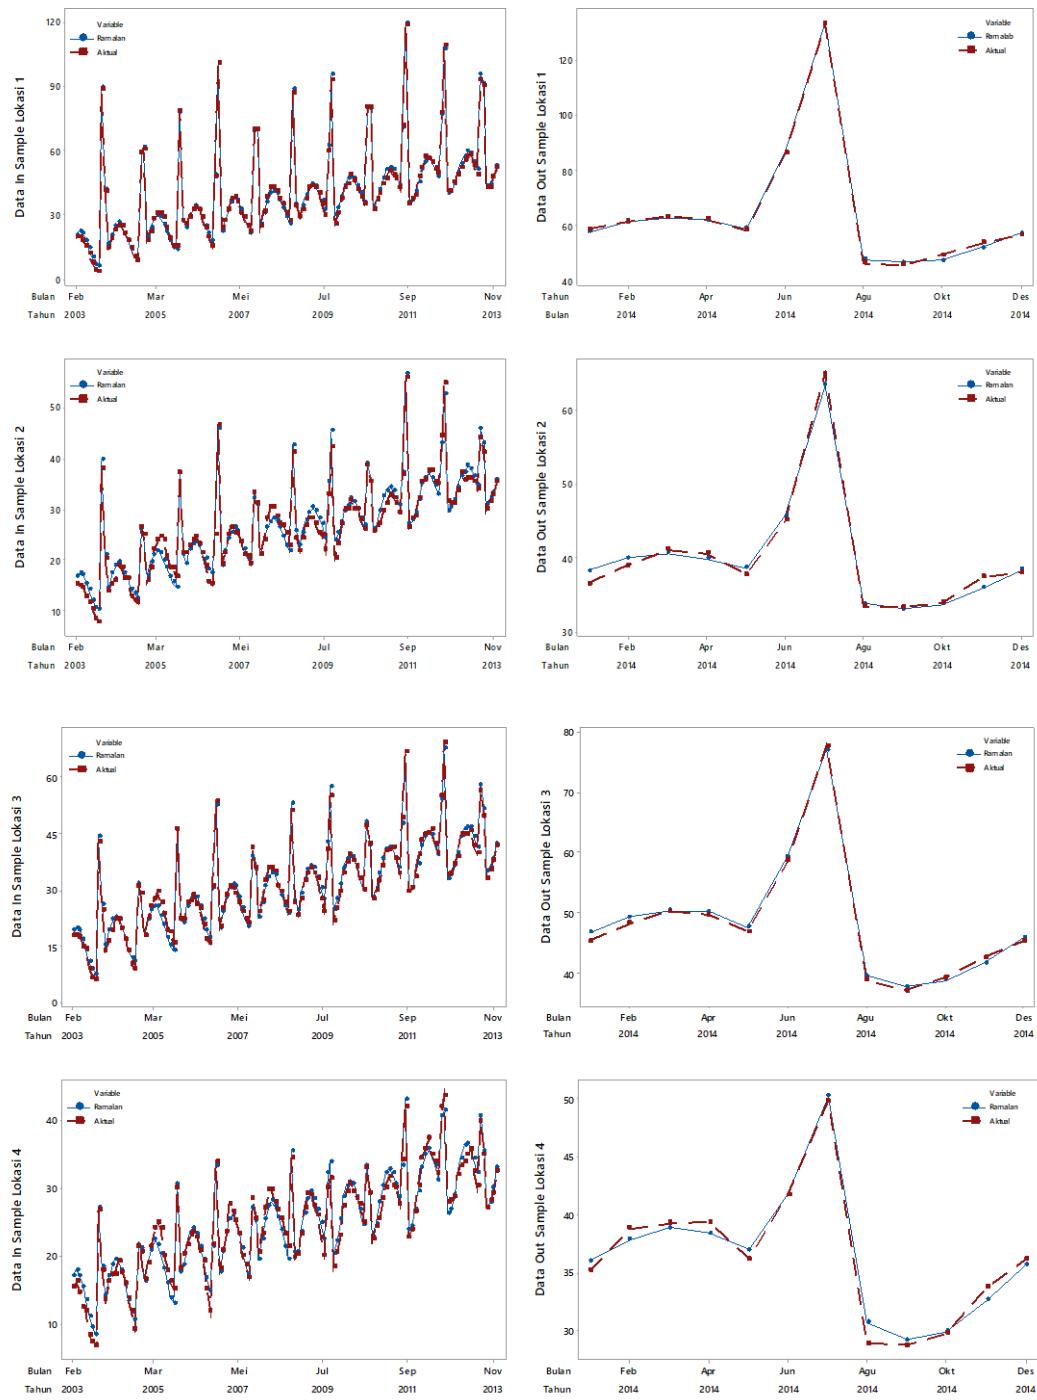
Model GSTARX-DLNN	RMSE in Sample				RMSE out Sample			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1								
GSTARX-DLNN(8,1,1,1)	1,753	1,415	1,537	1,455	0,995	1,065	0,796	0,851
GSTARX-DLNN(8,2,1,1)	1,247	1,251	1,420	1,377	1,037	1,006	0,694	0,864
GSTARX-DLNN(8,3,1,1)	1,516	1,664	1,336	1,271	0,974	1,043	0,724	0,850
GSTARX-DLNN(8,4,1,1)	1,530	1,599	1,669	1,634	1,017	1,060	0,763	0,910
GSTARX-DLNN(8,5,1,1)	1,425	1,310	1,580	1,314	0,969	1,038	0,799	0,842
GSTARX-DLNN(8,10,1,1)	1,232	1,383	1,388	1,366	1,004	1,012	0,766	0,865
GSTARX-DLNN(8,15,1,1)	1,376	1,278	1,579	1,466	0,996	1,039	0,739	0,874
GSTARX-DLNN(8,1,2,1)	1,592	1,243	1,322	1,277	1,007	0,995	0,757	0,842
GSTARX-DLNN(8,2,2,1)	1,393	1,422	1,472	1,416	1,010	1,101	0,718	0,845
GSTARX-DLNN(8,3,2,1)	1,675	1,595	1,517	1,421	1,005	1,059	0,737	0,850
GSTARX-DLNN(8,4,2,1)	1,433	1,546	1,613	1,476	0,978	1,046	0,757	0,846
GSTARX-DLNN(8,5,2,1)	1,164	1,102	1,541	1,448	1,018	1,080	0,757	0,845
GSTARX-DLNN(8,10,2,1)*	1,525	1,552	1,490	1,359	0,971	0,973	0,797	0,846
GSTARX-DLNN(8,15,2,1)	1,131	1,112	1,260	1,097	1,076	1,027	0,793	0,854
GSTARX-DLNN(8,1,3,1)	1,149	1,231	1,285	1,139	1,030	0,959	0,769	0,835
GSTARX-DLNN(8,2,3,1)	1,503	1,595	1,543	1,669	0,968	1,037	0,754	0,912
GSTARX-DLNN(8,3,3,1)	1,176	1,213	1,181	1,131	1,032	0,984	0,740	0,871
GSTARX-DLNN(8,4,3,1)	1,331	1,205	1,390	1,104	1,035	1,033	0,786	0,843
GSTARX-DLNN(8,5,3,1)	1,463	1,433	1,610	1,451	0,975	1,014	0,796	0,862
GSTARX-DLNN(8,10,3,1)	1,295	1,108	1,463	1,571	1,028	1,057	0,737	0,908
GSTARX-DLNN(8,15,3,1)	1,183	1,202	1,344	1,404	1,018	1,121	0,749	0,847
GSTARX-DLNN(8,1,4,1)	1,611	1,438	1,375	1,335	1,010	1,076	0,707	0,855
GSTARX-DLNN(8,2,4,1)	1,704	1,304	1,471	1,350	1,039	1,023	0,744	0,836
GSTARX-DLNN(8,3,4,1)	1,367	1,448	1,292	1,177	1,158	1,119	0,728	0,909
GSTARX-DLNN(8,4,4,1)	1,555	1,407	1,490	1,574	1,035	1,018	0,720	0,900
GSTARX-DLNN(8,5,4,1)	1,307	1,212	1,313	1,450	1,007	1,025	0,780	0,851
GSTARX-DLNN(8,10,4,1)	1,077	1,376	1,339	1,584	1,039	1,017	0,764	0,886
GSTARX-DLNN(8,15,4,1)	1,388	1,610	1,535	1,623	1,000	1,081	0,772	1,000
GSTARX-DLNN(8,1,5,1)	1,301	1,485	1,489	1,358	0,992	1,009	0,746	0,851
GSTARX-DLNN(8,2,5,1)	1,259	1,588	1,458	1,440	1,017	1,071	0,717	0,877
GSTARX-DLNN(8,3,5,1)	1,259	1,011	1,235	1,043	0,992	1,162	0,739	0,850
GSTARX-DLNN(8,4,5,1)	1,823	1,396	1,466	1,329	1,055	1,026	0,739	0,833
GSTARX-DLNN(8,5,5,1)	1,214	1,272	1,448	1,480	0,998	1,037	0,757	0,870
GSTARX-DLNN(8,10,5,1)	1,164	1,343	1,175	1,626	1,078	0,991	0,799	0,893
GSTARX-DLNN(8,15,5,1)	1,094	1,279	1,181	1,240	1,086	0,975	0,771	0,831

Tabel 4. 11 Nilai Kebaikan *Model* hybrid GSTARX-DLNN Data Simulasi 1 Skenario 1 (lanjutan)

Model GSTARX-DLNN	RMSE in Sample				RMSE out Sample			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 2								
GSTARX-DLNN(16,1,1,1)	0,073	0,077	0,086	0,564	0,056	0,070	0,074	0,064
GSTARX-DLNN(16,2,1,1)	0,073	0,079	0,087	0,564	0,056	0,074	0,077	0,063
GSTARX-DLNN(16,3,1,1)	0,074	0,082	0,089	0,564	0,046	0,077	0,079	0,063
GSTARX-DLNN(16,4,1,1)	0,073	0,080	0,089	0,564	0,054	0,083	0,068	0,104
GSTARX-DLNN(16,5,1,1)	0,072	0,081	0,090	0,564	0,065	0,066	0,081	0,073
GSTARX-DLNN(16,10,1,1)	0,072	0,087	0,090	0,564	0,090	0,055	0,079	0,097
GSTARX-DLNN(16,15,1,1)	0,074	0,090	0,097	0,564	0,088	0,287	0,131	0,357
GSTARX-DLNN(16,1,2,1)	0,073	0,077	0,087	0,564	0,054	0,069	0,074	0,065
GSTARX-DLNN(16,2,2,1)	0,073	0,083	0,088	0,564	0,049	0,081	0,073	0,058
GSTARX-DLNN(16,3,2,1)	0,072	0,079	0,089	0,564	0,061	0,077	0,074	0,065
GSTARX-DLNN(16,4,2,1)	0,074	0,080	0,088	0,564	0,041	0,071	0,077	0,072
GSTARX-DLNN(16,5,2,1)	0,070	0,085	0,091	0,564	0,050	0,101	0,079	0,087
GSTARX-DLNN(16,10,2,1)	0,072	0,086	0,090	0,564	0,095	0,119	0,078	0,068
GSTARX-DLNN(16,15,2,1)	0,071	0,087	0,101	0,564	0,153	0,099	0,142	0,201
GSTARX-DLNN(16,1,3,1)	0,074	0,077	0,088	0,564	0,054	0,069	0,075	0,066
GSTARX-DLNN(16,2,3,1)	0,073	0,079	0,086	0,564	0,047	0,077	0,078	0,068
GSTARX-DLNN(16,3,3,1)	0,072	0,080	0,089	0,563	0,056	0,073	0,075	0,064
GSTARX-DLNN(16,4,3,1)	0,077	0,085	0,091	0,564	0,086	0,065	0,081	0,066
GSTARX-DLNN(16,5,3,1)	0,070	0,085	0,094	0,564	0,071	0,085	0,095	0,064
GSTARX-DLNN(16,10,3,1)	0,071	0,084	0,091	0,564	0,099	0,058	0,096	0,170
GSTARX-DLNN(16,15,3,1)	0,072	0,089	0,097	0,564	0,131	0,188	0,148	0,296
GSTARX-DLNN(16,1,4,1)	0,073	0,077	0,087	0,564	0,055	0,069	0,075	0,065
GSTARX-DLNN(16,2,4,1)	0,072	0,079	0,086	0,564	0,053	0,071	0,076	0,061
GSTARX-DLNN(16,3,4,1)	0,073	0,080	0,092	0,564	0,052	0,072	0,075	0,068
GSTARX-DLNN(16,4,4,1)	0,074	0,080	0,086	0,564	0,050	0,113	0,079	0,086
GSTARX-DLNN(16,5,4,1)	0,071	0,082	0,093	0,564	0,053	0,093	0,101	0,078
GSTARX-DLNN(16,10,4,1)	0,073	0,085	0,096	0,564	0,191	0,097	0,143	0,096
GSTARX-DLNN(16,15,4,1)	0,068	0,088	0,092	0,565	0,163	0,448	0,089	0,175
GSTARX-DLNN(16,1,5,1)*	0,073	0,079	0,087	0,564	0,049	0,070	0,073	0,063
GSTARX-DLNN(16,2,5,1)	0,073	0,079	0,088	0,564	0,057	0,074	0,079	0,063
GSTARX-DLNN(16,3,5,1)	0,072	0,080	0,087	0,564	0,045	0,080	0,087	0,078
GSTARX-DLNN(16,4,5,1)	0,074	0,080	0,094	0,564	0,060	0,071	0,082	0,068
GSTARX-DLNN(16,5,5,1)	0,072	0,083	0,091	0,564	0,472	0,088	0,089	0,083
GSTARX-DLNN(16,10,5,1)	0,074	0,089	0,098	0,564	0,210	0,112	0,102	0,067
GSTARX-DLNN(16,15,5,1)	0,073	0,090	0,096	0,564	0,173	0,269	0,174	0,256

Ket: *model terbaik

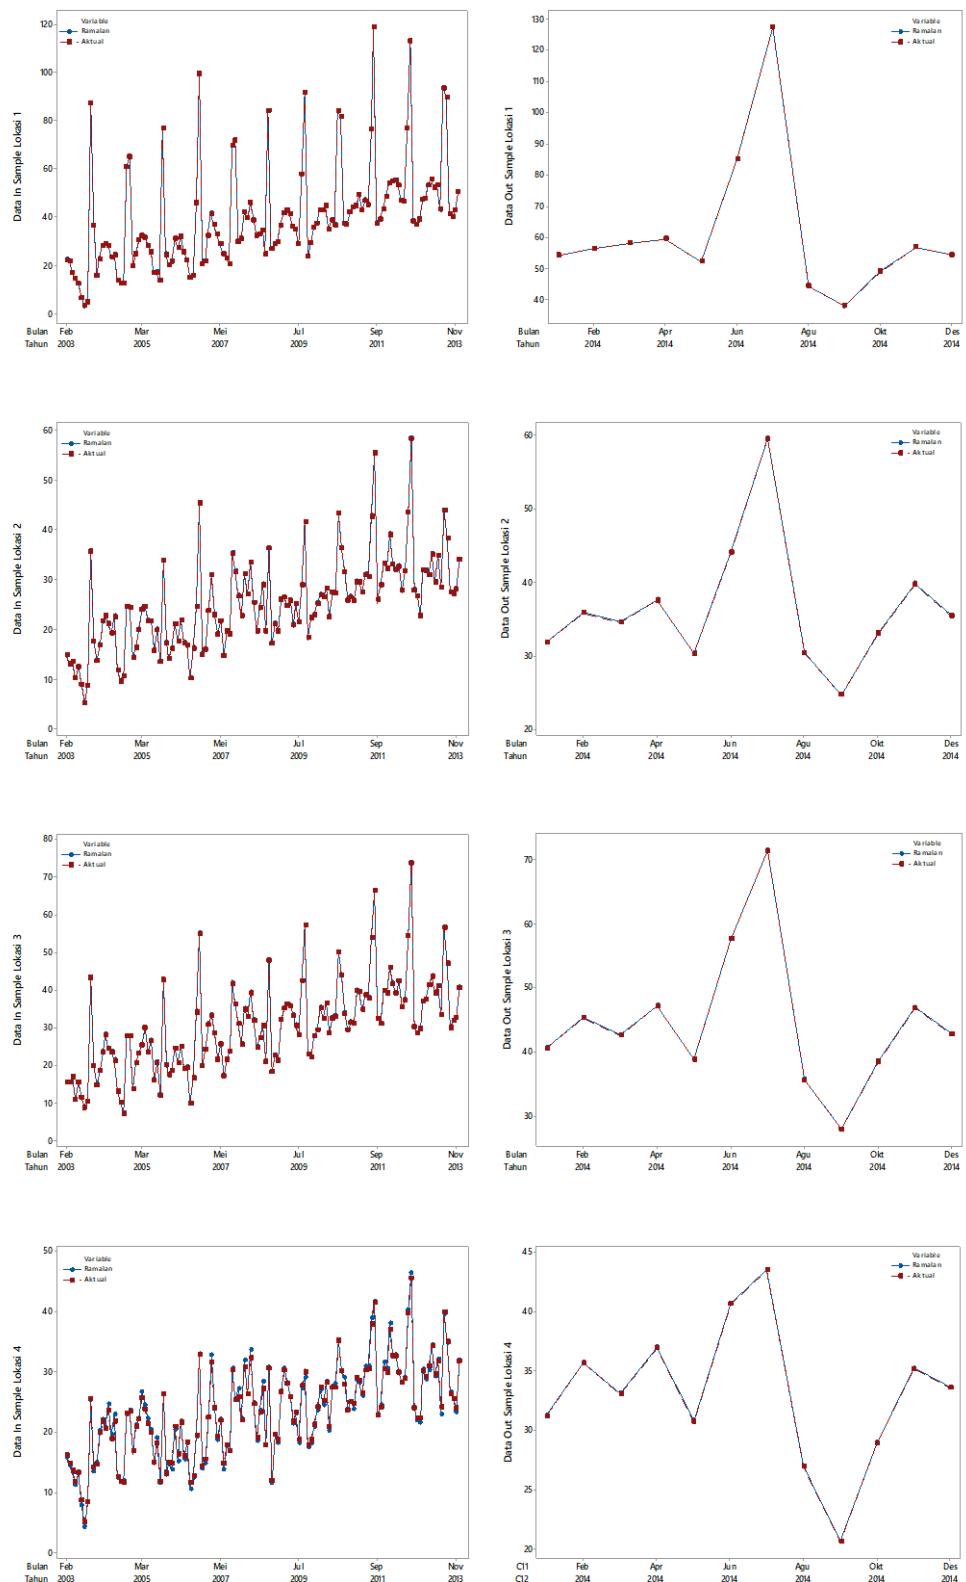
Peramalan data simulasi 1 di empat lokasi selanjutnya dilakukan dengan menggunakan *hybrid* GSTARX-DLNN (8,10,2,1) untuk skenario 1 dan menggunakan model *hybrid* GSTARX-DLNN(16,1,5,1) untuk skenario 2.



Gambar 4. 24 Time Series Plot Data Aktual dan Ramalan Model Hybrid GSTARX-DLNN

Simulasi 1 Skenario 1

Berdasarkan Gambar 4. 24 dapat diketahui bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender. Berikut ini adalah *time series plot* perbandingan hasil ramalan dan data aktual data simulasi 1 skenario 2



Gambar 4. 25 Time Series Plot Data Aktual dan Ramalan Model Hybrid GSTARX-DLNN
Simulasi 1 Skenario 2

Berdasarkan Gambar 4. 25 dapat diketahui bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender dengan baik. Setelah diperoleh nilai tingkat kesalahan ramalan untuk masing-masing data simulasi, model *hybrid GSTARX-DLNN* terbaik untuk setiap data simulasi dalam skenario 1 dan 2 dapat dilihat pada Tabel 4.12

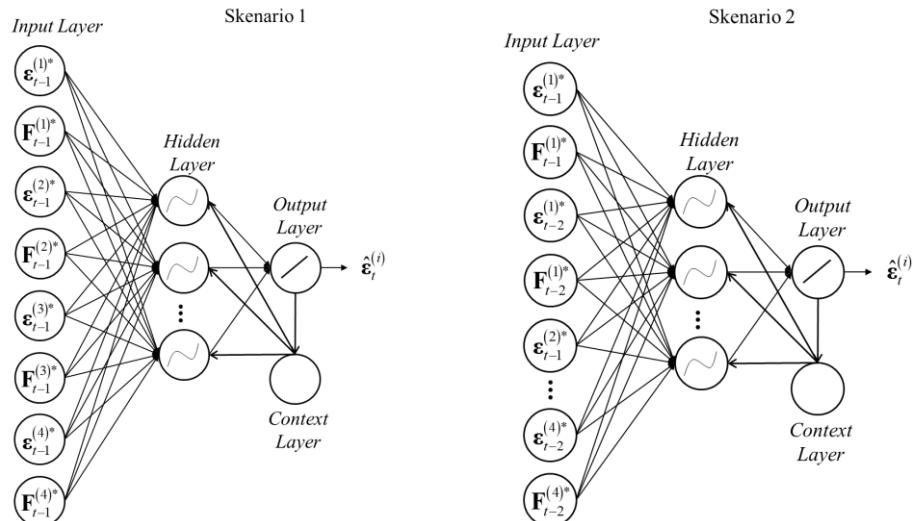
Tabel 4. 12 Nilai Kebaikan Model *Hybrid GSTARX-DLNN* pada Skenario I dan 2

Data Simulasi	Model GSTARX-DLNN	RMSE <i>in Sample</i>				RMSE <i>out Sample</i>			
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1									
1	GSTARX-DLNN (16,10,2,1)	1,525	1,552	1,490	1,359	0,971	0,973	0,797	0,846
2	GSTARX-DLNN (16,1,4,1)	0,994	1,197	1,234	0,962	0,721	0,966	1,508	1,041
3	GSTARX-DLNN (16,5,2,1)	0,982	0,995	0,959	1,130	0,679	0,569	0,636	0,752
4	GSTARX-DLNN (16,15,4,1)	0,968	0,928	0,971	0,952	0,944	0,692	1,149	0,933
5	GSTARX-DLNN (16,4,3,1)	0,844	1,007	0,930	1,004	2,088	1,719	1,488	1,671
6	GSTARX-DLNN (16,10,4,1)	1,119	1,441	1,271	1,150	0,845	0,714	0,933	0,872
7	GSTARX-DLNN (16,15,4,1)	0,935	0,868	0,850	0,853	0,815	0,947	1,167	1,428
8	GSTARX-DLNN (16,1,5,1)	1,048	1,028	1,221	1,070	1,386	1,489	1,352	1,833
9	GSTARX-DLNN (16,10,3,1)	0,885	0,975	0,942	0,881	0,902	1,181	1,158	1,254
10	GSTARX-DLNN (16,4,5,1)	0,964	1,071	1,049	1,154	0,836	0,936	0,828	0,924
Skenario 2									
1	GSTARX-DLNN (16,1,5,1)	0,073	0,079	0,087	0,564	0,049	0,070	0,073	0,063
2	GSTARX-DLNN (16,15,2,1)	0,060	0,079	0,078	0,698	0,270	0,153	0,338	0,272
3	GSTARX-DLNN (16,2,2,1)	0,041	0,027	0,028	0,525	0,041	0,015	0,017	0,023
4	GSTARX-DLNN (16,1,2,1)	0,044	0,047	0,069	0,360	0,043	0,048	0,063	0,043
5	GSTARX-DLNN (16,1,1,1)	0,034	0,061	0,068	0,363	0,029	0,068	0,071	0,087
6	GSTARX-DLNN (16,1,3,1)	0,090	0,072	0,080	0,464	0,108	0,068	0,095	0,086
7	GSTARX-DLNN (16,1,5,1)	0,046	0,056	0,031	0,377	0,059	0,057	0,076	0,077
8	GSTARX-DLNN (16,1,2,1)	0,052	0,054	0,059	0,180	0,050	0,049	0,056	0,060
9	GSTARX-DLNN (16,1,1,1)	0,053	0,056	0,066	0,399	0,073	0,062	0,089	0,080
10	GSTARX-DLNN (16,1,3,1)	0,024	0,034	0,016	0,190	0,020	0,031	0,012	0,036

Tabel 4. 12 menunjukkan model terbaik yang didapatkan untuk setiap data simulasi dengan menggunakan model *hybrid* GSTARX-DLNN. Dari 10 kali replikasi pada masing-masing skenario, model *hybrid* GSTARX-DLNN terbaik yang terpilih memiliki jumlah *neuron* yang bervariasi. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* untuk mendapatkan model yang optimum.

4.1.6. Pemodelan *Hybrid* GSTARX-Jordan RNN pada Data Simulasi

Pada pemodelan *hybrid* GSTARX-Jordan RNN, *input* yang digunakan adalah variabel pada model GSTAR. Sehingga input terdiri dari 8 variabel untuk data skenario 1 dan terdiri dari 16 input untuk data skenario 2. Berikut ini adalah arsitektur pemodelan *hybrid* GSTARX-Jordan RNN



Gambar 4. 26 Arsitekur GSTAR-Jordan RNN dengan 8 Input dan 16 input dan 1 *Hidden Layer* dengan $\boldsymbol{\varepsilon}_{t-1}^{(i)*}$ merupakan *standardize* dari $\boldsymbol{\varepsilon}_{t-1}^{(i)}$, dan vektor $\mathbf{0}$ berukuran sama dengan vektor $\boldsymbol{\varepsilon}_{t-1}^{(i)}$

$$\boldsymbol{\varepsilon}_{t-1}^{(1)*} = \begin{bmatrix} \boldsymbol{\varepsilon}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\varepsilon}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\varepsilon}_{t-1}^{(4)} \end{bmatrix},$$

$$\begin{aligned}
\mathbf{F}_{t-1}^{(1)*} &= \begin{bmatrix} w_{12}\boldsymbol{\epsilon}_{t-1}^{(2)} + w_{13}\boldsymbol{\epsilon}_{t-1}^{(3)} + w_{14}\boldsymbol{\epsilon}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ w_{21}\boldsymbol{\epsilon}_{t-1}^{(1)} + w_{23}\boldsymbol{\epsilon}_{t-1}^{(3)} + w_{24}\boldsymbol{\epsilon}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\
\mathbf{F}_{t-1}^{(3)*} &= \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\boldsymbol{\epsilon}_{t-1}^{(1)} + w_{32}\boldsymbol{\epsilon}_{t-1}^{(2)} + w_{34}\boldsymbol{\epsilon}_{t-1}^{(4)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{41}\boldsymbol{\epsilon}_{t-1}^{(1)} + w_{42}\boldsymbol{\epsilon}_{t-1}^{(2)} + w_{43}\boldsymbol{\epsilon}_{t-1}^{(3)} \end{bmatrix}, \\
\boldsymbol{\epsilon}_{t-2}^{(1)*} &= \begin{bmatrix} \boldsymbol{\epsilon}_{t-2}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\epsilon}_{t-2}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \boldsymbol{\epsilon}_{t-2}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\epsilon}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\epsilon}_{t-2}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \boldsymbol{\epsilon}_{t-2}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \boldsymbol{\epsilon}_{t-2}^{(4)} \end{bmatrix}, \\
\mathbf{F}_{t-2}^{(1)*} &= \begin{bmatrix} \omega_{12}\boldsymbol{\epsilon}_{t-2}^{(2)} + \omega_{13}\boldsymbol{\epsilon}_{t-2}^{(3)} + \omega_{14}\boldsymbol{\epsilon}_{t-2}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-2}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \omega_{21}\boldsymbol{\epsilon}_{t-2}^{(1)} + \omega_{23}\boldsymbol{\epsilon}_{t-2}^{(3)} + \omega_{24}\boldsymbol{\epsilon}_{t-2}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\
\mathbf{F}_{t-2}^{(3)*} &= \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \omega_{31}\boldsymbol{\epsilon}_{t-2}^{(1)} + \omega_{32}\boldsymbol{\epsilon}_{t-2}^{(2)} + \omega_{34}\boldsymbol{\epsilon}_{t-2}^{(4)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{F}_{t-2}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \omega_{41}\boldsymbol{\epsilon}_{t-2}^{(1)} + \omega_{42}\boldsymbol{\epsilon}_{t-2}^{(2)} + \omega_{43}\boldsymbol{\epsilon}_{t-2}^{(3)} \end{bmatrix}.
\end{aligned}$$

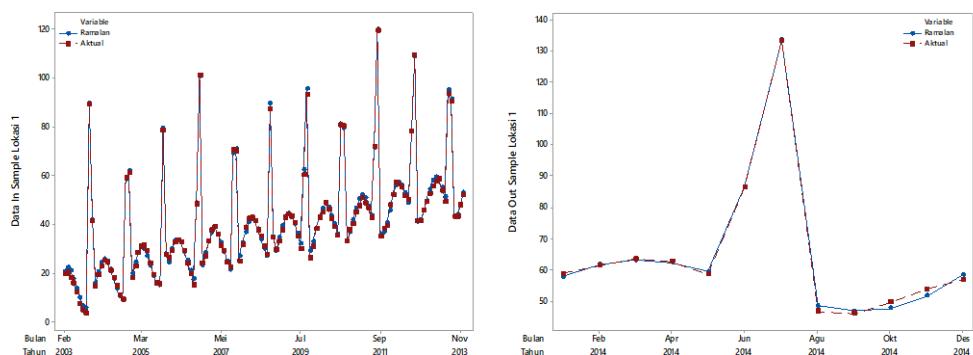
Banyaknya *neuron* yang digunakan pada *hidden layer* adalah 1, 2, 3, 4, 5, 10, dan 15. Fungsi aktivasi yang digunakan pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi yang digunakan untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *out sample*. Tabel 4. 13 menunjukkan hasil kebaikan model *hybrid GSTARX-Jordan RNN* menggunakan kriteria nilai RMSE pada masing-masing model. Pemilihan model terbaik dilakukan berdasarkan nilai RMSE terkecil pada data *out sample*. Namun, dapat diketahui bahwa nilai RMSE pada data *out sample* terdapat perbedaan kesimpulan pada setiap lokasi. Model terbaik yang dipilih merupakan model yang memiliki nilai minimum paling banyak di empat lokasi. Model *hybrid GSTARX-Jordan RNN* dengan delapan *input*, 1 unit *neuron*, yang dinotasikan dalam *hybrid GSTARX-Jordan RNN(8,1,1)* merupakan model

terbaik untuk data simulasi 1 skenario 1 karena memiliki nilai RMSE terkecil. Model *hybrid GSTARX-Jordan(16,10,1)* adalah model terbaik untuk data simulasi 1 skenario 2 dengan 16 input, 10 unit *neuron*.

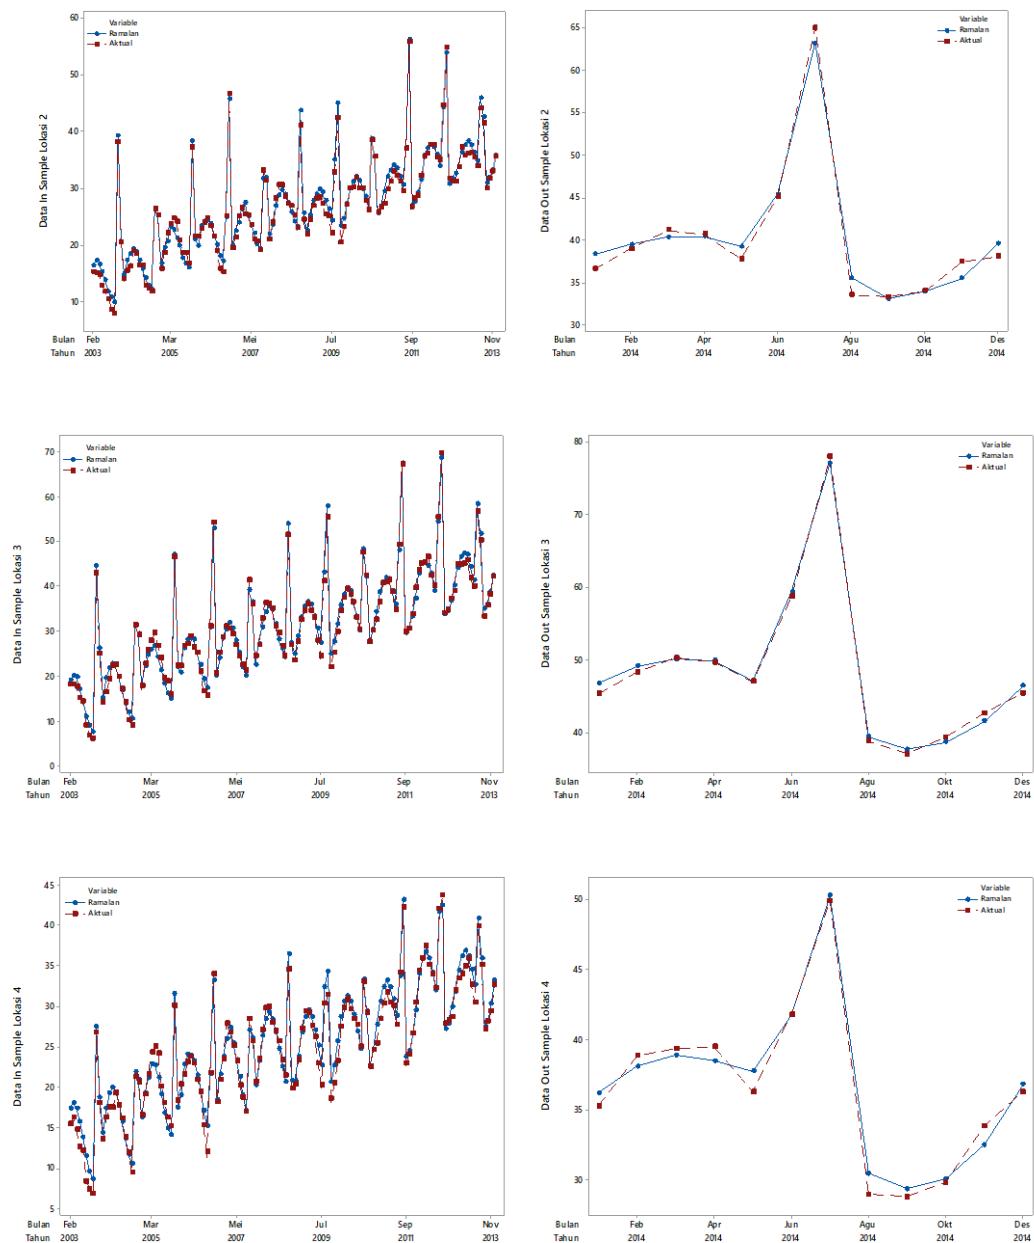
Tabel 4. 13 Nilai Kebaikan Model *hybrid GSTARX-Jordan RNN* Data Simulasi 1 Skenario 1 dan 2

Model GSTARX-Jordan RNN	RMSE <i>in Sample</i>				RMSE <i>out Sample</i>			
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1								
GSTARX-Jordan RNN (8,1,1)*	1,232	1,237	1,379	1,285	1,229	1,294	0,783	0,890
GSTARX-Jordan RNN (8,2,1)	0,918	0,899	1,108	0,902	1,268	1,212	0,840	1,020
GSTARX-Jordan RNN (8,3,1)	0,928	0,957	1,359	0,901	1,254	1,311	0,746	1,029
GSTARX-Jordan RNN (8,4,1)	0,982	0,872	1,176	0,908	1,375	1,256	0,902	0,933
GSTARX-Jordan RNN (8,5,1)	0,947	0,851	1,252	0,907	1,339	1,459	0,772	0,910
GSTARX-Jordan RNN (8,10,1)	1,323	1,266	1,469	1,268	1,380	2,168	0,916	1,344
GSTARX-Jordan RNN (8,15,1)	1,632	1,943	1,366	1,176	1,604	2,445	2,963	1,548
Skenario 2								
GSTARX-Jordan RNN (16,1,1)	2,073	2,264	2,565	2,127	3,241	3,415	3,852	3,294
GSTARX-Jordan RNN (16,2,1)	0,132	0,183	0,162	0,155	0,245	0,207	0,275	0,353
GSTARX-Jordan RNN (16,3,1)	0,213	0,209	0,183	0,193	0,198	0,311	0,510	0,199
GSTARX-Jordan RNN (16,4,1)	0,149	0,169	0,143	0,150	0,146	0,217	0,341	0,144
GSTARX-Jordan RNN (16,5,1)	0,091	0,170	0,125	0,131	0,119	0,146	0,164	0,126
GSTARX-Jordan RNN(16,10,1)*	0,062	0,073	0,069	0,070	0,059	0,111	0,135	0,079
GSTARX-Jordan RNN (16,15,1)	0,056	0,091	0,091	0,075	0,088	0,281	0,286	0,077

Selanjutnya adalah melakukan peramalan data simulasi 1 skenario 1 dan 2 di empat lokasi menggunakan model *hybrid GSTARX-Jordan RNN(8,1,1)* untuk skenario 1 dan model *hybrid GSTARX-Jordan RNN(16,10,1)* untuk skenario 2. Hasil ramalan di keempat lokasi ditampilkan dalam bentuk *time series* pada Gambar 4.27.

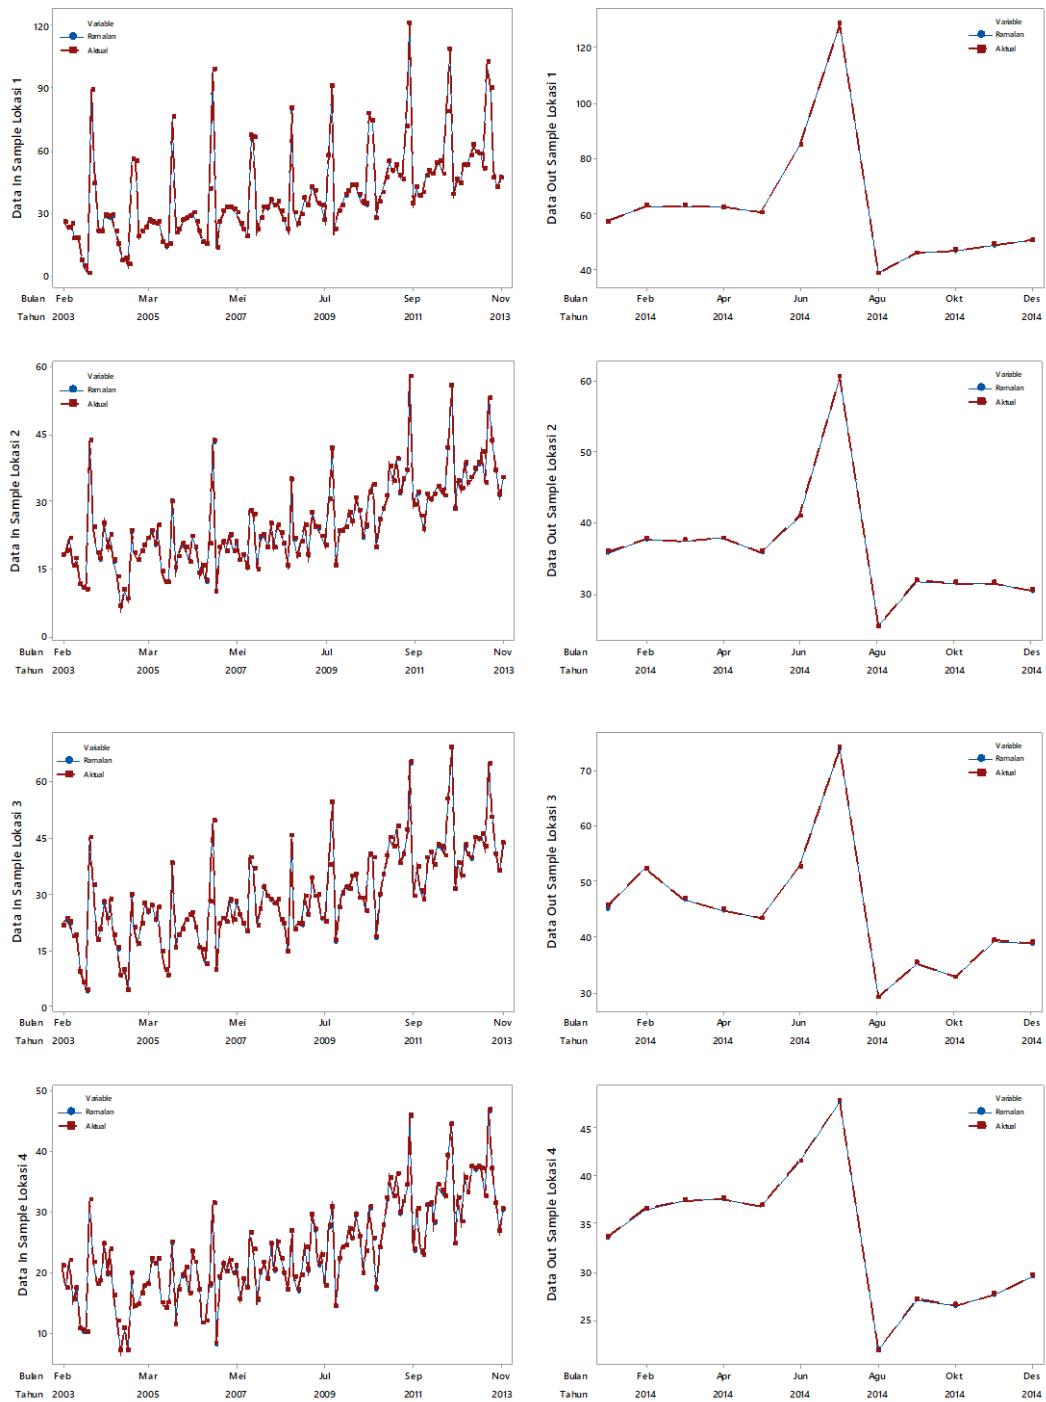


Gambar 4. 27 *Time Series Plot* Data Aktual dan Ramalan Model *Hybrid GSTARX-Jordan RNN* Simulasi 1 Skenario 1



Gambar 4. 27 Time Series Plot Data Aktual dan Ramalan Model Hybrid GSTARX-Jordan RNN Simulasi 1 Skenario 1 (lanjutan)

Berdasarkan Gambar 4. 27 dapat diketahui bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi 1 skenario 1 yang mengandung komponen tren, musiman, dan variasi kalender. Berikut ini adalah *time series plot* untuk hasil ramalan data simulasi 1 skenario 2.



Gambar 4. 28 Time Series Plot Data Aktual dan Ramalan Model Hybrid GSTARX-Jordan RNN Simulasi 1 Skenario 2

Berdasarkan Gambar 4. 28 dapat diketahui bahwa data hasil ramalan sudah mampu mengikuti pola data aktual dengan cukup tepat. Jika dibandingkan dengan *time series plot* hasil ramalan pada data simulasi 1 skenario 1, model *hybrid GSTARX-Jordan RNN* dapat lebih baik dalam meramalkan data pada skenario 2,

yaitu data yang mangandung komponen tren, musiman dan variasi kalender dengan residual yang mengikuti pola nonlinier. Diperoleh nilai RMSE dari pemodelan *hybrid GSTARX-Jordan RNN* untuk masing-masing data simulasi pada kedua skenario yang ditunjukkan pada Tabel 4. 14.

Tabel 4. 14 Nilai Kebaikan Model *Hybrid GSTARX-Jordan RNN* pada Skenario I dan 2

Data Simulasi	Model GSTARX-Jordan RNN	RMSE <i>in Sample</i>				RMSE <i>out Sample</i>			
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
Skenario 1									
1	GSTARX-Jordan RNN (8,1,1)	1,232	1,237	1,379	1,285	1,229	1,294	0,783	0,890
2	GSTARX-Jordan RNN (8,3,1)	0,885	1,013	0,942	0,844	1,023	1,487	1,828	1,264
3	GSTARX-Jordan RNN (8,3,1)	1,018	1,040	0,989	1,164	0,734	0,546	0,867	0,919
4	GSTARX-Jordan RNN (8,3,1)	1,037	0,973	1,011	0,940	0,949	0,666	1,041	1,072
5	GSTARX-Jordan RNN (8,2,1)	0,835	0,981	0,954	1,000	2,718	2,545	2,336	2,828
6	GSTARX-Jordan RNN (8,2,1)	0,983	1,033	0,980	1,063	0,920	0,674	1,353	0,862
7	GSTARX-Jordan RNN (8,2,1)	0,986	0,915	0,870	0,904	1,017	1,247	1,634	1,701
8	(GSTARX-Jordan RNN (8,15,1))	1,065	1,186	1,220	1,209	1,501	1,674	1,473	2,261
9	GSTARX-Jordan RNN (8,5,1)	0,951	1,034	0,889	0,903	1,088	1,412	1,139	1,057
10	GSTARX-Jordan RNN (8,4,1)	0,945	1,016	0,962	1,083	0,838	0,843	0,924	1,258
Skenario 2									
1	GSTARX-Jordan RNN (16,1,1)	0,069	0,066	0,080	0,053	0,075	0,039	0,052	0,055
2	GSTARX-Jordan RNN (16,3,1)	0,062	0,073	0,069	0,070	0,059	0,111	0,135	0,079
3	GSTARX-Jordan RNN (16,3,1)	0,062	0,052	0,044	0,044	0,070	0,068	0,024	0,040
4	GSTARX-Jordan RNN (16,3,1)	0,068	0,065	0,095	0,059	0,087	0,086	0,151	0,049
5	GSTARX-Jordan RNN (16,2,1)	0,054	0,079	0,097	0,102	0,037	0,103	0,104	0,147
6	GSTARX-Jordan RNN (16,2,1)	0,090	0,064	0,088	0,080	0,115	0,073	0,075	0,085
7	GSTARX-Jordan RNN (16,2,1)	0,059	0,044	0,029	0,048	0,273	0,214	0,243	0,443
8	GSTARX-Jordan RNN (16,15,1)	0,053	0,062	0,077	0,082	0,075	0,097	0,103	0,117
9	GSTARX-Jordan RNN (16,5,1)	0,051	0,036	0,061	0,050	0,058	0,100	0,070	0,055
10	GSTARX-Jordan RNN (16,4,1)	0,047	0,032	0,033	0,037	0,028	0,030	0,035	0,034

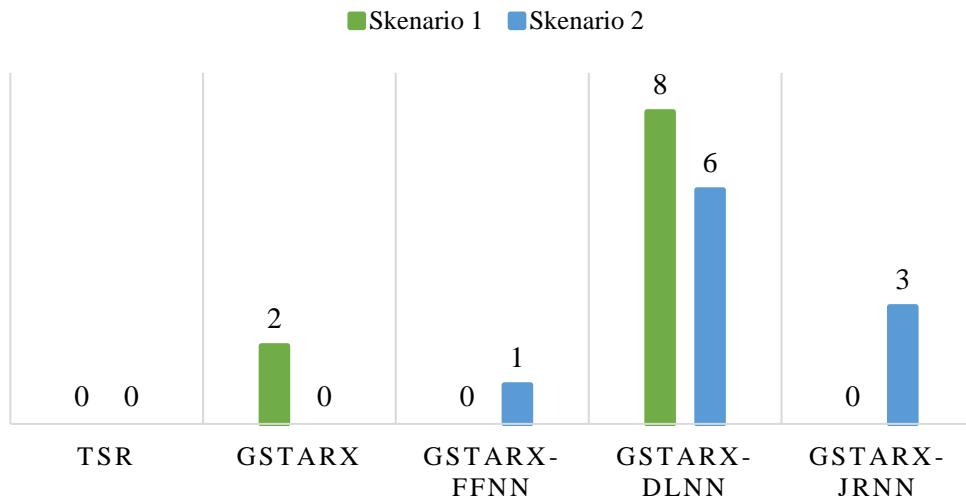
Berdasarkan Tabel 4. 14 dapat diketahui bahwa model terbaik yang didapatkan untuk setiap data simulasi pada skenario 1 dengan menggunakan *hybrid GSTARX-Jordan RNN* dari 10 kali replikasi menghasilkan model terbaik dengan jumlah *neuron* yang bervariasi. Begitu juga dengan hasil model terbaik yang terpilih pada keseluruhan replikasi data skenario 2. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* untuk mendapatkan model yang optimum. Tabel diatas juga menunjukkan model terbaik yang didapatkan untuk setiap data simulasi dalam dua skenario dengan menggunakan model *hybrid GSTARX-Jordan RNN*. Dari 10 kali replikasi pada masing-masing skenario, model *hybrid GSTARX-Jordan RNN* terbaik yang terpilih memiliki jumlah *neuron* yang bervariasi. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* untuk mendapatkan model yang optimum.

4.1.7. Pemilihan Model Terbaik pada Data Simulasi

Pada bagian ini akan dilakukan perbandingan kriteria kebaikan model menggunakan nilai RMSE dari keseluruhan pemodelan yang sudah dilakukan. Model terbaik dipilih berdasarkan nilai RMSE terkecil pada data *out sample*. Berdasarkan nilai RMSE yang diperoleh pada setiap pemodelan yang sudah diuraikan diatas, diketahui bahwa nilai RMSE terkecil berbeda-beda pada setiap lokasi. Sehingga, dalam melakukan pemilihan model terbaik untuk kedua skenario data dipilih berdasarkan rata-rata nilai RMSE dari empat lokasi. Berikut ini adalah gambaran model terbaik dari masing-masing skenario dengan rata-rata nilai RMSE terkecil.

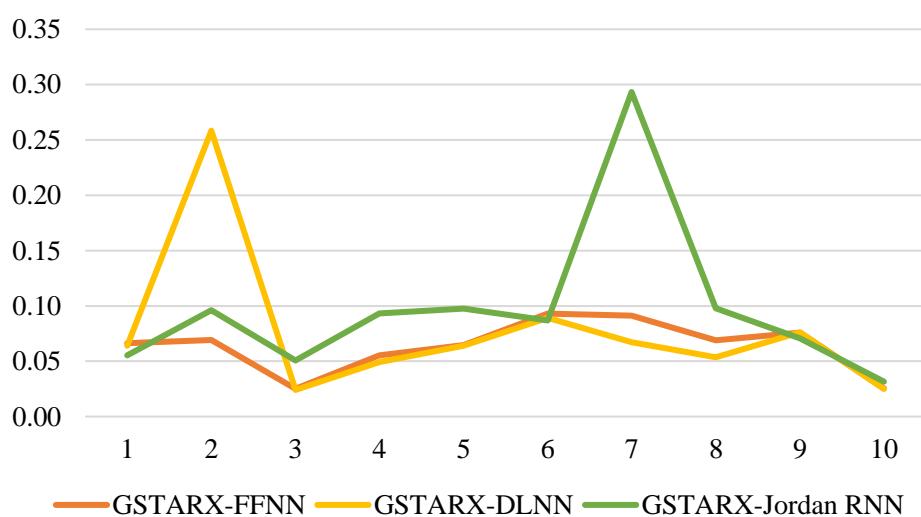
Gambar 4. 29 menunjukkan jumlah replikasi yang memiliki nilai rata-rata RMSE terkecil di setiap metode yang digunakan untuk masing-masing skenario data. Dari gambar tersebut dapat diketahui bahwa jika dilihat berdasarkan setiap skenario data, data skenario 1 memiliki rata-rata RMSE terkecil pada model GSTARX dan model *hybrid GSTARX-DLNN*. Sedangkan untuk data skenario 2 memiliki rata-rata nilai RMSE terkecil pada semua mode *hybrid* yang digunakan. Hal ini dikarenakan data skenario 2 mengandung komponen residual mengikuti pola nonlinier, sehingga lebih baik dimodelkan menggunakan model *hybrid* yang

mampu menangani kasus data yang memiliki struktur linier dan nonlinier secara simultan.



Gambar 4. 29 Diagram Batang Jumlah RMSE Terkecil Pada Setiap Metode

Secara keseluruhan baik pada data skenario 1 maupun skenario 2 model yang memiliki jumlah rata-rata RMSE terkecil adalah model *hybrid* GSTARX-DLNN. Jikan dilihat rata-rata nilai RMSE tiga model *hybrid* yang digunakan memiliki selisih nilai yang sangat kecil dan hampir sama, perbandingan kebaikan model *hybrid* yang digunakan dapat dilihat pada Gambar 4. 30.



Gambar 4. 30 Line Plot Rata-rata RMSE Model *Hybrid* pada setiap replikasi di Skenario 2

Berdasarkan Gambar 4. 30 diketahui bahwa rata-rata nilai RMSE model *hybrid* pada data skenario 2 terlihat bahwa ketiga *line plot* saling berdekatan. Hanya

terdapat 1 data yang memiliki rata-rata nilai RMSE cukup lebih tinggi daripada lainnya. Sehingga dapat disimpulkan bahwa model *hybrid* GSTARX-FFNN, GSTARX-DLNN, dan GSTARX-Jordan RNN merupakan metode terbaik dalam meramalkan data yang memiliki residual mengikuti pola nonlinier.

Penentuan model terbaik juga dapat dilakukan dengan membandingkan rasio dari rata-rata RMSE masing-masing metode yang digunakan. Tabel 4. 15 menunjukkan rasio rata-rata RMSE pada masing-masing metode pada kedua skenario data. Dari tabel tersebut terlihat bahwa rasio rata-rata RMSE pada data skenario 1 dan 2 tertinggi adalah pada metode GSTAR dan Jordan RNN, hal ini dikarenakan metode tersebut tidak dapat menangkap pola tren, musiman, dan variasi kalender. Sedangkan untuk metode GSTARX, *hybrid* GSTARX-FFNN, *hybrid* GSTARX-DLNN, dan *hybrid* GSTARX-Jordan RNN memiliki rasio rata-rata RMSE yang tidak jauh berbeda.

Tabel 4. 15 Rasio Rata-rata RMSE Terhadap Model TSR

Skenario	Metode	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
1	<i>Time Series Regression</i>	1	1	1	1
	GSTAR	20,307	5,562	7,397	3,843
	Jordan RNN	9,428	3,217	4,016	2,229
	GSTARX	0,582	0,568	0,587	0,587
	GSTARX-FFNN	0,506	0,449	0,480	0,479
	GSTARX-DLNN	0,453	0,406	0,421	0,442
	GSTARX-Jordan RNN	0,535	0,494	0,512	0,540
2	<i>Time Series Regression</i>	1	1	1	1
	GSTAR	14,135	4,522	5,445	3,639
	Jordan RNN	6,270	2,339	2,737	1,780
	GSTARX	1,042	1,081	1,041	1,039
	GSTARX-FFNN	0,016	0,016	0,016	0,018
	GSTARX-DLNN	0,021	0,016	0,021	0,021
	GSTARX-Jordan RNN	0,025	0,024	0,024	0,029

Rasio rata-rata RMSE pada data skenario 2 terlihat bahwa metode *Time Series Regression* dan GSTARX memiliki rasio yang hampir sama, dan rasio rata-rata RMSE dari model *hybrid* jauh lebih kecil dibandingkan metode lainnya pada masing-masing lokasi. Sehingga, dapat disimpulkan bahwa model *hybrid* memiliki performa lebih baik dalam memodelkan data yang mengandung komponen tren, musiman, variasi kalender, dan residual yang mengikuti pola nonlinier dibandingkan dengan performa model *hybrid* dalam memodelkan data yang

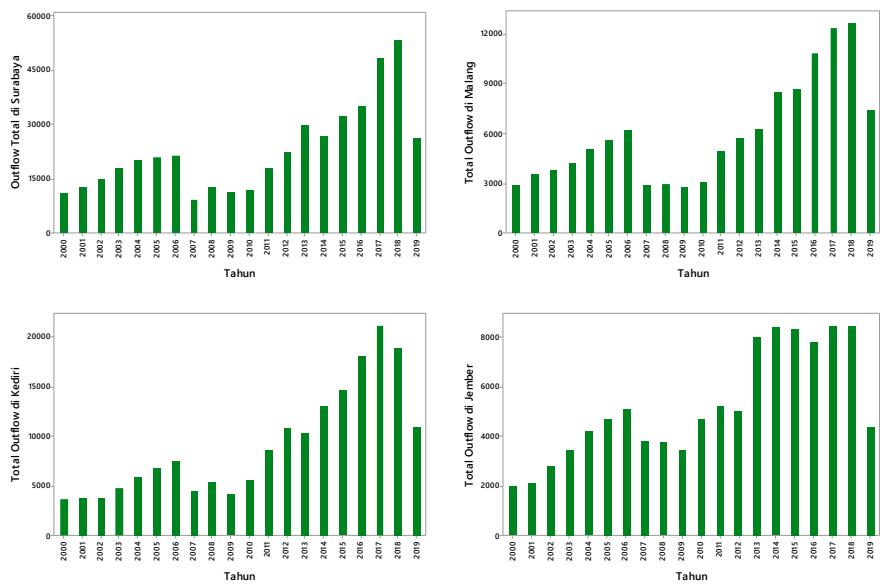
memiliki komponen residual mengikuti pola linier. Rasio RMSE juga menunjukkan seberapa besar suatu model mampu mereduksi nilai RMSE dari model TSR. Model *hybrid* yang mampu mereduksi nilai RMSE dengan persentase lebih besar adalah model *hybrid GSTARX-FFNN* yaitu sekitar 84% pada skenario 1 dan sekitar 57% pada skenario 1. Sehingga dapat disimpulkan bahwa, berdasarkan rasio RMSE terhadap model TSR, model *hybrid GSTARX-FFNN* merupakan model terbaik dalam memodelkan data *time series* yang memiliki komponen tren, musiman, variasi kalender, dan residual yang mengikuti pola linier maupun nonlinier.

4.2. Pemodelan Data *Inflow* dan *Outflow* di Jawa Timur

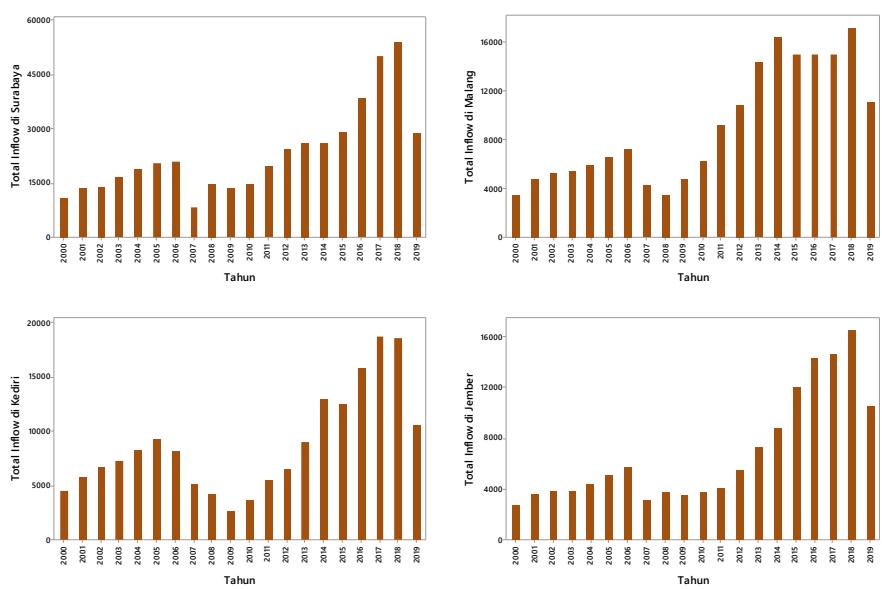
Pemodelan *inflow* dan *outflow* uang kartal di Jawa Timur terdiri dari empat Kantor Perwakilan Bank Indonesia (KP BI), yaitu Surabaya, Malang, Kediri, dan Jember. Data yang digunakan merupakan data bulanan periode Januari tahun 2000 sampai Juni 2019 untuk data total dan semua pecahan selain pecahan Rp. 2.000,-, Data periode Januari 2000 sampai Desember 2018 sebagai data *in sample* sedangkan data periode Januari 2019 sampai dengan Juni 2019 sebagai data *out sample*. Untuk data pecahan Rp. 2.000,- menggunakan data bulanan periode Januari 2010 sampai Juni 2019, untuk periode Januari 2010 sampai Desember 2018 sebagai data *in sample*, sedangkan Januari 2019 sampai Juni 2019 sebagai data *out sample*. Pemodelan data *inflow* dan *outflow* dilakukan dengan menggunakan metode naïve musiman, *time series regression*, ARIMAX, GSTARX, *hybrid GSTARX-FFNN*, *hybrid GSTARX-DLNN*, dan *hybrid GSTARX-Jordan RNN*.

4.2.1. Karakteristik Data *Inflow* dan *Outflow* di KP BI Jawa Timur

Perkembangan *inflow* dan *outflow* di masing-masing KP BI Provinsi Jawa Timur dari bulan Januari tahun 2000 hingga bulan Juni tahun 2019 ditunjukkan pada Gambar 4.31. Dapat diketahui bahwa total *inflow* dan *outflow* pada masing-masing wilayah mengalami kenaikan dari tahun 2000 hingga 2006, namun pada tahun 2007 mengalami penurunan yang cukup signifikan. Hal ini dikarenakan pada tahun 2007 terjadi perubahan kebijakan mengenai pembatasan penyetoran untuk Uang yang Tidak Layak Edar (UTLE) dan Uang yang Masih Layak Edar (ULE).



Gambar 4.31 Diagram Batang Perkembangan Total *Inflow* dan *Outflow* Setiap Tahun di KP BI Jawa Timur

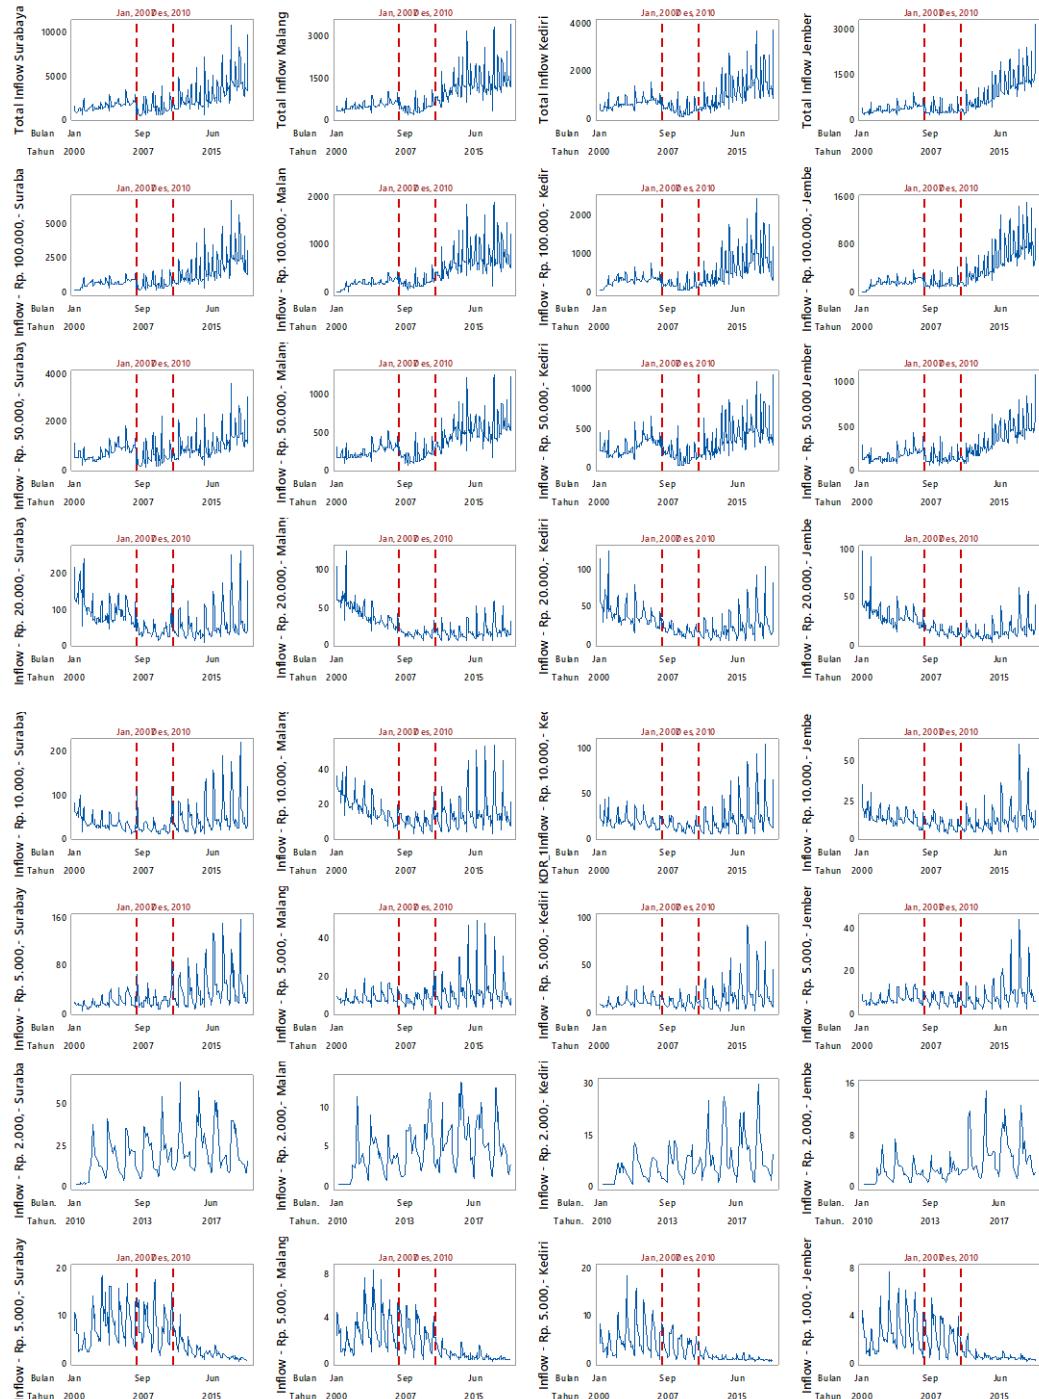


Gambar 4.31 Diagram Batang Perkembangan Total *Inflow* dan *Outflow* Setiap Tahun di KP BI Jawa Timur (lanjutan)

Selain itu BI memberlakukan ULE dikelola melalui Transaksi Uang Kartal Antar Bank (TUKAB). Diberlakukannya TUKAB menyebabkan antar bank dapat memenuhi kekurangan maupun kelebihan jumlah pecahan uang kartal tertentu yang ditentukan. Bahkan antar BI yang berdekatan dapat saling memenuhi kekurangan maupun kelebihan jumlah pecahan uang kartal yang dibutuhkan. Pada tahun 2011,

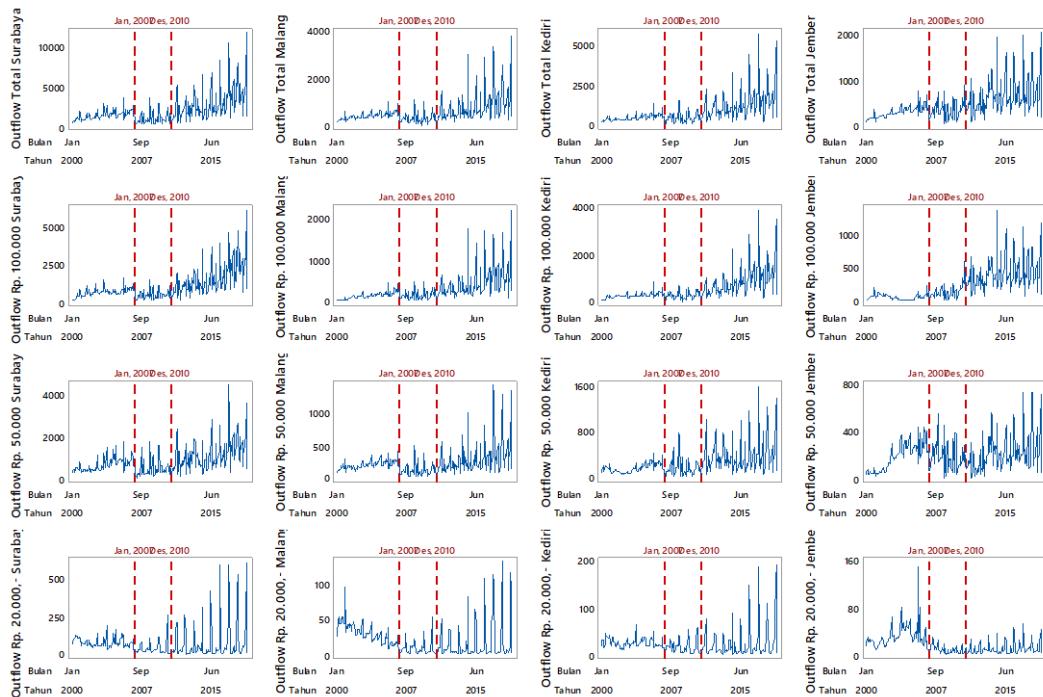
pola data kembali menunjukkan kenaikan yang cukup besar dibandingkan tahun sebelumnya. Kondisi ini disebabkan sejak tahun 2011 BI kembali menerima penyetoran UTLE dan ULE.

Berikut ini adalah visualisasi dari pola data *inflow* dan *outflow* pada masing-masing lokasi dalam total dan pecahan.

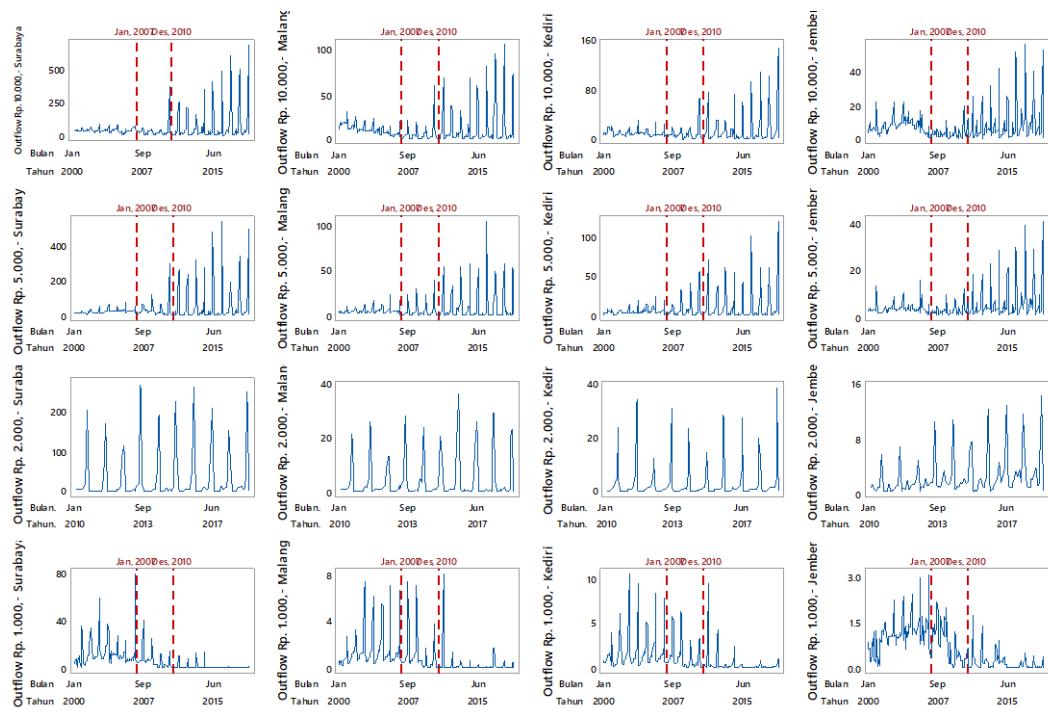


Gambar 4.32 Time Series Plot Data Inflow Total di KP BI Wilayah Jawa Timur

Berdasarkan Gambar 4. 32 yang menunjukkan pola data *inflow* dalam total maupun pecahan pada masing-masing wilayah KP BI Jawa Timur memiliki pola tren yang fluktuatif, dan terlihat terjadi penurunan pada tahun 2007 karena ada perubahan kebijakan, namun sudah mulai kembali naik pada tahun 2011 kecuali untuk data pecahan Rp. 2.000,- dan Rp. 1.000,-. Selain itu juga data *inflow* total, dan keseluruhan pecahan kecuali pecahan Rp. 1.000,- terlihat memiliki pola tren naik, dari gambar tersebut juga dapat diketahui bahwa data *inflow* memiliki pola musiman karena terdapat titik yang tinggi atau rendah pada waktu tertentu. Selain dipengaruhi oleh musiman bulanan, data *inflow* juga memiliki pola variasi kalender yaitu naik secara tajam pada bulan-bulan tertentu, karena dipengaruhi oleh kejadian hari raya idul fitri pada setiap tahunnya. Kejadian hari raya idul fitri akan mempengaruhi pola data *inflow* pada bulan terjadinya hari raya dan satu bulan sesudah terjadinya hari raya. Data *inflow* pecahan kecil memiliki pola tren yang tidak terlalu signifikan, terutama pada pecahan Rp. 1.000,- yang memiliki pola tren penurunan. Hal ini mungkin dikarenakan saat ini sudah jarang digunakannya uang kertas pecahan Rp. 1.000,- karena uang pecahan Rp. 1.000,- lebih sering digunakan dalam bentuk uang logam.



Gambar 4. 33. Time Series Plot Data Outflow Total dan Uang Pecahan Besar di KP BI Jawa Timur



Gambar 4. 34 Time Series Plot Data Outflow Total dan Uang Pecahan Kecil di KP BI Jawa Timur

Berdasarkan Gambar 4. 33 dan Gambar 4. 34 yang menunjukkan pola data *outflow* dalam total maupun pecahan pada masing-masing wilayah KP BI Jawa Timur memiliki pola tren yang fluktuatif hampir sama dengan pola data *inflow* pada masing-masing pecahan di setiap wilayah KP BI. Perbedaan pola data *inflow* dan *outflow* yaitu pada efek variasi kalender. Kejadian hari raya idul fitri akan cenderung mempengaruhi data *outflow* pada bulan kejadian hari raya dan pada bulan sebelum kejadian hari raya. Kejadian hari raya ini ditentukan berdasarkan kalender hijriah yang akan berbeda pada setiap tahunnya, sehingga kejadian ini meskipun terjadi setiap tahun namun tidak dapat disebut sebagai pola musiman, karena terjadinya tidak selalu pada bulan yang sama dalam setiap tahun.

Tabel 4.16 dan Tabel 4.17 menunjukkan statistika deskriptif data *inflow* dan *outflow* dalam total dan semua pecahan. Dari kedua tabel tersebut dapat diketahui bahwa data *inflow* dan *outflow* dalam total dan pecahan yang memiliki rata-rata tertinggi adalah di KP BI Surabaya. Hal ini dikarenakan Surabaya merupakan ibu kota Provinsi Jawa Timur dan KP BI Surabaya juga sebagai Sentra Pengelolaan Uang (SPU) depo kas utama timur 2. Sehingga aktifitas pengedaran uang di KP BI Surabaya lebih besar dibandingkan tiga wilayah lainnya.

Tabel 4. 16 Deskriptif Statistik Data *Inflow*

	Wilayah KP BI	N	Mean	StDev	Variance	Minimum	Maximum
Total	Surabaya	234	1987,60	1525,90	2328365,80	289,00	10609,30
	Malang	234	777,10	545,10	297118,50	110,70	3327,10
	Kediri	234	752,70	574,40	329930,00	59,00	3622,50
	Jember	234	587,00	464,00	215287,90	120,70	3059,70
Rp. 100.000,-	Surabaya	234	1016,60	974,30	949264,50	1,50	6559,40
	Malang	234	378,50	332,50	110566,30	0,00	1847,20
	Kediri	234	390,80	362,10	131110,30	0,70	2353,90
	Jember	234	301,00	287,10	82407,00	0,00	1502,00
Rp. 50.000,-	Surabaya	234	805,70	497,30	247352,90	118,10	3499,80
	Malang	234	340,90	201,50	40601,70	46,70	1227,30
	Kediri	234	290,20	186,40	34735,20	9,80	1147,60
	Jember	234	237,20	158,40	25081,50	51,70	1047,50
Rp. 20.000,-	Surabaya	234	64,17	43,66	1906,14	8,51	256,62
	Malang	234	24,69	17,53	307,43	3,28	124,61
	Kediri	234	27,29	18,60	345,79	2,87	122,21
	Jember	234	19,64	12,74	162,41	2,71	94,87
Rp. 10.000,-	Surabaya	234	38,96	30,25	914,83	8,77	214,58
	Malang	234	14,62	8,68	75,26	1,98	53,52
	Kediri	234	17,95	14,16	200,57	2,46	103,29
	Jember	234	11,78	6,91	47,71	2,27	60,12
Rp. 5.000,-	Surabaya	234	27,85	23,95	573,41	4,59	152,65
	Malang	234	9,33	6,73	45,31	1,38	49,46
	Kediri	234	12,65	12,09	146,07	1,15	89,01
	Jember	234	7,31	5,11	26,06	1,26	43,59
Rp. 2.000,-	Surabaya	114	25,71	60,02	3602,92	0,24	269,40
	Malang	114	3,86	7,61	57,87	0,04	36,54
	Kediri	114	3,59	7,66	58,67	0,03	38,92
	Jember	114	2,34	2,71	7,32	0,40	14,17
Rp. 1.000,-	Surabaya	234	5,18	4,20	17,61	0,25	17,73
	Malang	234	1,66	1,61	2,59	0,04	8,15
	Kediri	234	2,65	2,96	8,75	0,07	17,79
	Jember	234	1,46	1,43	2,04	0,07	7,49

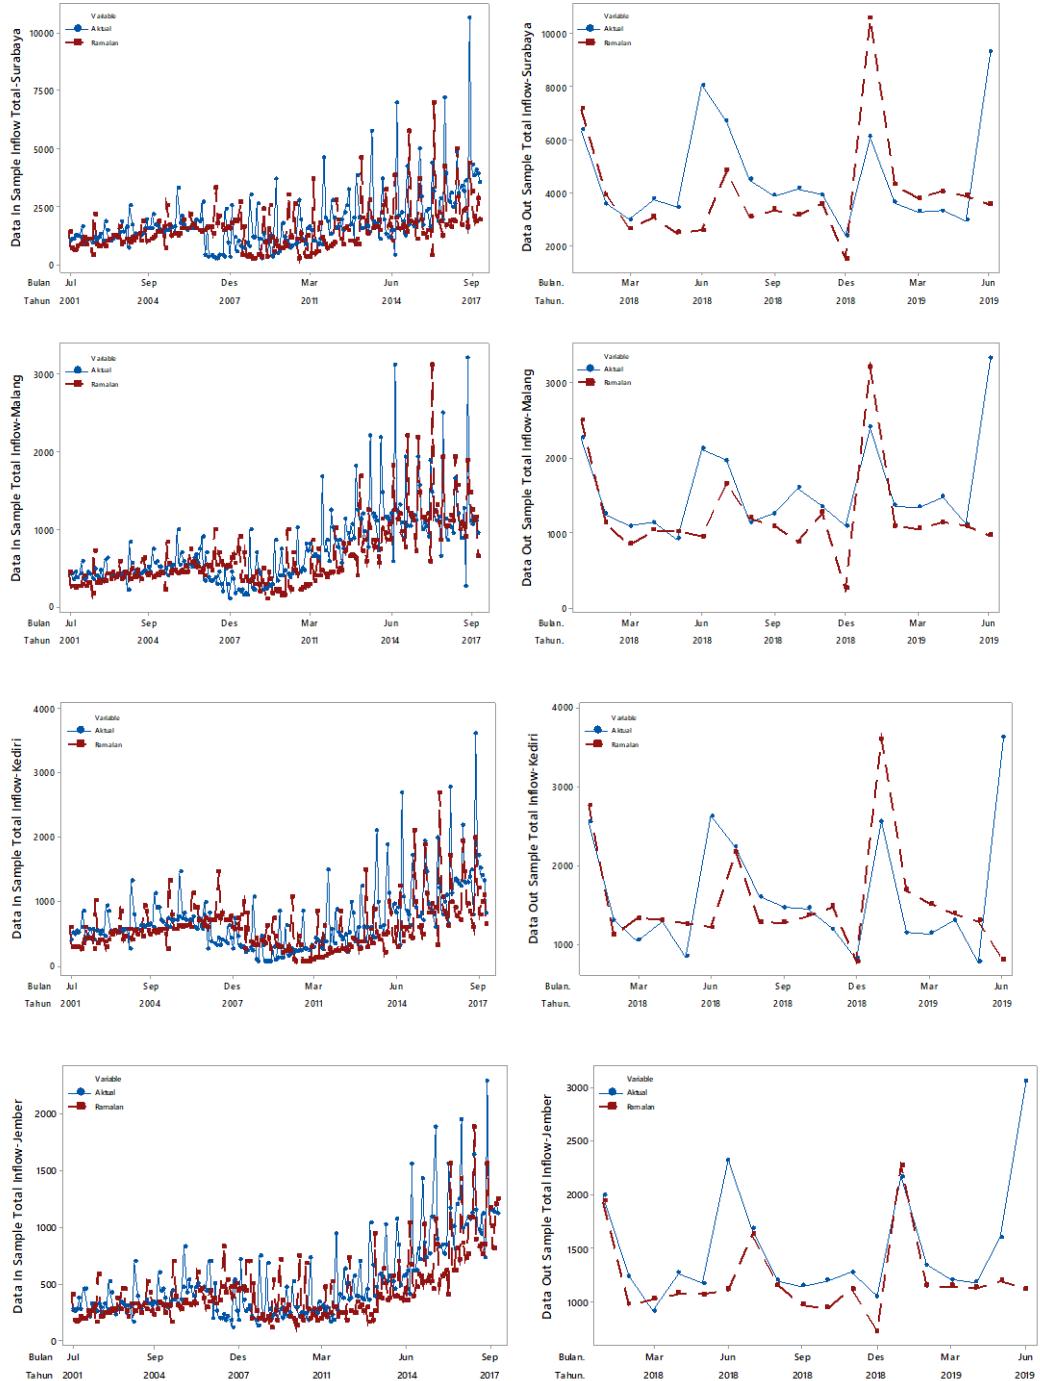
Tabel 4. 17 Deskriptif Statistik Data *Outflow*

	Wilayah KP BI	N	Mean	StDev	Variance	Minimum	Maximum
Total	Surabaya	234	1951,00	1647,00	2713007,00	272,00	11759,00
	Malang	234	512,80	513,90	264047,80	6,00	3753,20
	Kediri	234	777,90	767,40	588881,90	5,50	5746,10
	Jember	234	444,70	321,90	103638,30	21,80	2018,10
Rp. 100.000,-	Surabaya	234	962,50	902,20	813939,90	28,10	6113,60
	Malang	234	259,50	306,00	93657,80	0,40	2174,10
	Kediri	234	485,00	522,40	272919,30	0,10	3774,40
	Jember	234	221,80	225,40	50805,20	1,10	1358,40
Rp. 50.000,-	Surabaya	234	820,20	605,90	367168,10	72,70	4394,90
	Malang	234	214,90	189,20	35788,60	0,70	1406,20
	Kediri	234	250,20	227,50	51772,60	0,50	1591,00
	Jember	234	192,28	126,84	16088,82	10,30	712,62
Rp. 20.000,-	Surabaya	234	61,69	86,22	7433,43	0,65	596,96
	Malang	234	18,24	21,82	476,13	0,33	130,61
	Kediri	234	20,30	23,74	563,55	0,17	184,80
	Jember	234	16,38	17,17	294,82	0,25	146,35
Rp. 10.000,-	Surabaya	234	48,11	86,85	7542,88	0,71	684,50
	Malang	234	10,04	15,42	237,82	0,28	106,14
	Kediri	234	11,53	17,81	317,31	0,05	146,28
	Jember	234	7,62	7,97	63,45	0,77	55,57
Rp. 5.000,-	Surabaya	234	36,64	74,42	5538,03	0,43	546,20
	Malang	234	7,02	12,64	159,83	0,22	105,47
	Kediri	234	7,74	14,69	215,73	0,23	119,14
	Jember	234	4,38	5,55	30,84	0,66	41,12
Rp. 2.000,-	Surabaya	114	25,71	60,02	3602,92	0,24	269,40
	Malang	114	3,86	7,61	57,87	0,04	36,54
	Kediri	114	3,59	7,66	58,67	0,03	38,92
	Jember	114	2,34	2,71	7,32	0,40	14,17
Rp. 1.000,-	Surabaya	234	6,09	9,51	90,36	0,02	79,65
	Malang	234	0,84	1,37	1,88	0,01	8,02
	Kediri	234	1,02	1,64	2,67	0,01	10,45
	Jember	234	0,64	0,62	0,38	0,00	3,10

4.2.2. Pemodelan Naïve Musiman pada Data *Inflow* dan *Outflow*

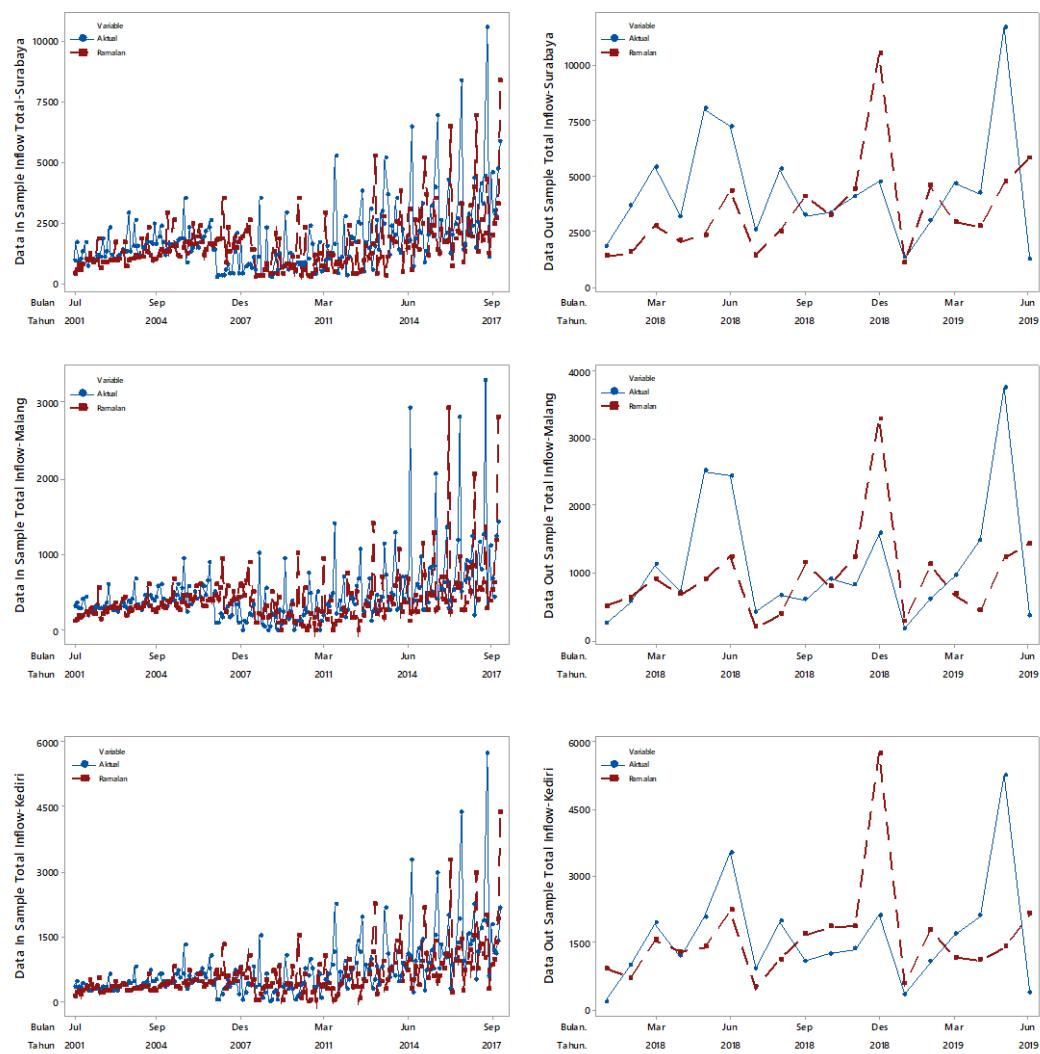
Model naïve musiman merupakan pemodelan *time series* sederhana yang menyatakan bahwa data ke- $t+1$ sama dengan data ke- t . Untuk memodelkan data *inflow* dan *outflow* yang mengandung komponen musiman bulanan (12 bulan) maka digunakan model naïve musiman dengan ketentuan data peramalan ke- $t+1$ akan

sama dengan data ke- $t+1$ -12. Berikut ini adalah *time series plot* perbandingan antara data aktual dan data hasil ramalan menggunakan model naïve musiman.

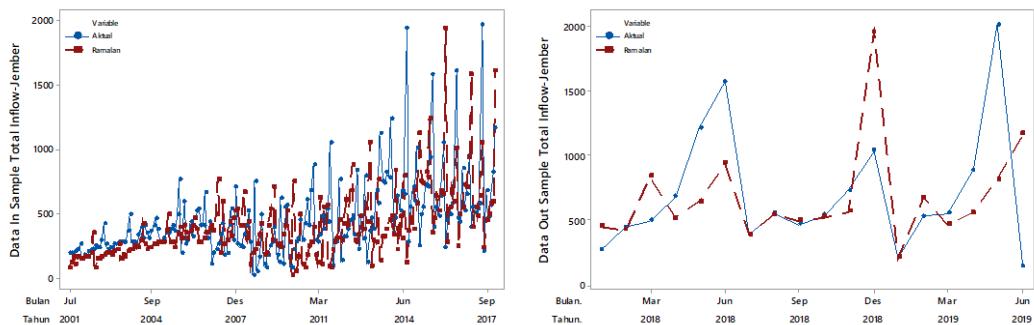


Gambar 4. 35 Time Series Plot Data Aktual Inflow Total dan Ramalan Menggunakan Model Naïve Musiman

Berdasarkan Gambar 4. 35 dan Gambar 4. 36 dapat diketahui bahwa data ramalan hasil pemodelan menggunakan metode naïve musiman pada data *in sample* dan *out sample* masing-masing KP BI di Jawa Timur belum mampu mengikuti pola data total *inflow* dan *outflow* yang mengandung komponen tren, musiman, dan variasi kalender. Hal tersebut dikarenakan hasil ramalan model naïve musiman hanya berdasarkan data 12 bulan terakhir. Sedangkan data *inflow* dan *outflow* tidak hanya memiliki pola musiman saja, tetapi juga dipengaruhi oleh efek variasi kalender.



Gambar 4. 36 Time Series Plot Data Aktual Outflow Total dan Ramalan Menggunakan Model Naïve Musiman



Gambar 4. 36 Time Series Plot Data Aktual Outflow Total dan Ramalan Menggunakan Model Naïve Musiman (lanjutan)

Selanjutnya dilakukan penghitungan nilai RMSE dan sMAPE untuk data *in sample* dan *out sample* data *inflow* dan *outflow* dalam total dan semua pecahan.

Tabel 4. 18 RMSE dari Model Naïve Musiman

`Pecahan	Data	Outflow				Inflow			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total	<i>In Sample</i>	1563,91	516,96	738,19	333,97	1329,41	416,59	478,88	285,10
	<i>Out Sample</i>	3110,70	961,09	1443,71	494,51	2306,85	720,49	825,41	568,21
Rp. 100.000,-	<i>In Sample</i>	747,40	289,68	458,97	210,78	781,04	246,23	295,14	174,48
	<i>Out Sample</i>	1569,94	491,96	899,33	256,92	1244,41	309,53	406,35	260,73
Rp. 50.000,-	<i>In Sample</i>	664,19	192,93	246,75	142,45	548,57	169,48	183,63	112,96
	<i>Out Sample</i>	1048,49	400,20	456,95	213,11	734,27	281,06	243,37	193,09
Rp. 20.000,-	<i>In Sample</i>	103,21	23,06	27,74	19,68	48,62	14,80	19,60	11,98
	<i>Out Sample</i>	233,19	55,43	68,19	17,01	91,90	20,65	37,90	17,01
Rp. 10.000,-	<i>In Sample</i>	100,79	18,83	20,78	9,12	37,59	10,78	17,00	8,45
	<i>Out Sample</i>	248,49	42,37	51,21	19,35	78,07	18,27	39,20	16,59
Rp. 5.000,-	<i>In Sample</i>	101,21	18,17	19,05	6,11	30,61	9,26	14,84	6,18
	<i>Out Sample</i>	155,80	26,07	35,63	14,34	55,18	15,13	33,88	14,17
Rp. 2.000,-	<i>In Sample</i>	91,49	11,55	11,21	3,28	21,24	4,35	8,41	3,83
	<i>Out Sample</i>	87,33	12,43	12,44	4,81	22,90	4,90	11,95	5,11
Rp. 1.000,-	<i>In Sample</i>	12,55	2,03	2,45	0,65	5,35	2,21	4,25	2,02
	<i>Out Sample</i>	0,57	0,51	0,30	0,18	0,68	0,13	0,42	0,19

Berdasarkan Tabel 4. 18 dan Tabel 4.19 yang menunjukkan nilai RMSE dan sMAPE hasil pemodelan menggunakan model naïve musiman pada data *inflow* dan *outflow* masih cukup tinggi baik pada data *in sample* maupun pada data *out sample*. Hasil ini juga sesuai dengan *time series plot* data ramalan yang belum mampu mengikuti pola data aktual *inflow* dan *outflow* di Provinsi Jawa Timur.

Tabel 4. 19 Nilai sMAPE dari Model Naïve Musiman

Pecahan	Data	Outflow				Inflow			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total semua pecahan	<i>In Sample</i>	56,93%	61,46%	61,47%	49,03%	51,16%	40,91%	54,17%	42,20%
	<i>Out Sample</i>	53,81%	58,13%	57,63%	37,13%	31,65%	31,90%	28,61%	21,27%
Rp. 100.000,-	<i>In Sample</i>	60,57%	72,38%	66,85%	76,50%	63,88%	53,44%	67,19%	53,52%
	<i>Out Sample</i>	50,91%	57,30%	56,48%	35,14%	32,66%	34,85%	35,91%	24,38%
Rp. 50.000,-	<i>In Sample</i>	60,07%	63,37%	68,99%	62,57%	52,43%	40,39%	55,38%	42,90%
	<i>Out Sample</i>	51,38%	56,51%	60,23%	58,55%	30,63%	35,02%	24,87%	19,57%
Rp. 20.000,-	<i>In Sample</i>	98,34%	92,18%	90,83%	71,28%	58,13%	50,93%	57,98%	47,13%
	<i>Out Sample</i>	166,60%	134,79%	156,99%	100,71%	75,96%	67,44%	88,89%	53,96%
Rp. 10.000,-	<i>In Sample</i>	97,41%	90,53%	96,22%	66,27%	64,59%	59,09%	72,63%	58,36%
	<i>Out Sample</i>	166,00%	113,50%	149,44%	101,34%	81,66%	73,72%	99,99%	71,00%
Rp. 5.000,-	<i>In Sample</i>	99,12%	92,97%	107,34%	63,75%	71,46%	66,53%	84,12%	63,66%
	<i>Out Sample</i>	167,80%	117,85%	137,89%	105,66%	89,61%	81,27%	113,51%	85,04%
Rp. 2.000,-	<i>In Sample</i>	158,60%	125,23%	139,56%	65,62%	97,45%	86,25%	113,28%	95,73%
	<i>Out Sample</i>	165,40%	116,88%	140,55%	93,61%	81,49%	76,58%	109,10%	85,70%
Rp. 1.000,-	<i>In Sample</i>	92,54%	94,90%	106,41%	86,04%	66,16%	83,02%	93,88%	83,42%
	<i>Out Sample</i>	101,42%	96,36%	87,09%	103,59%	66,11%	45,94%	62,87%	61,61%

4.2.3. Pemodelan *Time Series Regression* Data Inflow dan Outflow

Data *inflow* dan *outflow* dimodelkan menggunakan model *time series regression* (TSR). Model TSR merupakan pemodelan yang dilakukan secara univariat dengan menggunakan metode estimasi parameter *Ordinary Least Square* (OLS). Variabel prediktor atau variabel eksogen yang digunakan dalam model TSR ini adalah variabel *dummy* dari komponen tren, musiman, dan variasi kalender. Diperoleh hasil estimasi parameter model TSR untuk data *inflow* dan *outflow* total di seluruh KP BI Jawa Timur ditunjukkan pada Tabel 4.20.

Tabel 4. 20 Estimasi Parameter Model TSR Data *Inflow* Total KP BI Provinsi Jawa Timur

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Surabaya					
$\delta^{(1)}$	12,719	2,970	4,282	0,000	Signifikan
$D_1^{(1)}$	-1125,572	763,471	-1,474	0,142	Tidak Signifikan
$tD_1^{(1)}$	-3406,241	539,065	-6,319	0,000	Signifikan
$D_2^{(1)}$	0,287	7,474	0,038	0,969	Tidak Signifikan
$tD_2^{(1)}$	16,808	4,154	4,046	0,000	Signifikan
$\gamma_1^{(1)}$	1406,524	206,776	6,802	0,000	Signifikan
$\gamma_2^{(1)}$	646,963	204,645	3,161	0,002	Signifikan
$\gamma_3^{(1)}$	430,961	203,959	2,113	0,036	Signifikan
$\gamma_4^{(1)}$	427,061	204,611	2,087	0,038	Signifikan
$\gamma_5^{(1)}$	510,512	205,286	2,487	0,014	Signifikan
$\gamma_6^{(1)}$	295,756	206,610	1,431	0,154	Tidak Signifikan
$\gamma_7^{(1)}$	1022,676	210,155	4,866	0,000	Signifikan
$\gamma_8^{(1)}$	976,914	213,767	4,570	0,000	Signifikan
$\gamma_9^{(1)}$	542,387	214,438	2,529	0,012	Signifikan
$\gamma_{10}^{(1)}$	888,424	214,558	4,141	0,000	Signifikan
$\gamma_{11}^{(1)}$	395,020	215,484	1,833	0,068	Tidak Signifikan
$\gamma_{12}^{(1)}$	36,817	216,245	0,170	0,865	Tidak Signifikan
$\psi_1^{(1)}$	2230,908	338,106	6,598	0,000	Signifikan
$\psi_2^{(1)}$	1502,908	303,505	4,952	0,000	Signifikan
$\psi_3^{(1)}$	707,733	338,206	2,093	0,038	Signifikan
$\psi_4^{(1)}$	-773,201	276,696	-2,794	0,006	Signifikan
$\psi_1^{(1)}$	378,472	338,452	1,118	0,265	Tidak Signifikan
$\psi_2^{(1)}$	371,445	303,037	1,226	0,222	Tidak Signifikan
$\psi_3^{(1)}$	939,359	338,141	2,778	0,006	Signifikan
$\psi_4^{(1)}$	3016,267	277,108	10,885	< 2e-16	Signifikan

Tabel 4. 20 Estimasi Parameter Model TSR Data Inflow Total KP BI Provinsi Jawa Timur
(lanjutan)

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Malang					
$\delta^{(2)}$	4,173	1,035	4,033	0,000	Signifikan
$D_1^{(2)}$	-431,979	265,954	-1,624	0,106	Tidak Signifikan
$tD_1^{(2)}$	-186,573	187,782	-0,994	0,322	Tidak Signifikan
$D_2^{(2)}$	0,877	2,604	0,337	0,737	Tidak Signifikan
$tD_2^{(2)}$	1,849	1,447	1,278	0,203	Tidak Signifikan
$\gamma_1^{(2)}$	527,264	72,030	7,320	0,000	Signifikan
$\gamma_2^{(2)}$	291,710	71,288	4,092	0,000	Signifikan
$\gamma_3^{(2)}$	232,667	71,049	3,275	0,001	Signifikan
$\gamma_4^{(2)}$	190,291	71,276	2,670	0,008	Signifikan
$\gamma_5^{(2)}$	204,241	71,511	2,856	0,005	Signifikan
$\gamma_6^{(2)}$	102,596	71,972	1,425	0,156	Tidak Signifikan
$\gamma_7^{(2)}$	312,629	73,207	4,270	0,000	Signifikan
$\gamma_8^{(2)}$	316,453	74,465	4,250	0,000	Signifikan
$\gamma_9^{(2)}$	151,098	74,699	2,023	0,044	Signifikan
$\gamma_{10}^{(2)}$	235,803	74,741	3,155	0,002	Signifikan
$\gamma_{11}^{(2)}$	139,765	75,064	1,862	0,064	Tidak Signifikan
$\gamma_{12}^{(2)}$	35,245	75,329	0,468	0,640	Tidak Signifikan
$\psi_1^{(2)}$	706,652	117,779	6,000	0,000	Signifikan
$\psi_2^{(2)}$	443,941	105,725	4,199	0,000	Signifikan
$\psi_3^{(2)}$	260,169	117,813	2,208	0,028	Signifikan
$\psi_4^{(2)}$	-321,281	96,386	-3,333	0,001	Signifikan
$\psi_1^{(2)}$	-13,708	117,899	-0,116	0,908	Tidak Signifikan
$\psi_2^{(2)}$	115,324	105,563	1,092	0,276	Tidak Signifikan
$\psi_3^{(2)}$	196,467	117,791	1,668	0,097	Tidak Signifikan
$\psi_4^{(2)}$	959,041	96,530	9,935	< 2e-16	Signifikan

Tabel 4. 20 Estimasi Parameter Model TSR Data *Inflow* Total KP BI Provinsi Jawa Timur(lanjutan)

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Kediri					
$\delta^{(3)}$	5,251	0,998	5,262	0,000	Signifikan
$D_1^{(3)}$	375,820	256,458	1,465	0,144	Tidak Signifikan
$tD_1^{(3)}$	-1999,821	181,078	-11,044	< 2e-16	Signifikan
$D_2^{(3)}$	-9,018	2,511	-3,592	0,000	Signifikan
$tD_2^{(3)}$	9,668	1,395	6,929	0,000	Signifikan
$\gamma_1^{(3)}$	652,120	69,458	9,389	< 2e-16	Signifikan
$\gamma_2^{(3)}$	311,646	68,742	4,534	0,000	Signifikan
$\gamma_3^{(3)}$	241,499	68,512	3,525	0,001	Signifikan
$\gamma_4^{(3)}$	268,336	68,731	3,904	0,000	Signifikan
$\gamma_5^{(3)}$	286,641	68,958	4,157	0,000	Signifikan
$\gamma_6^{(3)}$	149,388	69,403	2,152	0,033	Signifikan
$\gamma_7^{(3)}$	391,161	70,593	5,541	0,000	Signifikan
$\gamma_8^{(3)}$	432,212	71,807	6,019	0,000	Signifikan
$\gamma_9^{(3)}$	290,777	72,032	4,037	0,000	Signifikan
$\gamma_{10}^{(3)}$	268,775	72,072	3,729	0,000	Signifikan
$\gamma_{11}^{(3)}$	184,321	72,384	2,546	0,012	Signifikan
$\gamma_{12}^{(3)}$	77,525	72,639	1,067	0,287	Tidak Signifikan
$\psi_1^{(3)}$	941,448	113,574	8,289	0,000	Signifikan
$\psi_2^{(3)}$	558,165	101,951	5,475	0,000	Signifikan
$\psi_3^{(3)}$	320,479	113,607	2,821	0,005	Signifikan
$\psi_4^{(3)}$	-210,528	92,945	-2,265	0,025	Signifikan
$\psi_1^{(3)}$	-26,388	113,690	-0,232	0,817	Tidak Signifikan
$\psi_2^{(3)}$	204,457	101,794	2,009	0,046	Signifikan
$\psi_3^{(3)}$	295,590	113,585	2,602	0,010	Signifikan
$\psi_4^{(3)}$	1076,119	93,084	11,561	< 2e-16	Signifikan

Tabel 4. 20 Estimasi Parameter Model TSR Data *Inflow* Total KP BI Provinsi Jawa Timur
(lanjutan)

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Jember					
$\delta^{(4)}$	3,343	0,593	5,634	0,000	Signifikan
$D_1^{(4)}$	-19,925	152,506	-0,131	0,896	Tidak Signifikan
$tD_1^{(4)}$	-1689,207	107,680	-15,687	< 2e-16	Signifikan
$D_2^{(4)}$	-2,302	1,493	-1,542	0,125	Tidak Signifikan
$tD_2^{(4)}$	9,715	0,830	11,708	< 2e-16	Signifikan
$\gamma_1^{(4)}$	425,958	41,304	10,313	< 2e-16	Signifikan
$\gamma_2^{(4)}$	211,798	40,878	5,181	0,000	Signifikan
$\gamma_3^{(4)}$	108,787	40,741	2,670	0,008	Signifikan
$\gamma_4^{(4)}$	117,528	40,872	2,876	0,004	Signifikan
$\gamma_5^{(4)}$	203,403	41,006	4,960	0,000	Signifikan
$\gamma_6^{(4)}$	138,956	41,271	3,367	0,001	Signifikan
$\gamma_7^{(4)}$	218,763	41,979	5,211	0,000	Signifikan
$\gamma_8^{(4)}$	146,688	42,701	3,435	0,001	Signifikan
$\gamma_9^{(4)}$	101,255	42,835	2,364	0,019	Signifikan
$\gamma_{10}^{(4)}$	166,110	42,859	3,876	0,000	Signifikan
$\gamma_{11}^{(4)}$	114,962	43,044	2,671	0,008	Signifikan
$\gamma_{12}^{(4)}$	70,204	43,196	1,625	0,106	Tidak Signifikan
$\psi_1^{(4)}$	529,721	67,538	7,843	0,000	Signifikan
$\psi_2^{(4)}$	302,875	60,626	4,996	0,000	Signifikan
$\psi_3^{(4)}$	372,300	67,558	5,511	0,000	Signifikan
$\psi_4^{(4)}$	-125,308	55,271	-2,267	0,025	Signifikan
$\psi_1^{(4)}$	-27,422	67,607	-0,406	0,685	Tidak Signifikan
$\psi_2^{(4)}$	31,082	60,533	0,513	0,608	Tidak Signifikan
$\psi_3^{(4)}$	26,336	67,545	0,390	0,697	Tidak Signifikan
$\psi_4^{(4)}$	560,921	55,353	10,133	< 2e-16	Signifikan

Tabel 4. 21 Hasil Estimasi Parameter Model TSR Data *Outflow* Total KP BI di Jawa Timur

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Surabaya					
$\delta^{(1)}$	13,168	3,312	3,976	0,000	Signifikan
$D_1^{(1)}$	-408,625	852,326	-0,479	0,632	Tidak Signifikan
$tD_1^{(1)}$	-3673,61	602,744	-6,095	0,000	Signifikan
$D_2^{(1)}$	-8,317	8,337	-0,998	0,320	Tidak Signifikan
$tD_2^{(1)}$	17,451	4,644	3,758	0,000	Signifikan
$\gamma_1^{(1)}$	-71,332	227,813	-0,313	0,755	Tidak Signifikan
$\gamma_2^{(1)}$	277,663	227,073	1,223	0,223	Tidak Signifikan
$\gamma_3^{(1)}$	682,792	227,773	2,998	0,003	Signifikan
$\gamma_4^{(1)}$	674,453	228,5	2,952	0,004	Signifikan
$\gamma_5^{(1)}$	692,452	229,943	3,011	0,003	Signifikan
$\gamma_6^{(1)}$	1216,343	233,892	5,2	0,000	Signifikan
$\gamma_7^{(1)}$	810,654	237,053	3,42	0,001	Signifikan
$\gamma_8^{(1)}$	832,21	237,631	3,502	0,001	Signifikan
$\gamma_9^{(1)}$	380,883	237,708	1,602	0,111	Tidak Signifikan
$\gamma_{10}^{(1)}$	262,781	238,859	1,1	0,273	Tidak Signifikan
$\gamma_{11}^{(1)}$	306,357	240,674	1,273	0,205	Tidak Signifikan
$\gamma_{12}^{(1)}$	1308,042	238,089	5,494	0,000	Signifikan
$\psi_1^{(1)}$	2916,852	377,787	7,721	0,000	Signifikan
$\psi_2^{(1)}$	1543,4	378,857	4,074	0,000	Signifikan
$\psi_3^{(1)}$	497,333	377,845	1,316	0,190	Tidak Signifikan
$\psi_4^{(1)}$	382,953	309,13	1,239	0,217	Tidak Signifikan
$\psi_1^{(1)}$	-704,285	377,722	-1,865	0,064	Tidak Signifikan
$\psi_2^{(1)}$	1209,627	338,512	3,573	0,000	Signifikan
$\psi_3^{(1)}$	2104,081	377,6	5,572	0,000	Signifikan
$\psi_4^{(1)}$	2962,504	309,456	9,573	0,000	Signifikan

Tabel 4. 21 Hasil Estimasi Parameter Model TSR Data *Outflow* Total KP BI di Jawa Timur
(lanjutan)

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Malang					
$\delta^{(2)}$	3,496	1,080	3,236	0,001	Signifikan
$D_1^{(2)}$	-16,917	277,950	-0,061	0,952	Tidak Signifikan
$tD_1^{(2)}$	-1111,402	196,560	-5,654	0,000	Signifikan
$D_2^{(2)}$	-2,969	2,719	-1,092	0,276	Tidak Signifikan
$tD_2^{(2)}$	5,483	1,514	3,621	0,000	Signifikan
$\gamma_1^{(2)}$	-57,669	74,292	-0,776	0,439	Tidak Signifikan
$\gamma_2^{(2)}$	12,525	74,050	0,169	0,866	Tidak Signifikan
$\gamma_3^{(2)}$	149,173	74,279	2,008	0,046	Signifikan
$\gamma_4^{(2)}$	137,356	74,516	1,843	0,067	Tidak Signifikan
$\gamma_5^{(2)}$	184,533	74,986	2,461	0,015	Signifikan
$\gamma_6^{(2)}$	338,200	76,274	4,434	0,000	Signifikan
$\gamma_7^{(2)}$	259,933	77,305	3,362	0,001	Signifikan
$\gamma_8^{(2)}$	131,054	77,493	1,691	0,092	Tidak Signifikan
$\gamma_9^{(2)}$	119,172	77,518	1,537	0,126	Tidak Signifikan
$\gamma_{10}^{(2)}$	30,415	77,894	0,390	0,697	Tidak Signifikan
$\gamma_{11}^{(2)}$	53,329	78,486	0,679	0,498	Tidak Signifikan
$\gamma_{12}^{(2)}$	340,791	77,643	4,389	0,000	Signifikan
$\psi_1^{(2)}$	946,521	123,199	7,683	0,000	Signifikan
$\psi_2^{(2)}$	444,208	123,548	3,595	0,000	Signifikan
$\psi_3^{(2)}$	117,920	123,218	0,957	0,340	Tidak Signifikan
$\psi_4^{(2)}$	96,170	100,810	0,954	0,341	Tidak Signifikan
$\psi_1^{(2)}$	-152,645	123,178	-1,239	0,217	Tidak Signifikan
$\psi_2^{(2)}$	267,982	110,391	2,428	0,016	Signifikan
$\psi_3^{(2)}$	670,282	123,138	5,443	0,000	Signifikan
$\psi_4^{(2)}$	1122,728	100,916	11,125	< 2e-16	Signifikan

Tabel 4. 21 Hasil Estimasi Parameter Model TSR Data *Outflow Total KP BI di Jawa Timur*
(lanjutan)

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Kediri					
$\delta^{(3)}$	4,367	1,601	2,728	0,007	Signifikan
$D_1^{(3)}$	-42,698	411,860	-0,104	0,918	Tidak Signifikan
$tD_1^{(3)}$	-1626,043	291,257	-5,583	0,000	Signifikan
$D_2^{(3)}$	-2,208	4,029	-0,548	0,584	Tidak Signifikan
$tD_2^{(3)}$	10,128	2,244	4,513	0,000	Signifikan
$\gamma_1^{(3)}$	-201,550	110,084	-1,831	0,069	Tidak Signifikan
$\gamma_2^{(3)}$	-26,693	109,726	-0,243	0,808	Tidak Signifikan
$\gamma_3^{(3)}$	117,032	110,065	1,063	0,289	Tidak Signifikan
$\gamma_4^{(3)}$	144,258	110,416	1,307	0,193	Tidak Signifikan
$\gamma_5^{(3)}$	193,257	111,113	1,739	0,084	Tidak Signifikan
$\gamma_6^{(3)}$	592,309	113,021	5,241	0,000	Signifikan
$\gamma_7^{(3)}$	305,555	114,549	2,667	0,008	Signifikan
$\gamma_8^{(3)}$	115,970	114,828	1,010	0,314	Tidak Signifikan
$\gamma_9^{(3)}$	80,751	114,865	0,703	0,483	Tidak Signifikan
$\gamma_{10}^{(3)}$	7,616	115,421	0,066	0,947	Tidak Signifikan
$\gamma_{11}^{(3)}$	-63,433	116,298	-0,545	0,586	Tidak Signifikan
$\gamma_{12}^{(3)}$	293,062	115,049	2,547	0,012	Signifikan
$\psi_1^{(3)}$	1344,613	182,554	7,366	0,000	Signifikan
$\psi_2^{(3)}$	653,575	183,071	3,570	0,000	Signifikan
$\psi_3^{(3)}$	144,059	182,582	0,789	0,431	Tidak Signifikan
$\psi_4^{(3)}$	209,261	149,378	1,401	0,163	Tidak Signifikan
$\psi_1^{(3)}$	-217,494	182,522	-1,192	0,235	Tidak Signifikan
$\psi_2^{(3)}$	386,482	163,575	2,363	0,019	Signifikan
$\psi_3^{(3)}$	905,867	182,464	4,965	0,000	Signifikan
$\psi_4^{(3)}$	1522,818	149,535	10,184	< 2e-16	Signifikan

Tabel 4. 21 Hasil Estimasi Parameter Model TSR *Data Outflow Total KP BI di Jawa Timur*
 (lanjutan)

Parameter	Estimasi	Standard Error	T _{hitung}	P _{value}	Keterangan
KP BI Jember					
$\delta^{(4)}$	3,734	0,758	4,925	0,000	Signifikan
$D_1^{(4)}$	-20,465	195,090	-0,105	0,917	Tidak Signifikan
$tD_1^{(4)}$	-250,652	137,963	-1,817	0,071	Tidak Signifikan
$D_2^{(4)}$	-1,682	1,908	-0,881	0,379	Tidak Signifikan
$tD_2^{(4)}$	0,448	1,063	0,421	0,674	Tidak Signifikan
$\gamma_1^{(4)}$	-82,452	52,144	-1,581	0,115	Tidak Signifikan
$\gamma_2^{(4)}$	-0,243	51,975	-0,005	0,996	Tidak Signifikan
$\gamma_3^{(4)}$	49,166	52,135	0,943	0,347	Tidak Signifikan
$\gamma_4^{(4)}$	75,305	52,302	1,440	0,152	Tidak Signifikan
$\gamma_5^{(4)}$	117,398	52,632	2,231	0,027	Signifikan
$\gamma_6^{(4)}$	241,960	53,536	4,520	0,000	Signifikan
$\gamma_7^{(4)}$	158,023	54,259	2,912	0,004	Signifikan
$\gamma_8^{(4)}$	17,246	54,392	0,317	0,752	Tidak Signifikan
$\gamma_9^{(4)}$	65,695	54,409	1,207	0,229	Tidak Signifikan
$\gamma_{10}^{(4)}$	53,118	54,673	0,972	0,333	Tidak Signifikan
$\gamma_{11}^{(4)}$	75,962	55,088	1,379	0,170	Tidak Signifikan
$\gamma_{12}^{(4)}$	318,211	54,497	5,839	0,000	Signifikan
$\psi_1^{(4)}$	485,229	86,472	5,611	0,000	Signifikan
$\psi_2^{(4)}$	245,908	86,717	2,836	0,005	Signifikan
$\psi_3^{(4)}$	-23,616	86,485	-0,273	0,785	Tidak Signifikan
$\psi_4^{(4)}$	-5,520	70,757	-0,078	0,938	Tidak Signifikan
$\psi_1^{(4)}$	-205,931	86,457	-2,382	0,018	Signifikan
$\psi_2^{(4)}$	244,799	77,482	3,159	0,002	Signifikan
$\psi_3^{(4)}$	378,354	86,429	4,378	0,000	Signifikan
$\psi_4^{(4)}$	602,503	70,832	8,506	0,000	Signifikan

Berdasarkan Tabel 4.20 dan Tabel 4.21 yang menunjukkan hasil estimasi parameter model TSR pada data *inflow* dan *outflow* total di masing-masing KP BI Jawa Timur. Dari keseluruhan parameter variabel eksogen yang digunakan terdapat beberapa parameter yang tidak signifikan, karena memiliki nilai P_{value} lebih dari

taraf signifikan $\alpha = 0,05$. Namun jika dilihat variabel eksogen secara keseluruhan yaitu komponen tren, perubahan kebijakan, musiman, dan variasi kalender terdapat parameter yang signifikan pada masing-masing komponen tersebut. Nilai estimasi parameter komponen tren ($\sigma^{(i)}$) pada masing-masing KP BI telah signifikan dan memiliki nilai yang positif, artinya data *inflow* dan *outflow* total pada masing-masing KP BI setiap bulan mengalami kenaikan yang signifikan, kenaikan tertinggi dimiliki oleh KP BI Surabaya baik pada data *inflow* maupun *outflow*. Komponen perubahan kebijakan tidak memberikan pengaruh yang signifikan terhadap data *inflow* di KP BI Malang dan terhadap data *outflow* di KP BI Jember, namun signifikan pada KP BI lainnya. Komponen musiman diketahui telah signifikan pada beberapa parameter musiman di masing-masing KP BI Jawa Timur. Sehingga, komponen musiman berpengaruh signifikan terhadap *inflow* dan *outflow* total masing-masing KP BI di Jawa Timur. Hasil estimasi parameter untuk komponen variasi kalender juga menunjukkan adanya parameter yang signifikan, sehingga secara signifikan variasi kalender mempengaruhi nilai *inflow* dan *outflow* pada masing-masing KP BI Jawa Timur. Nilai estimasi parameter komponen variasi kalender menunjukkan nilai yang lebih besar dibandingkan nilai estimasi parameter pada komponen musiman. Sehingga komponen variasi kalender cenderung lebih dominan dalam mempengaruhi perkembangan nilai *inflow* dan *outflow* baik dalam total maupun dalam masing-masing pecahan uang. Berdasarkan nilai estimasi parameter yang didapatkan maka persamaan model TSR untuk data *inflow* total dapat dituliskan sebagai berikut.

$$Y_t^{(1)} = 12,72t - 1125,57D_{1,t} - 3406,24D_{2,t} + 0,29tD_{1,t} + 16,81tD_{2,t} + 1406,52S_{1,t} + 646,96S_{2,t} + 430,96S_{3,t} + 427,06S_{4,t} + 510,51S_{5,t} + 295,76S_{6,t} + 1022,68S_{7,t} + 976,91S_{8,t} + 542,39S_{9,t} + 888,42S_{10,t} + 395,02S_{11,t} + 36,82S_{12,t} + 2230,91V_{1,t} + 1502,91V_{2,t} + 707,73V_{3,t} - 773,20V_{4,t} + 378,47V_{1,t-1} + 371,44V_{2,t-1} + 939,36V_{3,t-1} + 3016,27V_{4,t-1} + \varepsilon_t^{(1)}$$

$$Y_t^{(2)} = 4,17t - 431,98D_{1,t} - 186,57D_{2,t} + 0,88tD_{1,t} + 1,85tD_{2,t} + 527,26S_{1,t} + 291,71S_{2,t} + 232,67S_{3,t} + 190,29S_{4,t} + 204,24S_{5,t} + 102,60S_{6,t} + 312,63S_{7,t} + 316,45S_{8,t} + 151,10S_{9,t} + 235,80S_{10,t} + 139,76S_{11,t} + 35,25S_{12,t} + 706,65V_{1,t} + 443,94V_{2,t} + 260,17V_{3,t} - 321,28V_{4,t} - 13,71V_{1,t-1} + 115,32V_{2,t-1} + 196,47V_{3,t-1} + 959,04V_{4,t-1} + \varepsilon_t^{(2)}$$

$$Y_t^{(3)} = 5,25t + 375,82D_{1,t} - 1999,82D_{2,t} - 9,02tD_{1,t} + 9,67tD_{2,t} + 652,12S_{1,t} + 311,65S_{2,t} + 241,50S_{3,t} + 268,64S_{4,t} + 286,64S_{5,t} + 149,39S_{6,t} + 391,16S_{7,t} + 432,21S_{8,t} + 290,78S_{9,t} + 268,77S_{10,t} +$$

$$184,32S_{11,t} + 77,53S_{12,t} + 941,45V_{1,t} + 558,17V_{2,t} + 320,48V_{3,t} - 210,53V_{4,t} - 26,39V_{1,t-1} + 204,46V_{2,t-1} + 295,59V_{3,t-1} + 1076,12V_{4,t-1} + \varepsilon_t^{(3)}$$

$$Y_t^{(4)} = 3,34t - 19,92D_{1,t} - 1689,21D_{2,t} - 2,30tD_{1,t} + 9,71tD_{2,t} + 425,96S_{1,t} + 211,80S_{2,t} + 108,79S_{3,t} + 117,53S_{4,t} + 203,40S_{5,t} + 138,96S_{6,t} + 218,76S_{7,t} + 146,69S_{8,t} + 101,25S_{9,t} + 166,11S_{10,t} +$$

$$114,32S_{11,t} + 70,20S_{12,t} + 529,72V_{1,t} + 302,88V_{2,t} + 372,30V_{3,t} - 125,31V_{4,t} - 27,42V_{1,t-1} + 31,08V_{2,t-1} + 26,34V_{3,t-1} + 560,92V_{4,t-1} + \varepsilon_t^{(4)}.$$

Persamaan model-model diatas jika dituliskan dalam bentuk matriks adalah sebagai berikut.

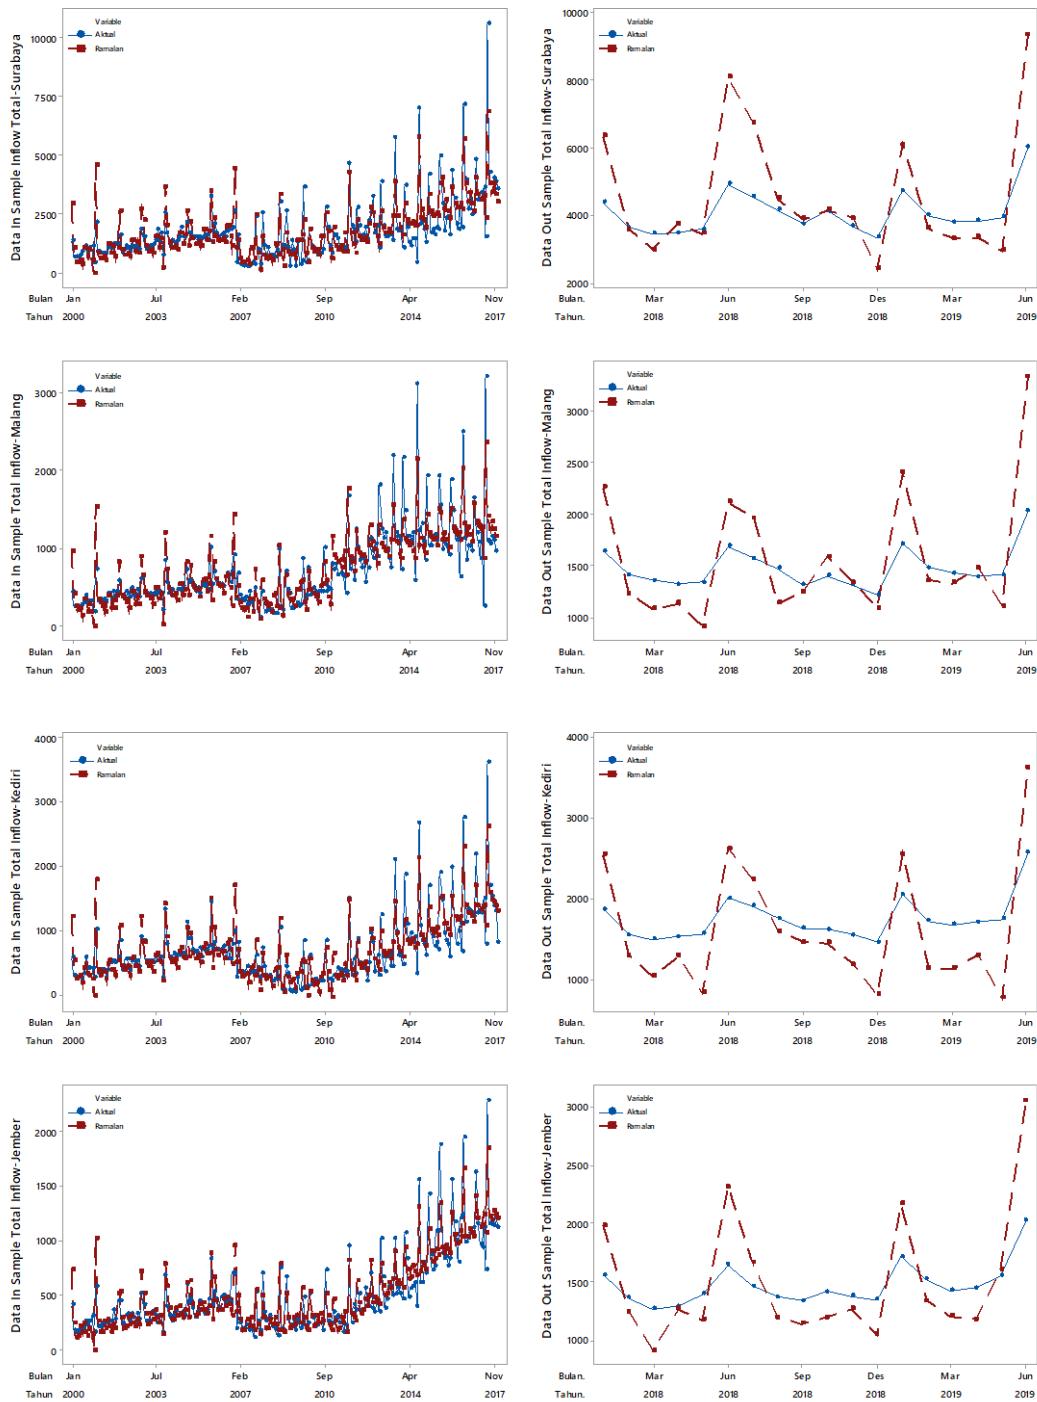
$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} = \begin{bmatrix} 12,72 & 0 & 0 & 0 \\ 0 & 4,17 & 0 & 0 \\ 0 & 0 & 5,25 & 0 \\ 0 & 0 & 0 & 3,34 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} -1125,57 & 0 & 0 & 0 \\ 0 & -431,98 & 0 & 0 \\ 0 & 0 & 375,82 & 0 \\ 0 & 0 & 0 & -19,92 \end{bmatrix} \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 1406,52 & 0 & 0 & 0 \\ 0 & 527,26 & 0 & 0 \\ 0 & 0 & 652,12 & 0 \\ 0 & 0 & 0 & 425,96 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 3016,27 & 0 & 0 & 0 \\ 0 & 959,04 & 0 & 0 \\ 0 & 0 & 1076,12 & 0 \\ 0 & 0 & 0 & 560,92 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix}$$

Selanjutnya digambarkan *time series plot* data *inflow* total dan hasil ramalan data *inflow* menggunakan model TSR pada data *in sample* dan *out sample*.

Berdasarkan Gambar 4. 37 dapat diketahui bahwa pada bagian data *in sample* terlihat bahwa hasil ramalan menggunakan model TSR sudah cukup mampu mengikuti pola komponen tren, musiman, dan variasi kalender pada data *inflow* total di masing-masing KP BI Jawa Timur. Namun pada bagian data *out sample* terlihat bahwa hasil ramalan belum mampu mengikuti pola data *inflow* total. Sehingga, model TSR belum cukup baik jika digunakan untuk meramalakan data *inflow* total di KP BI Jawa Timur.



Gambar 4. 37 Time Series Plot Data Aktual dan Ramalan *Inflow* Total dari Model TSR

Selanjutnya dilakukan perhitungan RMSE dan sMAPE pada data *inflow* dan *outflow* baik total maupun dalam pecahan. Hasil perhitungan nilai RMSE dan sMAPE dapat dilihat pada Tabel 4.22 dan Tabel 4. 23.

Tabel 4. 22 Nilai RMSE Hasil Pemodelan Data *Inflow* dan *Outflow* Menggunakan Model TSR

Pecahan	Data	<i>Inflow</i>				<i>Outflow</i>			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total semua pecahan	<i>In Sample</i>	613,23	213,62	205,99	122,49	685,11	223,42	331,06	156,81
	<i>Out Sample</i>	1387,12	437,64	553,45	372,90	1715,60	644,39	853,48	319,91
Rp. 100.000,-	<i>In Sample</i>	414,14	142,47	150,74	91,06	361,08	135,67	218,39	109,10
	<i>Out Sample</i>	913,69	237,16	409,42	250,54	1082,35	387,10	642,05	195,69
Rp. 50.000,-	<i>In Sample</i>	234,54	80,61	72,56	45,44	300,33	85,41	116,11	67,73
	<i>Out Sample</i>	408,62	150,13	162,31	110,67	489,18	271,92	257,46	124,07
Rp. 20.000,-	<i>In Sample</i>	23,69	6,71	8,48	5,87	44,31	8,75	11,58	10,37
	<i>Out Sample</i>	48,69	9,33	23,54	10,61	113,38	31,89	35,82	7,22
Rp. 10.000,-	<i>In Sample</i>	19,81	5,32	8,85	4,49	44,66	7,06	7,71	4,17
	<i>Out Sample</i>	43,17	8,40	21,56	8,48	132,81	22,17	30,49	8,75
Rp. 5.000,-	<i>In Sample</i>	16,07	5,15	8,04	3,54	42,39	6,59	6,43	2,55
	<i>Out Sample</i>	33,79	7,54	18,44	7,11	73,08	13,19	18,74	6,98
Rp. 2.000,-	<i>In Sample</i>	6,91	1,70	3,31	1,72	11,82	2,06	1,38	0,54
	<i>Out Sample</i>	13,49	2,83	6,69	2,21	29,99	6,21	4,01	1,06
Rp. 1.000,-	<i>In Sample</i>	2,34	0,89	1,63	0,73	5,59	0,73	0,87	0,30
	<i>Out Sample</i>	1,93	0,75	1,59	0,69	4,93	1,12	1,22	0,17

Tabel 4. 23 Nilai sMAPE Hasil Pemodelan Data *Inflow* dan *Outflow* Menggunakan Model TSR

Pecahan	Data	<i>Inflow</i>				<i>Outflow</i>			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total semua pecahan	<i>In Sample</i>	32,52%	39,03%	41,96%	32,18%	27,65%	23,51%	26,41%	19,36%
	<i>Out Sample</i>	30,64%	49,74%	45,95%	40,18%	18,74%	19,10%	30,67%	18,21%
Rp. 100.000,-	<i>In Sample</i>	39,54%	59,60%	51,32%	68,00%	43,93%	43,18%	43,48%	36,83%
	<i>Out Sample</i>	36,09%	50,53%	50,07%	39,12%	24,57%	23,30%	38,58%	23,22%
Rp. 50.000,-	<i>In Sample</i>	32,57%	32,98%	42,81%	33,57%	25,92%	20,17%	27,13%	18,20%
	<i>Out Sample</i>	26,47%	44,76%	45,57%	44,73%	17,09%	15,36%	27,05%	17,03%
Rp. 20.000,-	<i>In Sample</i>	65,88%	59,16%	45,86%	44,17%	29,53%	24,15%	27,00%	21,71%
	<i>Out Sample</i>	83,26%	103,38%	80,70%	51,52%	45,18%	35,69%	56,21%	30,60%
Rp. 10.000,-	<i>In Sample</i>	77,94%	67,17%	60,30%	46,72%	36,47%	26,15%	36,46%	24,89%
	<i>Out Sample</i>	91,14%	111,12%	86,82%	63,28%	52,52%	41,30%	62,04%	43,53%
Rp. 5.000,-	<i>In Sample</i>	95,12%	86,90%	85,77%	49,12%	47,70%	35,73%	50,35%	31,93%
	<i>Out Sample</i>	84,95%	102,91%	85,85%	65,84%	65,18%	61,21%	80,18%	60,84%
Rp. 2.000,-	<i>In Sample</i>	93,76%	75,78%	38,75%	34,90%	41,60%	42,24%	63,06%	53,97%
	<i>Out Sample</i>	62,39%	99,46%	63,99%	34,95%	64,52%	44,52%	68,49%	37,01%
Rp. 1.000,-	<i>In Sample</i>	100,32%	90,32%	92,25%	64,05%	47,22%	59,29%	70,42%	60,56%
	<i>Out Sample</i>	189,33%	173,80%	189,99%	144,58%	149,02%	146,12%	162,86%	147,96%

Tabel 4. 22 dan Tabel 4. 23 menunjukkan nilai kebaikan model TSR dalam memodelkan data *inflow* dan *outflow* total di masing-masing KP BI Jawa Timur. Berdasarkan kedua Tabel tersebut dapat diketahui bahwa nilai RMSE dan sMAPE masih cukup besar terutama pada data *inflow* dan *outflow* uang pecahan kecil yaitu pecahan Rp. 10.000, Rp. 5.000, Rp. 2.000,, dan Rp. 1.000. Pada data *inflow* dan *outflow* pecahan Rp. 1.000 bahkan memiliki nilai sMAPE lebih dari 100%. Hal ini dikarenakan model TSR belum mampu meramalkan dengan cukup baik sehingga didapatkan residual yang cukup besar.

4.2.4. Pemodelan ARIMAX Pada Data *Inflow* dan *Outflow*

Pemodelan ARIMAX dilakukan dengan tahap awal melakukan pemodelan TSR, jika residual dari model TSR belum memenuhi asumsi *white noise* maka residual tersebut dimodelkan lagi menggunakan model ARIMA. Sehingga langkah awal yang harus dilakukan sebelum melakukan pemodelan ARIMA adalah menguji asumsi *white noise* menggunakan uji *Ljung Box* pada residual model TSR dari masing-masing data *inflow* dan *outflow* baik total maupun pecahan. Berikut ini adalah hasil pengujian *Ljung Box* data *inflow* dan *outflow* total.

Tabel 4. 24 Hasil Uji *Ljung Box* Data Residual TSR *Inflow* dan *Outflow* di KP BI Jawa Timur

KP BI	Lag	<i>Outflow Total</i>		<i>Inflow Total</i>		
		χ^2	Pvalue	Lag	χ^2	Pvalue
Surabaya	6	16,945	0,009	6	5,731	0,454
	12	55,213	0,000	12	37,150	0,000
	18	73,948	0,000	18	40,892	0,002
	24	111,318	0,000	24	48,061	0,002
	30	117,076	0,000	30	62,464	0,000
Malang	6	23,398	0,001	6	10,348	0,111
	12	70,173	0,000	12	52,599	0,000
	18	85,335	0,000	18	56,185	0,000
	24	115,265	0,000	24	62,347	0,000
	30	121,833	0,000	30	73,763	0,000
Kediri	6	23,793	0,001	6	8,983	0,175
	12	66,783	0,000	12	36,918	0,000
	18	79,729	0,000	18	52,166	0,000
	24	105,868	0,000	24	61,305	0,000
	30	113,555	0,000	30	67,851	0,000
Jember	6	7,167	0,306	6	18,585	0,005
	12	44,117	0,000	12	47,880	0,000
	18	58,912	0,000	18	61,983	0,000
	24	87,337	0,000	24	71,243	0,000
	30	100,758	0,000	30	80,553	0,000

Berdasarkan Tabel 4. 24 dapat diketahui bahwa residual model TSR data *inflow* dan *outflow* total di masing-masing wilayah KP BI Jawa Timur belum memenuhi asumsi *white noise* karena memiliki nilai *Pvalue* kurang dari taraf signifikansi $\alpha = 0.05$. Selanjutnya dilakukan pemodelan pada residual model TSR menggunakan model ARIMA dengan prosedur Box Jenkins. Penentuan orde pada model ARIMA diidentifikasi menggunakan plot ACF dan PACF masing-masing data yang ditunjukkan pada Lampiran 33. Sehingga didapatkan model ARIMAX untuk total maupun pecahan data *inflow* dan *outflow* yang dapat dilihat pada Tabel 4.25 dan Tabel 4. 26.

Tabel 4. 25 Model ARIMAX Data *Inflow* KP BI Jawa Timur

Pecahan	Wilayah	Model	White Noise	Distribusi Normal
Total	Surabaya	ARIMA([12,15],0,0)	Ya	Tidak
	Malang	ARIMA([12],0,[12])	Ya	Ya
	Kediri	ARIMA([6,12,14,15],0,0)	Ya	Tidak
	Jember	ARIMA([6,12],0,0)	Ya	Ya
Rp. 100.000,-	Surabaya	ARIMA([6,12],0,0)	Ya	Ya
	Malang	ARIMA([12,24],0,0)	Ya	Ya
	Kediri	ARIMA([6,12],0,0)	Ya	Ya
	Jember	ARIMA([6,12],0,0)	Ya	Ya
Rp. 50.000,-	Surabaya	ARIMA([3,12,15],0,0)	Ya	Ya
	Malang	ARIMA([2,12,13,43],0,0)	Ya	Ya
	Kediri	ARIMA([12],0,0)	Tidak	Ya
	Jember	ARIMA([12,29,37],0,0)	Tidak	Ya
Rp. 20.000,-	Surabaya	ARIMA([1,12,36],0,0)	Ya	Tidak
	Malang	ARIMA([9,11,12,20],0,0)	Ya	Tidak
	Kediri	ARIMA([1,11,12,13,36],0,0)	Ya	Ya
	Jember	ARIMA([11,12,20,22],0,0)	Ya	Tidak
Rp. 10.000,-	Surabaya	ARIMA([11,23],0,0)	Tidak	Tidak
	Malang	ARIMA([1,11,12,13,23,34],0,0)	Ya	Tidak
	Kediri	ARIMA([1,11,12,36],0,1)	Tidak	Tidak
	Jember	ARIMA([11,12],0,2)	Ya	Tidak
Rp. 5.000,-	Surabaya	ARIMA([1,11,12,23],0,0)	Ya	Tidak
	Malang	ARIMA([11,12,22],0,0)	Tidak	Tidak
	Kediri	ARIMA([12,23,36],0,0)	Tidak	Tidak
	Jember	ARIMA([1,11,22],0,0)	Ya	Tidak
Rp. 2.000,-	Surabaya	ARIMA([1,4],0,0)	Ya	Ya
	Malang	*	Ya	Ya
	Kediri	ARIMA([1,2,10],0,0)	Ya	Ya
	Jember	ARIMA([1,10],0,0)	Ya	Ya
Rp. 1.000,-	Surabaya	ARIMA([1,11,23,25],0,0)	Ya	Ya
	Malang	ARIMA([1,2,11,12,13,14],0,0)	Ya	Tidak
	Kediri	ARIMA([1,11,12,13,16,23,34],0,0)	Ya	Ya
	Jember	ARIMA([1,11,12,13],0,0)	Tidak	Ya

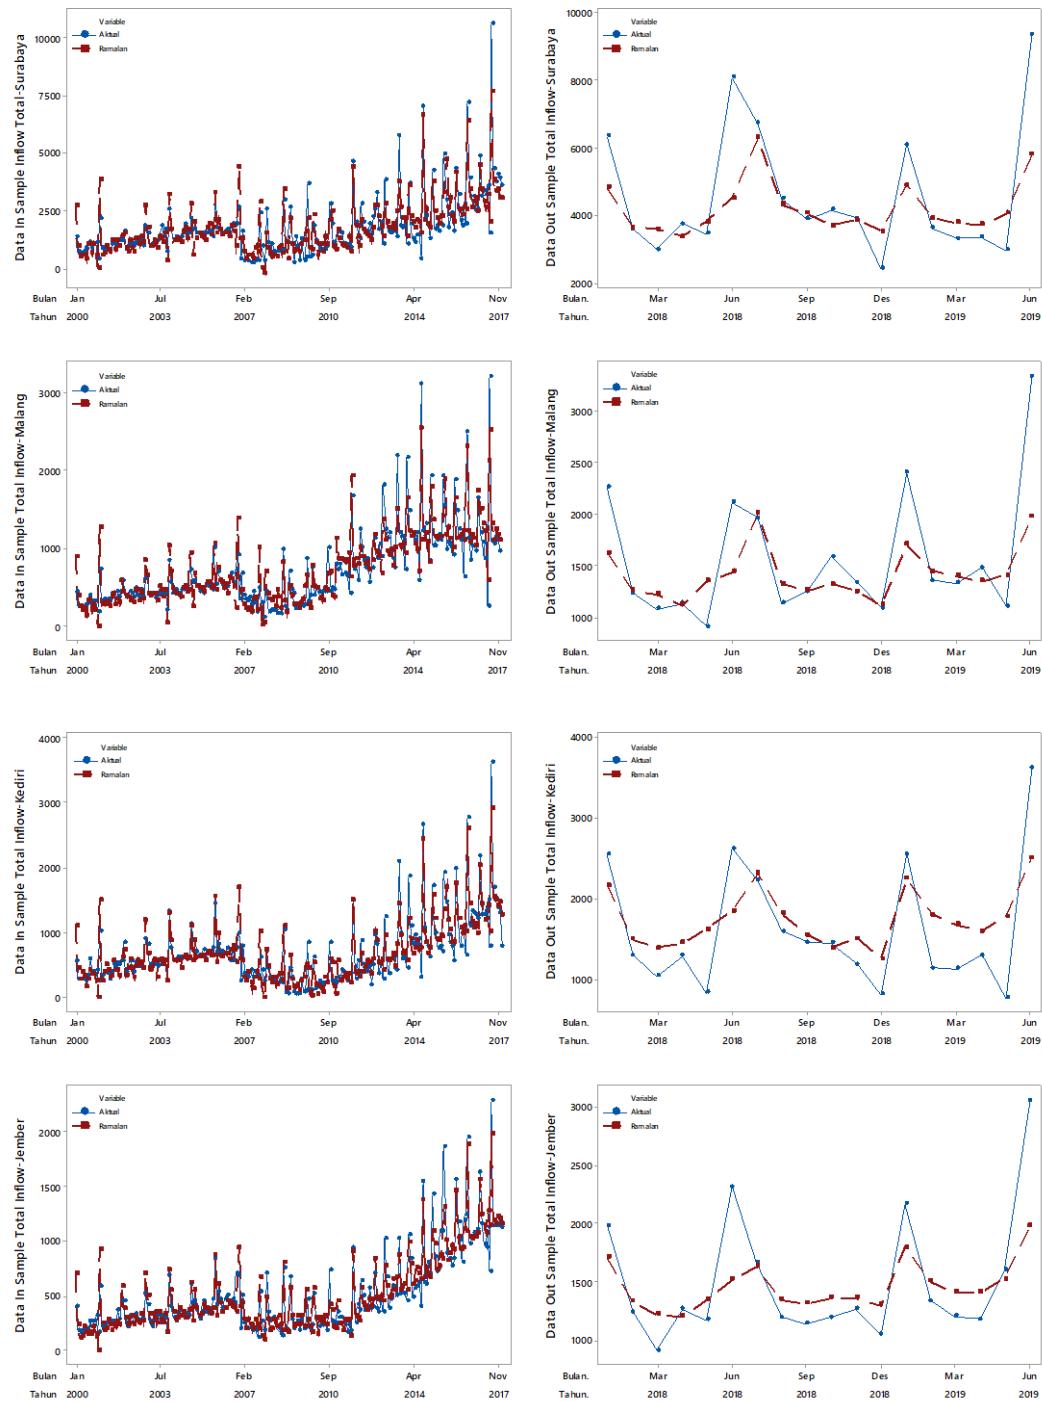
(*) Model TSR telah *white noise*

Tabel 4. 26 Model ARIMAX Data *Outflow* KP BI Jawa Timur

Pecahan	Wilayah	Model	White Noise	Distribusi Normal
Total	Surabaya	ARIMA([1,6,10,12,23],0,0)	Ya	Tidak
	Malang	ARIMA([1,4,12,23],0,0)	Ya	Tidak
	Kediri	ARIMA([1,6,12,23],0,0)	Ya	Tidak
	Jember	ARIMA([10,12,13,23,24],0,0)	Tidak	Ya
Rp. 100.000,-	Surabaya	ARIMA([6,10,12,13,15,23],0,0)	Ya	Ya
	Malang	ARIMA([1,2,4,12,23],0,0)	Ya	Tidak
	Kediri	ARIMA([1,6,12,23],0,0)	Ya	Tidak
	Jember	ARIMA([12,13,23,24],0,0)	Tidak	Ya
Rp. 50.000,-	Surabaya	ARIMA([22,23,34],0,0)	Ya	Ya
	Malang	ARIMA([10,12,15,23],0,0)	Ya	Ya
	Kediri	ARIMA([6,12,15,22,23],0,0)	Tidak	Ya
	Jember	ARIMA([2,13,22,23],0,0)	Tidak	Ya
Rp. 20.000,-	Surabaya	ARIMA([10,12,13],0,0)	Ya	Tidak
	Malang	ARIMA([11,12,36],0,0)	Ya	Tidak
	Kediri	ARIMA([10,12,13,24],0,0)	Ya	Tidak
	Jember	ARIMA([1,2,12,24,35],0,0)	Ya	Tidak
Rp. 10.000,-	Surabaya	ARIMA([2,10,12,13,36],0,0)	Ya	Ya
	Malang	ARIMA([11,12,22,36],0,0)	Ya	Ya
	Kediri	ARIMA([11,12,13,22],0,0)	Ya	Ya
	Jember	ARIMA([12,13,23],0,0)	Tidak	Tidak
Rp. 5.000,-	Surabaya	ARIMA([2,12,23,24],0,0)	Ya	Tidak
	Malang	ARIMA([2,11,12,35],0,0)	Ya	Tidak
	Kediri	ARIMA([2,12,23,24],0,0)	Ya	Tidak
	Jember	ARIMA([10,12,13,23,46],0,0)	Ya	Tidak
Rp. 2.000,-	Surabaya	ARIMA([1,23],0,0)	Ya	Tidak
	Malang	*	Ya	Tidak
	Kediri	*	Ya	Tidak
	Jember	*	Ya	Ya
Rp. 1.000,-	Surabaya	ARIMA([1,11,12,24,34,47],0,0)	Ya	Tidak
	Malang	ARIMA([1,11,12,24,35],0,0)	Ya	Tidak
	Kediri	ARIMA([1,6,12,13,24,47,48],0,0)	Ya	Tidak
	Jember	ARIMA(1,0,0)	Ya	Tidak

(*) Model TSR telah *white noise*

Setelah diperoleh model pada data *inflow* dan *outflow* total maupun pecahan, maka digambarkan *time series plot* antara data aktual dan hasil ramalan menggunakan model ARIMAX.



Gambar 4. 38 Time Series Plot Data Inflow dan Hasil Ramalan Menggunakan Model ARIMAX

Gambar 4. 38 menunjukkan bahwa pada bagian data *in sample* terlihat bahwa hasil ramalan menggunakan model ARIMAX sudah cukup mampu mengikuti pola tren, musiman, dan variasi kalender pada data *inflow* total di setiap KP BI Jawa Timur. Namun pada bagian data *out sample* terlihat

bahwa hasil ramalan belum cukup mengikuti pola data *inflow* total dengan tepat. Sehingga, hasil ramalan model ARIMAX tidak berbeda jauh dengan hasil ramalan model TSR yang belum cukup baik jika digunakan untuk meramalkan data *inflow* total di setiap KP BI Jawa Timur secara individu. Selanjutnya dilakukan perhitungan nilai RMSE dan sMAPE untuk mengetahui kebaikan model ARIMAX dalam meramalkan data *inflow* dan *outflow* total maupun pecahan di KP BI Provinsi Jawa Timur.

Tabel 4. 27 Nilai RMSE Hasil Pemodelan ARIMAX Data *Inflow* dan *Outflow* KP BI Jawa Timur

Pecahan	Data	<i>Outflow</i>				<i>Inflow</i>			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total semua pecahan	<i>In Sample</i>	534,00	164,83	250,35	128,94	547,61	185,55	182,41	113,46
	<i>Out Sample</i>	1022,74	433,46	641,19	240,76	1356,74	445,55	529,46	366,22
Rp. 100.000,-	<i>In Sample</i>	288,29	102,09	172,82	90,84	359,28	117,81	133,67	82,52
	<i>Out Sample</i>	816,03	317,37	571,76	157,94	882,89	244,78	399,09	234,64
Rp. 50.000,-	<i>In Sample</i>	268,86	73,98	98,67	62,90	217,98	71,84	70,93	42,78
	<i>Out Sample</i>	435,25	210,69	191,71	114,31	389,33	155,78	157,55	111,13
Rp. 20.000,-	<i>In Sample</i>	35,21	7,52	9,80	8,60	19,53	5,68	6,89	4,76
	<i>Out Sample</i>	110,86	26,43	34,61	8,27	44,41	8,33	17,33	10,28
Rp. 10.000,-	<i>In Sample</i>	35,56	5,92	6,20	3,54	15,09	4,21	6,68	3,70
	<i>Out Sample</i>	116,84	16,43	25,55	6,52	22,62	5,00	11,13	5,49
Rp. 5.000,-	<i>In Sample</i>	30,82	5,08	4,76	2,10	11,15	5,46	6,89	2,29
	<i>Out Sample</i>	66,16	11,56	15,74	5,19	19,78	5,86	9,00	7,64
Rp. 2.000,-	<i>In Sample</i>	10,00	2,06	1,38	0,54	6,22	1,70	2,92	1,54
	<i>Out Sample</i>	29,49	6,21	4,01	1,06	13,67	2,83	6,75	2,28
Rp. 1.000,-	<i>In Sample</i>	4,99	0,63	0,68	0,28	1,81	0,62	1,13	0,53
	<i>Out Sample</i>	4,12	0,85	1,24	0,17	1,46	0,57	0,90	0,50

Tabel 4. 27 dan Tabel 4. 28 menunjukkan nilai kebaikan model ARIMAX dalam memodelkan data *inflow* dan *outflow* total dan pecahan di masing-masing KP BI Jawa Timur. Berdasarkan kedua tabel tersebut dapat diketahui bahwa nilai RMSE dan sMAPE masih cukup besar terutama terlihat pada nilai sMAPE untuk data *inflow* dan *outflow* uang pecahan kecil yaitu pecahan Rp. 10.000, Rp. 5.000, Rp. 2.000, dan Rp. 1.000. Pada data *inflow* dan *outflow* pecahan Rp. 1.000 memiliki nilai sMAPE hingga lebih dari 100%. Hal ini dikarenakan model ARIMAX belum mampu meramalkan dengan cukup baik serta model ARIMAX memiliki performa kebaikan model tidak jauh berbeda dengan model TSR.

Tabel 4. 28 Nilai sMAPE Hasil Pemodelan ARIMAX Data *Inflow* dan *Outflow* KP BI Jawa Timur

Pecahan	Data	<i>Outflow</i>				<i>Inflow</i>			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total semua pecahan	<i>In Sample</i>	27,33%	30,77%	32,13%	27,39%	26,00%	22,16%	24,92%	18,45%
	<i>Out Sample</i>	21,53%	37,94%	36,32%	34,36%	17,80%	16,49%	27,15%	16,12%
Rp. 100.000,-	<i>In Sample</i>	35,91%	50,70%	43,95%	57,95%	40,32%	39,50%	43,28%	35,68%
	<i>Out Sample</i>	28,16%	42,40%	45,30%	32,84%	22,68%	21,44%	37,21%	21,00%
Rp. 50.000,-	<i>In Sample</i>	30,56%	31,06%	42,14%	32,11%	24,67%	19,46%	27,81%	17,26%
	<i>Out Sample</i>	27,31%	36,60%	39,73%	45,61%	17,11%	15,80%	25,76%	16,00%
Rp. 20.000,-	<i>In Sample</i>	59,50%	53,42%	47,01%	46,51%	25,52%	20,15%	23,56%	20,01%
	<i>Out Sample</i>	78,76%	95,43%	84,62%	60,55%	47,84%	32,78%	47,20%	35,25%
Rp. 10.000,-	<i>In Sample</i>	69,24%	50,62%	50,79%	43,81%	30,61%	23,28%	32,05%	21,11%
	<i>Out Sample</i>	86,22%	95,08%	85,72%	57,54%	32,94%	26,83%	39,42%	27,87%
Rp. 5.000,-	<i>In Sample</i>	78,05%	60,97%	64,21%	42,91%	34,11%	36,72%	50,33%	25,75%
	<i>Out Sample</i>	84,21%	85,96%	72,66%	59,06%	45,40%	93,84%	49,19%	48,34%
Rp. 2.000,-	<i>In Sample</i>	99,04%	75,78%	38,75%	34,90%	43,35%	42,24%	62,54%	54,23%
	<i>Out Sample</i>	57,11%	99,46%	63,99%	34,95%	66,85%	44,52%	76,67%	42,31%
Rp. 1.000,-	<i>In Sample</i>	94,55%	83,36%	80,44%	59,39%	35,44%	43,11%	50,81%	41,48%
	<i>Out Sample</i>	180,82%	159,90%	184,18%	147,58%	113,41%	126,16%	135,69%	117,20%

4.2.5. Pemodelan GSTARX Pada Data *Inflow* dan *Outflow*

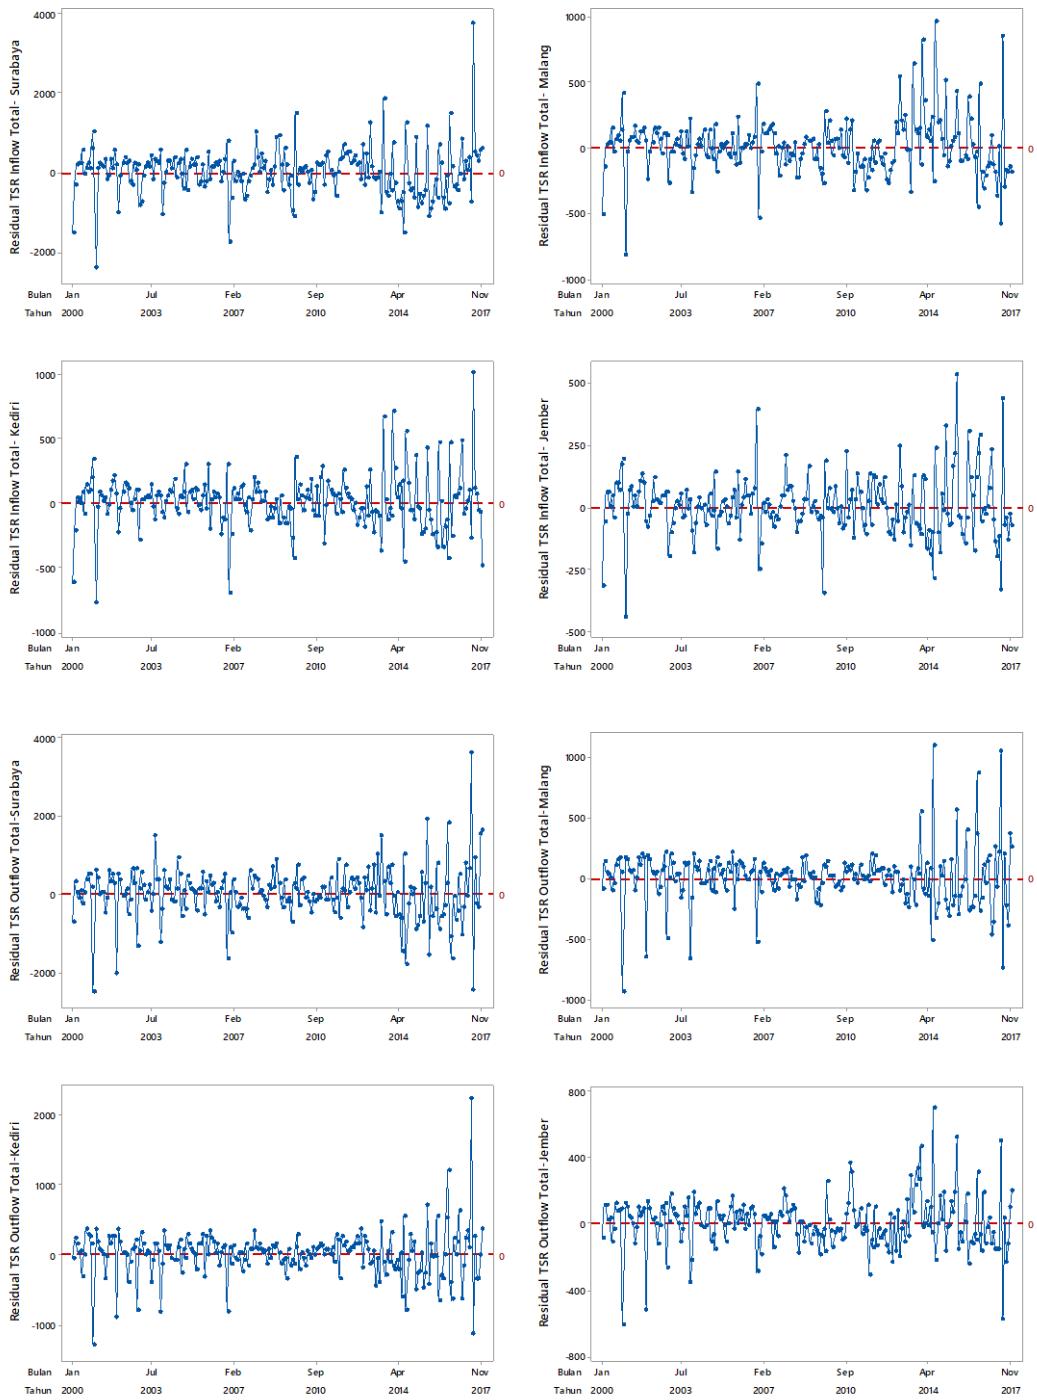
Pemodelan GSTARX merupakan metode yang digunakan untuk meramalkan data *time series* multivariat. Sehingga sebelum melakukan pemodelan menggunakan metode GSTARX terlebih dahulu dilihat korelasi antar wilayah KP BI di Jawa Timur. Data *inflow* dan *outflow* diduga berkorelasi antar lokasi karena berada dalam satu wilayah provinsi dan berdekatan sehingga masuk dalam satu jaringan distribusi pengedaran uang. Sehingga dalam penelitian ini sebelum dilakukan pemodelan dan peramalan data *inflow* dan *outflow* terlebih dahulu dilakukan identifikasi nilai koefisien korelasi antar wilayah KP BI pada masing-masing pecahan uang dan total.

Tabel 4. 29 menunjukkan koefisien korelasi pada setiap data pecahan maupun total *inflow* dan *outflow* memiliki koefisien korelasi yang cukup tinggi antar wilayah KP BI di Jawa Timur. Sehingga dapat disimpulkan bahwa data *inflow* dan *outflow* masing-masing dalam pecahan maupun total cenderung memiliki korelasi yang cukup tinggi antar wilayah KP BI di Jawa Timur.

Tabel 4. 29 Koefisien Korelasi Masing-masing Data *Inflow* dan *Outflow*

Pecahan	Wilayah	<i>Inflow</i>				<i>Outflow</i>			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Total	Surabaya	1,000	0,897	0,942	0,915	1,000	0,948	0,945	0,879
	Malang	0,897	1,000	0,898	0,888	0,948	1,000	0,948	0,901
	Kediri	0,942	0,898	1,000	0,913	0,945	0,948	1,000	0,897
	Jember	0,915	0,888	0,913	1,000	0,879	0,901	0,897	1,000
Rp. 100.000	Surabaya	1,000	0,907	0,953	0,933	1,000	0,927	0,917	0,817
	Malang	0,907	1,000	0,895	0,892	0,927	1,000	0,937	0,853
	Kediri	0,953	0,895	1,000	0,917	0,917	0,937	1,000	0,846
	Jember	0,933	0,892	0,917	1,000	0,817	0,853	0,846	1,000
Rp. 50.000	Surabaya	1,000	0,818	0,867	0,829	1,000	0,870	0,873	0,705
	Malang	0,818	1,000	0,857	0,868	0,870	1,000	0,876	0,751
	Kediri	0,867	0,857	1,000	0,868	0,873	0,876	1,000	0,715
	Jember	0,829	0,868	0,868	1,000	0,705	0,751	0,715	1,000
Rp. 20.000	Surabaya	1,000	0,847	0,918	0,848	1,000	0,816	0,928	0,457
	Malang	0,847	1,000	0,875	0,917	0,816	1,000	0,811	0,502
	Kediri	0,918	0,875	1,000	0,907	0,928	0,811	1,000	0,485
	Jember	0,848	0,917	0,907	1,000	0,457	0,502	0,485	1,000
Rp. 10.000	Surabaya	1,000	0,825	0,894	0,781	1,000	0,896	0,950	0,853
	Malang	0,825	1,000	0,813	0,832	0,896	1,000	0,911	0,841
	Kediri	0,894	0,813	1,000	0,856	0,950	0,911	1,000	0,864
	Jember	0,781	0,832	0,856	1,000	0,853	0,841	0,864	1,000
Rp. 5.000	Surabaya	1,000	0,785	0,807	0,702	1,000	0,861	0,924	0,832
	Malang	0,785	1,000	0,804	0,760	0,861	1,000	0,893	0,834
	Kediri	0,807	0,804	1,000	0,808	0,924	0,893	1,000	0,893
	Jember	0,702	0,760	0,808	1,000	0,832	0,834	0,893	1,000
Rp. 2.000	Surabaya	1,000	0,754	0,710	0,664	1,000	0,925	0,955	0,897
	Malang	0,754	1,000	0,670	0,681	0,925	1,000	0,909	0,874
	Kediri	0,710	0,670	1,000	0,863	0,955	0,909	1,000	0,901
	Jember	0,664	0,681	0,863	1,000	0,897	0,874	0,901	1,000
Rp. 1.000	Surabaya	1,000	0,895	0,871	0,909	1,000	0,791	0,819	0,773
	Malang	0,895	1,000	0,927	0,947	0,791	1,000	0,935	0,747
	Kediri	0,871	0,927	1,000	0,944	0,819	0,935	1,000	0,757
	Jember	0,909	0,947	0,944	1,000	0,773	0,747	0,757	1,000

Sehingga diperlukan pemodelan yang mampu mengatasi adanya efek spasial pada data, dalam penelitian ini digunakan model GSTAR. Pemodelan GSTARX memiliki dua tahap, tahap pertama yaitu melakukan pemodelan data *inflow* dan *outflow* menggunakan model TSR untuk menangkap pola komponen tren, musiman, dan variasi kalender. Selanjutnya, pada tahap kedua dilakukan pemodelan residual dari model TSR data *inflow* dan *outflow* menggunakan model GSTAR secara bersamaan pada semua wilayah KP BI Jawa Timur. Orde model GSTARX ditentukan berdasarkan pada plot MPCCF dari residual model TSR pada semua wilayah KP BI Jawa Timur. *Time series plot* residual model TSR data *inflow* dan *outflow* total di semua KP BI di Jawa Timur dapat dilihat pada Gambar 4.40.



Gambar 4. 39 Time Series Plot Residual Model TSR Data Inflow dan Outflow Total di KP BI Jawa Timur

Gambar 4. 39 menunjukkan *time serie plot* dari residual model TSR data *inflow* dan *outflow*, gambar tersebut menunjukkan bahwa pola data residual telah stasioner karena pola fluktuasinya berada disekitar nilai 0. Mendeteksi stasioneritas

data selain dapat dilakukan dengan melihat *time series plot* data, juga dapat dilakukan dengan melihat plot MCCF yang ditunjukkan pada Gambar 4. 40.

Schematic Representation of Cross Correlations-Inflow Total													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	-..-	-.-.	-..-	+..--	++++
resi2	++++	-.-.	-....	-....	-....	-....	-....	-....	-....	++++
resi3	++++	-.-.	-....	-....	-....+	++++
resi4	++++	-..-	-.-.	-.-.	-.-.	+.++-	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Cross Correlations- outflow Total													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	----	-.-.	+++.-	++++
resi2	++++	----	-..-	-.-.	+.++	-.-.	++++
resi3	++++	----	-.-.	-.-.	+++.	-.-.	++++
resi4	++++	-.-.	-.-.	-.-.	++++

+ is > 2*std error, - is < -2*std error, . is between

Gambar 4. 40 Plot MCCF Residual Model TSR Data *inflow* dan *Outflow* Total

Berdasarkan Gambar 4. 40 dapat diketahui bahwa nilai-nilai korelasi silang dari residual data *inflow* dan *outflow* total memiliki pola yang *cut off* pada beberapa *lag* tertentu. Sehingga dapat disimpulkan bahwa residual model TSR pada data *inflow* dan *outflow* total telah stasioner.

Schematic Representation of Partial Cross Correlations- Inflow Total												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
resi1	+..-	-.-.	-.+.---+..
resi2	-+..	..+	-+..+	-....+.
resi3	--+-	-.-.	-.+	-....	-....	.+..
resi4	...+	-.-.	-.-.	-.-.	-.-.	+.++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations-Outflow Total												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
resi1	-.-.-	+....
resi2	-....	-....	-.-.	-....	+....
resi3	-....	-.-.	+....	-....
resi4	-.-+	...+	-.-.	-.-.	-....+

+ is > 2*std error, - is < -2*std error, . is between

Gambar 4. 41 Plot MPCC Residual Model TSR Data *Inflow* dan *Outflow* Total

Berdasarkan plot MPCCF yang ditunjukkan pada Gambar 4. 41 dapat diketahui bahwa pada *lag* ke-1 plot MPCCF residual model TSR data *inflow* dan *outflow* total pada semua wilayah KP BI di Jawa Timur telah signifikan. Sedangkan pada *lag* lainnya tidak terdapat KP BI Jawa Timur yang signifikan secara keseluruhan. Sehingga dapat ditentukan bahwa orde GSTAR yang digunakan untuk memodelkan residual model TSR data *inflow* total KP BI di Jawa Timur adalah

GSTAR(1₁). Selanjutnya pemodelan data *inflow* total pada semua KP BI dengan GSTARX mengikuti model GSTARX(1₁). Secara lengkap model GSTARX pada seluruh data *inflow* dan *outflow* baik dalam total maupun pecahan dari KP BI di Jawa Timur dapat dilihat pada Tabel 4.30.

Tabel 4. 30 Model GSTARX Pada Data *Inflow* dan *Outflow* di KP BI Jawa Timur

	Data	Model
<i>Inflow</i>	Total	GSTARX(1 ₁)
	Rp 100,000	GSTARX(1 ₁)
	Rp 50,000	GSTARX(1 ₁)
	Rp 20,000	GSTARX(1 ₁)
	Rp 10,000	GSTARX(1 ₁)
	Rp 5,000	GSTARX([1,12] ₁)
	Rp 2,000	GSTARX(1 ₁)
<i>Outflow</i>	Rp 1,000	GSTARX(1 ₁)
	Total	GSTARX(2 ₁)
	Rp 100,000	GSTARX(2 ₁)
	Rp 50,000	GSTARX(1 ₁)
	Rp 20,000	GSTARX(2 ₁)
	Rp 10,000	GSTARX([1,12] ₁)
	Rp 5,000	GSTARX(12 ₁)
	Rp 2,000	GSTARX(1 ₁)
	Rp 1,000	GSTARX(1 ₁)

Setelah menentukan orde model GSTARX pada masing-masing data *inflow* dan *outflow* total dan pecahan, selanjutnya dilakukan estimasi parameter model GSTARX. Metode estimasi parameter yang digunakan adalah *Generalized Least Square* (GLS). Bobot lokasi yang digunakan dalam penelitian ini terdiri dari bobot seragam, biner, invers jarak, Korelasi Silang (KS), dan Normalisasi Inferensi Korelasi Silang (NIKS). Setiap model GSTARX data *inflow* dan *outflow* total maupun pecahan dihitung dengan lima bobot lokasi yang digunakan tersebut dan dilakukan pemilihan bobot lokasi terbaik berdasarkan nilai sMAPE terkecil hasil pemodelan pada masing-masing data *inflow* dan *outflow*. Hasil tersebut dapat dilihat pada Tabel 4.31.

Tabel 4. 31 Bobot Lokasi Terbaik Model GSTARX

Data	Bobot Lokasi	sMAPE				RMSE			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow									
Total	Biner	18,52%	21,64%	31,12%	18,18%	1231,193	486,252	609,247	379,164
Rp 100,000	NIKS	24,63%	24,79%	36,88%	22,72%	823,51	253,13	390,29	242,96
Rp 50,000	Invers Jarak	14,92%	15,48%	25,04%	15,07%	348,22	148,61	162,78	105,37
Rp 20,000	NIKS	33,95%	30,08%	44,41%	29,15%	45,60	8,72	20,99	10,89
Rp 10,000	KS	41,01%	31,88%	51,69%	28,56%	39,42	5,86	20,06	7,03
Rp 5,000	KS	42,57%	35,56%	50,50%	36,89%	23,03	4,60	12,71	5,26
Rp 2,000	NIKS	56,55%	36,53%	75,35%	27,22%	11,42	2,03	5,89	1,76
Rp 1,000	KS	109,43%	91,53%	87,61%	76,63%	5,15	1,22	1,33	0,28
Data Outflow									
Total	KS	26,81%	47,67%	43,77%	38,71%	1562,51	635,91	788,65	299,33
Rp 100,000	NIKS	32,69%	45,65%	47,01%	35,98%	955,26	372,88	577,07	176,18
Rp 50,000	NIKS	17,91%	44,86%	46,43%	45,09%	372,94	273,04	269,10	132,46
Rp 20,000	Biner	85,85%	103,91%	79,55%	48,15%	113,72	31,07	35,07	7,27
Rp 10,000	Invers Jarak	80,63%	97,87%	71,11%	56,88%	90,15	20,15	21,87	6,26
Rp 5,000	Biner	73,49%	101,71%	80,46%	50,79%	84,28	15,39	19,80	4,65
Rp 2,000	Biner	68,43%	101,34%	63,23%	34,34%	30,21	6,09	3,97	1,00
Rp 1,000	Biner	189,70%	168,05%	181,75%	140,53%	5,35	1,19	1,25	0,19

Berdasarkan Tabel 4.31 dapat diketahui bobot lokasi terbaik model GSTARX untuk masing-masing data *inflow* dan *outflow* KP BI Jawa Timur baik dalam total maupun pecahan. Kemudian dilakukan estimasi parameter model GSTARX untuk data *inflow* dan *outflow* total dengan bobot lokasi yang digunakan untuk data *inflow* total adalah bobot biner, dan bobot lokasi yang digunakan untuk data *outflow* total adalah bobot KS.

Tabel 4. 32 Estimasi Parameter Model GSTARX Data *Inflow* Total dengan Bobot Biner

Data	Lokasi	Parameter	Estimasi	Error	Tvalue	P-value
Inflow	Surabaya	ϕ_{10}^1	0,380	0,074	5,163	0,000*
		ϕ_{11}^1	-0,676	0,228	-2,968	0,003*
	Malang	ϕ_{20}^1	0,397	0,061	6,466	0,000*
		ϕ_{21}^1	-0,308	0,104	-2,964	0,003*
	Total	ϕ_{30}^1	0,259	0,072	3,604	0,000*
		ϕ_{31}^1	-0,008	0,023	-0,348	0,728
	Jember	ϕ_{40}^1	0,287	0,065	4,391	0,000*
		ϕ_{41}^1	-0,028	0,038	-0,730	0,466

*Signifikan

Tabel 4. 33 Estimasi Parameter Model GSTARX Data *Outflow* Total dengan Bobot KS

Data	KP BI	Parameter	Estimasi	Error	Tvalue	P-value
Surabaya		ϕ_{10}^1	0,160	0,078	2,052	0,041*
		ϕ_{11}^1	-1,412	0,241	-5,869	0,000*
		ϕ_{10}^2	0,072	0,080	0,894	0,372
		ϕ_{11}^2	-0,631	0,248	-2,540	0,012*
Malang		ϕ_{20}^1	-0,071	0,071	-0,996	0,320
		ϕ_{21}^1	-0,110	0,055	-1,991	0,048*
		ϕ_{20}^2	0,046	0,072	0,637	0,525
		ϕ_{21}^2	-0,120	0,053	-2,268	0,024*
Outflow Total		ϕ_{30}^1	0,052	0,073	0,711	0,478
		ϕ_{31}^1	-0,353	0,093	-3,776	0,000*
		ϕ_{30}^2	0,050	0,076	0,659	0,510
		ϕ_{31}^2	-0,195	0,088	-2,226	0,027*
Jember		ϕ_{40}^1	0,368	0,070	5,258	0,000*
		ϕ_{41}^1	-0,211	0,034	-6,150	0,000*
		ϕ_{40}^2	0,118	0,071	1,661	0,098
		ϕ_{41}^2	-0,069	0,033	-2,087	0,038*

*Signifikan

Berdasarkan pada Tabel 4.32 dan Tabel 4.33 dapat diketahui bahwa parameter model GSTARX data *inflow* total dengan bobot lokasi yang digunakan adalah bobot biner terdapat beberapa parameter yang tidak signifikan yaitu pada parameter bobot lokasi KP BI Kediri dan Jember. Begitu juga untuk hasil estimasi parameter model GSTARX data *outflow* total dengan bobot lokasi yang digunakan adalah bobot korelasi silang terdapat beberapa parameter yang tidak signifikan, diantaranya adalah parameter waktu di KP BI Malang dan kediri. Persamaan model GSTARX dengan bobot biner pada data *inflow* total di KP BI Jawa Timur adalah sebagai berikut.

Persamaan model GSTARX data *inflow* total

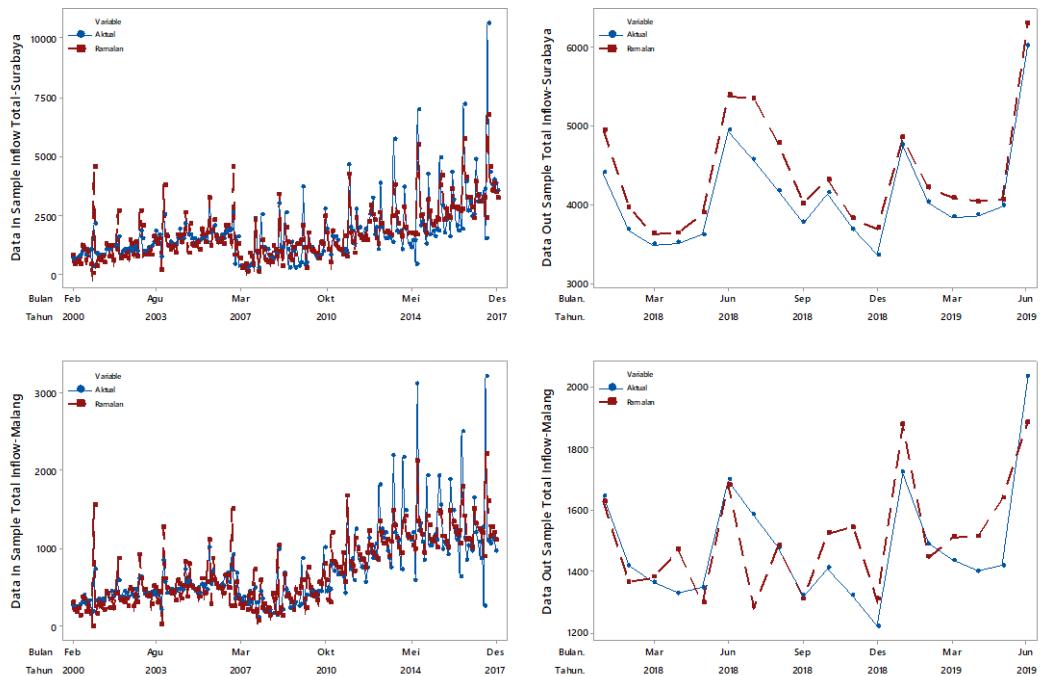
$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} = \begin{bmatrix} 12,72 & 0 & 0 & 0 \\ 0 & 4,17 & 0 & 0 \\ 0 & 0 & 5,25 & 0 \\ 0 & 0 & 0 & 3,34 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} -1125,57 & 0 & 0 & 0 \\ 0 & -431,98 & 0 & 0 \\ 0 & 0 & 375,82 & 0 \\ 0 & 0 & 0 & -19,92 \end{bmatrix} \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 1406,52 & 0 & 0 & 0 \\ 0 & 527,26 & 0 & 0 \\ 0 & 0 & 652,12 & 0 \\ 0 & 0 & 0 & 425,96 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots +$$

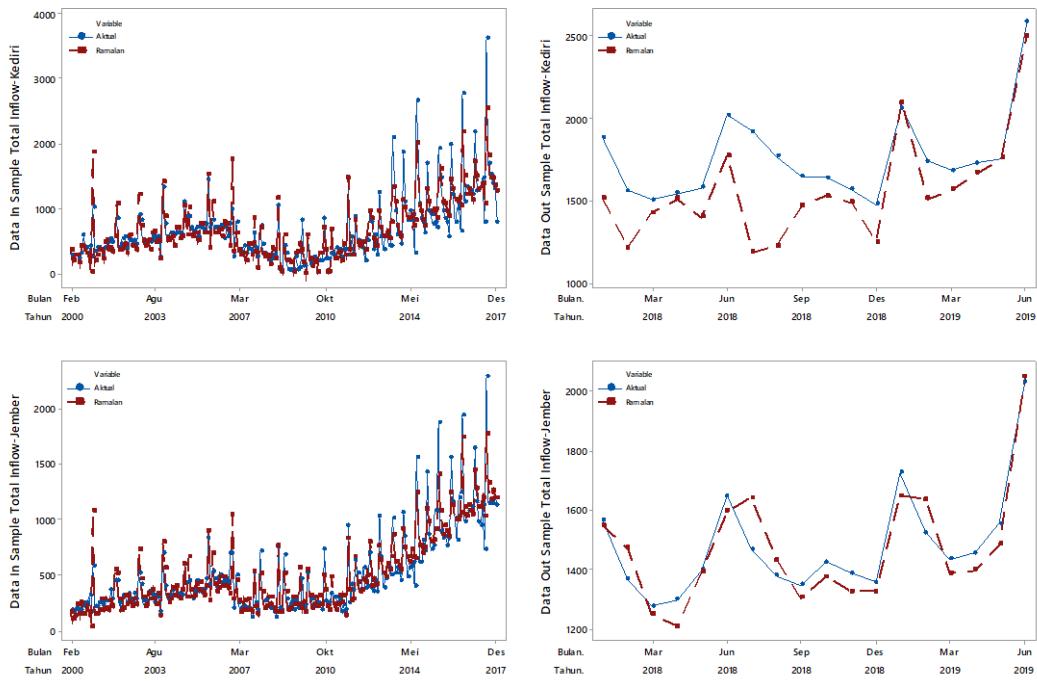
$$\begin{bmatrix} 3016,27 & 0 & 0 & 0 \\ 0 & 959,04 & 0 & 0 \\ 0 & 0 & 1076,12 & 0 \\ 0 & 0 & 0 & 560,92 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix}.$$

dengan

$$\begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,380 & -0,225 & -0,225 & -0,225 \\ -0,103 & 0,397 & -0,103 & -0,103 \\ -0,003 & 0,259 & -0,003 & -0,003 \\ -0,009 & -0,009 & -0,009 & 0,0287 \end{bmatrix} \begin{bmatrix} \varepsilon_{t-1}^{(1)} \\ \varepsilon_{t-1}^{(2)} \\ \varepsilon_{t-1}^{(3)} \\ \varepsilon_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}$$



Gambar 4. 42 Time Series Plot Data Aktual Inflow Total dengan Hasil Ramalan Model GSTARX



Gambar 4.42. Time Series Plot Data Aktual Inflow Total dengan Hasil Ramalan Model GSTARX (lanjutan)

Gambar 4.42 menunjukkan bahwa hasil ramalan data *inflow* menggunakan model GSTARX dengan bobot lokasi biner pada bagian data *in sample* dan *out sample* belum mampu mengikuti pola data aktual dengan tepat.

4.2.6. Pemodelan *Hybrid* GSTARX-FFNN Pada Data *Inflow* dan *Outflow*

Proses pemodelan *hybrid* GSTARX-FFNN merupakan model yang dapat digunakan untuk data *time series* yang diduga memiliki komponen residual yang mengikuti pola linier dan nonlinier, model ini mampu memodelkan data dengan tipe tersebut secara simultan. Pemodelan *hybrid* GSTARX-FFNN dilakukan dengan dua tahap, tahap pertama adalah memodelkan data *inflow* dan *outflow* menggunakan model TSR. Selanjutnya, residual dari model TSR dimodelkan menggunakan model FFNN dengan input yang digunakan adalah residual model TSR dan residual model TSR yang telah diboboti dengan bobot GSTAR. Bobot yang digunakan adalah bobot seragam, biner, invers jarak, KS, dan NIKS. Jumlah *neuron* yang digunakan pada *hidden layer* model FFNN adalah 1, 2, 3, 4, 5, 10, dan 15, serta fungsi aktivasi yang digunakan pada *hidden layer* adalah *tangent hyperbolic* dan fungsi aktivasi pada *output layer* adalah linier. Jumlah input yang

digunakan berdasarkan model GSTARX yang telah ditentukan pada data *inflow* dan *outflow* baik dalam total maupun pecahan seperti yang dijelaskan pada Tabel 4. 30.

Sebelum dilakukan pemodelan *hybrid* GSTARX-FFNN terlebih dahulu dilakukan pengujian linieritas menggunakan uji Terasvirta. Berikut ini adalah hasil pengujian Terasvirta pada data *inflow* dan *outflow* KP BI Jawa Timur.

Tabel 4. 34 Hasil Uji Terasvirta Data *Outflow* di KP BI Jawa Timur

Data	KP BI	F _{hitung}	Lag	df ₁	df ₂	P-value	Keterangan
Total	Surabaya	17,986	1	2	230	0,000	Nonlinier
	Malang	14,673	1	2	230	0,000	Nonlinier
	Kediri	29,251	1	2	230	0,000	Nonlinier
	Jember	22,737	1	2	230	0,000	Nonlinier
Rp.100.000	Surabaya	17,649	1	2	230	0,000	Nonlinier
	Malang	26,967	1	2	230	0,000	Nonlinier
	Kediri	35,396	1	2	230	0,000	Nonlinier
	Jember	60,584	1	2	230	0,000	Nonlinier
Rp.50.000	Surabaya	16,626	1	2	230	0,000	Nonlinier
	Malang	9,621	1	2	230	0,000	Nonlinier
	Kediri	17,497	1	2	230	0,000	Nonlinier
	Jember	17,570	1	2	230	0,000	Nonlinier
Rp.20.000	Surabaya	17,682	1	2	230	0,000	Nonlinier
	Malang	21,540	1	2	230	0,000	Nonlinier
	Kediri	21,466	1	2	230	0,000	Nonlinier
	Jember	18,820	1	2	230	0,000	Nonlinier
Rp.10.000	Surabaya	16,492	1	2	230	0,000	Nonlinier
	Malang	12,688	1	2	230	0,000	Nonlinier
	Kediri	25,263	1	2	230	0,000	Nonlinier
	Jember	13,760	1	2	230	0,000	Nonlinier
Rp.5.000	Surabaya	15,946	1	2	230	0,000	Nonlinier
	Malang	22,984	1	2	230	0,000	Nonlinier
	Kediri	39,642	1	2	230	0,000	Nonlinier
	Jember	10,115	1	2	230	0,000	Nonlinier
Rp.2.000	Surabaya	28,522	1	2	110	0,000	Nonlinier
	Malang	27,067	1	2	110	0,000	Nonlinier
	Kediri	50,738	1	2	110	0,000	Nonlinier
	Jember	11,657	1	2	110	0,000	Nonlinier
Rp.1.000	Surabaya	33,771	1	2	230	0,000	Nonlinier
	Malang	48,637	1	2	230	0,000	Nonlinier
	Kediri	39,705	1	2	230	0,000	Nonlinier
	Jember	33,617	1	2	230	0,000	Nonlinier

Tabel 4. 35 Hasil Uji Terasvirta Data *Inflow* di KP BI Jawa Timur

Data	KP BI	F _{hitung}	Lag	df ₁	df ₂	P-value	Keterangan
Total	Surabaya	8,166	1	2	229	0,000	Nonlinier
	Malang	25,663	1	2	229	0,000	Nonlinier
	Kediri	9,844	1	2	229	0,000	Nonlinier
	Jember	21,614	1	2	229	0,000	Nonlinier
Rp.100.000	Surabaya	4,903	1	2	230	0,008	Nonlinier
	Malang	19,313	1	2	230	0,000	Nonlinier
	Kediri	8,483	1	2	230	0,000	Nonlinier
	Jember	18,708	1	2	230	0,000	Nonlinier
Rp.50.000	Surabaya	6,084	1	2	229	0,002	Nonlinier
	Malang	19,099	1	2	229	0,000	Nonlinier
	Kediri	9,678	1	2	229	0,000	Nonlinier
	Jember	13,002	1	2	229	0,000	Nonlinier
Rp.20.000	Surabaya	5,242	1	2	229	0,006	Nonlinier
	Malang	11,531	1	2	229	0,000	Nonlinier
	Kediri	3,800	1	2	229	0,023	Nonlinier
	Jember	7,376	1	2	229	0,001	Nonlinier
Rp.10.000	Surabaya	3,089	1, 2	7	223	0,003	Nonlinier
	Malang	11,235	1, 2	7	223	0,000	Nonlinier
	Kediri	5,327	1, 2	7	223	0,000	Nonlinier
	Jember	1,245	1, 2	7	223	0,260	Linier
Rp.5.000	Surabaya	0,171	1	2	229	0,841	Linier
	Malang	19,203	1	2	229	0,000	Nonlinier
	Kediri	6,897	1	2	229	0,001	Nonlinier
	Jember	4,723	1	2	229	0,009	Nonlinier
Rp.2.000	Surabaya	2,759	1, 2	7	103	0,007	Nonlinier
	Malang	2,145	1, 2	7	103	0,033	Nonlinier
	Kediri	4,083	1, 2	7	103	0,000	Nonlinier
	Jember	2,827	1, 2	7	103	0,006	Nonlinier
Rp.1.000	Surabaya	7,514	1, 2	7	223	0,000	Nonlinier
	Malang	5,868	1, 2	7	223	0,000	Nonlinier
	Kediri	2,236	1, 2	7	223	0,028	Nonlinier
	Jember	3,891	1, 2	7	223	0,000	Nonlinier

Berdasarkan Tabel 4. 34 dan Tabel 4.35 menunjukkan hasil uji linieritas menggunakan uji terasvirta pada data *inflow* dan *outflow* di KP BI Jawa Timur baik dalam total maupun pecahan. Hasil pengujian pada data *outflow* menunjukkan bahwa seluruh data *outflow* nonlinier terhadap *lag* ke-1. Sedangkan untuk data *inflow* pada pecahan Rp. 10.000 dan Rp. 5.000 terdapat KP BI yang linier yaitu KP BI Jember pada pecahan Rp. 10.000 dan KP BI Surabaya pada pecahan Rp. 5.000.

Data *inflow* total, pecahan Rp. 100.000, pecahan Rp. 50.000, pecahan Rp. 20.000, dan pecahan Rp. 5.000 nonlinier terhadap *lag* ke-1 dan untuk data *inflow* pecahan Rp. 10.000, pecahan Rp. 2.000, dan pecahan Rp. 1.000 nonlinier terhadap *lag* ke-1 dan 2.

Pemodelan *hybrid* GSTARX-FFNN pada data *inflow* dan *outflow* dilakukan dengan mengkombinasikan jumlah *neuron* pada *hidden layer* dan jenis bobot lokasi pada pemodelan GSTAR yang digunakan. Pemilihan jumlah *neuron* dan bobot terbaik didasarkan pada nilai RMSE dan sMAPE terkecil. Hasil perhitungan RMSE dan sMAPE untuk pemodelan GSTARX-FFNN dapat dilihat pada Tabel 4.36 dan Tabel 4. 37.

Berdasarkan Tabel 4. 36 dan Tabel 4. 37 yang menunjukkan nilai RMSE dan sMAPE model *hybrid* GSTARX-FFNN data *inflow* total, dapat diketahui bahwa model terbaik untuk data *inflow* total adalah dengan delapan input, 4 *neuron* pada *hidden layer* atau dinotasikan GSTARX-FFNN(8,4,1) dan bobot lokasi yang digunakan adalah NIKS.

Tabel 4. 36 Nilai RMSE Model *Hybrid* GSTARX-FFNN Data Total *Inflow* di KP BI Jawa Timur

Bobot Lokasi	Model GSTARX-FFNN	KP BI-In Sample				KP BI-Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-FFNN (8,1,1)	583,27	214,16	209,25	124,33	1241,41	396,39	525,91	366,64
	GSTARX-FFNN (8,2,1)	583,77	215,33	207,47	125,85	1230,89	403,31	510,99	355,57
	GSTARX-FFNN (8,3,1)	584,24	209,34	206,93	122,77	1227,86	387,13	516,59	368,88
	GSTARX-FFNN (8,4,1)	584,04	210,13	203,72	124,91	1224,82	423,18	513,30	365,36
	GSTARX-FFNN (8,5,1)	583,83	223,91	214,39	123,31	1234,18	404,32	524,15	362,25
	GSTARX-FFNN (8,10,1)	583,97	216,75	214,50	123,57	1212,99	408,76	541,59	368,37
	GSTARX-FFNN (8,15,1)	590,44	212,90	222,90	129,25	823,18	299,93	331,77	210,41
Biner	GSTARX-FFNN (8,1,1)	595,66	214,82	206,86	126,98	1242,03	391,66	532,35	360,05
	GSTARX-FFNN (8,2,1)	596,85	211,96	210,27	124,27	1235,54	396,97	517,76	368,53
	GSTARX-FFNN (8,3,1)	594,93	213,30	207,80	125,35	1235,31	386,18	518,60	379,58
	GSTARX-FFNN (8,4,1)	594,95	210,38	210,69	122,04	1221,93	411,77	531,65	371,67
	GSTARX-FFNN (8,5,1)	594,71	209,65	207,06	125,53	1226,23	420,69	527,77	377,17
	GSTARX-FFNN (8,10,1)	600,17	220,86	210,37	127,12	1221,70	408,20	526,15	385,15
	GSTARX-FFNN (8,15,1)	601,21	217,46	219,58	126,43	1241,30	414,20	519,35	364,54

Tabel 4. 36 Nilai RMSE Model *Hybrid GSTARX-FFNN* Data Total *Inflow* di KP BI Jawa Timur
(lanjutan)

Bobot Lokasi	Model GSTARX-FFNN	KP BI-In Sample				KP BI-Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Invers Jarak	GSTARX-FFNN (8,1,1)	589,06	217,56	211,54	129,19	1245,23	399,35	517,23	362,93
	GSTARX-FFNN (8,2,1)	581,84	213,79	210,59	124,83	1237,49	386,27	514,21	379,44
	GSTARX-FFNN (8,3,1)	581,54	210,48	209,57	125,37	1233,05	385,85	516,18	375,19
	GSTARX-FFNN (8,4,1)	589,52	223,98	231,08	128,67	1224,29	405,36	518,24	366,13
	GSTARX-FFNN (8,5,1)	587,36	218,99	214,78	129,65	1230,14	416,75	529,50	368,86
	GSTARX-FFNN (8,10,1)	582,27	217,24	215,13	124,00	1215,48	411,97	537,59	371,29
	GSTARX-FFNN (8,15,1)	584,26	208,17	218,23	122,09	1233,40	400,42	529,36	354,40
Korelasi Silang (KS)	GSTARX-FFNN (8,1,1)	589,19	216,49	211,76	127,26	1247,80	399,12	516,23	368,51
	GSTARX-FFNN (8,2,1)	581,99	214,06	211,53	123,61	1238,89	386,46	514,90	372,12
	GSTARX-FFNN (8,3,1)	583,81	209,12	208,04	124,63	1233,41	400,41	516,94	370,77
	GSTARX-FFNN (8,4,1)	587,88	214,70	222,26	123,99	1235,23	400,96	518,60	359,79
	GSTARX-FFNN (8,5,1)	582,40	213,88	206,57	120,71	1219,70	393,10	524,37	357,78
	GSTARX-FFNN (8,10,1)	582,18	217,65	215,74	123,55	1216,90	411,33	537,16	364,40
	GSTARX-FFNN (8,15,1)	584,38	208,15	219,60	120,86	1235,23	400,79	528,65	351,26
Normalisasi Inferensi Korelasi Silang (NIKS)	GSTARX-FFNN (8,1,1)	590,90	212,66	214,23	122,94	1250,05	399,97	513,73	364,16
	GSTARX-FFNN (8,2,1)	586,09	212,86	212,17	125,21	1238,73	412,36	519,67	366,40
	GSTARX-FFNN (8,3,1)	582,82	216,46	208,07	119,65	1229,19	405,46	510,21	353,26
	GSTARX-FFNN (8,4,1)*	581,49	220,04	210,73	128,47	1222,41	428,25	546,39	356,53
	GSTARX-FFNN (8,5,1)	579,81	217,22	206,73	119,82	1231,72	401,15	521,02	353,52
	GSTARX-FFNN (8,10,1)	582,87	218,04	208,03	124,25	1232,14	388,79	523,05	341,65
	GSTARX-FFNN (8,15,1)	585,92	220,12	210,46	122,35	1232,81	406,29	517,27	375,58

*model terbaik

Tabel 4. 37 Nilai sMAPE Model *Hybrid GSTARX-FFNN* Data *Inflow* Total di KP BI Jawa Timur

Bobot Lokasi	Model GSTARX-FFNN	KP BI-In Sample				KP BI-Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-FFNN (8,1,1)	29,7%	32,2%	32,4%	33,5%	18,6%	18,9%	18,9%	19,0%
	GSTARX-FFNN (8,2,1)	29,4%	31,8%	31,0%	32,7%	18,7%	19,3%	19,0%	19,3%
	GSTARX-FFNN (8,3,1)	30,0%	31,9%	30,9%	32,3%	18,6%	19,1%	18,9%	19,2%
	GSTARX-FFNN (8,4,1)	29,6%	31,3%	31,0%	30,8%	18,9%	18,8%	18,8%	19,2%
	GSTARX-FFNN (8,5,1)	30,0%	32,5%	32,0%	31,1%	18,3%	19,0%	18,7%	19,3%
	GSTARX-FFNN (8,10,1)	29,4%	32,6%	32,1%	32,4%	19,3%	19,0%	18,5%	19,1%
	GSTARX-FFNN (8,15,1)	30,0%	32,8%	32,3%	31,7%	19,6%	23,2%	23,2%	22,5%
Biner	GSTARX-FFNN (8,1,1)	30,7%	31,9%	32,2%	31,7%	18,4%	18,9%	18,7%	18,4%
	GSTARX-FFNN (8,2,1)	30,8%	32,3%	32,5%	33,2%	18,5%	18,8%	19,2%	18,5%
	GSTARX-FFNN (8,3,1)	31,1%	31,9%	32,0%	33,0%	18,5%	18,9%	19,0%	19,1%
	GSTARX-FFNN (8,4,1)	30,9%	31,3%	32,6%	33,0%	18,6%	19,0%	19,2%	19,0%
	GSTARX-FFNN (8,5,1)	30,6%	32,0%	31,4%	31,5%	18,2%	18,7%	18,7%	18,7%
	GSTARX-FFNN (8,10,1)	30,3%	32,2%	32,4%	32,2%	18,5%	18,6%	18,5%	18,8%
	GSTARX-FFNN (8,15,1)	30,8%	32,1%	32,6%	31,1%	18,2%	18,9%	19,3%	18,9%

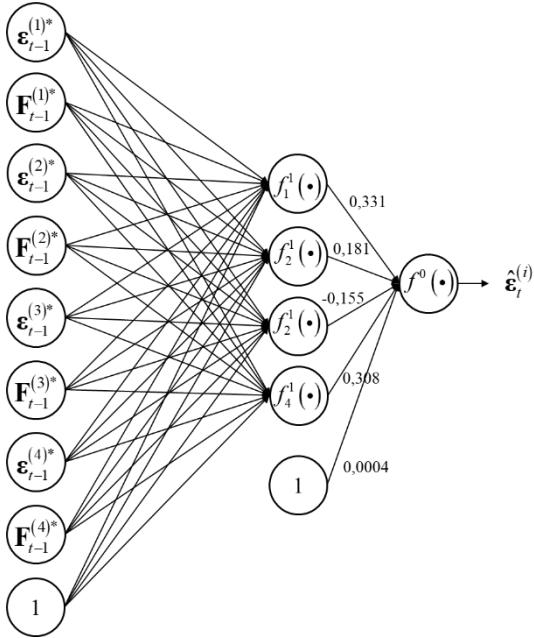
Tabel 4. 37 Nilai sMAPE Model *Hybrid GSTARX-FFNN* Data *Inflow Total* di KP BI Jawa Timur
(lanjutan)

Bobot Lokasi	Model GSTARX-FFNN	KP BI-In Sample				KP BI-Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Invers Jarak	GSTARX-FFNN (8,1,1)	29.5%	32.7%	32.8%	32.6%	18.5%	19.3%	19.0%	19.1%
	GSTARX-FFNN (8,2,1)	30.4%	31.6%	32.1%	33.6%	18.4%	19.1%	18.9%	19.2%
	GSTARX-FFNN (8,3,1)	30.2%	31.5%	31.0%	32.5%	18.7%	19.2%	18.9%	19.3%
	GSTARX-FFNN (8,4,1)	30.5%	32.9%	34.0%	32.7%	19.2%	18.9%	19.2%	18.7%
	GSTARX-FFNN (8,5,1)	31.2%	32.7%	31.8%	31.0%	18.7%	18.5%	18.9%	19.4%
	GSTARX-FFNN (8,10,1)	29.8%	32.8%	32.1%	32.4%	19.1%	19.2%	18.4%	19.1%
	GSTARX-FFNN (8,15,1)	29.5%	33.5%	32.6%	32.0%	19.0%	19.1%	18.7%	19.1%
	GSTARX-FFNN (8,1,1)	29.5%	32.8%	32.5%	32.9%	18.5%	19.3%	18.9%	19.0%
KS	GSTARX-FFNN (8,2,1)	30.4%	31.6%	31.9%	33.2%	18.4%	19.1%	18.9%	19.2%
	GSTARX-FFNN (8,3,1)	31.0%	31.4%	30.9%	32.3%	18.6%	19.0%	18.8%	19.3%
	GSTARX-FFNN (8,4,1)	29.6%	32.8%	32.9%	32.8%	18.7%	18.9%	18.7%	18.7%
	GSTARX-FFNN (8,5,1)	31.5%	32.4%	31.5%	32.1%	18.9%	19.3%	18.7%	19.1%
	GSTARX-FFNN (8,10,1)	29.8%	32.7%	32.1%	32.3%	19.1%	19.1%	18.4%	19.1%
	GSTARX-FFNN (8,15,1)	29.5%	33.6%	32.3%	31.9%	19.0%	19.1%	18.7%	19.0%
	GSTARX-FFNN (8,1,1)	29.6%	32.8%	31.1%	32.7%	18.8%	19.3%	18.4%	18.8%
	GSTARX-FFNN (8,2,1)	30.2%	34.0%	31.6%	33.0%	18.5%	19.2%	18.4%	19.0%
NIKS	GSTARX-FFNN (8,3,1)	30.4%	31.2%	31.0%	31.2%	18.8%	19.3%	18.4%	19.0%
	GSTARX-FFNN (8,4,1)*	30.3%	31.0%	31.5%	36.6%	18.4%	18.6%	17.7%	19.0%
	GSTARX-FFNN (8,5,1)	30.7%	31.9%	30.8%	32.1%	18.3%	18.9%	18.8%	19.2%
	GSTARX-FFNN (8,10,1)	33.2%	32.8%	31.4%	32.0%	18.4%	19.3%	18.4%	18.9%
	GSTARX-FFNN (8,15,1)	31.2%	32.5%	32.3%	31.9%	18.7%	19.5%	18.3%	19.3%

*model terbaik

Tabel 4. 38 Hasil Estimasi Parameter Model *Hybrid GSTARX-FFNN(8,4,1)* Data *Inflow Total*

Predictor	Predicted				
	Hidden Layer				Yt
	Neuron 1	Neuron 2	Neuron 3	Neuron 4	
Input Layer	(Bias)	-0,517	-0,511	-0,266	0,377
	$\epsilon_{t-1}^{(1)*}$	0,087	-0,086	-0,253	0,117
	$\epsilon_{t-1}^{(2)*}$	0,370	0,228	0,274	0,151
	$\epsilon_{t-1}^{(3)*}$	-0,323	0,096	-0,482	0,166
	$\epsilon_{t-1}^{(4)*}$	0,214	0,267	0,175	0,144
	$F_{t-1}^{(1)*}$	0,409	-0,304	0,126	-0,104
	$F_{t-1}^{(2)*}$	0,067	-0,297	0,496	-0,067
	$F_{t-1}^{(3)*}$	0,232	-0,297	0,315	-0,318
	$F_{t-1}^{(4)*}$	-0,285	-0,117	-0,028	-0,087
	(Bias)				0,0004
Hidden Layer	Neuron 1				0,331
	Neuron 2				0,181
	Neuron 3				-0,155
	Neuron 4				0,308



Gambar 4. 43 Arsitektur Model *Hybrid GSTAR-FFNN(8,4,1)*

Berdasarkan hasil estimasi parameter model *hybrid GSTARX-FFNN(8,4,1)* dengan bobot NIKS maka diperoleh persamaan sebagai berikut.

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} = \begin{bmatrix} 12,72 & 0 & 0 & 0 \\ 0 & 4,17 & 0 & 0 \\ 0 & 0 & 5,25 & 0 \\ 0 & 0 & 0 & 3,34 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} -1125,57 & 0 & 0 & 0 \\ 0 & -431,98 & 0 & 0 \\ 0 & 0 & 375,82 & 0 \\ 0 & 0 & 0 & -19,92 \end{bmatrix} \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 1406,52 & 0 & 0 & 0 \\ 0 & 527,26 & 0 & 0 \\ 0 & 0 & 652,12 & 0 \\ 0 & 0 & 0 & 425,96 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 3016,27 & 0 & 0 & 0 \\ 0 & 959,04 & 0 & 0 \\ 0 & 0 & 1076,12 & 0 \\ 0 & 0 & 0 & 560,92 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} \boldsymbol{\varepsilon}_t^{(1)} \\ \boldsymbol{\varepsilon}_t^{(2)} \\ \boldsymbol{\varepsilon}_t^{(3)} \\ \boldsymbol{\varepsilon}_t^{(4)} \end{bmatrix}$$

dengan

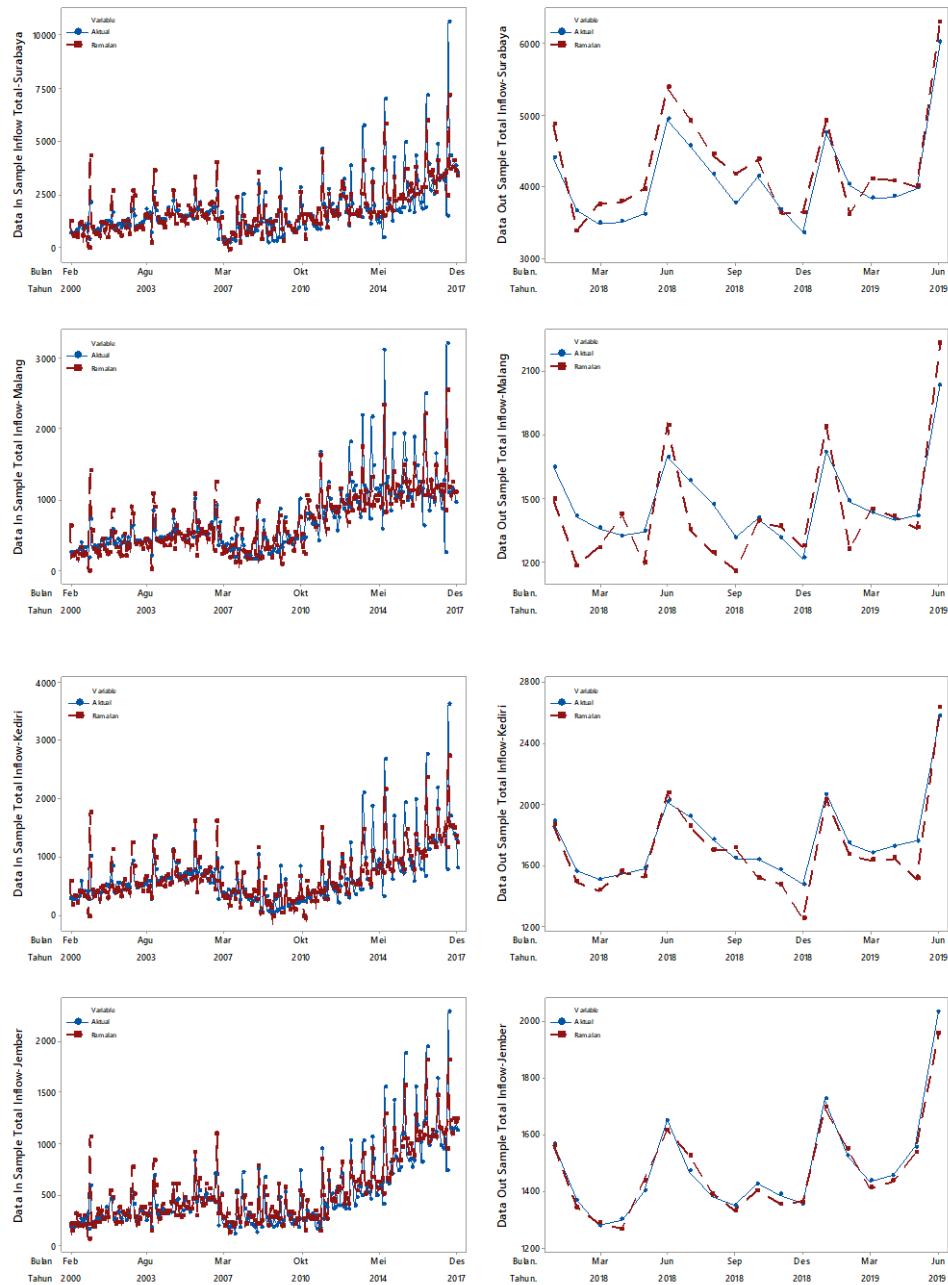
$$\hat{\boldsymbol{\varepsilon}}_t = 0,0004 + 0,331 \times \tanh f_1^1(\cdot) + 0,181 \times \tanh f_2^1(\cdot) - 0,155 \times \tanh f_3^1(\cdot) + 0,308 \times \tanh f_4^1(\cdot)$$

dan

$$f_1^1(\cdot) = -0,517 + 0,087\boldsymbol{\varepsilon}_{t-1}^{(1)*} + 0,370\boldsymbol{\varepsilon}_{t-1}^{(2)*} - 0,323\boldsymbol{\varepsilon}_{t-1}^{(3)*} + 0,214\boldsymbol{\varepsilon}_{t-1}^{(4)*} +$$

$$0,409\mathbf{F}_{t-1}^{(1)*} + 0,067\mathbf{F}_{t-1}^{(2)*} + 0,232\mathbf{F}_{t-1}^{(3)*} - 0,285\mathbf{F}_{t-1}^{(4)*}$$

$$\begin{aligned}
f_2^1(\bullet) = & -0,511 + 0,086 \boldsymbol{\varepsilon}_{t-1}^{(1)*} + 0,228 \boldsymbol{\varepsilon}_{t-1}^{(2)*} - 0,096 \boldsymbol{\varepsilon}_{t-1}^{(3)*} + 0,267 \boldsymbol{\varepsilon}_{t-1}^{(4)*} - \\
& 0,304 \mathbf{F}_{t-1}^{(1)*} - 0,297 \mathbf{F}_{t-1}^{(2)*} - 0,297 \mathbf{F}_{t-1}^{(3)*} - 0,117 \mathbf{F}_{t-1}^{(4)*} \\
f_3^1(\bullet) = & -0,266 - 0,253 \boldsymbol{\varepsilon}_{t-1}^{(1)*} + 0,274 \boldsymbol{\varepsilon}_{t-1}^{(2)*} - 0,482 \boldsymbol{\varepsilon}_{t-1}^{(3)*} + 0,175 \boldsymbol{\varepsilon}_{t-1}^{(4)*} + \\
& 0,126 \mathbf{F}_{t-1}^{(1)*} + 0,496 \mathbf{F}_{t-1}^{(2)*} + 0,315 \mathbf{F}_{t-1}^{(3)*} - 0,028 \mathbf{F}_{t-1}^{(4)*} \\
f_4^1(\bullet) = & 0,377 + 0,117 \boldsymbol{\varepsilon}_{t-1}^{(1)*} + 0,151 \boldsymbol{\varepsilon}_{t-1}^{(2)*} + 0,166 \boldsymbol{\varepsilon}_{t-1}^{(3)*} + 0,444 \boldsymbol{\varepsilon}_{t-1}^{(4)*} - \\
& 0,104 \mathbf{F}_{t-1}^{(1)*} - 0,067 \mathbf{F}_{t-1}^{(2)*} - 0,318 \mathbf{F}_{t-1}^{(3)*} - 0,087 \mathbf{F}_{t-1}^{(4)*}.
\end{aligned}$$



Gambar 4.44 Time Series Plot Perbandingan Data Aktual Inflow Total dengan Ramalan Model Hybrid GSTARX-FFNN

Berdasarkan Gambar 4.44 dapat diketahui bahwa hasil ramalan data *inflow* total menggunakan model *hybrid GSTARX-FFNN(8,4,1)* pada data *in sample* sudah mampu mengikuti pola data aktual. Namun pada data *out sample* di KP BI Kediri dan Jember hasil ramalan mampu mengikuti pola data aktual dengan lebih baik dibandingkan di KP BI Surabaya dan Malang. Nilai RMSE dan sMAPE model *hybrid GSTARX-FFNN* terbaik dari keseluruhan data *inflow* dan *outflow* KP BI Jawa Timur baik dalam total maupun pecahan dapat dilihat pada Tabel 4.39 dan Tabel 4.40.

Tabel 4.39 Nilai RMSE Model Terbaik GSTARX-FFNN Data *Inflow* di KP BI Jawa Timur

Data	Bobot Lokasi	Model GSTARX-FFNN	KP BI- <i>In Sample</i>				KP BI- <i>Out Sample</i>			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data <i>Inflow</i>										
Total	NIKS	GSTARX-FFNN(8,4,1)	581,49	220,04	210,73	128,47	1222,41	428,25	546,39	356,53
Rp. 100.000	Biner	GSTARX-FFNN(8,1,1)	413,43	142,69	150,82	92,53	847,32	207,17	379,67	226,37
Rp. 50.000	Biner	GSTARX-FFNN(8,1,1)	223,55	79,09	73,64	44,60	316,16	132,07	149,11	114,86
Rp. 20.000	Seragam	GSTARX-FFNN(8,15,1)	22,18	6,48	8,04	5,50	32,11	7,81	13,22	7,57
Rp. 10.000	Seragam	GSTARX-FFNN(8,15,1)	20,42	5,82	9,65	4,92	30,16	8,75	15,09	7,13
Rp. 5.000	Biner	GSTARX-FFNN(16,3,1)	16,73	5,40	8,20	3,03	33,37	6,66	18,39	4,39
Rp. 2.000	NIKS	GSTARX-FFNN(8,4,1)	7,02	1,73	3,36	2,02	13,65	2,30	6,82	1,59
Rp. 1.000	Invers Jarak	GSTARX-FFNN(8,3,1)	7,62	1,86	2,87	1,01	5,48	1,61	1,48	0,33
Data <i>Outflow</i>										
Total	Seragam	GSTARX-FFNN(16,15,1)	693,82	256,11	378,16	187,36	1074,93	419,67	573,62	261,60
Rp. 100.000	Seragam	GSTARX-FFNN(16,15,1)	362,96	147,06	237,63	117,22	612,65	240,25	376,27	159,50
Rp. 50.000	NIKS	GSTARX-FFNN(8,2,1)	297,19	90,25	120,09	72,57	500,82	256,58	243,43	119,22
Rp. 20.000	KS	GSTARX-FFNN(16,5,1)	45,38	9,73	13,02	9,74	122,81	35,54	37,91	11,63
Rp. 10.000	Invers Jarak	GSTARX-FFNN(16,1,1)	44,68	6,78	7,91	4,27	134,13	21,84	31,35	8,18
Rp. 5.000	Biner	GSTARX-FFNN(8,4,1)	42,89	6,29	6,66	3,44	71,51	13,14	18,84	9,62
Rp. 2.000	Seragam	GSTARX-FFNN(8,4,1)	12,07	2,16	1,52	1,10	29,75	6,05	3,95	1,87
Rp. 1.000	Biner	GSTARX-FFNN(8,4,1)	5,46	0,74	0,87	0,42	5,01	1,33	1,21	0,28

Tabel 4. 40 Nilai sMAPE Model Terbaik GSTARX-FFNN Data *Inflow* di KP BI Jawa Timur

Data	Bobot Lokasi	Model GSTARX-FFNN	KP BI- <i>In Sample</i>				KP BI- <i>Out Sample</i>			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow										
Total	NIKS	GSTARX-FFNN(8,4,1)	30,3%	31,0%	31,5%	36,6%	18,4%	18,6%	17,7%	19,0%
Rp. 100.000	Biner	GSTARX-FFNN(8,4,1)	52,2%	60,9%	54,7%	50,4%	24,4%	24,7%	24,1%	24,4%
Rp. 50.000	Biner	GSTARX-FFNN(8,4,1)	25,1%	28,0%	26,9%	26,1%	14,8%	17,0%	17,5%	17,1%
Rp. 20.000	Seragam	GSTARX-FFNN(8,15,1)	26,0%	27,9%	28,0%	27,9%	30,4%	35,6%	35,2%	34,4%
Rp. 10.000	Seragam	GSTARX-FFNN(8,15,1)	30,3%	35,1%	35,3%	35,3%	29,1%	36,9%	35,9%	36,9%
Rp. 5.000	Biner	GSTARX-FFNN(16,3,1)	47,9%	36,6%	49,2%	28,6%	64,2%	55,1%	76,5%	32,0%
Rp. 2.000	NIKS	GSTARX-FFNN(8,4,1)	41,9%	49,9%	64,3%	76,5%	64,9%	39,5%	71,6%	32,3%
Rp. 1.000	Invers Jarak	GSTARX-FFNN(8,3,1)	101,7%	73,3%	72,2%	48,1%	191,8%	156,6%	172,5%	64,6%
Data Outflow										
Total	Seragam	GSTARX-FFNN(16,15,1)	50,3%	43,8%	43,4%	74,6%	28,4%	26,4%	27,6%	29,2%
Rp. 100.000	Seragam	GSTARX-FFNN(16,15,1)	60,0%	257,6%	40,8%	54,9%	42,9%	30,9%	29,7%	31,6%
Rp. 50.000	NIKS	GSTARX-FFNN(8,2,1)	51,4%	116,2%	47,4%	40,4%	20,1%	23,8%	24,3%	26,3%
Rp. 20.000	KS	GSTARX-FFNN(16,5,1)	272,2%	84,6%	198,3%	160,2%	79,6%	82,9%	81,1%	81,9%
Rp. 10.000	Invers Jarak	GSTARX-FFNN(16,1,1)	78,8%	59,6%	61,2%	47,0%	92,1%	99,6%	79,7%	61,7%
Rp. 5.000	Biner	GSTARX-FFNN(8,4,1)	91,9%	73,6%	74,5%	60,7%	86,2%	84,1%	84,4%	65,2%
Rp. 2.000	Seragam	GSTARX-FFNN(8,4,1)	92,3%	95,5%	77,8%	69,9%	51,4%	88,1%	48,4%	74,9%
Rp. 1.000	Biner	GSTARX-FFNN(8,4,1)	99,8%	85,8%	87,8%	67,6%	184,0%	141,7%	163,8%	124,5%

4.2.7. Pemodelan *Hybrid GSTARX-DLNN* pada Data *Inflow* dan *Outflow*

Proses pemodelan data *inflow* dan *outflow* di KP BI Jawa Timur menggunakan model *hybrid GSTARX-DLNN* sama dengan proses pemodelan menggunakan model *hybrid GSTARX-FFNN* hanya berbeda pada model arsitektur *neural network*. Model *hybrid GSTARX-DLNN* memiliki dua *hidden layer*, pada *hidden layer* pertama jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, 5, 10, dan 15. Sedangkan pada *hidden layer* kedua jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, dan 5. Jumlah input yang digunakan menyesuaikan pada model GSTARX masing-masing data *inflow* dan *outflow* yang sudah dijelaskan pada Tabel 4. 30. Fungsi aktivasi yang digunakan pada *hidden layer* dan *output layer* sama dengan fungsi aktivasi pada model *hybrid GSTARX-FFNN*. Serta dilakukan pemodelan dengan beberapa jenis bobot lokasi.

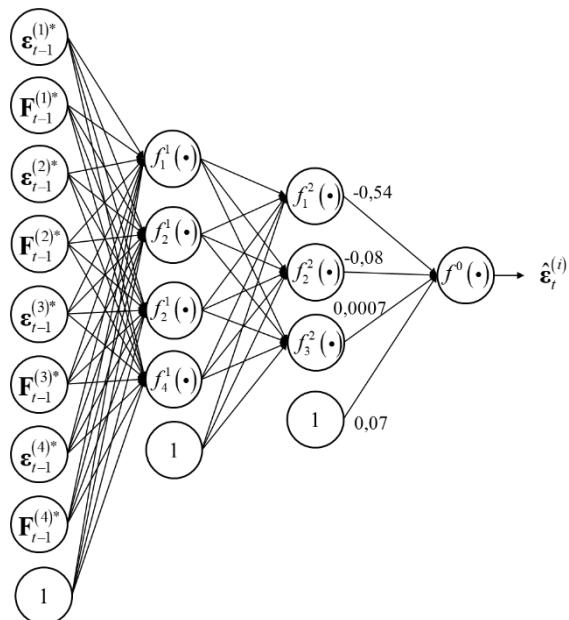
Didapatkan nilai RMSE dan sMAPE hasil pemodelan data *inflow* total menggunakan model *hybrid GSTARX-DLNN* pada masing-masing bobot lokasi yang digunakan ditunjukkan pada Tabel 4. 41.

Tabel 4. 41 Nilai RMSE dan sMAPE Model *Hybrid GSTARX-DLNN* Data *Inflow* Total

Nilai	Bobot Lokasi	Model GSTARX-DLNN	KP BI-In Sample				KP BI-Out Sample			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
RMSE	Seragam	GSTARX-DLNN(8,1,2,1)	606,09	206,82	200,80	146,63	1388,18	413,49	549,73	305,91
	Biner	GSTARX-DLNN(8,2,3,1)	608,90	219,73	211,40	143,50	1408,54	473,36	539,82	378,76
	Invers Jarak	GSTARX-DLNN(8,4,3,1)*	611,30	205,41	199,86	138,04	1399,34	417,26	546,36	320,28
	KS	GSTARX-DLNN(8,2,4,1)	603,16	206,02	201,28	133,86	1372,18	421,57	554,10	312,65
	NIKS	GSTARX-DLNN(8,15,5,1)	612,12	207,05	198,33	130,33	1419,19	435,32	528,98	339,48
sMAPE	Seragam	GSTARX-DLNN(8,1,2,1)	27,58%	25,09%	27,33%	22,57%	18,73%	18,30%	29,87%	15,97%
	Biner	GSTARX-DLNN(8,2,3,1)	29,57%	29,52%	34,75%	31,18%	18,96%	19,42%	28,76%	17,43%
	Invers Jarak	GSTARX-DLNN(8,4,3,1)*	26,94%	24,85%	27,16%	26,56%	18,84%	18,71%	29,68%	15,26%
	KS	GSTARX-DLNN(8,2,4,1)	27,12%	24,49%	25,91%	22,74%	18,53%	18,37%	30,07%	16,25%
	NIKS	GSTARX-DLNN(8,15,5,1)	27,03%	21,99%	24,97%	21,71%	18,93%	18,37%	28,99%	17,22%

*model terbaik

Berdasarkan Tabel 4. 41 dapat diketahui bahwa model *hybrid GSTARX-DLNN* terbaik adalah model dengan 8 input, 4 *neuron* pada *hidden layer* pertama, 3 *neuron* pada *hidden layer* kedua atau GSTARX-DLNN(8,4,3,1) dengan bobot lokasi terbaik adalah invers jarak.



Gambar 4. 45 Arsitektur Model *Hybrid GSTAR-DLNN(8,4,3,1)* Data *Inflow* Total

Tabel 4. 42 Hasil Estimasi Parameter Model *Hybrid GSTARX-DLNN(8,4,3,1)* Data *Inflow Total*

Predictor	Predicted							
	Hidden Layer 1			Hidden Layer 2			Output Layer	
	Neuron 1	Neuron 2	Neuron 3	Neuron 4	Neuron 1	Neuron 2	Neuron 3	Yt
<i>Input Layer</i>	(Bias)	-0,58	-0,20	0,08	-0,21			
	$\epsilon_{t-1}^{(1)*}$	-0,16	-0,40	-0,35	-0,33			
	$\epsilon_{t-1}^{(2)*}$	-0,10	-0,45	0,08	-0,14			
	$\epsilon_{t-1}^{(3)*}$	0,16	-0,30	0,14	0,25			
	$\epsilon_{t-1}^{(4)*}$	0,02	-0,25	0,11	-0,18			
	$\mathbf{F}_{t-1}^{(1)*}$	0,44	0,49	0,17	0,22			
	$\mathbf{F}_{t-1}^{(2)*}$	-0,20	0,44	0,30	0,60			
	$\mathbf{F}_{t-1}^{(3)*}$	-0,20	0,16	-0,32	0,15			
	$\mathbf{F}_{t-1}^{(4)*}$	-1,12	-0,15	-0,42	0,55			
	(Bias)				0,32	-0,28	0,19	
<i>Hidden Layer 1</i>	Neuron 1				-0,34	0,13	-0,63	
	Neuron 2				0,26	0,05	0,15	
	Neuron 3				-0,67	0,33	-0,18	
	Neuron 4				0,57	0,32	0,20	
<i>Hidden Layer 2</i>	(Bias)						0,07	
	Neuron 1						-0,54	
	Neuron 2						-0,08	
	Neuron 3						0,0007	

Berdasarkan hasil estimasi parameter model *hybrid GSTARX-DLNN(8,4,3,1)* dengan bobot invers jarak maka diperoleh persamaan sebagai berikut.

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} = \begin{bmatrix} 12,72 & 0 & 0 & 0 \\ 0 & 4,17 & 0 & 0 \\ 0 & 0 & 5,25 & 0 \\ 0 & 0 & 0 & 3,34 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} -1125,57 & 0 & 0 & 0 \\ 0 & -431,98 & 0 & 0 \\ 0 & 0 & 375,82 & 0 \\ 0 & 0 & 0 & -19,92 \end{bmatrix} \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots + \\
 \begin{bmatrix} 1406,52 & 0 & 0 & 0 \\ 0 & 527,26 & 0 & 0 \\ 0 & 0 & 652,12 & 0 \\ 0 & 0 & 0 & 425,96 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots + \\
 \begin{bmatrix} 3016,27 & 0 & 0 & 0 \\ 0 & 959,04 & 0 & 0 \\ 0 & 0 & 1076,12 & 0 \\ 0 & 0 & 0 & 560,92 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} \begin{bmatrix} \epsilon_t^{(1)} \\ \epsilon_t^{(2)} \\ \epsilon_t^{(3)} \\ \epsilon_t^{(4)} \end{bmatrix}$$

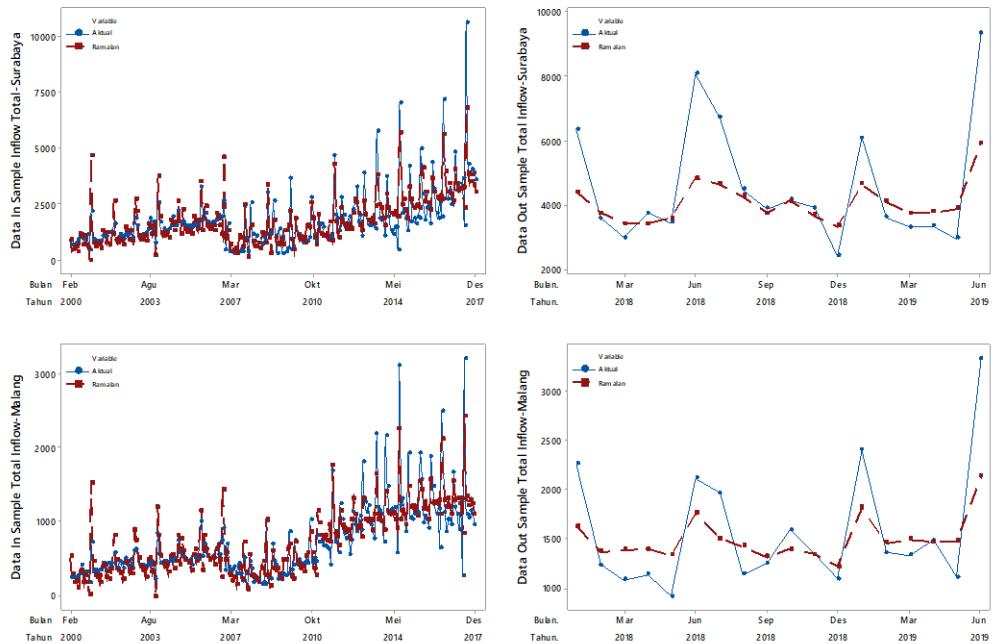
dengan

$$\hat{\epsilon}_t = 0,07 - 0,54 \times \tanh f_1^2(\bullet) - 0,08 \times \tanh f_2^2(\bullet) + 0,0007 \times \tanh f_3^2(\bullet)$$

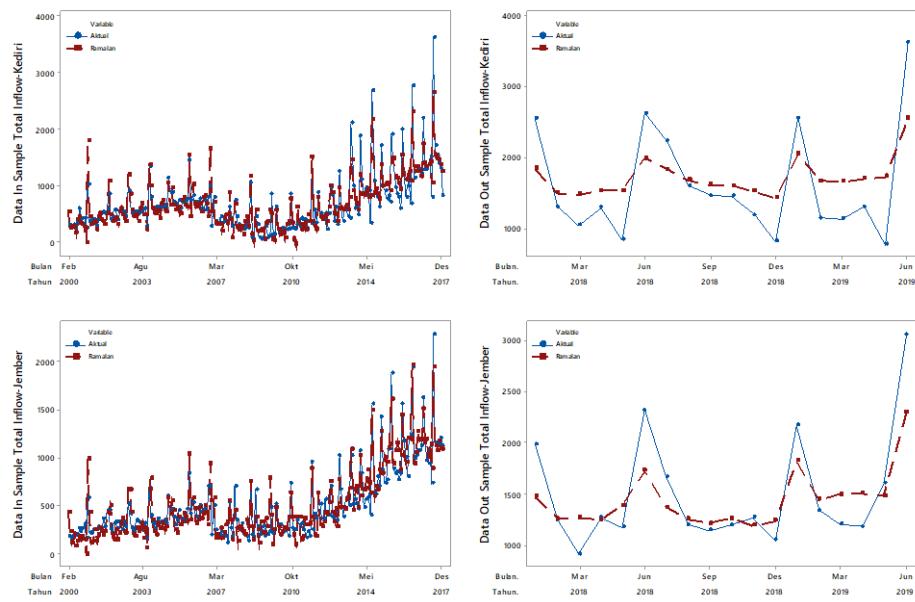
dan

$$\begin{aligned} f_1^2(\bullet) &= 0,32 - 0,34 \times \tanh f_1^1(\bullet) + 0,26 \times \tanh f_2^1(\bullet) - 0,67 \times \tanh f_3^1(\bullet) + 0,57 \times \tanh f_4^1(\bullet) \\ f_2^2(\bullet) &= -0,28 - 0,13 \times \tanh f_1^1(\bullet) + 0,05 \times \tanh f_2^1(\bullet) + 0,33 \times \tanh f_3^1(\bullet) + 0,32 \times \tanh f_4^1(\bullet) \\ f_3^2(\bullet) &= 0,19 - 0,63 \times \tanh f_1^1(\bullet) + 0,15 \times \tanh f_2^1(\bullet) - 0,18 \times \tanh f_3^1(\bullet) + 0,20 \times \tanh f_4^1(\bullet) \\ f_1^1(\bullet) &= -0,58 - 0,16\epsilon_{t-1}^{(1)*} - 0,1\epsilon_{t-1}^{(2)*} + 0,16\epsilon_{t-1}^{(3)*} + 0,02\epsilon_{t-1}^{(4)*} - 0,44F_{t-1}^{(1)*} - 0,02F_{t-1}^{(2)*} - 0,02F_{t-1}^{(3)*} - 1,12F_{t-1}^{(4)*} \\ f_2^1(\bullet) &= -0,2 - 0,4\epsilon_{t-1}^{(1)*} - 0,45\epsilon_{t-1}^{(2)*} - 0,30\epsilon_{t-1}^{(3)*} - 0,25\epsilon_{t-1}^{(4)*} - 0,49F_{t-1}^{(1)*} + 0,44F_{t-1}^{(2)*} + 0,16F_{t-1}^{(3)*} - 0,15F_{t-1}^{(4)*} \\ f_3^1(\bullet) &= 0,08 - 0,35\epsilon_{t-1}^{(1)*} + 0,08\epsilon_{t-1}^{(2)*} + 0,14\epsilon_{t-1}^{(3)*} + 0,11\epsilon_{t-1}^{(4)*} - 0,17F_{t-1}^{(1)*} + 0,30F_{t-1}^{(2)*} - 0,32F_{t-1}^{(3)*} - 0,42F_{t-1}^{(4)*} \\ f_4^1(\bullet) &= -0,21 - 0,33\epsilon_{t-1}^{(1)*} - 0,14\epsilon_{t-1}^{(2)*} + 0,25\epsilon_{t-1}^{(3)*} - 0,18\epsilon_{t-1}^{(4)*} - 0,22F_{t-1}^{(1)*} + 0,60F_{t-1}^{(2)*} + 0,15F_{t-1}^{(3)*} + 0,55F_{t-1}^{(4)*}. \end{aligned}$$

Berdasarkan Gambar 4.46 dapat diketahui bahwa hasil ramalan data *inflow* total menggunakan model *hybrid GSTARX-DLNN(8,4,3,1)* pada data *in sample* dan *out sample* sudah mampu mengikuti pola data aktual dengan baik. Jika dibandingkan *time series plot* pada data *out sample* antar KP BI di Jawa Timur, hasil ramalan data *inflow* di KP BI Surabaya, Malang, dan Kediri, memiliki hasil ramalan lebih tepat dalam mengikuti pola data aktual dibandingkan di KP BI Jember. Nilai RMSE dan sMAPE model *hybrid GSTARX-DLNN* terbaik dari keseluruhan data *inflow* dan *outflow* KP BI Jawa Timur baik dalam total maupun pecahan dapat dilihat pada Tabel 4.43 dan Tabel 4.44.



Gambar 4.46 Time Series Plot Data Inflow Total dan Hasil Ramalan Model Hybrid GSTARX-DLNN di KP BI Jawa Timur



Gambar 4.46 Time Series Plot Data Inflow Total dan Hasil Ramalan Model Hybrid GSTARX-DLNN di KP BI Jawa Timur (lanjutan)

Tabel 4.43 Nilai RMSE Model Terbaik GSTARX-DLNN Data Inflow di KP BI Jawa Timur

Data	Bobot Lokasi	GSTARX-DLNN	KP BI-In Sample				KP BI-Out Sample			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow										
Total	Invers Jarak	GSTARX-DLNN (8,4,3,1)	611,30	205,41	199,86	138,04	1399,34	417,26	546,36	320,28
Rp. 100.000	NIKS	GSTARX-DLNN (8,2,3,1)	608,39	216,52	209,19	143,27	1407,12	457,57	538,67	373,92
Rp. 50.000	KS	GSTARX-DLNN (8,3,3,1)	233,93	78,60	75,08	54,92	406,54	148,42	156,65	104,65
Rp. 20.000	Biner	GSTARX-DLNN (8,10,4,1)	23,17	6,54	7,86	5,41	48,25	8,72	23,14	10,07
Rp. 10.000	KS	GSTARX-DLNN (8,4,2,1)	19,90	5,12	8,48	4,04	43,08	7,70	20,73	6,78
Rp. 5.000	Seragam	GSTARX-DLNN (16,5,3,1)	16,52	6,39	8,88	3,36	33,01	8,19	19,10	3,28
Rp. 2.000	NIKS	GSTARX-DLNN (8,10,3,1)	7,02	1,72	3,38	1,86	13,63	2,47	6,90	1,78
Rp. 1.000	KS	GSTARX-DLNN (8,15,3,1)	8,41	2,21	3,25	1,71	5,25	1,37	1,44	0,65
Data Outflow										
Total	KS	GSTARX-DLNN (16,3,2,1)	681,58	220,05	322,98	174,15	1701,72	628,15	769,08	303,24
Rp. 100.000	Invers Jarak	GSTARX-DLNN (16,5,4,1)	355,43	139,28	213,13	125,11	1072,70	360,58	609,95	162,98
Rp. 50.000	Seragam	GSTARX-DLNN (8,10,4,1)	298,85	87,87	117,67	69,01	488,46	282,46	260,58	119,74
Rp. 20.000	Seragam	GSTARX-DLNN (16,2,5,1)	45,14	9,26	11,51	11,56	111,95	31,78	32,94	6,39
Rp. 10.000	NIKS	GSTARX-DLNN (16,1,1,1)	43,73	6,87	8,46	4,32	133,10	21,65	31,65	9,30
Rp. 5.000	Biner	GSTARX-DLNN (8,15,2,1)	42,05	6,22	6,68	2,38	72,63	13,53	19,39	6,84
Rp. 2.000	Biner	GSTARX-DLNN (8,15,2,1)	11,94	2,16	1,50	0,81	29,70	5,99	3,96	1,35
Rp. 1.000	NIKS	GSTARX-DLNN (8,3,4,1)	5,53	0,76	0,87	0,32	4,91	1,13	1,19	0,19

Tabel 4.44 Nilai sMAPE Model Terbaik GSTARX-DLNN Data *Inflow* di KP BI Jawa Timur

Data	Bobot Lokasi	GSTARX-DLNN	KP BI-In Sample				KP BI-Out Sample			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow										
Total	Invers Jarak	GSTARX-DLNN (8,4,3,1)	26,9%	24,8%	27,2%	26,6%	18,8%	18,7%	29,7%	15,3%
Rp. 100.000	NIKS	GSTARX-DLNN (8,2,3,1)	47,3%	57,4%	54,0%	59,2%	24,3%	22,2%	36,7%	22,2%
Rp. 50.000	KS	GSTARX-DLNN (8,3,3,1)	25,4%	19,0%	27,5%	22,4%	16,8%	15,3%	24,1%	16,6%
Rp. 20.000	Biner	GSTARX-DLNN (8,10,4,1)	29,5%	23,9%	25,7%	20,7%	45,1%	30,1%	53,2%	27,3%
Rp. 10.000	KS	GSTARX-DLNN (8,4,2,1)	37,1%	24,3%	33,7%	23,0%	52,2%	36,3%	54,6%	29,1%
Rp. 5.000	Seragam	GSTARX-DLNN (16,5,3,1)	46,9%	47,7%	56,2%	39,7%	63,5%	63,6%	80,1%	20,1%
Rp. 2.000	NIKS	GSTARX-DLNN (8,10,3,1)	41,9%	46,3%	64,2%	68,5%	65,1%	39,3%	70,5%	27,3%
Rp. 1.000	KS	GSTARX-DLNN (8,15,3,1)	107,6%	89,7%	89,8%	87,3%	184,3%	88,6%	156,9%	92,4%
Data Outflow										
Total	KS	GSTARX-DLNN (16,3,2,1)	30,8%	35,4%	42,8%	50,6%	30,3%	48,6%	42,9%	28,5%
Rp. 100.000	Invers Jarak	GSTARX-DLNN (16,5,4,1)	40,2%	60,9%	48,4%	81,4%	35,9%	44,5%	48,7%	30,1%
Rp. 50.000	Seragam	GSTARX-DLNN (8,10,4,1)	32,4%	34,8%	43,6%	33,7%	26,5%	43,9%	46,6%	39,6%
Rp. 20.000	Seragam	GSTARX-DLNN (16,2,5,1)	67,6%	62,7%	50,0%	60,5%	86,6%	98,6%	72,1%	51,2%
Rp. 10.000	NIKS	GSTARX-DLNN (16,1,1,1)	76,8%	56,4%	65,8%	50,2%	91,8%	88,7%	79,9%	71,0%
Rp. 5.000	Biner	GSTARX-DLNN (8,15,2,1)	90,4%	74,4%	89,9%	40,3%	83,2%	97,1%	86,9%	53,8%
Rp. 2.000	Biner	GSTARX-DLNN (8,15,2,1)	93,6%	101,9%	69,7%	56,3%	65,6%	82,3%	58,5%	54,3%
Rp. 1.000	NIKS	GSTARX-DLNN (8,3,4,1)	101,4%	94,2%	91,8%	60,8%	182,1%	168,4%	183,7%	109,8%

4.2.8. Pemodelan *Hybrid GSTARX-Jordan RNN* Pada Data *Inflow* dan *Outflow*

Pemodelan data *inflow* dan *outflow* di KP BI Jawa Timur menggunakan model *hybrid GSTARX-Jordan RNN* memiliki proses yang sama dengan pemodelan menggunakan model *hybrid GSTARX-FFNN* dan *hybrid GSTARX-DLNN*. Model *hybrid GSTARX-Jordan RNN* memiliki satu *hidden layer* dan satu *context layer* yang berisi *delay neuron* dan berfungsi untuk menyimpan kembali memori jaringan dari *output layer* yang selanjutnya diproses kembali menuju *hidden layer* dan dilanjutkan menuju *output layer*.

Pemilihan model *hybrid GSTARX-Jordan RNN* terbaik berdasarkan pada nilai RMSE dan sMAPE terkecil pada masing-masing bobot lokasi yang digunakan. Nilai RMSE dan sMAPE yang diperoleh dari pemodelan data *inflow* total dapat dilihat pada Tabel 4.45 dan Tabel 4.46.

Tabel 4.45 Nilai RMSE Pemodelan Data *inflow* Total Menggunakan Model *Hybrid GSTARX-Jordan RNN*

Bobot Lokasi	Model GSTARX-Jordan RNN	KP BI-In Sample				KP BI-Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-Jordan RNN (8,1,1)	604,10	213,08	207,95	121,55	1382,55	441,06	596,70	383,55
	GSTARX-Jordan RNN (8,2,1)	614,28	262,87	206,59	122,75	1409,86	467,48	572,11	367,21
	GSTARX-Jordan RNN (8,3,1)	608,61	216,61	208,65	137,04	1397,45	459,63	606,77	381,76
	GSTARX-Jordan RNN (8,4,1)	613,03	213,48	205,53	143,62	1375,51	400,63	634,27	306,88
	GSTARX-Jordan RNN (8,5,1)	612,62	213,60	212,86	168,40	1326,55	399,40	641,13	324,20
	GSTARX-Jordan RNN (8,10,1)	629,32	220,87	211,79	185,54	1419,97	413,43	549,35	375,38
	GSTARX-Jordan RNN (8,15,1)	622,90	216,49	216,52	191,64	1393,36	392,81	624,52	556,44
Biner	GSTARX-Jordan RNN (8,1,1)	604,85	212,83	209,30	121,40	1381,92	440,10	612,13	378,56
	GSTARX-Jordan RNN (8,2,1)	607,05	212,46	209,38	128,51	1381,59	441,03	613,93	378,41
	GSTARX-Jordan RNN (8,3,1)	609,02	218,31	209,22	149,91	1406,07	492,74	595,22	450,98
	GSTARX-Jordan RNN (8,4,1)	616,01	212,32	202,43	196,95	1425,03	452,23	592,05	414,50
	GSTARX-Jordan RNN (8,5,1)	607,05	212,46	209,38	128,51	1381,59	441,03	613,93	378,41
	GSTARX-Jordan RNN (8,10,1)	618,55	217,21	233,31	200,17	1176,55	519,34	643,38	462,57
	GSTARX-Jordan RNN (8,15,1)	618,76	216,82	278,88	251,40	1294,92	484,30	891,65	1168,27
Invers Jarak	GSTARX-Jordan RNN (8,1,1)	604,55	212,91	208,84	121,53	1382,65	441,38	592,44	383,82
	GSTARX-Jordan RNN (8,2,1)	617,00	274,42	208,15	123,00	1429,41	462,00	567,47	386,51
	GSTARX-Jordan RNN (8,3,1)	608,92	277,10	213,05	130,41	1398,10	466,26	613,53	365,96
	GSTARX-Jordan RNN (8,4,1)	613,50	212,02	205,66	154,76	1390,59	406,09	650,97	315,95
	GSTARX-Jordan RNN (8,5,1)	617,00	274,42	208,15	123,00	1429,41	462,00	567,47	386,51
	GSTARX-Jordan RNN (8,10,1)	617,49	230,71	212,02	237,75	1426,68	509,97	537,03	301,72
	GSTARX-Jordan RNN (8,15,1)	643,35	240,60	213,30	306,83	1490,71	351,69	633,01	786,85
Korelasi Silang (KS)	GSTARX-Jordan RNN (8,1,1)	604,56	212,81	209,24	121,21	1382,63	441,22	588,14	378,98
	GSTARX-Jordan RNN (8,2,1)	616,66	271,88	206,90	121,40	1433,02	464,89	561,79	368,16
	GSTARX-Jordan RNN (8,3,1)	608,81	269,40	210,72	131,09	1397,70	470,85	606,66	369,24
	GSTARX-Jordan RNN (8,4,1)	611,36	211,71	204,53	146,79	1388,40	400,07	634,63	314,92
	GSTARX-Jordan RNN (8,5,1)	616,66	271,88	206,90	121,40	1433,02	464,89	561,79	368,16
	GSTARX-Jordan RNN (8,10,1)*	621,62	221,45	213,93	155,72	1410,14	348,08	678,29	340,39
	GSTARX-Jordan RNN (8,15,1)	638,40	337,94	212,54	178,99	1431,64	640,19	830,16	430,75
Normalisasi Inferensi Korelasi Silang (NIKS)	GSTARX-Jordan RNN (8,1,1)	604,84	212,35	216,46	121,28	1382,25	441,50	556,54	378,35
	GSTARX-Jordan RNN (8,2,1)	616,26	278,98	212,91	122,61	1418,80	461,03	551,04	387,65
	GSTARX-Jordan RNN (8,3,1)	609,82	283,97	215,25	136,10	1402,60	464,06	556,22	368,08
	GSTARX-Jordan RNN (8,4,1)	608,12	264,92	212,83	125,59	1379,78	436,96	617,84	382,69
	GSTARX-Jordan RNN (8,5,1)	616,26	278,98	212,91	122,61	1418,80	461,03	551,04	387,65
	GSTARX-Jordan RNN (8,10,1)	618,40	225,53	205,92	144,89	1384,72	394,90	717,75	896,46
	GSTARX-Jordan RNN (8,15,1)	626,04	217,99	209,87	193,43	1399,16	447,72	705,59	486,68

*model terbaik

Tabel 4.46 Nilai sMAPE Pemodelan Data *Inflow* Total Menggunakan Model *Hybrid GSTARX-Jordan RNN*

Bobot Lokasi	Model GSTARX-Jordan RNN	KP BI-In Sample				KP BI-Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-Jordan RNN (8,1,1)	27,1%	24,6%	27,6%	19,2%	18,7%	18,9%	32,7%	18,5%
	GSTARX-Jordan RNN (8,2,1)	27,2%	29,2%	27,7%	19,3%	18,5%	20,5%	30,6%	17,9%
	GSTARX-Jordan RNN (8,3,1)	27,1%	24,3%	25,2%	22,3%	18,8%	19,8%	33,7%	19,3%
	GSTARX-Jordan RNN (8,4,1)	27,3%	25,3%	27,3%	20,1%	18,8%	20,0%	30,7%	17,4%
	GSTARX-Jordan RNN (8,5,1)	27,3%	26,4%	27,2%	25,6%	18,5%	19,8%	30,8%	18,2%
	GSTARX-Jordan RNN (8,10,1)	27,1%	25,6%	26,1%	29,5%	19,1%	21,0%	29,5%	20,6%
	GSTARX-Jordan RNN (8,15,1)	26,8%	24,9%	27,1%	30,7%	19,9%	19,8%	29,7%	25,6%
	GSTARX-Jordan RNN (8,1,1)	27,2%	24,6%	27,4%	19,1%	18,7%	18,9%	34,3%	18,5%
Biner	GSTARX-Jordan RNN (8,2,1)	27,3%	24,5%	27,3%	20,0%	18,7%	19,0%	34,3%	19,0%
	GSTARX-Jordan RNN (8,3,1)	27,2%	25,6%	25,8%	22,4%	18,7%	25,1%	33,3%	23,3%
	GSTARX-Jordan RNN (8,4,1)	27,2%	24,8%	26,4%	23,5%	18,8%	21,1%	30,2%	22,7%
	GSTARX-Jordan RNN (8,5,1)	27,3%	24,5%	27,3%	20,0%	18,7%	19,0%	34,3%	19,0%
	GSTARX-Jordan RNN (8,10,1)	27,0%	24,6%	27,5%	25,4%	17,1%	25,0%	34,5%	21,7%
	GSTARX-Jordan RNN (8,15,1)	27,0%	25,0%	31,2%	27,0%	17,6%	23,1%	43,1%	72,2%
	GSTARX-Jordan RNN (8,1,1)	27,2%	24,6%	27,5%	19,2%	18,7%	18,9%	32,1%	18,5%
	GSTARX-Jordan RNN (8,2,1)	27,3%	30,3%	27,8%	19,3%	18,7%	19,8%	29,9%	19,0%
Invers Jarak	GSTARX-Jordan RNN (8,3,1)	27,1%	30,0%	25,5%	21,4%	18,8%	20,5%	34,0%	17,6%
	GSTARX-Jordan RNN (8,4,1)	27,3%	25,4%	27,4%	21,1%	19,5%	19,5%	31,0%	17,9%
	GSTARX-Jordan RNN (8,5,1)	27,3%	30,3%	27,8%	19,3%	18,7%	19,8%	29,9%	19,0%
	GSTARX-Jordan RNN (8,10,1)	26,8%	26,5%	27,2%	30,9%	18,8%	25,1%	30,4%	18,0%
	GSTARX-Jordan RNN (8,15,1)	27,4%	27,5%	26,4%	28,8%	23,5%	18,6%	29,8%	32,4%
	GSTARX-Jordan RNN (8,1,1)	27,2%	24,5%	27,4%	19,1%	18,7%	18,9%	32,1%	18,4%
	GSTARX-Jordan RNN (8,2,1)	27,3%	30,0%	27,4%	19,2%	18,8%	20,1%	30,4%	18,0%
	GSTARX-Jordan RNN (8,3,1)	27,1%	29,4%	25,2%	22,0%	18,9%	20,7%	33,6%	18,4%
Korelasi Silang (KS)	GSTARX-Jordan RNN (8,4,1)	27,3%	25,3%	27,2%	20,0%	19,4%	19,6%	30,7%	17,8%
	GSTARX-Jordan RNN (8,5,1)	27,3%	30,0%	27,4%	19,2%	18,8%	20,1%	30,4%	18,0%
	GSTARX-Jordan RNN (8,10,1)*	27,1%	25,3%	27,6%	23,4%	19,0%	18,0%	28,8%	19,0%
	GSTARX-Jordan RNN (8,15,1)	27,7%	33,1%	28,0%	29,4%	19,4%	29,4%	48,1%	22,7%
	GSTARX-Jordan RNN (8,1,1)	27,1%	24,3%	27,2%	19,0%	18,7%	19,0%	30,6%	18,6%
	GSTARX-Jordan RNN (8,2,1)	27,4%	30,4%	27,1%	19,2%	18,6%	20,1%	29,7%	19,0%
	GSTARX-Jordan RNN (8,3,1)	27,1%	30,4%	25,9%	25,2%	18,9%	20,5%	30,1%	17,5%
	GSTARX-Jordan RNN (8,4,1)	27,2%	29,6%	26,8%	19,7%	19,0%	20,8%	32,8%	19,9%
Normalisasi Inferensi Korelasi Silang (NIKSP)	GSTARX-Jordan RNN (8,5,1)	27,4%	30,4%	27,1%	19,2%	18,6%	20,1%	29,7%	19,0%
	GSTARX-Jordan RNN (8,10,1)	27,1%	26,6%	27,1%	22,7%	18,2%	19,9%	35,8%	32,0%
	GSTARX-Jordan RNN (8,15,1)	26,8%	24,3%	25,8%	35,5%	18,2%	19,7%	30,6%	23,8%

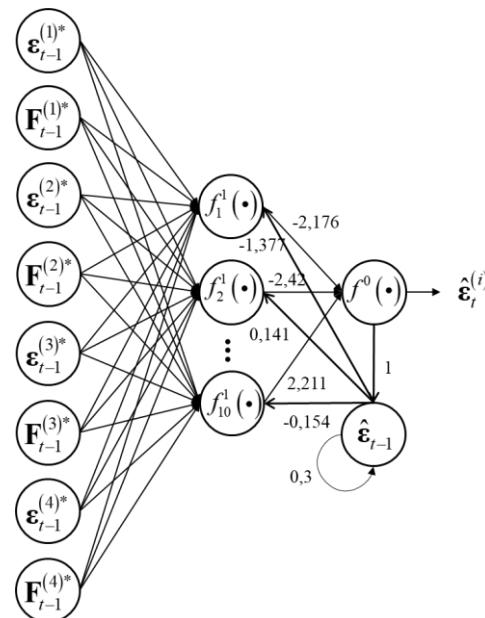
*model terbaik

Berdasarkan tabel tersebut dapat diketahui bahwa nilai RMSE dan sMAPE model *hybrid* GSTARX-Jordan RNN data *inflow* total, dapat diketahui bahwa model terbaik untuk data *inflow* total adalah dengan delapan input, 10 *neuron* pada *hidden layer* atau dinotasikan GSTARX-Jordan RNN(8,10,1) dan bobot lokasi yang digunakan adalah KS.

Tabel 4. 47 Hasil Estimasi Koefisien Model GSTARX-Jordan RNN(8,10,1) Data *Inflow* Total

Predictor	Predicted					Context Unit	Output Layer
	Neuron 1	Neuron 2	...	Neuron 9	Neuron 10		
<i>Input Layer</i>	$\boldsymbol{\varepsilon}_{t-1}^{(1)*}$	2,133	-2,031	...	-0,644	1,537	
	$\boldsymbol{\varepsilon}_{t-1}^{(2)*}$	-0,355	5,371	...	-0,764	-1,864	
	$\boldsymbol{\varepsilon}_{t-1}^{(3)*}$	-4,425	-1,281	...	0,378	-3,774	
	$\boldsymbol{\varepsilon}_{t-1}^{(4)*}$	2,632	0,102	...	2,419	1,718	
	$\mathbf{F}_{t-1}^{(1)*}$	2,391	-2,275	...	0,453	-0,920	
	$\mathbf{F}_{t-1}^{(2)*}$	1,482	-0,630	...	1,539	1,970	
	$\mathbf{F}_{t-1}^{(3)*}$	0,480	3,618	...	0,399	3,490	
	$\mathbf{F}_{t-1}^{(4)*}$	-4,985	-2,051	...	-0,906	-2,128	
<i>Hidden Layer</i>	Neuron 1						-2,176
	Neuron 2						-2,420

	Neuron 9						-3,500
	Neuron 10						1,278
<i>Context Unit</i>	-1,377	0,141	...	0,174	-0,154	0,300	
<i>Output Layer</i> (Yt)						1	



Gambar 4. 47 Arsitektur Model *Hybrid* GSTAR-Jordan RNN(8,10,1)

Berdasarkan hasil estimasi parameter model *hybrid* GSTARX-Jordan RNN(8,10,1) dengan bobot KS maka diperoleh persamaan sebagai berikut.

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \\ Y_t^{(4)} \end{bmatrix} = \begin{bmatrix} 12,72 & 0 & 0 & 0 \\ 0 & 4,17 & 0 & 0 \\ 0 & 0 & 5,25 & 0 \\ 0 & 0 & 0 & 3,34 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} -1125,57 & 0 & 0 & 0 \\ 0 & -431,98 & 0 & 0 \\ 0 & 0 & 375,82 & 0 \\ 0 & 0 & 0 & -19,92 \end{bmatrix} \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 1406,52 & 0 & 0 & 0 \\ 0 & 527,26 & 0 & 0 \\ 0 & 0 & 652,12 & 0 \\ 0 & 0 & 0 & 425,96 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots +$$

$$\begin{bmatrix} 3016,27 & 0 & 0 & 0 \\ 0 & 959,04 & 0 & 0 \\ 0 & 0 & 1076,12 & 0 \\ 0 & 0 & 0 & 560,92 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} \varepsilon_t^{(1)} \\ \varepsilon_t^{(2)} \\ \varepsilon_t^{(3)} \\ \varepsilon_t^{(4)} \end{bmatrix}$$

dengan

$$\hat{\boldsymbol{\varepsilon}}_t = -2,176 \times \tanh f_1^1(\bullet) - 2,42 \times \tanh f_2^1(\bullet) + \dots - 3,5 \times \tanh f_9^1(\bullet) + 1,278 \times \tanh f_{10}^1(\bullet)$$

dan

$$f_1^1(\bullet) = 2,133\boldsymbol{\varepsilon}_{t-1}^{(1)*} - 0,355\boldsymbol{\varepsilon}_{t-1}^{(2)*} - 4,425\boldsymbol{\varepsilon}_{t-1}^{(3)*} + 2,632\boldsymbol{\varepsilon}_{t-1}^{(4)*} + 2,391\mathbf{F}_{t-1}^{(1)*} + 1,482\mathbf{F}_{t-1}^{(2)*} + 0,48\mathbf{F}_{t-1}^{(3)*} - 4,985\mathbf{F}_{t-1}^{(4)*} - 1,377\hat{\boldsymbol{\varepsilon}}_{t-1}$$

$$f_2^1(\bullet) = -2,031\boldsymbol{\varepsilon}_{t-1}^{(1)*} + 5,371\boldsymbol{\varepsilon}_{t-1}^{(2)*} - 1,281\boldsymbol{\varepsilon}_{t-1}^{(3)*} + 0,102\boldsymbol{\varepsilon}_{t-1}^{(4)*} - 2,275\mathbf{F}_{t-1}^{(1)*} - 0,63\mathbf{F}_{t-1}^{(2)*} + 3,618\mathbf{F}_{t-1}^{(3)*} - 2,051\mathbf{F}_{t-1}^{(4)*} + 0,141\hat{\boldsymbol{\varepsilon}}_{t-1}$$

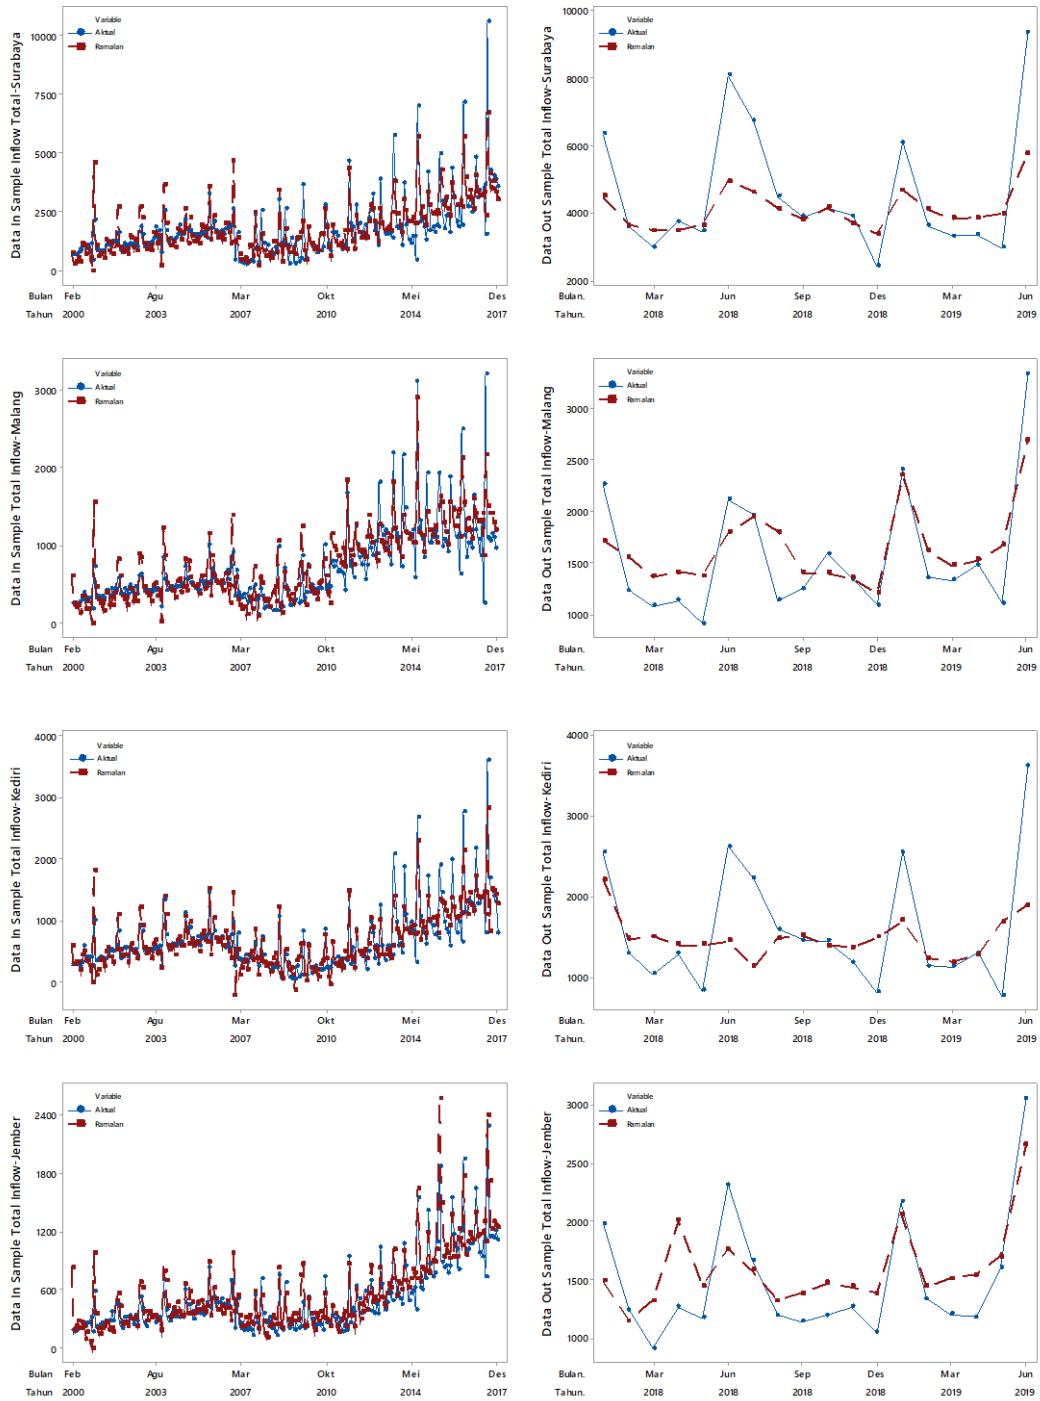
:

$$f_9^1(\bullet) = -0,644\boldsymbol{\varepsilon}_{t-1}^{(1)*} - 0,764\boldsymbol{\varepsilon}_{t-1}^{(2)*} + 0,378\boldsymbol{\varepsilon}_{t-1}^{(3)*} + 2,419\boldsymbol{\varepsilon}_{t-1}^{(4)*} + 0,453\mathbf{F}_{t-1}^{(1)*} + 1,539\mathbf{F}_{t-1}^{(2)*} + 0,399\mathbf{F}_{t-1}^{(3)*} - 0,906\mathbf{F}_{t-1}^{(4)*} + 0,174\hat{\boldsymbol{\varepsilon}}_{t-1}$$

$$f_{10}^1(\bullet) = 1,537\boldsymbol{\varepsilon}_{t-1}^{(1)*} - 1,864\boldsymbol{\varepsilon}_{t-1}^{(2)*} - 3,774\boldsymbol{\varepsilon}_{t-1}^{(3)*} + 1,718\boldsymbol{\varepsilon}_{t-1}^{(4)*} - 0,92\mathbf{F}_{t-1}^{(1)*} + 1,97\mathbf{F}_{t-1}^{(2)*} + 3,49\mathbf{F}_{t-1}^{(3)*} - 2,128\mathbf{F}_{t-1}^{(4)*} - 0,154\hat{\boldsymbol{\varepsilon}}_{t-1}.$$

Berdasarkan Gambar 4. 48 dapat diketahui bahwa hasil ramalan data *inflow* total menggunakan model *hybrid* GSTARX-Jordan RNN(8,10,1) pada data *in sample* sudah cukup mampu mengikuti pola data aktual dengan baik. Jika dibandingkan *time series plot* pada data *out sample* antar KP BI di Jawa Timur, hasil ramalan data *inflow* di KP BI Surabaya memiliki hasil ramalan yang lebih tepat dalam mengikuti pola data aktual dibandingkan di KP BI Malang, Kediri, dan Jember. Nilai RMSE dan sMAPE model *hybrid* GSTARX-Jordan RNN terbaik

dari keseluruhan data *inflow* dan *outflow* KP BI Jawa Timur baik dalam total maupun pecahan dapat dilihat pada Tabel 4.48 dan Tabel 4.49.



Gambar 4. 48 Time Series Plot Data *inflow* Total dan Hasil Ramalan Menggunakan Model Hybrid GSTARX-Jordan RNN

Tabel 4. 48 Nilai RMSE Model Terbaik dari Model GSTARX-Jordan RNN

Data	Bobot Lokasi	GSTARX-Jordan RNN	KP BI-In Sample				KP BI-Out Sample			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow										
Total	KS	GSTARX-Jordan RNN(8,10,1)	618,40	225,53	205,92	144,89	1384,72	394,90	717,75	896,46
Rp. 100.000	Invers Jarak	GSTARX-Jordan RNN(8,1,1)	406,26	141,50	145,63	93,76	891,76	237,62	395,44	260,88
Rp. 50.000	Invers Jarak	GSTARX-Jordan RNN(8,3,1)	234,05	80,58	72,92	60,72	422,51	148,35	144,25	105,62
Rp. 20.000	Biner	GSTARX-Jordan RNN(8,10,1)	26,34	8,83	9,97	13,20	51,42	8,71	24,47	15,02
Rp. 10.000	Invers Jarak	GSTARX-Jordan RNN(8,1,1)	19,96	5,30	8,80	6,82	43,37	8,30	21,12	9,56
Rp. 5.000	Seragam	GSTARX-Jordan RNN(16,3,1)	16,77	6,48	9,68	9,28	33,77	6,73	17,03	7,99
Rp. 2.000	KS	GSTARX-Jordan RNN(8,1,1)	6,97	1,78	3,36	2,28	13,90	2,67	8,11	1,99
Rp. 1.000	KS	GSTARX-Jordan RNN(8,3,1)	8,98	4,02	4,06	2,03	5,89	1,66	1,84	0,28
Data Outflow										
Total	NIKS	GSTARX-Jordan RNN(16,2,1)	678,20	216,69	335,33	181,73	1668,45	644,16	808,49	306,99
Rp. 100.000	Biner	GSTARX-Jordan RNN(16,1,1)	361,09	135,93	221,07	115,82	1071,81	387,58	646,86	252,08
Rp. 50.000	Invers Jarak	GSTARX-Jordan RNN(8,3,1)	301,53	85,93	119,97	81,43	511,62	295,83	259,01	136,74
Rp. 20.000	Biner	GSTARX-Jordan RNN(16,1,1)	45,20	8,80	11,92	11,53	113,46	31,97	33,82	7,62
Rp. 10.000	Biner	GSTARX-Jordan RNN(16,1,1)	43,79	7,66	7,74	5,03	129,94	23,35	29,94	9,38
Rp. 5.000	Biner	GSTARX-Jordan RNN(8,1,1)	42,93	6,61	6,35	2,50	72,63	13,04	18,57	6,32
Rp. 2.000	Invers Jarak	GSTARX-Jordan RNN(8,2,1)	11,95	2,07	5,64	1,92	29,84	17,61	14,73	6,99
Rp. 1.000	NIKS	GSTARX-Jordan RNN(8,2,1)	5,64	0,79	0,87	0,47	4,87	1,11	1,18	0,34

Tabel 4. 49 Nilai sMAPE Model Terbaik dari Model GSTARX-Jordan RNN

Data	Bobot Lokasi	Model GSTARX-Jordan RNN	KP BI-In Sample				KP BI-Out Sample			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow										
Total	KS	GSTARX-Jordan RNN (8,10,1)	27,1%	25,3%	27,6%	23,4%	19,0%	18,0%	28,8%	19,0%
Rp. 100.000	Invers Jarak	GSTARX-Jordan RNN (8,1,1)	41,8%	46,3%	43,5%	48,4%	24,2%	22,7%	33,4%	24,3%
Rp. 50.000	Invers Jarak	GSTARX-Jordan RNN (8,3,1)	25,2%	19,9%	28,2%	21,1%	17,7%	15,6%	24,1%	15,9%
Rp. 20.000	Biner	GSTARX-Jordan RNN (8,10,1)	35,0%	32,8%	32,1%	39,3%	34,7%	37,3%	64,4%	43,8%
Rp. 10.000	Invers Jarak	GSTARX-Jordan RNN (8,1,1)	37,1%	26,3%	37,4%	56,7%	52,3%	40,0%	55,1%	49,2%
Rp. 5.000	Seragam	GSTARX-Jordan RNN (16,3,1)	46,6%	66,3%	58,1%	138,8%	65,0%	43,4%	66,2%	47,0%
Rp. 2.000	KS	GSTARX-Jordan RNN (8,1,1)	40,4%	46,7%	63,0%	94,2%	65,3%	42,3%	77,6%	36,8%
Rp. 1.000	KS	GSTARX-Jordan RNN (8,3,1)	119,6%	120,8%	101,7%	100,6%	187,3%	125,3%	128,1%	57,6%

Tabel 4.49 Nilai sMAPE Model Terbaik dari Model GSTARX-Jordan RNN (lanjutan)

Data	Bobot Lokasi	Model GSTARX-Jordan RNN	KP BI-In Sample				KP BI-Out Sample			
			Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Data Inflow										
Total	NIKS	GSTARX-Jordan RNN (16,2,1)	30,0%	34,8%	39,8%	36,1%	29,1%	48,7%	43,4%	40,2%
Rp. 100.000	Biner	GSTARX-Jordan RNN (16,1,1)	38,3%	57,4%	47,9%	77,6%	35,5%	50,7%	50,3%	40,1%
Rp. 50.000	Invers Jarak	GSTARX-Jordan RNN (8,3,1)	32,9%	31,7%	43,1%	42,5%	28,1%	43,0%	47,2%	38,0%
Rp. 20.000	Biner	GSTARX-Jordan RNN (16,1,1)	66,8%	60,0%	46,0%	47,7%	84,0%	102,9%	78,6%	60,5%
Rp. 10.000	Biner	GSTARX-Jordan RNN (16,1,1)	76,0%	73,1%	58,0%	51,1%	93,2%	110,0%	90,5%	70,7%
Rp. 5.000	Biner	GSTARX-Jordan RNN (8,1,1)	93,5%	94,7%	88,5%	47,1%	85,1%	96,6%	86,1%	44,0%
Rp. 2.000	Invers Jarak	GSTARX-Jordan RNN (8,2,1)	94,1%	81,1%	43,7%	163,8%	62,1%	101,9%	62,3%	93,8%
Rp. 1.000	NIKS	GSTARX-Jordan RNN (8,2,1)	99,5%	99,5%	87,4%	75,5%	184,8%	169,0%	159,1%	130,2%

4.2.9. Pemilihan Model Terbaik untuk Meramalkan Data *Inflow* dan *Outflow* di Provinsi Jawa Timur

Setelah dilakukan pemodelan data *inflow* dan *outflow* menggunakan beberapa metode yang sudah dijelaskan sebelumnya, maka dilakukan pemilihan model yang memiliki performa terbaik dalam meramalkan data *inflow* dan *outflow* baik dalam total maupun masing-masing pecahan. Perbandingan kriteria kebaikan model dilakukan menggunakan nilai sMAPE secara keseluruhan di KP BI Jawa Timur. Pemilihan model terbaik ini dilakukan dengan cara dilihat berdasarkan rata-rata nilai sMAPE dari keseluruhan KP BI di Jawa Timur dan juga dilihat dari nilai sMAPE pada masing-masing KP BI di Jawa Timur. Berikut ini adalah hasil perhitungan rata-rata RMSE dan sMAPE terkecil.

Tabel 4. 50 Rata-rata Nilai sMAPE Pemodelan Data *Inflow* dan *Outflow* di KP BI Jawa Timur

Pecahan	Model Naïve Musiman	Model TSR	Model ARIMA X	Model GSTAR X	Model GSTARX -FFNN	Model GSTARX -DLNN	Model GSTARX-Jordan RNN
Data <i>Inflow</i>	Total	28,4%	21,7%	19,4%	22,4%	18,4%*	20,6%
	Rp. 100.000,-	31,9%	27,4%	25,6%	27,3%	24,4%*	26,3%
	Rp. 50.000,-	27,5%	19,1%	18,7%	17,6%	16,6%*	18,2%
	Rp. 20.000,-	71,6%	41,9%	40,8%	34,4%	33,9%*	38,9%
	Rp. 10.000,-	81,6%	49,8%	31,8%*	38,3%	34,7%	43,1%
	Rp. 5.000,-	92,4%	66,9%	59,2%	41,4%*	57,0%	56,8%
	Rp. 2.000,-	88,2%	53,6%	57,6%	48,9%	52,1%	50,6%*
	Rp. 1.000,-	59,1%*	151,5%	123,1%	91,3%	146,4%	130,6%
Data <i>Outflow</i>	Total	51,7%	41,6%	32,5%	39,2%	27,9%*	37,6%
	Rp. 100.000,-	50,0%	44,0%	37,2%	40,3%	33,8%*	39,8%
	Rp. 50.000,-	56,7%	40,4%	37,3%	38,6%	23,6%*	39,1%
	Rp. 20.000,-	139,8%	79,7%	79,8%	79,4%	81,4%	77,1%*
	Rp. 10.000,-	132,6%	88,1%	81,1%	76,6%*	83,3%	82,9%
	Rp. 5.000,-	132,3%	84,9%	75,5%*	76,6%	80,0%	80,3%
	Rp. 2.000,-	129,1%	65,2%	63,9%	66,8%	65,7%	65,2%*
	Rp. 1.000,-	97,1%*	174,4%	168,1%	170,0%	153,5%	161,0%

*model terbaik

Tabel 4.50 menunjukkan nilai rata-rata sMAPE yang diperoleh dari masing-masing pemodelan data *inflow* dan *outflow* di KP BI Jawa Timur cukup bervariasi. Model terbaik untuk data *inflow* dan *outflow* dalam total maupun pecahan ditunjukkan pada Tabel 4.51. Sebagian besar model terbaik yang terpilih merupakan model *hybrid* yang terdiri dari model *hybrid* GSTARX-FFNN, dan GSTARX-DLNN, sehingga dapat dinyatakan bahwa model *hybrid* memiliki performa lebih baik dalam menangkap pola data *inflow* dan *outflow* di KP BI Jawa Timur. Jika dibandingkan kebaikan ketiga model *hybrid* tersebut, model *hybrid* GSTARX-Jordan RNN tidak terpilih sebagai model terbaik dalam memodelkan data *inflow* dan *outflow* baik dalam total maupun pecahan. Connor, Atlas, dan Martin (1992) menyatakan bahwa *recurrent networks* adalah *nonlinier neural networks* yang serupa dengan model ARMA linier. Sehingga model RNN sangat cocok digunakan untuk data *time series* yang mengandung komponen model *moving average* (MA). Sedangkan data residual model TSR *inflow* dan *outflow* dalam total maupun pecahan di KP BI Jawa Timur hanya mengandung komponen *autoregressive* (AR), hal ini dibuktikan pada proses pemodelan ARIMAX dan dapat dilihat pada Tabel 4. 25 dan Tabel 4. 26.

Tabel 4. 51 Model Terbaik Data *Inflow* dan *Outflow* di KP BI Jawa Timur

Data	Pecahan	Model Terbaik	Bobot Lokasi
<i>Inflow</i>	Total	<i>Hybrid GSTARX-FFNN(8,4,1)</i>	NIKS
	Rp. 100.000,-	<i>Hybrid GSTARX-FFNN(8,1,1)</i>	Biner
	Rp. 50.000,-	<i>Hybrid GSTARX-FFNN(8,1,1)</i>	Biner
	Rp. 20.000,-	<i>Hybrid GSTARX-FFNN(8,15,1)</i>	Seragam
	Rp. 10.000,-	ARIMAX	-
	Rp. 5.000,-	GSTARX ([1,12] ₁)	KS
	Rp. 2.000,-	<i>Hybrid GSTARX-DLNN(8,10,3,1)</i>	NIKS
	Rp. 1.000,-	Naïve Musiman	-
<i>Outflow</i>	Total	<i>Hybrid GSTARX-FFNN(16,15,1)</i>	Seragam
	Rp. 100.000,-	<i>Hybrid GSTARX-FFNN(16,15,1)</i>	Seragam
	Rp. 50.000,-	<i>Hybrid GSTARX-FFNN(8,2,1)</i>	NIKS
	Rp. 20.000,-	<i>Hybrid GSTARX-DLNN(16,2,5,1)</i>	Seragam
	Rp. 10.000,-	GSTARX ([1,12] ₁)	Invers Jarak
	Rp. 5.000,-	ARIMAX	-
	Rp. 2.000,-	<i>Hybrid GSTARX-DLNN(8,15,2,1)</i>	Biner
	Rp. 1.000,-	Naïve Musiman	-

Jika dilihat model terbaik yang terpilih berdasarkan pecahan uang pada data *inflow* dan *outflow* di KP BI Jawa Timur, uang pecahan kecil cenderung lebih baik dimodelkan menggunakan model univariat yang tidak menghiraukan efek spasial atau dependensi lokasi. Hal ini dikarenakan data *inflow* dan *outflow* untuk uang pecahan kecil cenderung tidak memiliki pola yang kompleks seperti pada data *inflow* dan *outflow* total serta uang pecahan besar. Kecuali untuk pecahan Rp. 2.000 dengan model terbaik yaitu model *hybrid GSTARX-DLNN*, hal ini dikarenakan data pecahan Rp. 2.000,- pada *inflow* dan *outflow* memiliki jumlah data yang berbeda dengan pecahan uang lainnya. Perbedaan ini dikarenakan mulai beredarnya uang pecahan Rp. 2.000,- ini berbeda dengan pecahan uang lainnya. Pecahan uang Rp. 2.000,- baru mulai beredar pada akhir tahun 2009, sehingga data yang digunakan mulai tahun 2010 hingga pertengahan tahun 2019.

Model terbaik yang terpilih untuk meramalkan uang pecahan Rp. 1.000 *inflow* dan *outflow* adalah model naïve musiman yang merupakan model paling sederhana pada penelitian ini. Selain dikarenakan uang pecahan Rp. 1.000 tidak memiliki pola data yang kompleks, hal ini juga dikarenakan data *inflow* maupun

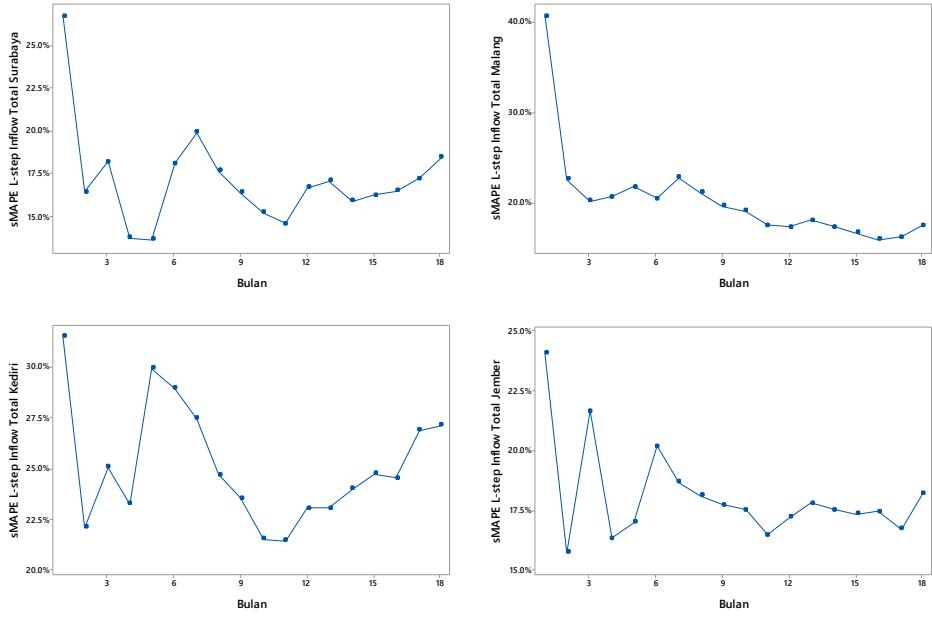
outflow untuk pecahan Rp. 1.000 sangat kecil dan mendekati 0 dalam satuan miliar rupiah. Hal ini dikarenakan saat ini penggunaan uang kertas pecahan Rp. 1.000,- semakin berkurang.

Tabel 4. 52 Rasio Rata-rata sMAPE dari Pemodelan Data *Inflow* dan *Outflow*

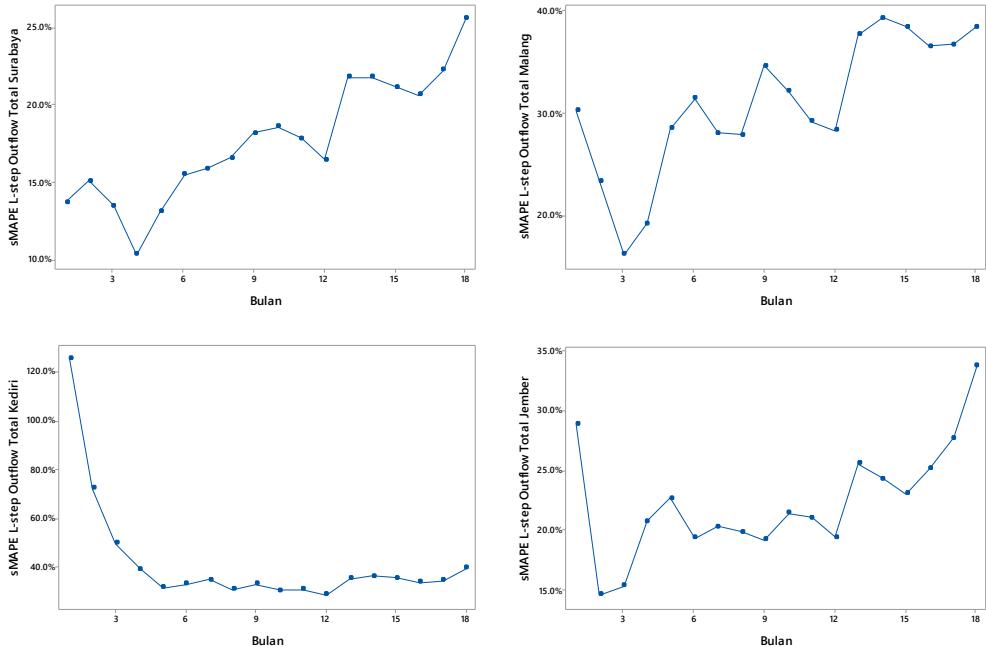
	Pecahan	Model TSR	Model GSTARX	Model GSTARX-FFNN	Model GSTARX-DLNN	Model GSTARX-Jordan RNN
Data <i>Inflow</i>	Total	1	1,03	0,85	0,95	0,98
	Rp. 100.000,-	1	0,99	0,89	0,96	0,95
	Rp. 50.000,-	1	0,92	0,87	0,95	0,96
	Rp. 20.000,-	1	0,82	0,81	0,93	1,07
	Rp. 10.000,-	1	0,77	0,70	0,86	0,99
	Rp. 5.000,-	1	0,62	0,85	0,85	0,83
	Rp. 2.000,-	1	0,91	0,97	0,94	1,03
	Rp. 1.000,-	1	0,60	0,97	0,86	0,82
Data <i>Outflow</i>	Total	1	0,94	0,67	0,90	0,97
	Rp. 100.000,-	1	0,92	0,77	0,91	0,97
	Rp. 50.000,-	1	0,96	0,59	0,97	0,97
	Rp. 20.000,-	1	1,00	1,02	0,97	1,02
	Rp. 10.000,-	1	0,87	0,95	0,94	1,03
	Rp. 5.000,-	1	0,90	0,94	0,95	0,92
	Rp. 2.000,-	1	1,03	1,01	1,00	1,23
	Rp. 1.000,-	1	0,97	0,88	0,92	0,92

Tabel 4. 52 menunjukkan rasio rata-rata sMAPE dari model GSTARX dan model *hybrid* terhadap model TSR. Berdasarkan tabel tersebut dapat diketahui bahwa reduksi nilai sMAPE terhadap model TSR untuk metode GSTARX, *hybrid* GSTARX-FFNN, *hybrid* GSTARX-DLNN, dan *hybrid* GSTARX-Jordan RNN memiliki nilai rasio sMAPE yang lebih kecil dari rasio sMAPE model TSR. Namun pada sebagian besar model *hybrid* memiliki rasio rata-rata sMAPE lebih kecil dibandingkan model GSTARX. Nilai rasio sMAPE merupakan persentase dari reduksi nilai sMAPE model lain terhadap model TSR. Dimisalkan pada data *inflow* total dapat diketahui bahwa model *hybrid* GSTARX-FFNN, GSTARX-DLNN, dan GSTARX-Jordan RNN mampu mereduksi sMAPE model TSR berturut-turut sebesar 15%, 5%, dan 2%. Sehingga, menunjukkan bahwa model *hybrid* GSTARX-FFNN mampu mereduksi sMAPE model TSR dengan persentase lebih besar dibandingkan model *hybrid* GSTARX-DLNN dan GSTARX-Jordan RNN.

Selanjutnya dilakukan penghitungan nilai sMAPE setiap langkah peramalan data *out sample*, untuk mengetahui sampai peramalan pada bulan ke berapa model terbaik mampu meramalkan data *inflow* dan *outflow* di KP BI Jawa Timur dengan baik.



Gambar 4. 49 Nilai sMAPE Setiap Langkah Peramalan Data *Out Sample* Total *Inflow*



Gambar 4. 50 Nilai sMAPE Setiap Langkah Peramalan Data *Out Sample* Total *Outflow*

Gambar 4. 49 dan Gambar 4. 50 menunjukkan nilai sMAPE setiap langkah peramalan data *out sample* pada data *inflow* dan *outflow* total di seluruh KP BI Jawa Timur. Plot nilai sMAPE data *out sample* yang digambarkan pada Gambar 4. 49 merupakan nilai sMAPE dari model *hybrid GSTARX-FFNN(8,4,1)* dengan bobot NIKS pada data *inflow* total, dan Gambar 4. 50 merupakan *plot* nilai sMAPE dari model *hybrid GSTARX-FFNN(16,15,1)* dengan bobot seragam pada data *outflow* total. Kedua gambar tersebut terlihat cukup berbeda, model terbaik yang terpilih pada data *inflow* total jika digunakan untuk meramalkan hingga 6 bulan dan 18 bulan kedepan di KP BI Surabaya memiliki nilai sMAPE disekitar nilai 18%, KP BI Malang memiliki nilai sMAPE 20,4% untuk peramalan hingga 6 bulan kedepan dan 17,4% untuk peramalan hingga 18 bulan kedepan, KP BI Kediri memiliki nilai sMAPE sekitar 28% untuk peramalan hingga 6 dan 18 bulan kedepan, dan KP BI Jember memiliki nilai sMAPE sekitar 20% untuk peramalan hingga 6 dan 18 bulan kedepan. Secara keseluruhan nilai sMAPE dari model terbaik yang terpilih pada pemodelan data *inflow* total jika digunakan untuk meramalkan hingga 18 bulan kedepan masih cukup baik, karena nilainya cukup stabil kecuali pada nilai sMAPE untuk peramalan bulan ke-1.

Plot sMAPE untuk peramalan data *outflow* di KP BI Jawa Timur memiliki pola yang sama yaitu model terbaik yang digunakan untuk meramalkan hanya mampu bertahan hingga ramalan kurang lebih bulan ke-4, karena setelah ramalan bulan ke-4 nilai sMAPE terus meningkat. Perbedaan yang terlihat pada plot sMAPE di masing-masing KP BI Jawa Timur adalah pada nilai sMAPE ramalan buan ke-1. Nilai sMAPE di KP BI Kediri pada ramalan bulan ke-1 sangat tinggi, sehingga menyebabkan pola nilai sMAPE di bulan selanjutnya terlihat stabil dan tidak mengalami kenaikan yang cukup signifikan. Namun jika dilihat berdasarkan besarnya nilai sMAPE untuk ramalan bulan ke-4 dan bulan ke-18 memiliki selisih yang cukup besar, yaitu mengalami kenaikan nilai sMAPE sekitar 10%.

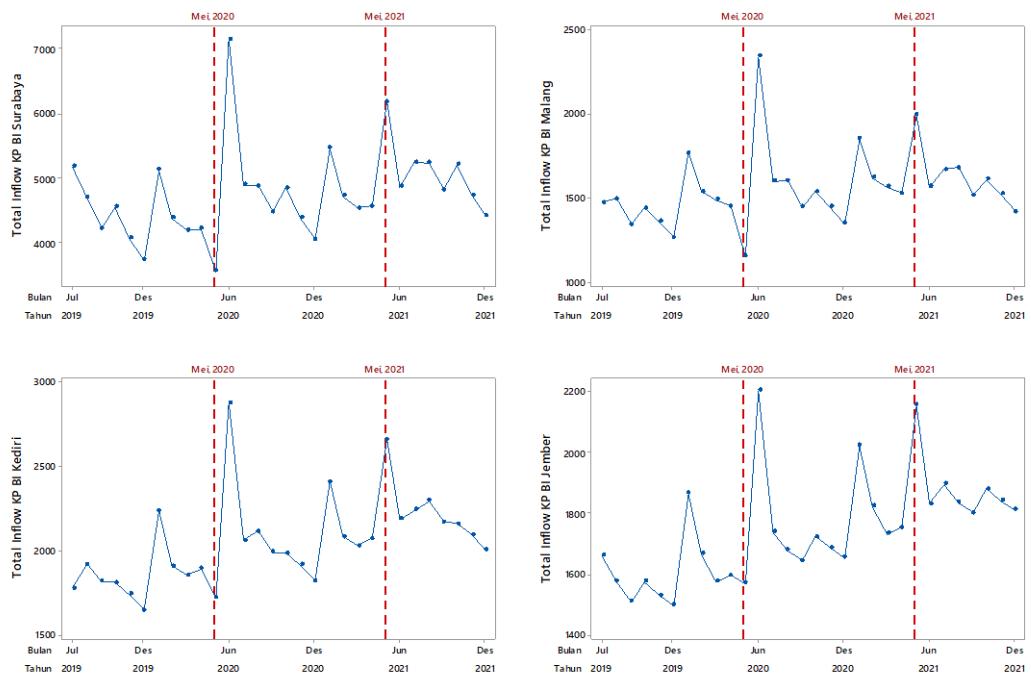
Tabel 4. 53 Model Terbaik Data *Inflow* dan *Outflow* Masing-masing KP BI Jawa Timur

Data	KP BI	<i>Inflow</i>		<i>Outflow</i>	
		Metode	Bobot Lokasi	Metode	Bobot Lokasi
Total	Surabaya	GSTARX(1 ₁)	Seragam	ARIMAX ([1,6,10,12,23],0,0)	-
	Malang	ARIMAX ([12],0,[12])	-	GSTARX-FFNN(16,15,1)	Seragam
	Kediri	GSTARX-FNN(8,4,1)	NIKS	GSTARX-FFNN(16,15,1)	Seragam
	Jember	GSTARX-DLNN(8,3,2)	KS	GSTARX-DLNN(8,4,3,1)	Invers Jarak
Rp. 100.000,-	Surabaya	ARIMAX ([6,12],0,0)	-	ARIMAX ([6,10,12,13,15,23],0,0)	-
	Malang	ARIMAX ([12,24],0,0)	-	GSTARX-FFNN(16,15,1)	Seragam
	Kediri	GSTARX-FNN(8,1,1)	Invers Jarak	GSTARX-FFNN(16,15,1)	Seragam
	Jember	ARIMAX ([6,12],0,0)	-	GSTARX-DLNN(8,2,3,1)	Invers Jarak
Rp. 50.000,-	Surabaya	GSTARX(1 ₁)	Biner	GSTARX(1 ₁)	NIKS
	Malang	GSTARX-DLNN(8,10,4,1)	KS	GSTARX-FFNN(8,2,1)	NIKS
	Kediri	GSTARX-FFNN(8,5,1)	KS	GSTARX-FFNN(8,2,1)	NIKS
	Jember	GSTARX-DLNN(8,10,4,1)	Seragam	GSTARX-FFNN(8,5,1)	Biner
Rp. 20.000,-	Surabaya	GSTARX-FFNN(8,15,1)	Seragam	ARIMAX ([10,12,13],0,0)	-
	Malang	GSTARX-DLNN(8,5,4,1)	KS	GSTARX-FFNN(16,10,1)	Invers Jarak
	Kediri	GSTARX-FFNN(8,15,1)	Seragam	GSTARX-DLNN(16,1,3,1)	NIKS
	Jember	GSTARX-DLNN(8,10,2,1)	NIKS	GSTARX-DLNN(16,10,4)	Invers Jarak
Rp. 10.000,-	Surabaya	GSTARX-FFNN(8,15,1)	Seragam	GSTARX ([1,12] ₁)	Invers Jarak
	Malang	ARIMAX ([1,11,12,13,36],0,0)	-	GSTARX-DLNN(8,5,3,1)	Biner
	Kediri	GSTARX-FFNN(8,15,1)	Seragam	GSTARX ([1,12] ₁)	KS
	Jember	ARIMAX([11,12],0,0)	-	GSTARX ([1,12] ₁)	Biner
Rp. 5.000,-	Surabaya	GSTARX ([1,12] ₁)	KS	GSTARX (12 ₁)	Biner
	Malang	GSTARX-Jordan RNN(8,2,1)	KS	GSTARX-FFNN(8,4,1)	Biner
	Kediri	ARIMAX ([12,23,36],0,0)	-	ARIMAX ([2,12,23,24],0,0)	-
	Jember	GSTARX-DLNN(8,15,2,1)	Biner	GSTARX-Jordan RNN(8,1,1)	Biner
Rp. 2.000,-	Surabaya	GSTARX(1 ₁)	NIKS	GSTARX-DLNN(8,2,3,1)	Seragam
	Malang	GSTARX(1 ₁)	KS	GSTARX-LNN(8,10,3,1)	NIKS
	Kediri	TSR	-	GSTARX-FFNN(8,4,1)	Seragam
	Jember	GSTARX(1 ₁)	Seragam	GSTARX(1 ₁)	Biner
Rp. 1.000,-	Surabaya	Naïve Musiman	-	Naïve Musiman	-
	Malang	Naïve Musiman	-	Naïve Musiman	-
	Kediri	Naïve Musiman	-	Naïve Musiman	-
	Jember	Naïve Musiman	-	Naïve Musiman	-

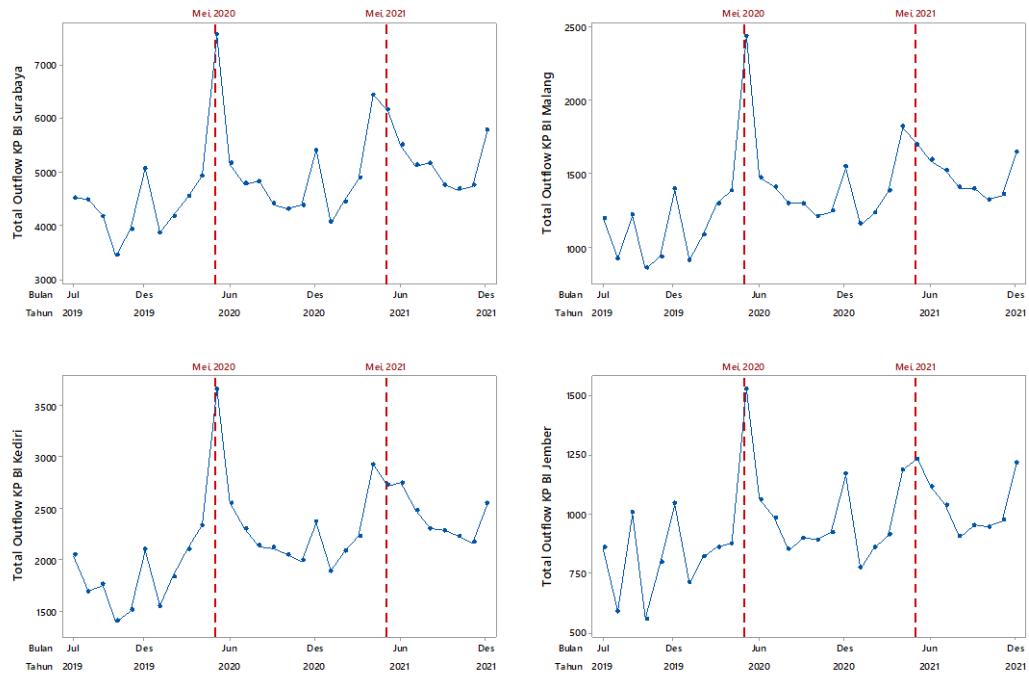
Model terbaik yang terpilih ditunjukkan pada Tabel 4. 52 adalah model terbaik data *inflow* dan *outflow* untuk keseluruhan KP BI di Jawa Timur. Hal ini menyebabkan hasil pemodelan tidak selalu memberikan hasil peramalan yang baik pada semua KP BI di Jawa Timur. Model terbaik yang terpilih berdasarkan masing-masing KP BI di Jawa Timur untuk data *inflow* dan *outflow* dalam total maupun pecahan ditunjukkan pada Tabel 4. 53. Model terbaik yang terpilih pada setiap data *inflow* dan *outflow* di masing-masing KP BI Jawa Timur yaitu Surabaya, Malang, Kediri, dan Jember adalah berbeda.

4.2.10. Peramalan Data *Inflow* dan *Outflow* di KP BI Jawa Timur

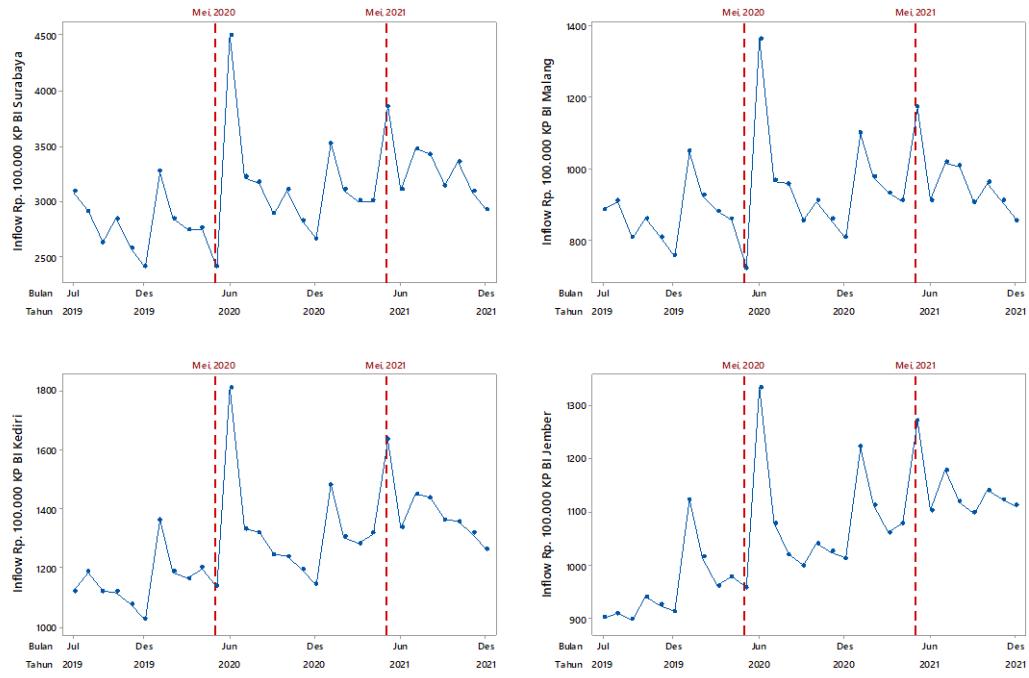
Berdasarkan model terbaik yang sudah didapatkan dari beberapa pemodelan pada data *inflow* dan *outflow* di KP BI Jawa Timur, selanjutnya dilakukan peramalan data *inflow* dan *outflow* dalam total maupun per pecahan untuk periode tahun 2020 dan 2021 dengan masing-masing model terbaik yang terpilih. Berikut ini ditunjukkan *time series plot* hasil peramalan data *inflow* dan *outflow* di masing-masing KP BI Jawa Timur baik dalam total maupun pecahan.



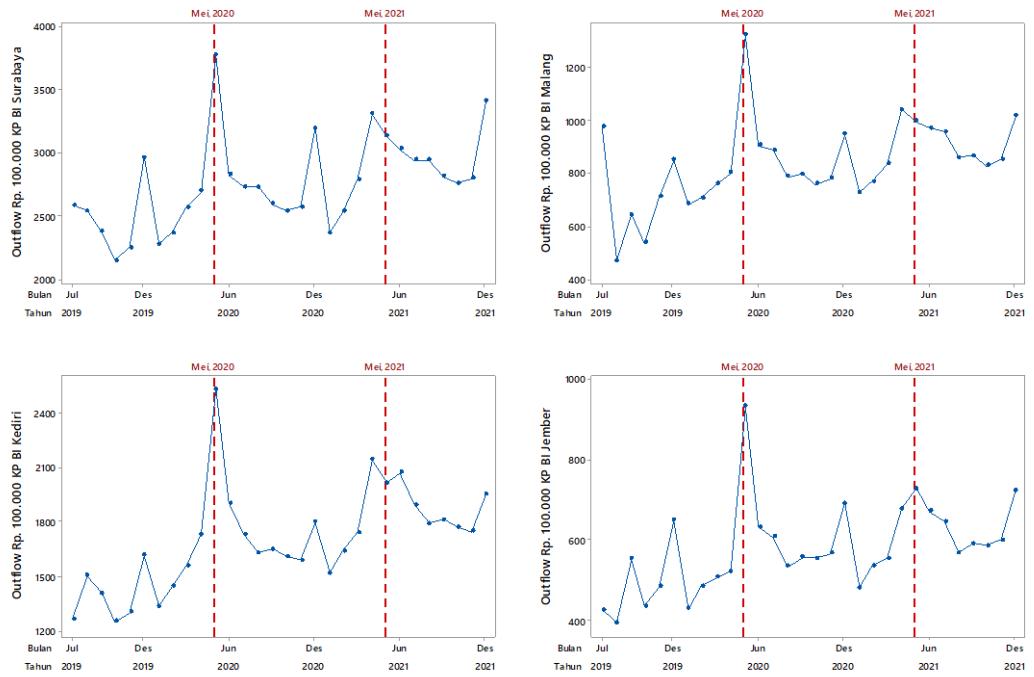
Gambar 4. 51 *Time Series Plot* Hasil Ramalan Data *Inflow* Total di KP BI Jawa Timur



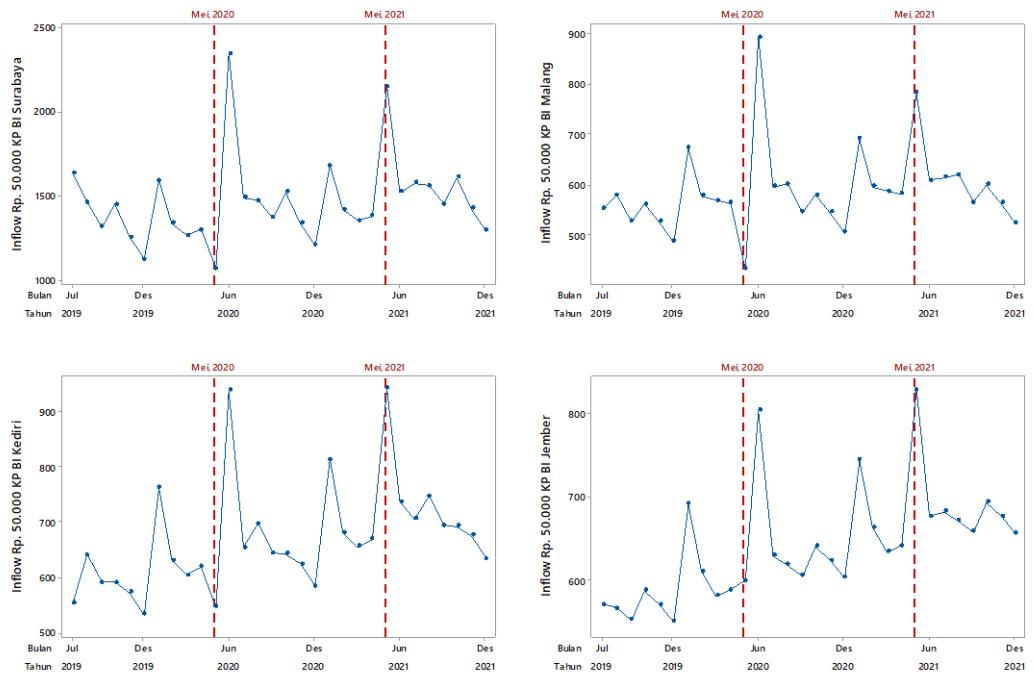
Gambar 4. 52 Time Series Plot Hasil Ramalan Data *Outflow Total* di KP BI Jawa Timur



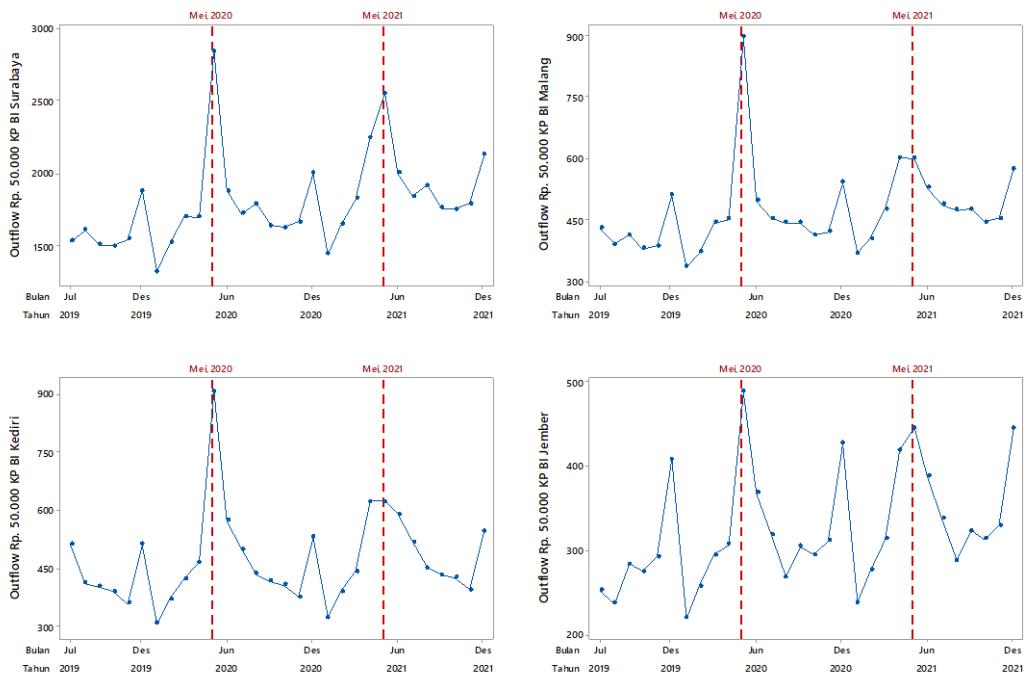
Gambar 4. 53 Time Series Plot Hasil Ramalan Data *Inflow Rp. 100.000,-* di KP BI Jawa Timur



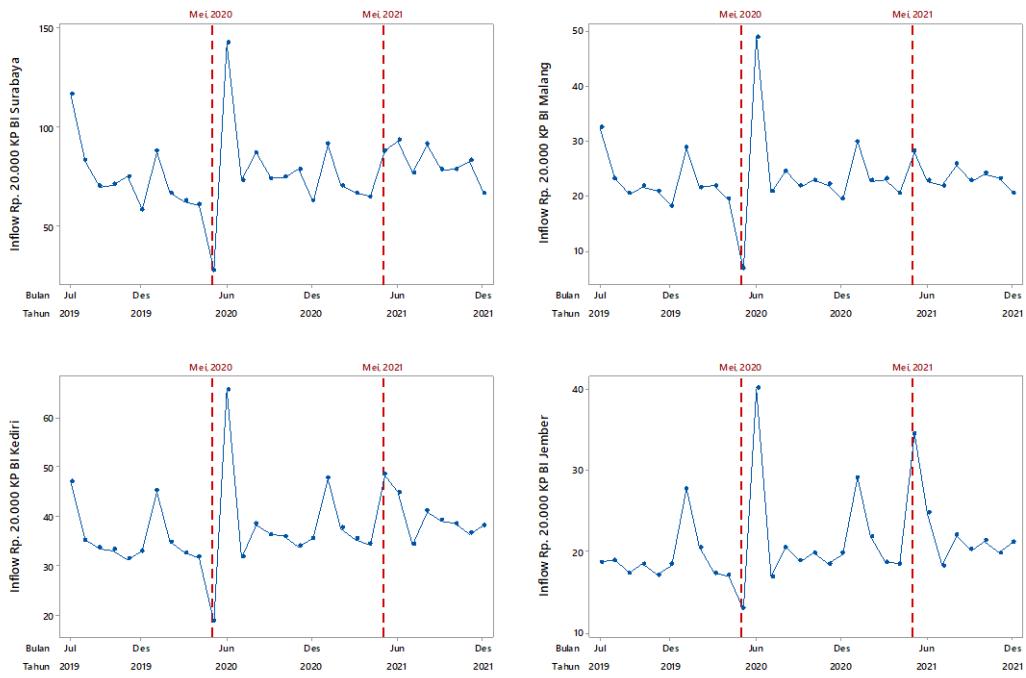
Gambar 4. 54 Time Series Plot Hasil Ramalan Data Outflow Rp. 100.000,- di KP BI Jawa Timur



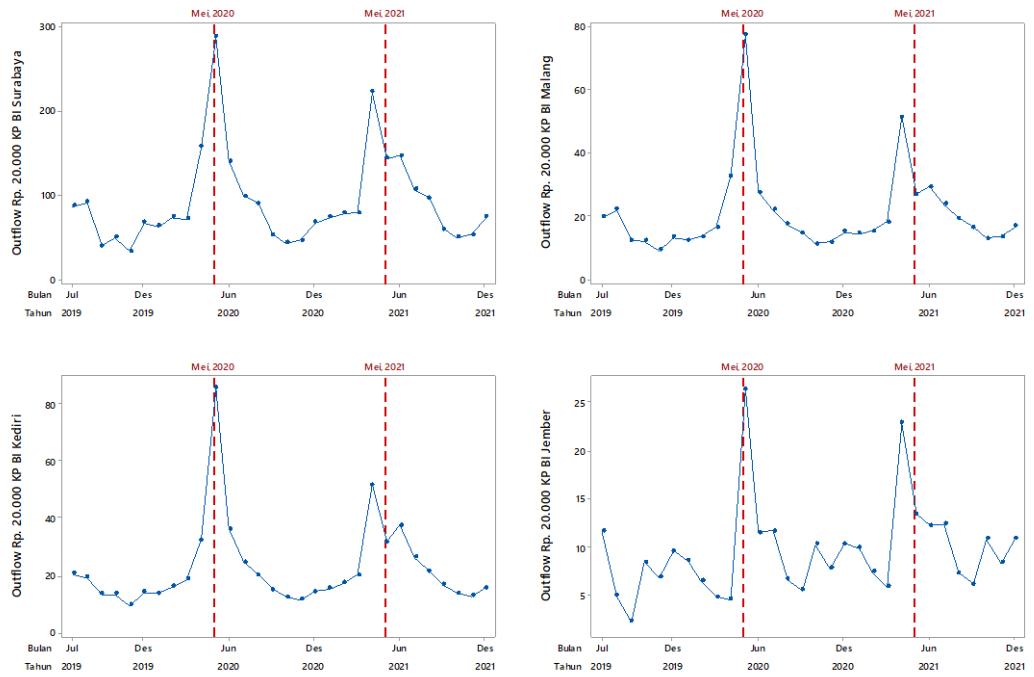
Gambar 4. 55 Time Series Plot Hasil Ramalan Data Inflow Rp. 50.000,- di KP BI Jawa Timur



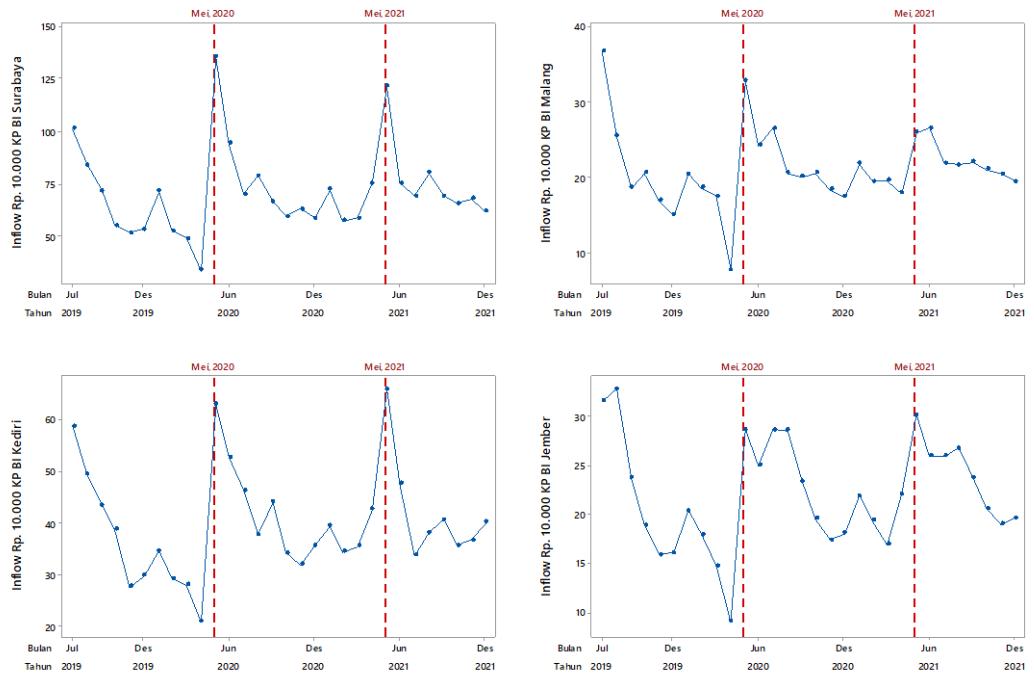
Gambar 4. 56 Time Series Plot Hasil Ramalan Data *Outflow Rp. 50.000,-* di KP BI Jawa Timur



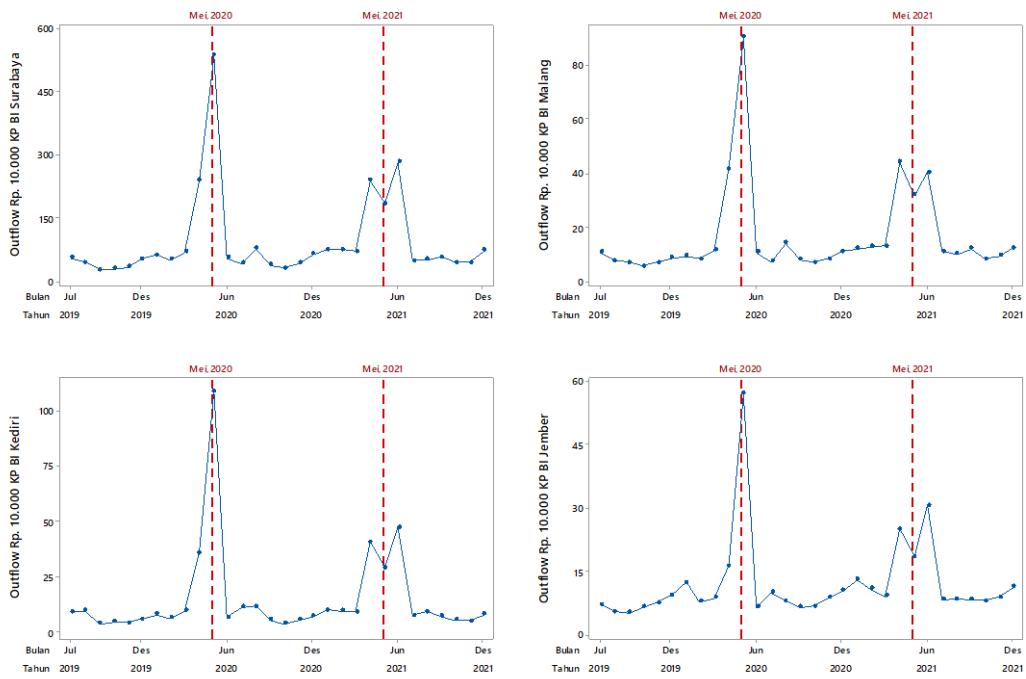
Gambar 4. 57 Time Series Plot Hasil Ramalan Data *Inflow Rp. 20.000,-* di KP BI Jawa Timur



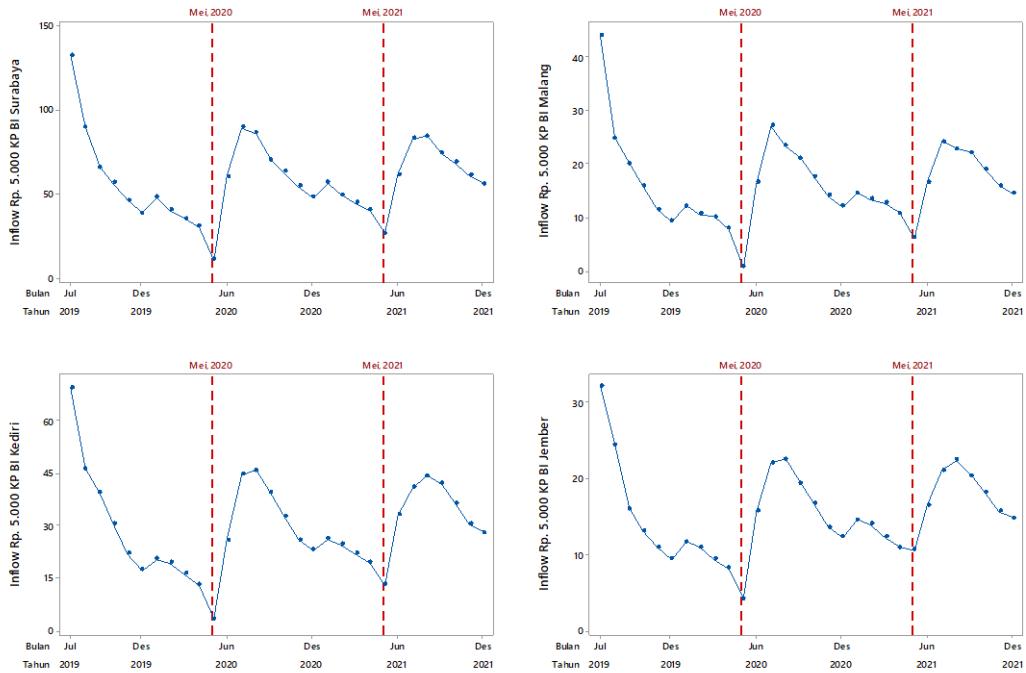
Gambar 4. 58 Time Series Plot Hasil Ramalan Data Outflow Rp. 20.000,- di KP BI Jawa Timur



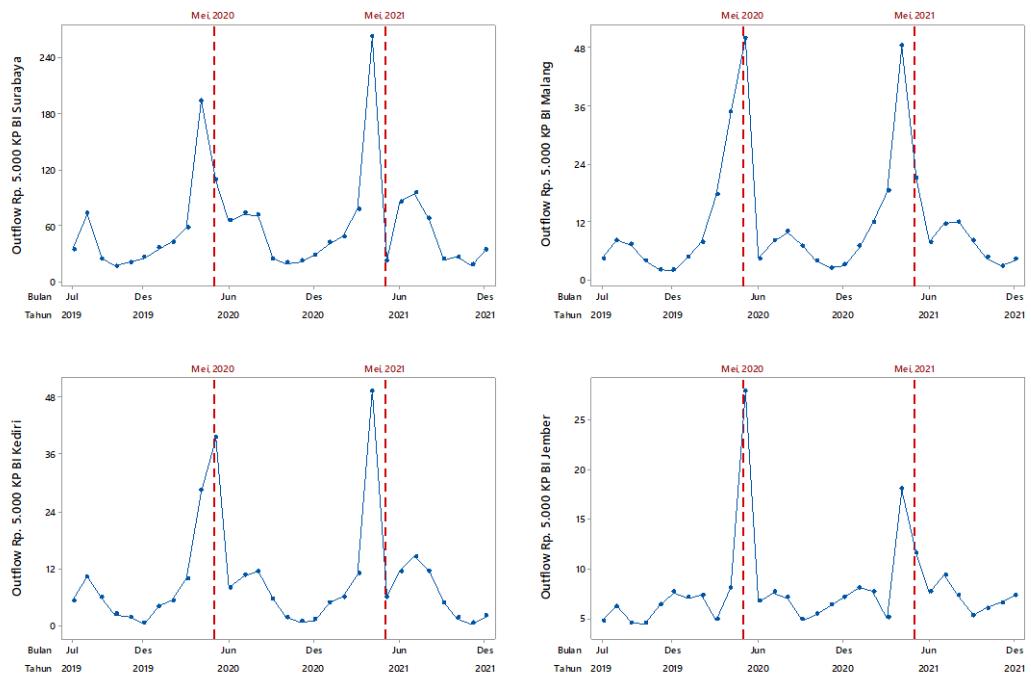
Gambar 4. 59 Time Series Plot Hasil Ramalan Data Inflow Rp. 10.000,- di KP BI Jawa Timur



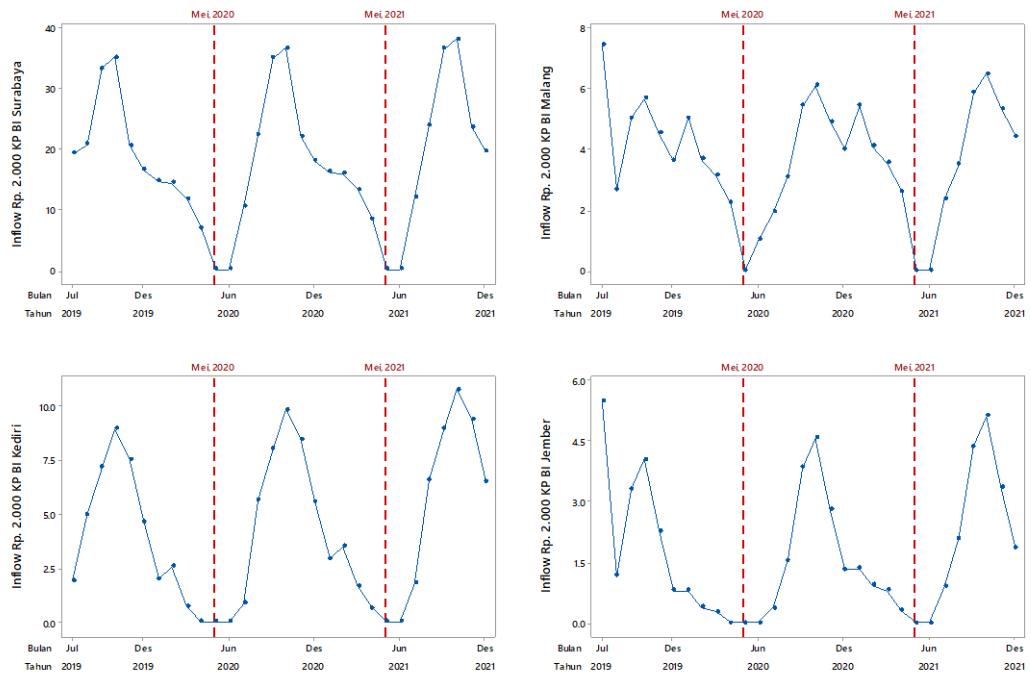
Gambar 4. 60 Time Series Plot Hasil Ramalan Data Outflow Rp. 10.000,- di KP BI Jawa Timur



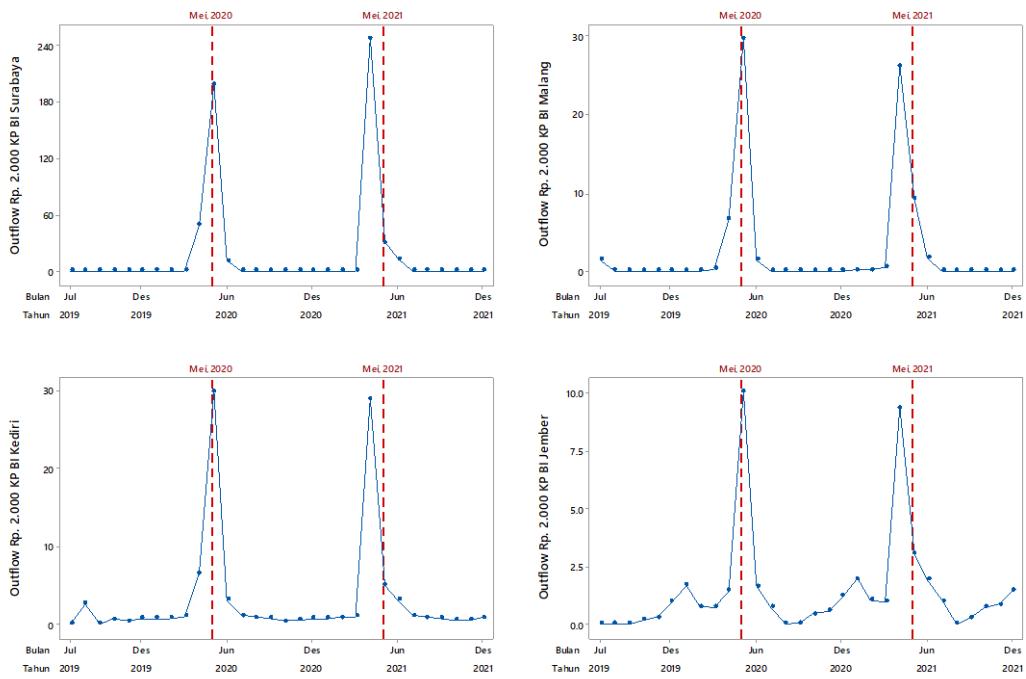
Gambar 4. 61 Time Series Plot Hasil Ramalan Data Inflow Rp. 5.000,- di KP BI Jawa Timur



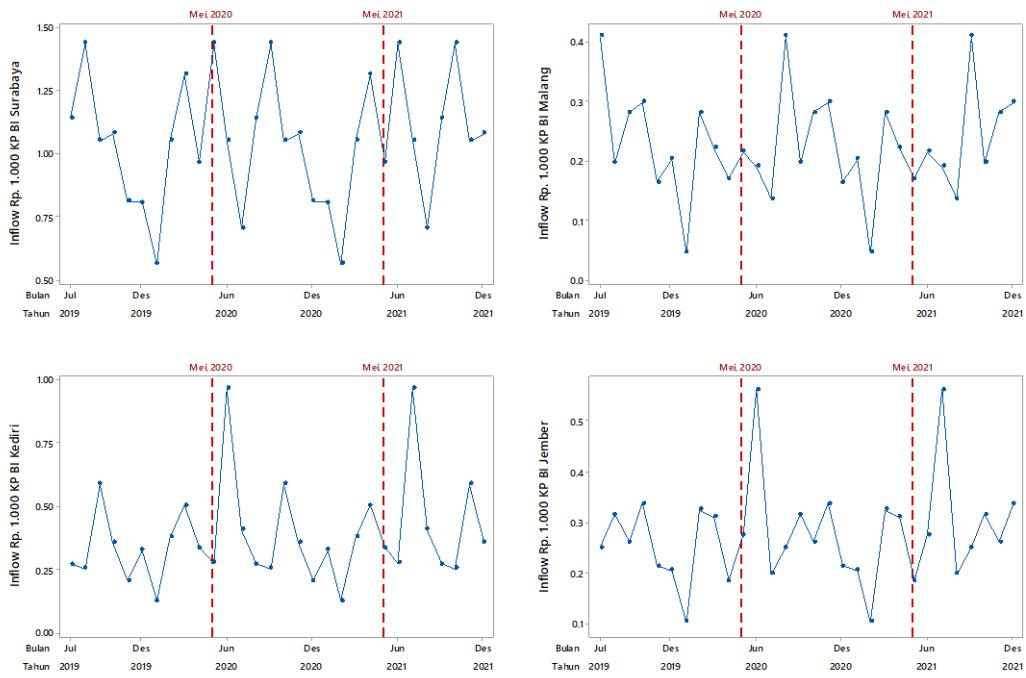
Gambar 4. 62 Time Series Plot Hasil Ramalan Data *Outflow Rp. 5.000,-* di KP BI Jawa Timur



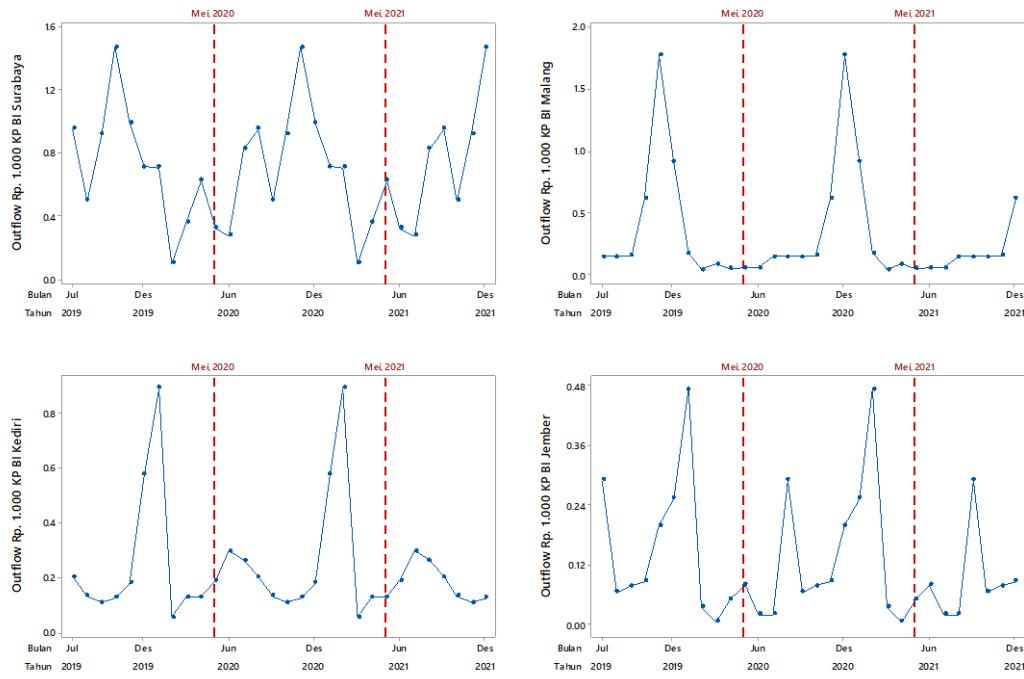
Gambar 4. 63 Time Series Plot Hasil Ramalan Data *Inflow Rp. 2.000,-* di KP BI Jawa Timur



Gambar 4. 64 Time Series Plot Hasil Ramalan Data *Outflow Rp. 5.000,-* di KP BI Jawa Timur



Gambar 4. 65 Time Series Plot Hasil Ramalan Data *Inflow Rp. 1.000,-* di KP BI Jawa Timur



Gambar 4. 66 Time Series Plot Hasil Ramalan Data *Outflow* Rp. 1.000,- di KP BI Jawa Timur

Berdasarkan *time series plot* hasil peramalan data *inflow* dan *outflow* di KP BI Jawa Timur menggunakan model terbaik yang terpilih pada masing-masing data, dapat diketahui bahwa untuk data *inflow* dalam total dan uang pecahan besar model yang digunakan mampu meramalkan data *inflow* sesuai dengan efek variasi kalender (hari raya idul fitri) yaitu nilai *inflow* akan naik tajam pada bulan hari raya idul fitri atau satu bulan setelah hari idul fitri. Hasil ramalan data *outflow* juga sudah mampu menangkap efek variasi kalender, karena pada keseluruhan *time series plot* hasil ramalan nilai *outflow* naik tajam pada bulan hari raya idul fitri atau satu bulan sebelum terjadinya hari raya idul fitri.

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah diuraikan sebelumnya maka diperoleh kesimpulan sebagai berikut

1. Hasil dari kajian simulasi yaitu model *hybrid* yang terdiri dari *hybrid GSTARX-FFNN*, *GSTARX-DLNN*, *GSTARX-Jordan RNN* adalah metode yang memiliki performa lebih baik dalam memodelkan data *time series* yang mengandung komponen tren, musiman, variasi kalender serta residual yang mengikuti pola nonlinier. Model *hybrid* dalam meramalkan data yang memiliki residual yang mengikuti pola linier diperoleh rasio nilai RMSE yang mirip antara model *hybrid* dan model lainnya. Model *hybrid GSTARX-DLNN* memiliki performa yang lebih baik dibandingkan model *hybrid* lainnya. Model *hybrid* yang mampu mereduksi *error* peramalan paling besar adalah model *hybrid GSTARX-FFNN*.
2. Berdasarkan hasil dari pemodelan data *inflow* dan *outflow* dalam total seluruh pecahan dan masing-masing pecahan yaitu model terbaik yang didapatkan untuk memodelkan data *inflow* dan *outflow* dalam total serta uang pecahan besar adalah model *hybrid GSTARX-FFNN* dan *hybrid GSTARX-DLNN*. Hasil ini sesuai dengan kesimpulan dari M4-*Competition* bahwa model *hybrid* mampu meningkatkan akurasi peramalan. Model terbaik yang terpilih untuk meramalkan data *inflow* dan *outflow* uang pecahan kecil adalah model yang lebih sederhana. Hal ini dikarenakan data *inflow* dan *outflow* untuk uang pecahan kecil memiliki pola yang berbeda dengan data total dan uang pecahan besar.
3. Performa dari masing-masing model terbaik yang terpilih untuk hasil ramalan data *inflow* memiliki nilai sMAPE yang stabil hingga ramalan bulan ke-18. Performa kebaikan model terbaik yang terpilih dalam meramalkan data *outflow* hanya bertahan hingga bulan ke-4, karena setelah bulan ke-4 rata-rata nilai sMAPE meningkat cukup signifikan. Hasil ramalan data *inflow* dan

outflow di KP BI Jawa Timur baik dalam total maupun masing-masing pecahan telah mampu menangkap efek variasi kalender (hari raya idul fitri).

5.2. Saran

Berdasarkan beberapa kesimpulan yang telah diperoleh diatas maka diberikan saran untuk penelitian selanjutnya bahwa perlu dilakukan pengembangan dalam penentuan orde pada model GSTAR. Selain itu juga perlu dilakukan kajian lebih lanjut untuk peramalan data *inflow* dan *outflow* uang pecahan kecil yaitu Rp.10.000, Rp.5.000, Rp.2.000, dan Rp.1.000, karena pola data uang pecahan kecil menunjukkan pola yang berbeda dengan pola data total dan uang pecahan besar pada data *inflow* dan *outflow*. Karena saat ini penggunaan uang tunai dalam transaksi sehari-hari sudah semakin berkurang, sebagian besar orang lebih sering melakukan transaksi menggunakan non tunai.

DAFTAR PUSTAKA

- Apriliadara, M., Suhartono, dan Prastyo, D. (2016). *VARI-X model for currency inflow and outflow forecasting with Eid Fitri effect in Indonesia*. 1746: 020-041.
- Baltagi, B. (1980). *On Seemingly Unrelated Regressions with Error Components*. *Econometrica*, 48: 1547-1551.
- Bank Indonesia. (2018). *Laporan Kerja Tahunan Bank Indonesia Tahun 2018*. Bank Indonesia. Jakarta.
- Bengio, Y., Lamblin, P., Popovici, D., dan Larochelle, H. (2007). Greedy layer-wise training of deep networks. *Adv. Neural Inf. Process. Syst.* 19: 153-160.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. (2002). Generalized STAR models with experimental weights. *Proceedings of the 17th International Workshop on Statistical Modelling 2002*. Eds: Stasinopoulos, M. dan Touloumi, G. Chania. 143-152.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. (2008). Consistency and asymptotic normality of least square estimators in generalized STAR models. *Statistica Neerlandica*, 62(4): 482-508.
- Bowerman, B.L., dan O'Connell, R.T. (1993). *Forecasting and Time Series: An Applied Approach* (3th ed.). California: Duxbury Press.
- Bowerman, B. L., O'Connell, R. T., dan Koehler, A. B. (2005). *Forecasting, time series, and regression: An applied approach*. Belmont, California: Duxbury Press.
- Box, G. P., Jenkins, G. M., dan Reinsel, G. C. (1994). *Time Series Analysis forecasting and control*, 3rd ed., Englewood Cliffs: Prentice Hall.
- Chatfield, C. (1997). *Forecasting in the 1990s*. 46(4): 461-473. United Kingdom: University of Bath.
- Clements, M. P., dan Galvao, A. B. (2013). Forecasting with Vector Autoregressive Models of Data Vintages: US Output Growth and Inflation. *International Journal of Forecasting*, 29: 698-714.

- Connor, J., Atlas, LE., dan Martin, DR. (1992). Recurrent Networks and NARMA Modeling. *Advances in Neural Information Processing Systems*: 301-308.
- Cryer, J.D., dan Chan, KS. (2008). Time Series Analysis: With Application in R: Second Edition. USA: Springer Science dan Business Media, LLC
- Dalton, M., Matsuko, J., dan Vasak, M. (2015). Deep learning neural networks for ultra-short-term wind forecasting. *Industrial Technology (ICIT), IEEE International Conference*: 1657–1663.
- Dumitru, C.-D., dan Gligor, A. (2017). Daily Average Wind Energy Forecasting Using Artificial Neural Networks. *Procedia Engineering*. 181: 829–836.
- Fausett, L.V. (1994). *Fundamental of Neural Network: Architectures, Algorithm, and Applications*. New Jersey: Prentice Hall Inc.
- Franses, P.H., dan Dijk, D.v. (2000). *Non-Linear Time Series Models in Empirical Finance*. Cambridge University Press.
- Franses, P.H., dan Griensven, K.v. (1998). Forecasting Exchange Rates Using Neural Networks for Technical Trading Rules. *Studies in Nonlinear Dynamics and Econometrics*, 2(4): 109-114.
- Gooijer, J. G. D., dan Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting*. 22: 443-473.
- Hajirahimi, Z dan Khashei, M. (2019). Hybrid structures in time series modeling and forecasting: A review. *Engineering Applications of Artificial Intelligence*. 86: 83-106.
- Hannan, E.J. (1970). Multiple Time Series. New York: John Wiley & Sons.
- Huang, T. Y., Li, J., & Hsu, T-W. (2007). Structure and Parameter Learning Algorithm of Jordan Type Recurrent Neural Networks. *IEEE International Conference on Neural Networks - Conference Proceedings*. 1819 - 1824.
- Hyndman, R.J., dan Athanasopoulos, G. (2014). *Forecasting: Principles and Practice*. Otexts.
- Lee, M.H., Suhartono, dan Hamzah, N.A. (2010). Calender variation model based on ARIMAX for forecasting sales data with Ramadhan effect. *Proceedings of the Regional Conference on Statistical Science*, 349-361.
- Lewis, N.D. (2016). *Deep Learning Made Easy with R*. South Carolina: Create space Independent Publishing Platform.

- Liu, L.M. (2006). *Time Series Analysis and Forecasting*. Illinois: Scientific Computing Associates.
- Kelikume, I dan Salami, A. (2014). Time Series Modeling and Forecasting Inflation: Evidence from Nigeria. *The International Journal of Business and Finance Research*. 8(2): 41-51.
- Pfeifer, P.E., dan Deutsch, S.J. (1980a). A Three Stage Iterative Procedure for Space-Time Modeling. *Technometrics*, 22(1): 35-47.
- Pfeifer, P.E., dan Deutsch, S.J. (1980b). Identification and Interpretation of First Order Space-Time ARMA Models. *Technometrics*, 22(1): 397-408.
- Pfeifer, P.E., dan Deutsch, S.J. (1980c). Stationary and invertibility regions for low order STARMA models. *Communications in Statistics - Simulation and Computation*, 9(5): 551-562.
- Ruchjana, B.N. (2002). Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi S-TAR¹. *Forum Statistika dan Komputasi*, ISSN 0853-8115: 1-6.
- Shumway, R. H., dan Stoffer, D. S. (2006). *Time Series Analysis and Its Applications with R Examples*. New York: Springer.
- Sigalingging H, Setiawan E, dan Sihaloho H D. (2004). *Kebijakan Pengedaran Uang Di Indonesia*, No. 13, Seri Kebanksentralan, Pusat Pendidikan dan Studi Kebanksentralan (PPSK) BANK INDONESIA: Jakarta.
- Solikin dan Suseno. (2002a). *Penyusunan Statistik Uang Beredar*, No. 2. Seri Kebanksentralan, Pusat Pendidikan dan Studi Kebanksentralan (PPSK) BANK INDONESIA: Jakarta.
- Solikin dan Suseno. (2002b). *UANG - Pengertian, Penciptaan, dan Perannya dalam Perekonomian*, No. 1, Seri Kebanksentralan, Pusat Pendidikan dan Studi Kebanksentralan (PPSK) BANK INDONESIA: Jakarta.
- Suhartono. (2007). *Feedforward Neural Networks for Time Series Forecasting*. PhD thesis, Department of Mathematics, Gadjah Mada University, Yogyakarta.
- Suhartono dan Atok, R.M., (2005), “Perbandingan Antara Model VARIMA dan GSTAR untuk Peramalan Data Deret Waktu dan Lokasi”. *Prosiding Seminar Nasional Statistika, Institut Teknologi Sepuluh Nopember, Surabaya*.

- Suhartono., dan Atok, R. (2006). Pemilihan Bobot Lokasi yang Optimal pada Model GSTAR. *Prosiding Konferensi Nasional Matematika XIII*. Semarang: Universitas Negeri Semarang.
- Suhartono, Dana, I., dan Rahayu, S. (2019). Hybrid Model for Forecasting Space-Time Data with Calendar Variation Effects. *TELKOMNIKA*, 17(1): 118-130.
- Suhartono dan Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by Using Cross-Correlation Inference. *Journal of Quantitative Methods*, 2(2): 45-53.
- Suhartono dan Subanar (2007). Some Comments on the Theorem Providing Stasianerity Condition for GSTAR Models in the Paper by Borovkova et al. *Journal of The Indonesian Mathematical Society (MIHMI)*, 13(1): 44-52.
- Suhartono, Dana, I., dan Rahayu, S. P. (2019). Hybrid Model for Forecasting Space-Time Data with Calendar Variation Effects. *TELKOMNIKA*, 17(1): 118-130.
- Suhartono, Wahyuningrum, S.R., Setiawan, dan Akbar, M.S. (2016). GSTARX-GLS Model for Spatio-Temporal Data Forecasting. *Malaysian Journal of Mathematical Sciences*, 10: 91-103.
- Terasvista, T., Lin, C.F., dan Granger, C.W.J. (1993). Power of The Neural Network Linearity Test. *Journal of Time Series Analysis*, 14: 159-171.
- Tiao, G., C. dan Box, G., E., P. (1981) Modeling Multiple Time Series with Applications. *Journal of the American Statistical Association*. 76(376): 802-816.
- Tong, H. (1990). *Non-Linear Time Series: A Dynamical System Approach*. Oxford University Press.
- Trapletti, A. (2000). *On Neural Networks as Statistical Time Series Models*. PhD thesis, Institute for Statistics, Wien University.
- Tsay, R.S. (2002). *Analysis of Financial Time series*. Canada: John Wiley & Sons.
- Wahyuningrum, S.R. (2014). *Model GSTAR-SUR untuk Peramalan Data Spatio-Temporal*. Laporan Tesis. Institut Teknologi Sepuluh Nopember, Surabaya.
- Wei, W.W.S. (2006). *Time Series Analysis: Univariate and Multivariate Methods* (2nd ed.). New York: Addison Wesley.

- Wulansari, R.E., Suryanto, E., Ferawati, K., Andalita, I., dan Suhartono. (2014). Penerapan Time Series Regression with Calendar Variation Effect pada Data Netflow Uang Kartal Bank Indonesia Sebagai Solusi Kontrol Likuiditas Perbankan di Indonesia. *Statistika: Forum Teori dan Aplikasi Statistika*, 14(2): 59-68.
- Wutsqa, D.U., dan Suhartono. (2010). Peramalan Deret Waktu Multivariat Seasonal pada Data Pariwisata dengan Model Var-Gstar. *Jurnal ILMU DASAR*, 11(1): 101-109.
- Wutsqa, D.U., Suhartono, dan Sutijo, B. (2010). Generalized Space-Time Autoregressive Modeling. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Application (ICMSA 2010)*. Eds: Shean, N.W., Wen, G.K., Leen, K.H., Wah, O.K., dan Ken, Y.L. Universiti Tunku Abdul Rahman, Kuala Lumpur, Malaysia.
- Wysocki, A., dan Ławryńczuk, M. (2015). Jordan neural network for modelling and predictive control of dynamic systems. *20th International Conference on Methods and Models in Automation and Robotics (MMAR)*: 145-150.
- Zellner, A. (1962). An Efficient Method of Estimating Seemingly Unrelated Regressions and Tests for Aggregation Bias. *Journal of the American Statistical Association*, 57(298): 348–368.
- Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50: 159-175.
- Zhang, G. P., dan Berardi, V. L. (1998). An investigation of neural networks in thyroid function diagnosis. *Health Care Management Science*, 1(1): 29-37.

(Halaman ini sengaja dikosongkan)

LAMPIRAN

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah)

PERIODE	Total <i>Inflow</i>				Total <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	424,107	113,504	131,939	75,985	1,384,913	453,884	586,538	411,341
	Februari	582,717	159,387	195,540	114,995	718,511	257,505	298,285	190,120
	Maret	757,441	207,550	265,663	164,718	660,631	257,064	288,215	173,978
	April	597,821	175,925	166,221	102,878	686,047	242,508	287,245	185,797
	Mei	804,001	200,931	259,105	167,272	784,042	258,174	300,418	213,813
	Juni	1,019,916	253,196	293,299	150,879	898,933	268,746	254,096	198,336
	Juli	912,592	231,638	329,493	148,451	1,047,712	296,022	335,188	197,947
	Agustus	1,269,213	257,080	495,971	163,138	1,158,830	406,266	601,371	262,620
	September	986,082	298,120	400,212	167,170	888,830	270,896	417,476	224,817
	Oktober	881,208	229,736	307,898	163,787	1,076,983	323,159	415,713	262,059
	November	970,874	229,736	326,988	196,112	1,133,218	317,543	430,867	318,810
	Desember	1,889,089	558,304	568,015	346,731	426,553	177,342	265,092	171,426
...									
2018	
	Maret	5463.26	1114.60	1950.90	498.71	3026.74	1094.94	1055.18	919.83
	April	3217.63	729.39	1202.61	687.34	3785.22	1142.08	1308.01	1274.18
	Mei	8060.76	2505.25	2085.28	1222.84	3482.81	922.80	854.54	1181.37
	Juni	7256.98	2442.83	3533.73	1579.33	8105.03	2116.44	2636.89	2327.38
	Juli	2578.82	420.21	929.29	391.44	6736.15	1965.63	2235.62	1681.14
	Agustus	5335.79	670.43	1987.62	555.30	4528.86	1147.12	1611.58	1207.55
	September	3237.39	608.56	1097.30	475.32	3922.56	1264.75	1482.62	1151.26
	Oktober	3394.66	911.13	1273.26	545.12	4188.73	1601.73	1469.90	1201.62
	November	4,116,677	816,329	1,368,388	735,035	3,946,377	1,349,525	1,201,410	1,276,810
	Desember	4,798,891	1,579,953	2,129,286	1,042,054	2,433,538	1,098,726	831,825	1,058,932
2019	Januari	1,362,400	180,991	371,020	218,202	6,135,708	2,404,639	2,564,564	2,177,735
	Februari	3,007,821	615,212	1,080,576	534,526	3,652,968	1,370,578	1,158,526	1,347,484
	Maret	4,722,725	951,375	1,697,391	559,515	3,334,494	1,338,771	1,148,498	1,214,428
	April	4,259,685	1,494,344	2,111,267	895,658	3,362,034	1,489,535	1,323,609	1,186,949
	Mei	11,759,050	3,753,178	5,256,799	2,018,124	2,989,991	1,123,480	780,489	1,609,075
	Juni	1,282,163	360,094	399,206	147,108	9,371,840	3,327,055	3,622,474	3,059,716

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 100.000,- <i>Inflow</i>				Rp. 100.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	1.94	0.01	1.80	0.04	28.07	0.98	9.61	11.02
	Februari	1.51	0.01	0.71	0.19	60.31	1.61	9.59	9.21
	Maret	5.89	0.11	3.21	0.31	94.72	2.21	23.27	35.54
	April	21.42	1.92	8.89	0.34	128.33	1.31	13.49	30.45
	Mei	43.81	4.02	15.59	1.36	187.19	6.70	15.75	68.81
	Juni	71.02	11.93	14.79	4.19	251.39	2.33	16.35	56.43
	Juli	75.95	18.35	26.08	8.19	150.07	1.96	65.18	65.28
	Agustus	101.75	28.55	139.20	12.91	550.17	28.14	244.15	68.87
	September	206.93	35.65	129.33	31.12	360.85	18.37	172.96	78.35
	Oktober	374.67	55.65	129.54	58.04	361.61	32.64	113.96	77.14
	November	439.88	54.68	140.06	71.15	457.81	32.64	121.24	98.92
	Desember	151.10	40.67	113.49	57.87	820.11	108.39	262.87	198.04
...									
2018	
	Maret	1903.60	633.98	670.72	539.28	3328.37	748.42	1522.04	340.20
	April	2324.78	616.27	807.08	794.80	1280.88	442.72	808.24	418.80
	Mei	2138.48	416.96	432.26	721.98	3887.00	893.49	705.01	579.11
	Juni	5380.26	1247.46	1773.31	1502.00	4735.35	1646.03	2091.44	799.06
	Juli	3840.93	1028.95	1181.48	936.29	1772.30	247.25	785.41	265.86
	Agustus	2570.76	502.25	847.42	667.22	3280.98	395.33	1564.20	377.67
	September	2271.18	656.77	858.13	633.51	1862.29	349.70	865.79	299.75
	Oktober	2491.45	868.54	890.15	688.97	1977.28	537.89	976.15	336.82
	November	2495.73	770.20	738.62	803.13	2459.56	467.48	1025.51	464.66
	Desember	1409.92	571.79	487.51	595.92	2851.87	950.84	1537.81	592.81
2019	Januari	3965.79	1438.17	1737.00	1392.44	631.69	78.89	252.74	121.38
	Februari	2288.06	775.27	737.13	844.49	1697.41	350.47	776.28	345.96
	Maret	2122.19	759.38	768.99	734.71	2878.12	529.96	1245.90	342.06
	April	1241.24	605.20	398.21	416.86	2354.62	787.04	1423.68	540.73
	Mei	1078.40	501.63	266.70	584.89	6113.63	2174.14	3393.60	1167.59
	Juni	3004.20	1204.48	1147.58	1047.51	797.41	232.02	298.16	90.77

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 50.000,- <i>Inflow</i>				Rp. 50.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	1066.62	302.66	424.91	269.53	276.26	72.78	92.19	42.18
	Februari	498.36	157.47	201.81	118.42	393.17	105.79	141.31	72.20
	Maret	459.72	162.50	202.61	112.12	484.24	124.80	199.56	85.40
	April	471.53	148.50	202.44	125.99	318.57	111.45	127.37	43.29
	Mei	506.94	157.90	211.02	140.20	441.52	129.02	207.24	62.58
	Juni	657.73	181.73	189.98	140.05	567.12	177.39	203.83	65.23
	Juli	740.99	198.95	249.80	136.92	578.36	162.16	201.58	53.09
	Agustus	742.10	262.58	342.69	177.51	532.95	150.92	188.68	57.66
	September	455.81	145.97	190.53	128.82	464.47	211.00	164.25	55.52
	Oktober	502.28	168.65	192.40	137.62	361.80	131.00	143.03	57.96
	November	479.78	165.72	197.26	182.49	355.03	131.00	143.36	63.06
	Desember	202.47	88.24	102.11	72.37	828.90	306.75	229.52	95.90
2018

	Maret	1023.86	418.04	337.37	342.28	2059.86	357.96	410.05	142.34
	April	1373.45	486.32	468.32	454.15	1844.16	239.78	362.15	248.75
	Mei	1268.33	471.72	403.60	436.90	2650.68	1285.34	1090.32	527.76
	Juni	2602.95	852.09	824.46	808.64	2029.26	743.62	1236.29	712.54
	Juli	2230.84	832.39	761.52	623.48	794.47	168.68	140.93	117.38
	Agustus	1553.83	522.96	544.62	452.87	2045.59	268.06	420.40	170.92
	September	1440.71	541.99	503.08	444.70	1358.82	248.72	226.48	165.04
	Oktober	1488.26	669.08	486.60	443.73	1382.89	367.15	286.56	188.02
	November	1298.92	533.96	394.58	428.53	1596.74	335.17	327.42	250.50
	Desember	918.00	497.60	289.40	429.31	1821.05	613.46	565.08	421.60
2019	Januari	2017.33	916.92	761.09	732.10	576.35	92.41	92.45	49.02
	Februari	1253.38	549.34	374.82	460.29	1226.27	258.79	272.39	176.94
	Maret	1121.55	544.15	344.96	444.10	1685.67	404.27	394.38	201.16
	April	1241.24	605.20	398.21	416.86	1632.99	448.42	538.59	289.90
	Mei	1078.40	501.63	266.70	584.89	3610.05	1342.81	1372.26	700.65
	Juni	3004.20	1204.48	1147.58	1047.51	477.66	127.05	99.43	53.25

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 20.000,- <i>Inflow</i>				Rp. 20.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	210.71	103.96	110.71	94.87	63.50	23.97	17.64	14.34
	Februari	126.79	57.53	56.35	40.32	74.41	34.14	29.26	22.64
	Maret	113.45	57.38	52.33	36.87	106.95	55.04	28.01	28.31
	April	120.95	55.66	48.18	38.54	98.48	42.19	14.69	19.88
	Mei	146.95	58.01	46.50	44.56	108.98	43.78	20.29	25.61
	Juni	108.20	47.17	29.08	33.57	127.15	51.93	44.02	19.86
	Juli	157.51	51.18	40.25	34.90	118.49	44.83	37.43	20.27
	Agustus	199.24	70.86	70.28	42.24	114.25	53.08	36.81	24.57
	September	154.22	57.18	63.79	40.13	101.59	46.44	38.34	23.73
	Oktober	141.39	66.37	61.98	44.16	100.43	44.14	31.73	19.90
	November	149.71	65.22	62.25	43.09	105.50	44.14	37.86	21.95
	Desember	50.02	30.90	32.35	26.61	116.74	95.57	39.92	15.64
<hr/>									
2018	
	
	Maret	32.79	15.24	16.61	13.64	23.40	3.37	9.82	5.45
	April	29.92	18.54	12.43	10.09	30.34	7.59	14.03	6.65
	Mei	28.32	11.24	6.87	9.72	517.02	130.61	106.45	33.79
	Juni	57.12	8.61	20.39	8.25	142.34	17.76	84.61	20.51
	Juli	256.62	49.85	102.30	54.83	2.33	1.30	1.10	2.28
	Agustus	138.55	35.85	78.19	24.71	1.79	2.98	0.87	1.92
	September	54.29	16.10	37.67	16.05	6.37	2.17	2.08	4.31
	Oktober	65.31	22.40	31.45	21.11	11.43	2.55	4.35	6.25
	November	49.60	16.35	24.40	15.57	20.08	6.44	8.21	6.74
	Desember	34.58	10.50	21.68	13.51	51.17	5.51	11.70	8.97
<hr/>									
2019	Januari	56.56	18.30	24.25	20.94	58.04	4.88	13.77	17.73
	Februari	37.32	18.17	17.23	15.71	38.69	2.22	17.83	4.35
	Maret	29.89	13.60	10.54	14.75	72.10	9.06	33.56	6.40
	April	29.57	12.24	10.52	10.04	117.51	116.66	78.92	23.74
	Mei	42.75	10.85	15.60	16.62	596.96	90.68	184.80	41.97
	Juni	175.26	30.59	79.76	42.01	2.39	0.33	0.72	0.76

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 10.000,- <i>Inflow</i>				Rp. 10.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	79.77	35.91	35.87	34.28	31.21	10.36	8.87	4.77
	Februari	60.88	28.90	21.78	20.04	33.61	13.80	11.12	6.77
	Maret	57.39	26.68	18.24	16.76	48.16	19.29	11.18	10.31
	April	52.19	26.72	17.29	13.73	34.12	16.13	7.28	5.91
	Mei	63.61	27.26	16.61	19.28	47.97	16.69	10.88	6.20
	Juni	46.99	20.04	11.93	14.70	51.22	17.31	19.49	5.44
	Juli	58.09	21.97	12.66	13.48	40.42	18.43	18.38	6.26
	Agustus	98.39	37.43	40.97	24.13	41.48	20.00	19.20	7.45
	September	55.82	24.17	24.45	19.36	37.38	16.98	17.09	5.98
	Oktober	43.33	24.65	21.34	16.10	35.54	16.59	13.82	5.79
	November	46.91	24.23	21.23	15.70	33.25	16.59	18.92	6.96
	Desember	14.88	13.05	11.69	10.37	62.06	31.94	22.43	21.96
...									
2018	
	Maret	27.29	13.37	15.67	10.97	22.33	2.13	4.58	4.76
	April	23.93	9.81	9.44	7.62	28.50	5.78	9.46	6.20
	Mei	23.92	13.65	5.17	6.87	502.26	106.14	101.72	40.18
	Juni	34.74	4.51	12.84	5.45	140.68	18.48	64.28	23.17
	Juli	214.58	35.44	103.29	44.59	1.89	1.34	0.76	1.89
	Agustus	131.63	43.51	56.98	31.46	1.30	1.80	0.85	1.81
	September	68.69	18.16	40.73	18.06	3.39	0.81	1.41	3.02
	Oktober	60.97	18.06	29.24	17.98	10.64	1.41	2.61	6.77
	November	38.79	14.20	24.57	12.94	17.43	3.94	3.05	6.43
	Desember	31.43	8.90	16.29	9.94	35.65	5.04	7.79	8.81
2019	Januari	47.75	15.26	21.21	16.50	49.02	2.54	6.41	15.72
	Februari	33.22	13.68	14.64	12.83	23.23	1.57	7.98	3.46
	Maret	25.43	11.00	10.67	10.53	48.65	4.61	15.96	4.72
	April	22.34	10.81	11.20	6.80	74.96	68.98	46.45	20.57
	Mei	30.12	6.69	9.64	9.11	684.50	73.43	146.28	52.08
	Juni	119.21	20.89	63.69	17.75	2.04	0.28	0.33	0.77

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 5.000,- <i>Inflow</i>				Rp. 5.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	16.57	8.48	8.81	8.61	12.36	4.26	2.11	2.45
	Februari	17.31	8.27	7.58	6.07	11.16	3.21	3.32	3.14
	Maret	13.25	7.10	5.73	5.06	13.19	5.10	2.59	3.98
	April	12.43	6.81	5.67	4.65	10.89	4.04	2.29	2.63
	Mei	14.87	7.41	5.63	5.72	14.77	4.04	3.26	2.93
	Juni	10.87	5.43	4.85	4.34	16.71	3.61	7.62	2.70
	Juli	11.85	4.33	4.01	3.60	15.77	3.36	5.06	2.55
	Agustus	13.12	5.46	5.46	4.63	16.95	3.79	5.37	3.05
	September	12.26	6.30	6.18	4.24	14.38	4.13	5.75	3.07
	Oktober	11.93	6.28	6.62	4.99	17.49	4.09	4.43	2.35
	November	13.50	6.17	7.13	4.98	16.31	4.09	4.86	4.50
	Desember	4.59	3.85	4.29	3.45	22.63	11.96	8.89	13.49
...									
2018	
	
	Maret	19.90	8.68	9.96	8.64	15.02	1.52	2.82	3.10
	April	16.72	5.67	6.74	4.70	21.06	21.82	5.88	3.79
	Mei	14.79	6.15	4.84	3.87	344.37	58.91	60.83	28.73
	Juni	22.20	2.69	5.04	2.10	141.71	12.80	43.10	18.45
	Juli	152.65	15.08	72.79	17.73	1.28	1.07	0.50	1.59
	Agustus	94.33	29.93	54.48	18.72	1.34	1.54	0.55	1.18
	September	55.23	23.56	28.57	30.68	1.57	6.05	0.83	1.42
	Oktober	45.11	13.72	22.44	24.77	4.60	1.27	1.84	3.67
	November	36.65	9.57	13.05	9.35	9.90	1.90	2.45	3.65
	Desember	24.02	6.30	11.24	6.98	23.41	3.00	4.58	5.95
2019	Januari	32.55	10.66	15.44	11.31	29.40	1.39	3.46	9.19
	Februari	27.33	9.20	9.78	9.49	12.94	1.27	4.09	1.86
	Maret	22.70	6.75	9.63	7.05	22.72	2.03	5.22	2.70
	April	14.60	6.85	7.28	4.73	54.47	52.91	17.63	12.64
	Mei	19.62	3.62	3.68	5.12	498.75	47.88	119.14	41.12
	Juni	63.09	7.85	44.72	5.26	1.27	0.22	0.28	0.66

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 2.000,- <i>Inflow</i>				Rp. 2.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2010	Januari	0.416	0.009	0.020	0.001	4.329	0.983	0.422	1.080
	Februari	0.788	0.034	0.026	0.003	6.112	1.030	0.361	1.509
	Maret	0.827	0.098	0.071	0.096	4.763	1.029	0.393	0.747
	April	1.185	0.087	0.160	0.211	5.148	1.047	0.888	0.663
	Mei	1.077	0.140	0.274	0.212	6.582	0.981	1.237	0.477
	Juni	1.733	0.105	0.241	0.244	9.267	1.418	2.552	0.910
	Juli	0.923	0.094	0.108	0.089	20.031	2.998	5.055	1.149
	Agustus	1.139	0.040	0.248	0.033	206.354	21.366	24.522	5.871
	September	1.656	0.642	0.257	0.701	11.392	5.019	3.777	1.274
	Oktober	7.901	2.608	3.512	2.509	0.477	0.338	0.168	0.511
	November	12.443	2.443	6.327	1.533	0.396	0.419	0.150	0.436
	Desember	37.241	2.182	3.136	1.796	0.438	0.330	0.195	0.456
...									
2018	
	Maret	18.417	5.299	4.636	4.680	9.478	0.547	1.051	1.838
	April	15.526	5.112	3.748	2.616	9.020	10.800	2.060	1.931
	Mei	8.524	2.604	1.621	1.905	153.475	29.578	19.941	11.546
	Juni	7.406	0.999	0.784	0.850	65.245	3.842	13.787	5.313
	Juli	39.724	3.687	13.973	4.045	2.471	0.332	0.220	1.172
	Agustus	39.051	12.433	29.472	12.206	0.973	0.341	0.249	0.905
	September	31.474	7.847	14.039	8.035	2.217	0.662	0.292	0.910
	Oktober	36.560	9.672	9.821	4.878	2.478	0.363	0.569	2.273
	November	25.659	5.068	5.928	6.990	7.627	0.881	1.078	2.022
	Desember	15.138	3.519	5.577	3.143	9.880	1.355	1.506	2.860
2019	Januari	15.082	5.172	5.354	4.244	14.270	0.329	1.242	4.064
	Februari	13.203	4.798	4.726	4.492	5.598	0.543	1.183	1.338
	Maret	12.197	3.768	3.552	3.135	10.674	0.869	1.307	1.836
	April	12.230	3.216	2.416	2.723	19.663	19.102	4.764	5.188
	Mei	7.511	1.100	1.160	1.616	250.386	23.562	38.922	14.171
	Juni	15.326	2.612	9.084	1.940	0.447	0.043	0.034	0.402

Lampiran 1. Data *Inflow* dan *Outflow* Wilayah KP BI Jawa Timur (dalam miliar rupiah) (lanjutan)

PERIODE	Rp. 1.000,- <i>Inflow</i>				Rp. 1.000,- <i>Outflow</i>				
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember	
2000	Januari	6.644	2.261	3.793	3.220	4.464	0.663	0.902	0.863
	Februari	10.302	4.346	8.139	4.211	5.288	0.451	0.687	0.616
	Maret	8.463	2.500	4.773	2.238	8.013	0.609	0.772	0.697
	April	5.636	2.346	3.813	1.993	4.769	0.377	0.771	0.214
	Mei	5.888	2.848	3.910	2.059	0.216	0.255	1.205	0.475
	Juni	2.633	1.781	2.614	1.076	2.787	0.362	1.552	0.883
	Juli	2.077	0.790	1.727	0.609	6.297	0.707	1.574	0.648
	Agustus	2.770	0.942	2.089	0.843	11.015	0.881	1.521	1.193
	September	2.644	1.150	2.590	0.809	5.802	0.910	1.631	0.245
	Oktober	2.276	1.066	2.902	0.841	0.519	0.932	0.724	0.239
	November	2.396	1.048	2.354	1.024	0.853	0.932	0.338	0.207
	Desember	2.777	0.453	0.877	0.535	36.699	2.708	3.912	1.236
...									
2018	
	Maret	0.776	0.327	0.193	0.339	0.142	0.086	0.041	0.011
	April	0.812	0.357	0.246	0.198	0.128	0.065	0.053	0.000
	Mei	0.409	0.480	0.175	0.116	0.238	0.644	0.115	0.459
	Juni	0.311	0.078	0.065	0.082	0.802	0.232	0.069	0.188
	Juli	0.790	0.226	0.258	0.183	0.105	0.063	0.069	0.041
	Agustus	0.660	0.186	0.422	0.374	0.121	0.049	0.112	0.046
	September	0.958	0.332	0.394	0.218	0.359	0.045	0.124	0.049
	Oktober	1.019	0.252	0.199	0.189	0.156	0.081	0.281	0.057
	November	0.949	0.162	0.262	0.310	0.278	0.033	0.133	0.021
	Desember	0.420	0.122	0.131	0.137	0.098	0.059	0.203	0.063
2019	Januari	0.622	0.150	0.223	0.202	0.298	0.050	0.230	0.099
	Februari	0.410	0.118	0.191	0.179	0.233	0.049	0.201	0.028
	Maret	0.532	0.123	0.143	0.148	0.162	0.073	0.244	0.045
	April	0.417	0.147	0.150	0.113	0.249	0.516	0.375	0.016
	Mei	0.292	0.097	0.136	0.112	1.624	0.538	1.153	0.400
	Juni	0.254	0.141	0.094	0.071	0.118	0.031	0.005	0.020

Lampiran 2. Output SAS Pemodelan TSR data Simulasi 1 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.309912	0.003897	79.52	<.0001
S1	1	16.70258	0.555507	30.07	<.0001
S2	1	20.16982	0.557186	36.2	<.0001
S3	1	21.36381	0.558887	38.23	<.0001
S4	1	19.83735	0.56061	35.39	<.0001
S5	1	16.27659	0.562355	28.94	<.0001
S6	1	12.22087	0.564121	21.66	<.0001
S7	1	7.783411	0.589706	13.2	<.0001
S8	1	4.283463	0.613168	6.99	<.0001
S9	1	3.272458	0.621448	5.27	<.0001
S10	1	3.855251	0.666711	5.78	<.0001
S11	1	7.323541	0.606211	12.08	<.0001
S12	1	12.2313	0.575159	21.27	<.0001
V1t	1	9.21071	1.253057	7.35	<.0001
V2t	1	47.40261	0.894436	53	<.0001
V3t	1	66.90331	1.258032	53.18	<.0001
V4t	1	82.51169	1.070691	77.06	<.0001
V1t1	1	63.24146	1.258864	50.24	<.0001
V2t1	1	48.01853	0.894408	53.69	<.0001
V3t1	1	33.08521	1.252261	26.42	<.0001
V4t1	1	31.4179	1.019744	30.81	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.174876	0.004062	43.05	<.0001
S1	1	15.08144	0.578997	26.05	<.0001
S2	1	16.05528	0.580747	27.65	<.0001
S3	1	16.75755	0.58252	28.77	<.0001
S4	1	15.95003	0.584315	27.3	<.0001
S5	1	14.34011	0.586134	24.47	<.0001
S6	1	12.7158	0.587975	21.63	<.0001
S7	1	10.47721	0.614642	17.05	<.0001
S8	1	9.388514	0.639096	14.69	<.0001
S9	1	8.452905	0.647726	13.05	<.0001
S10	1	9.112647	0.694903	13.11	<.0001
S11	1	10.21233	0.631844	16.16	<.0001
S12	1	12.60566	0.59948	21.03	<.0001
V1t	1	4.173256	1.306042	3.2	0.0018
V2t	1	10.84208	0.932257	11.63	<.0001
V3t	1	22.35983	1.311227	17.05	<.0001
V4t	1	28.36578	1.115965	25.42	<.0001
V1t1	1	21.34459	1.312095	16.27	<.0001
V2t1	1	13.15627	0.932228	14.11	<.0001
V3t1	1	11.69306	1.305213	8.96	<.0001
V4t1	1	8.537036	1.062864	8.03	<.0001

Lampiran 2. Output SAS Pemodelan TSR data Simulasi 1 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.227689	0.004272	53.3	<.0001
S1	1	16.50087	0.608953	27.1	<.0001
S2	1	18.6437	0.610794	30.52	<.0001
S3	1	19.35819	0.612658	31.6	<.0001
S4	1	18.80315	0.614547	30.6	<.0001
S5	1	15.87373	0.61646	25.75	<.0001
S6	1	12.81905	0.618396	20.73	<.0001
S7	1	9.456656	0.646443	14.63	<.0001
S8	1	7.283519	0.672162	10.84	<.0001
S9	1	5.611827	0.681238	8.24	<.0001
S10	1	6.351415	0.730856	8.69	<.0001
S11	1	8.746394	0.664535	13.16	<.0001
S12	1	12.4219	0.630496	19.7	<.0001
V1t	1	5.030436	1.373614	3.66	0.0004
V2t	1	15.23396	0.98049	15.54	<.0001
V3t	1	33.66019	1.379068	24.41	<.0001
V4t	1	35.91083	1.173703	30.6	<.0001
V1t1	1	31.34403	1.37998	22.71	<.0001
V2t1	1	20.05482	0.98046	20.45	<.0001
V3t1	1	17.68293	1.372742	12.88	<.0001
V4t1	1	15.05302	1.117854	13.47	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.156877	0.004141	37.88	<.0001
S1	1	15.28677	0.590334	25.9	<.0001
S2	1	17.03201	0.592118	28.76	<.0001
S3	1	17.61385	0.593926	29.66	<.0001
S4	1	16.67373	0.595757	27.99	<.0001
S5	1	14.97799	0.597611	25.06	<.0001
S6	1	12.80574	0.599488	21.36	<.0001
S7	1	10.32571	0.626677	16.48	<.0001
S8	1	8.262593	0.65161	12.68	<.0001
S9	1	7.202722	0.660409	10.91	<.0001
S10	1	7.741545	0.708509	10.93	<.0001
S11	1	9.667348	0.644217	15.01	<.0001
S12	1	12.51028	0.611218	20.47	<.0001
V1t	1	2.084525	1.331615	1.57	0.1203
V2t	1	7.603473	0.950511	8	<.0001
V3t	1	14.34506	1.336903	10.73	<.0001
V4t	1	18.05689	1.137817	15.87	<.0001
V1t1	1	16.77803	1.337787	12.54	<.0001
V2t1	1	10.60237	0.950482	11.15	<.0001
V3t1	1	11.55018	1.33077	8.68	<.0001
V4t1	1	7.239213	1.083676	6.68	<.0001

Lampiran 3. Output SAS Pemodelan TSR data Simulasi 2 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.319704	0.002879	111.06	<.0001
S1	1	16.7254	0.410322	40.76	<.0001
S2	1	19.58361	0.411562	47.58	<.0001
S3	1	21.00081	0.412818	50.87	<.0001
S4	1	19.95712	0.414091	48.2	<.0001
S5	1	16.63868	0.41538	40.06	<.0001
S6	1	12.09442	0.416684	29.03	<.0001
S7	1	8.044594	0.435583	18.47	<.0001
S8	1	4.236884	0.452912	9.35	<.0001
S9	1	2.919105	0.459028	6.36	<.0001
S10	1	3.964824	0.492461	8.05	<.0001
S11	1	7.089779	0.447774	15.83	<.0001
S12	1	11.6807	0.424837	27.49	<.0001
V1t	1	6.547668	0.925562	7.07	<.0001
V2t	1	48.0004	0.660669	72.65	<.0001
V3t	1	65.79463	0.929236	70.81	<.0001
V4t	1	81.83069	0.790859	103.47	<.0001
V1t1	1	61.3872	0.929851	66.02	<.0001
V2t1	1	48.90403	0.660649	74.02	<.0001
V3t1	1	32.18004	0.924974	34.79	<.0001
V4t1	1	31.90946	0.753227	42.36	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.190682	0.00343	55.59	<.0001
S1	1	13.67983	0.488911	27.98	<.0001
S2	1	15.28676	0.490389	31.17	<.0001
S3	1	16.07338	0.491886	32.68	<.0001
S4	1	15.73737	0.493403	31.9	<.0001
S5	1	14.01332	0.494938	28.31	<.0001
S6	1	12.21163	0.496493	24.6	<.0001
S7	1	10.50286	0.519011	20.24	<.0001
S8	1	8.910179	0.53966	16.51	<.0001
S9	1	8.357985	0.546947	15.28	<.0001
S10	1	8.905582	0.586784	15.18	<.0001
S11	1	9.974842	0.533537	18.7	<.0001
S12	1	12.10705	0.506207	23.92	<.0001
V1t	1	1.570476	1.102836	1.42	0.1572
V2t	1	12.41706	0.787208	15.77	<.0001
V3t	1	21.72978	1.107215	19.63	<.0001
V4t	1	28.51376	0.942333	30.26	<.0001
V1t1	1	18.64023	1.107948	16.82	<.0001
V2t1	1	13.42721	0.787184	17.06	<.0001
V3t1	1	10.19427	1.102136	9.25	<.0001
V4t1	1	9.500537	0.897494	10.59	<.0001

Lampiran 3. Output SAS Pemodelan TSR data Simulasi 2 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.241297	0.003637	66.35	<.0001
S1	1	15.33986	0.518363	29.59	<.0001
S2	1	17.56434	0.51993	33.78	<.0001
S3	1	18.9596	0.521517	36.35	<.0001
S4	1	18.28177	0.523125	34.95	<.0001
S5	1	15.8203	0.524753	30.15	<.0001
S6	1	12.2388	0.526401	23.25	<.0001
S7	1	8.75268	0.550276	15.91	<.0001
S8	1	6.058294	0.572169	10.59	<.0001
S9	1	5.098655	0.579895	8.79	<.0001
S10	1	6.525864	0.622131	10.49	<.0001
S11	1	8.51978	0.565677	15.06	<.0001
S12	1	11.94753	0.536701	22.26	<.0001
V1t	1	1.358079	1.169271	1.16	0.2479
V2t	1	16.38019	0.834629	19.63	<.0001
V3t	1	33.05285	1.173913	28.16	<.0001
V4t	1	35.99419	0.999099	36.03	<.0001
V1t1	1	27.78854	1.17469	23.66	<.0001
V2t1	1	20.92218	0.834604	25.07	<.0001
V3t1	1	17.77307	1.168529	15.21	<.0001
V4t1	1	16.66352	0.951559	17.51	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.170886	0.003101	55.11	<.0001
S1	1	14.83385	0.441963	33.56	<.0001
S2	1	16.65838	0.443299	37.58	<.0001
S3	1	16.68739	0.444652	37.53	<.0001
S4	1	16.78456	0.446023	37.63	<.0001
S5	1	14.4628	0.447411	32.33	<.0001
S6	1	12.20296	0.448816	27.19	<.0001
S7	1	10.37999	0.469172	22.12	<.0001
S8	1	8.731725	0.487838	17.9	<.0001
S9	1	7.198182	0.494426	14.56	<.0001
S10	1	7.994897	0.530437	15.07	<.0001
S11	1	9.279486	0.482303	19.24	<.0001
S12	1	11.66353	0.457598	25.49	<.0001
V1t	1	0.733697	0.996935	0.74	0.4633
V2t	1	8.894206	0.711616	12.5	<.0001
V3t	1	13.53705	1.000894	13.52	<.0001
V4t	1	17.76869	0.851845	20.86	<.0001
V1t1	1	13.52422	1.001556	13.5	<.0001
V2t1	1	10.64692	0.711594	14.96	<.0001
V3t1	1	9.041335	0.996303	9.07	<.0001
V4t1	1	8.944863	0.811311	11.03	<.0001

Lampiran 4. Output SAS Pemodelan TSR data Simulasi 3 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.299546	0.003762	79.63	<.0001
S1	1	15.74901	0.536236	29.37	<.0001
S2	1	19.13291	0.537857	35.57	<.0001
S3	1	19.63985	0.539499	36.4	<.0001
S4	1	18.35031	0.541162	33.91	<.0001
S5	1	15.22577	0.542846	28.05	<.0001
S6	1	10.40992	0.544551	19.12	<.0001
S7	1	6.607906	0.569249	11.61	<.0001
S8	1	3.648331	0.591896	6.16	<.0001
S9	1	2.289305	0.599889	3.82	0.0002
S10	1	3.359307	0.643582	5.22	<.0001
S11	1	6.947006	0.585181	11.87	<.0001
S12	1	10.71027	0.555206	19.29	<.0001
V1t	1	2.581314	1.209586	2.13	0.035
V2t	1	22.68194	0.863406	26.27	<.0001
V3t	1	32.37224	1.214389	26.66	<.0001
V4t	1	41.41813	1.033547	40.07	<.0001
V1t1	1	30.99256	1.215192	25.5	<.0001
V2t1	1	23.97903	0.86338	27.77	<.0001
V3t1	1	15.98372	1.208818	13.22	<.0001
V4t1	1	16.99365	0.984367	17.26	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.171389	0.003626	47.27	<.0001
S1	1	13.49896	0.516793	26.12	<.0001
S2	1	14.22149	0.518355	27.44	<.0001
S3	1	14.56228	0.519938	28.01	<.0001
S4	1	13.83487	0.52154	26.53	<.0001
S5	1	12.21049	0.523164	23.34	<.0001
S6	1	10.32472	0.524807	19.67	<.0001
S7	1	8.908422	0.548609	16.24	<.0001
S8	1	7.827468	0.570436	13.72	<.0001
S9	1	7.126654	0.578138	12.33	<.0001
S10	1	7.138214	0.620247	11.51	<.0001
S11	1	9.18475	0.563963	16.29	<.0001
S12	1	11.08491	0.535075	20.72	<.0001
V1t	1	0.879487	1.165729	0.75	0.4522
V2t	1	4.946391	0.832101	5.94	<.0001
V3t	1	10.45844	1.170358	8.94	<.0001
V4t	1	15.24484	0.996073	15.3	<.0001
V1t1	1	10.12909	1.171132	8.65	<.0001
V2t1	1	6.111749	0.832076	7.35	<.0001
V3t1	1	5.291621	1.164989	4.54	<.0001
V4t1	1	5.81779	0.948676	6.13	<.0001

Lampiran 4. Output SAS Pemodelan TSR data Simulasi 3 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.218598	0.003713	58.88	<.0001
S1	1	15.27072	0.529211	28.86	<.0001
S2	1	16.9213	0.53081	31.88	<.0001
S3	1	17.7516	0.532431	33.34	<.0001
S4	1	16.80508	0.534072	31.47	<.0001
S5	1	13.93054	0.535734	26	<.0001
S6	1	10.27752	0.537417	19.12	<.0001
S7	1	7.369181	0.561791	13.12	<.0001
S8	1	5.370375	0.584142	9.19	<.0001
S9	1	4.473418	0.59203	7.56	<.0001
S10	1	4.932199	0.63515	7.77	<.0001
S11	1	7.527092	0.577514	13.03	<.0001
S12	1	11.08019	0.547933	20.22	<.0001
V1t	1	13.62727	1.19374	11.42	<.0001
V2t	1	9.956906	0.852095	11.69	<.0001
V3t	1	8.73152	1.19848	7.29	<.0001
V4t	1	8.453283	1.020007	8.29	<.0001
V1t1	1	1.507617	1.199273	1.26	0.2114
V2t1	1	7.332368	0.852069	8.61	<.0001
V3t1	1	14.78835	1.192982	12.4	<.0001
V4t1	1	19.10094	0.971472	19.66	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.148973	0.004017	37.08	<.0001
S1	1	13.47677	0.572656	23.53	<.0001
S2	1	15.25869	0.574387	26.57	<.0001
S3	1	15.63147	0.57614	27.13	<.0001
S4	1	15.09293	0.577916	26.12	<.0001
S5	1	12.94835	0.579715	22.34	<.0001
S6	1	10.59558	0.581536	18.22	<.0001
S7	1	8.27937	0.607911	13.62	<.0001
S8	1	6.934629	0.632097	10.97	<.0001
S9	1	5.948366	0.640632	9.29	<.0001
S10	1	6.240867	0.687292	9.08	<.0001
S11	1	9.044438	0.624925	14.47	<.0001
S12	1	10.96875	0.592914	18.5	<.0001
V1t	1	-0.30141	1.291739	-0.23	0.8159
V2t	1	3.205777	0.922047	3.48	0.0007
V3t	1	5.530399	1.296867	4.26	<.0001
V4t	1	9.987439	1.103744	9.05	<.0001
V1t1	1	7.798624	1.297725	6.01	<.0001
V2t1	1	4.305274	0.922019	4.67	<.0001
V3t1	1	3.731522	1.290919	2.89	0.0046
V4t1	1	5.181286	1.051224	4.93	<.0001

Lampiran 5. Output SAS Pemodelan TSR data Simulasi 4 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.301446	0.004414	68.3	<.0001
S1	1	16.54668	0.629121	26.3	<.0001
S2	1	20.38741	0.631022	32.31	<.0001
S3	1	21.13574	0.632948	33.39	<.0001
S4	1	20.29471	0.6349	31.97	<.0001
S5	1	17.0242	0.636876	26.73	<.0001
S6	1	12.90156	0.638876	20.19	<.0001
S7	1	8.158806	0.667851	12.22	<.0001
S8	1	4.352933	0.694422	6.27	<.0001
S9	1	3.123749	0.703799	4.44	<.0001
S10	1	4.554034	0.75506	6.03	<.0001
S11	1	7.349365	0.686543	10.7	<.0001
S12	1	11.86389	0.651377	18.21	<.0001
V1t	1	10.21773	1.419106	7.2	<.0001
V2t	1	47.20792	1.012962	46.6	<.0001
V3t	1	68.50302	1.42474	48.08	<.0001
V4t	1	81.99444	1.212574	67.62	<.0001
V1t1	1	63.24196	1.425683	44.36	<.0001
V2t1	1	47.76022	1.012931	47.15	<.0001
V3t1	1	33.60522	1.418205	23.7	<.0001
V4t1	1	32.02477	1.154876	27.73	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.171733	0.005183	33.13	<.0001
S1	1	13.7873	0.73886	18.66	<.0001
S2	1	15.6955	0.741093	21.18	<.0001
S3	1	16.0429	0.743355	21.58	<.0001
S4	1	15.40733	0.745647	20.66	<.0001
S5	1	14.45456	0.747968	19.33	<.0001
S6	1	13.06083	0.750317	17.41	<.0001
S7	1	10.55234	0.784347	13.45	<.0001
S8	1	8.867938	0.815552	10.87	<.0001
S9	1	8.56363	0.826565	10.36	<.0001
S10	1	9.099994	0.886768	10.26	<.0001
S11	1	10.01896	0.806299	12.43	<.0001
S12	1	11.42637	0.764998	14.94	<.0001
V1t	1	4.554221	1.666645	2.73	0.0073
V2t	1	10.8914	1.189656	9.16	<.0001
V3t	1	23.1505	1.673262	13.84	<.0001
V4t	1	28.63238	1.424087	20.11	<.0001
V1t1	1	20.58841	1.674369	12.3	<.0001
V2t1	1	12.42987	1.18962	10.45	<.0001
V3t1	1	13.24725	1.665587	7.95	<.0001
V4t1	1	8.499855	1.356324	6.27	<.0001

Lampiran 5. Output SAS Pemodelan TSR data Simulasi 4 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.221234	0.004958	44.62	<.0001
S1	1	15.29186	0.706683	21.64	<.0001
S2	1	17.91076	0.708819	25.27	<.0001
S3	1	18.84124	0.710982	26.5	<.0001
S4	1	18.67282	0.713174	26.18	<.0001
S5	1	16.03092	0.715394	22.41	<.0001
S6	1	12.89966	0.717641	17.98	<.0001
S7	1	9.307781	0.750189	12.41	<.0001
S8	1	6.780722	0.780035	8.69	<.0001
S9	1	5.521993	0.790569	6.98	<.0001
S10	1	6.376434	0.848149	7.52	<.0001
S11	1	8.740663	0.771185	11.33	<.0001
S12	1	11.71879	0.731683	16.02	<.0001
V1t	1	4.862649	1.594063	3.05	0.0029
V2t	1	15.38014	1.137847	13.52	<.0001
V3t	1	34.21392	1.600392	21.38	<.0001
V4t	1	35.08191	1.362068	25.76	<.0001
V1t1	1	30.2465	1.601451	18.89	<.0001
V2t1	1	20.09573	1.137812	17.66	<.0001
V3t1	1	18.85258	1.593051	11.83	<.0001
V4t1	1	15.24016	1.297256	11.75	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.154053	0.005169	29.8	<.0001
S1	1	13.93844	0.73679	18.92	<.0001
S2	1	16.0695	0.739017	21.74	<.0001
S3	1	16.76296	0.741273	22.61	<.0001
S4	1	16.34055	0.743558	21.98	<.0001
S5	1	14.97023	0.745872	20.07	<.0001
S6	1	12.47043	0.748215	16.67	<.0001
S7	1	9.978153	0.78215	12.76	<.0001
S8	1	7.799841	0.813268	9.59	<.0001
S9	1	6.878634	0.82425	8.35	<.0001
S10	1	8.393411	0.884284	9.49	<.0001
S11	1	9.132551	0.80404	11.36	<.0001
S12	1	11.35961	0.762855	14.89	<.0001
V1t	1	2.368784	1.661976	1.43	0.1569
V2t	1	7.211505	1.186323	6.08	<.0001
V3t	1	15.10446	1.668575	9.05	<.0001
V4t	1	17.28994	1.420098	12.18	<.0001
V1t1	1	15.391	1.669679	9.22	<.0001
V2t1	1	9.543275	1.186287	8.04	<.0001
V3t1	1	11.13687	1.660921	6.71	<.0001
V4t1	1	8.410958	1.352525	6.22	<.0001

Lampiran 6. Output SAS Pemodelan TSR data Simulasi 5 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.330707	0.003246	101.9	<.0001
S1	1	15.29387	0.46263	33.06	<.0001
S2	1	18.23277	0.464028	39.29	<.0001
S3	1	19.86458	0.465445	42.68	<.0001
S4	1	18.22277	0.466879	39.03	<.0001
S5	1	15.1874	0.468332	32.43	<.0001
S6	1	10.35428	0.469803	22.04	<.0001
S7	1	5.757465	0.491111	11.72	<.0001
S8	1	2.281847	0.51065	4.47	<.0001
S9	1	0.841909	0.517546	1.63	0.1066
S10	1	2.425743	0.555241	4.37	<.0001
S11	1	5.539935	0.504856	10.97	<.0001
S12	1	10.11554	0.478996	21.12	<.0001
V1t	1	8.767651	1.043553	8.4	<.0001
V2t	1	47.24466	0.744891	63.42	<.0001
V3t	1	67.47648	1.047696	64.4	<.0001
V4t	1	83.3241	0.891678	93.45	<.0001
V1t1	1	63.64273	1.048389	60.71	<.0001
V2t1	1	47.86793	0.744869	64.26	<.0001
V3t1	1	34.57822	1.04289	33.16	<.0001
V4t1	1	32.91797	0.849249	38.76	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.200061	0.004092	48.9	<.0001
S1	1	12.67285	0.583229	21.73	<.0001
S2	1	14.05578	0.584992	24.03	<.0001
S3	1	15.17586	0.586778	25.86	<.0001
S4	1	14.2129	0.588587	24.15	<.0001
S5	1	12.4699	0.590419	21.12	<.0001
S6	1	10.41136	0.592273	17.58	<.0001
S7	1	8.616069	0.619135	13.92	<.0001
S8	1	7.391141	0.643768	11.48	<.0001
S9	1	6.306696	0.652461	9.67	<.0001
S10	1	6.674149	0.699983	9.53	<.0001
S11	1	8.440739	0.636463	13.26	<.0001
S12	1	10.16748	0.603862	16.84	<.0001
V1t	1	4.295688	1.315589	3.27	0.0015
V2t	1	10.65713	0.939072	11.35	<.0001
V3t	1	23.88918	1.320813	18.09	<.0001
V4t	1	30.56106	1.124123	27.19	<.0001
V1t1	1	21.94515	1.321687	16.6	<.0001
V2t1	1	12.72012	0.939043	13.55	<.0001
V3t1	1	11.88046	1.314754	9.04	<.0001
V4t1	1	9.992295	1.070633	9.33	<.0001

Lampiran 6. Output SAS Pemodelan TSR data Simulasi 5 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.251079	0.004234	59.31	<.0001
S1	1	14.0535	0.603463	23.29	<.0001
S2	1	16.72465	0.605287	27.63	<.0001
S3	1	17.62689	0.607135	29.03	<.0001
S4	1	16.49569	0.609006	27.09	<.0001
S5	1	13.76273	0.610902	22.53	<.0001
S6	1	10.33734	0.61282	16.87	<.0001
S7	1	6.564277	0.640614	10.25	<.0001
S8	1	4.298079	0.666101	6.45	<.0001
S9	1	3.719379	0.675096	5.51	<.0001
S10	1	3.813664	0.724266	5.27	<.0001
S11	1	6.859684	0.658544	10.42	<.0001
S12	1	10.88517	0.624811	17.42	<.0001
V1t	1	5.360243	1.36123	3.94	0.0001
V2t	1	15.97591	0.97165	16.44	<.0001
V3t	1	35.31575	1.366634	25.84	<.0001
V4t	1	37.46398	1.163121	32.21	<.0001
V1t1	1	30.59351	1.367539	22.37	<.0001
V2t1	1	20.3502	0.97162	20.94	<.0001
V3t1	1	19.72909	1.360366	14.5	<.0001
V4t1	1	17.04987	1.107776	15.39	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.184735	0.004443	41.58	<.0001
S1	1	12.75568	0.633292	20.14	<.0001
S2	1	14.63369	0.635206	23.04	<.0001
S3	1	15.31399	0.637145	24.04	<.0001
S4	1	14.72949	0.639109	23.05	<.0001
S5	1	12.53424	0.641098	19.55	<.0001
S6	1	9.749677	0.643112	15.16	<.0001
S7	1	7.716863	0.67228	11.48	<.0001
S8	1	6.136652	0.699027	8.78	<.0001
S9	1	5.306477	0.708466	7.49	<.0001
S10	1	5.681805	0.760067	7.48	<.0001
S11	1	7.653908	0.691095	11.08	<.0001
S12	1	9.950496	0.655696	15.18	<.0001
V1t	1	3.024035	1.428515	2.12	0.0365
V2t	1	7.455518	1.019679	7.31	<.0001
V3t	1	15.4479	1.434187	10.77	<.0001
V4t	1	19.14186	1.220614	15.68	<.0001
V1t1	1	15.24159	1.435136	10.62	<.0001
V2t1	1	9.527661	1.019648	9.34	<.0001
V3t1	1	11.54748	1.427609	8.09	<.0001
V4t1	1	9.275372	1.162533	7.98	<.0001

Lampiran 7. Output SAS Pemodelan TSR data Simulasi 6 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.2846	0.003968	71.73	<.0001
S1	1	18.42265	0.565545	32.58	<.0001
S2	1	21.50011	0.567254	37.9	<.0001
S3	1	22.94525	0.568986	40.33	<.0001
S4	1	21.51533	0.57074	37.7	<.0001
S5	1	18.93034	0.572516	33.07	<.0001
S6	1	14.12815	0.574314	24.6	<.0001
S7	1	9.517543	0.600362	15.85	<.0001
S8	1	6.043341	0.624247	9.68	<.0001
S9	1	5.085984	0.632677	8.04	<.0001
S10	1	5.636736	0.678757	8.3	<.0001
S11	1	9.238802	0.617164	14.97	<.0001
S12	1	13.75671	0.585551	23.49	<.0001
V1t	1	11.15648	1.275698	8.75	<.0001
V2t	1	46.72207	0.910597	51.31	<.0001
V3t	1	65.03337	1.280763	50.78	<.0001
V4t	1	82.80613	1.090037	75.97	<.0001
V1t1	1	64.88037	1.28161	50.62	<.0001
V2t1	1	47.98878	0.910569	52.7	<.0001
V3t1	1	32.80214	1.274888	25.73	<.0001
V4t1	1	32.24154	1.038169	31.06	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.152645	0.004338	35.19	<.0001
S1	1	15.82098	0.618322	25.59	<.0001
S2	1	17.03734	0.62019	27.47	<.0001
S3	1	18.13051	0.622084	29.14	<.0001
S4	1	17.43832	0.624001	27.95	<.0001
S5	1	16.2408	0.625943	25.95	<.0001
S6	1	14.18257	0.627909	22.59	<.0001
S7	1	12.50108	0.656388	19.05	<.0001
S8	1	10.91121	0.682502	15.99	<.0001
S9	1	10.08236	0.691719	14.58	<.0001
S10	1	9.901335	0.742099	13.34	<.0001
S11	1	11.94364	0.674759	17.7	<.0001
S12	1	14.12566	0.640195	22.06	<.0001
V1t	1	6.307264	1.394746	4.52	<.0001
V2t	1	11.12532	0.995574	11.17	<.0001
V3t	1	21.88988	1.400284	15.63	<.0001
V4t	1	30.69283	1.19176	25.75	<.0001
V1t1	1	22.13482	1.401211	15.8	<.0001
V2t1	1	12.42842	0.995544	12.48	<.0001
V3t1	1	11.07735	1.393861	7.95	<.0001
V4t1	1	8.425322	1.135052	7.42	<.0001

Lampiran 7. Output SAS Pemodelan TSR data Simulasi 6 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.207015	0.004183	49.49	<.0001
S1	1	17.16014	0.596204	28.78	<.0001
S2	1	19.42639	0.598006	32.49	<.0001
S3	1	20.2996	0.599831	33.84	<.0001
S4	1	19.84013	0.60168	32.97	<.0001
S5	1	17.39216	0.603553	28.82	<.0001
S6	1	13.53035	0.605449	22.35	<.0001
S7	1	10.85434	0.632908	17.15	<.0001
S8	1	8.491556	0.658089	12.9	<.0001
S9	1	6.883542	0.666975	10.32	<.0001
S10	1	7.089466	0.715554	9.91	<.0001
S11	1	10.12495	0.650622	15.56	<.0001
S12	1	13.67966	0.617295	22.16	<.0001
V1t	1	6.299538	1.344855	4.68	<.0001
V2t	1	15.34729	0.959962	15.99	<.0001
V3t	1	32.75736	1.350195	24.26	<.0001
V4t	1	36.93824	1.14913	32.14	<.0001
V1t1	1	32.09175	1.351088	23.75	<.0001
V2t1	1	19.64055	0.959933	20.46	<.0001
V3t1	1	15.36702	1.344002	11.43	<.0001
V4t1	1	15.6495	1.09445	14.3	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.134752	0.004711	28.6	<.0001
S1	1	16.27807	0.671551	24.24	<.0001
S2	1	17.74858	0.67358	26.35	<.0001
S3	1	18.91773	0.675637	28	<.0001
S4	1	18.55281	0.677719	27.38	<.0001
S5	1	16.60784	0.679829	24.43	<.0001
S6	1	13.81194	0.681964	20.25	<.0001
S7	1	11.71776	0.712894	16.44	<.0001
S8	1	9.575309	0.741257	12.92	<.0001
S9	1	8.75415	0.751266	11.65	<.0001
S10	1	9.205134	0.805984	11.42	<.0001
S11	1	11.55366	0.732846	15.77	<.0001
S12	1	13.93108	0.695308	20.04	<.0001
V1t	1	4.783134	1.514815	3.16	0.002
V2t	1	7.713255	1.08128	7.13	<.0001
V3t	1	13.27112	1.52083	8.73	<.0001
V4t	1	18.64146	1.294354	14.4	<.0001
V1t1	1	17.31866	1.521836	11.38	<.0001
V2t1	1	9.979773	1.081247	9.23	<.0001
V3t1	1	9.676051	1.513854	6.39	<.0001
V4t1	1	7.900721	1.232764	6.41	<.0001

Lampiran 8. Output SAS Pemodelan TSR data Simulasi 7 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.314816	0.003348	94.03	<.0001
S1	1	15.50903	0.477238	32.5	<.0001
S2	1	18.96819	0.478681	39.63	<.0001
S3	1	20.26585	0.480142	42.21	<.0001
S4	1	18.50403	0.481622	38.42	<.0001
S5	1	15.73674	0.483121	32.57	<.0001
S6	1	11.2144	0.484638	23.14	<.0001
S7	1	6.356591	0.506619	12.55	<.0001
S8	1	2.93283	0.526775	5.57	<.0001
S9	1	2.147357	0.533888	4.02	0.0001
S10	1	2.758312	0.572774	4.82	<.0001
S11	1	6.02441	0.520798	11.57	<.0001
S12	1	11.16645	0.494121	22.6	<.0001
V1t	1	8.717554	1.076505	8.1	<.0001
V2t	1	48.02766	0.768413	62.5	<.0001
V3t	1	67.04625	1.08078	62.04	<.0001
V4t	1	83.29446	0.919835	90.55	<.0001
V1t1	1	62.55307	1.081495	57.84	<.0001
V2t1	1	48.22204	0.768389	62.76	<.0001
V3t1	1	33.40916	1.075822	31.05	<.0001
V4t1	1	32.01828	0.876066	36.55	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.185552	0.0039	47.57	<.0001
S1	1	13.25524	0.555945	23.84	<.0001
S2	1	14.24741	0.557626	25.55	<.0001
S3	1	15.23795	0.559328	27.24	<.0001
S4	1	14.76027	0.561052	26.31	<.0001
S5	1	13.23479	0.562798	23.52	<.0001
S6	1	10.91942	0.564566	19.34	<.0001
S7	1	9.229524	0.590171	15.64	<.0001
S8	1	7.067972	0.613652	11.52	<.0001
S9	1	6.861627	0.621938	11.03	<.0001
S10	1	6.452199	0.667237	9.67	<.0001
S11	1	8.463995	0.606689	13.95	<.0001
S12	1	10.41956	0.575613	18.1	<.0001
V1t	1	4.501836	1.254045	3.59	0.0005
V2t	1	11.32639	0.895141	12.65	<.0001
V3t	1	23.34214	1.259024	18.54	<.0001
V4t	1	30.56029	1.071535	28.52	<.0001
V1t1	1	20.33505	1.259857	16.14	<.0001
V2t1	1	14.01383	0.895114	15.66	<.0001
V3t1	1	11.00502	1.253249	8.78	<.0001
V4t1	1	9.625221	1.020548	9.43	<.0001

Lampiran 8. Output SAS Pemodelan TSR data Simulasi 7 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.235282	0.004086	57.58	<.0001
S1	1	14.95152	0.582487	25.67	<.0001
S2	1	17.3701	0.584247	29.73	<.0001
S3	1	18.41809	0.586031	31.43	<.0001
S4	1	17.71097	0.587838	30.13	<.0001
S5	1	14.74455	0.589667	25	<.0001
S6	1	11.28058	0.591519	19.07	<.0001
S7	1	7.754783	0.618347	12.54	<.0001
S8	1	4.403803	0.642948	6.85	<.0001
S9	1	3.9187	0.65163	6.01	<.0001
S10	1	4.880343	0.699091	6.98	<.0001
S11	1	7.397879	0.635653	11.64	<.0001
S12	1	10.791	0.603093	17.89	<.0001
V1t	1	3.864792	1.313914	2.94	0.004
V2t	1	16.47535	0.937876	17.57	<.0001
V3t	1	35.36522	1.319131	26.81	<.0001
V4t	1	37.53456	1.122692	33.43	<.0001
V1t1	1	29.00361	1.320004	21.97	<.0001
V2t1	1	21.20957	0.937847	22.62	<.0001
V3t1	1	18.12708	1.31308	13.81	<.0001
V4t1	1	16.47838	1.06927	15.41	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.166887	0.003947	42.28	<.0001
S1	1	13.09148	0.562676	23.27	<.0001
S2	1	14.65065	0.564376	25.96	<.0001
S3	1	15.60823	0.566099	27.57	<.0001
S4	1	15.4206	0.567845	27.16	<.0001
S5	1	13.82862	0.569612	24.28	<.0001
S6	1	11.57768	0.571401	20.26	<.0001
S7	1	8.789467	0.597316	14.71	<.0001
S8	1	5.888777	0.621081	9.48	<.0001
S9	1	5.657713	0.629468	8.99	<.0001
S10	1	5.555553	0.675314	8.23	<.0001
S11	1	8.079764	0.614034	13.16	<.0001
S12	1	10.36739	0.582581	17.8	<.0001
V1t	1	2.938597	1.269227	2.32	0.0224
V2t	1	8.216704	0.905978	9.07	<.0001
V3t	1	14.56862	1.274266	11.43	<.0001
V4t	1	20.08172	1.084508	18.52	<.0001
V1t1	1	14.52378	1.275109	11.39	<.0001
V2t1	1	11.8435	0.90595	13.07	<.0001
V3t1	1	10.71835	1.268421	8.45	<.0001
V4t1	1	9.541792	1.032903	9.24	<.0001

Lampiran 9. Output SAS Pemodelan TSR data Simulasi 8 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.293825	0.003943	74.53	<.0001
S1	1	16.02243	0.561989	28.51	<.0001
S2	1	19.8699	0.563687	35.25	<.0001
S3	1	20.88953	0.565408	36.95	<.0001
S4	1	20.15058	0.567151	35.53	<.0001
S5	1	16.39771	0.568916	28.82	<.0001
S6	1	12.10055	0.570703	21.2	<.0001
S7	1	7.231296	0.596587	12.12	<.0001
S8	1	4.2248	0.620322	6.81	<.0001
S9	1	3.122246	0.628699	4.97	<.0001
S10	1	3.968282	0.674489	5.88	<.0001
S11	1	7.599593	0.613284	12.39	<.0001
S12	1	12.02133	0.58187	20.66	<.0001
V1t	1	9.899395	1.267676	7.81	<.0001
V2t	1	46.79896	0.904871	51.72	<.0001
V3t	1	65.31014	1.272709	51.32	<.0001
V4t	1	80.28923	1.083183	74.12	<.0001
V1t1	1	63.75155	1.273551	50.06	<.0001
V2t1	1	47.19536	0.904844	52.16	<.0001
V3t1	1	33.87127	1.266872	26.74	<.0001
V4t1	1	29.66229	1.031641	28.75	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.159423	0.004265	37.38	<.0001
S1	1	14.22652	0.607973	23.4	<.0001
S2	1	15.54794	0.609811	25.5	<.0001
S3	1	16.06321	0.611672	26.26	<.0001
S4	1	15.45109	0.613558	25.18	<.0001
S5	1	14.10501	0.615468	22.92	<.0001
S6	1	12.45178	0.617401	20.17	<.0001
S7	1	10.43628	0.645402	16.17	<.0001
S8	1	8.956659	0.67108	13.35	<.0001
S9	1	8.458253	0.680142	12.44	<.0001
S10	1	9.329404	0.72968	12.79	<.0001
S11	1	10.48179	0.663466	15.8	<.0001
S12	1	12.37297	0.629481	19.66	<.0001
V1t	1	4.124408	1.371404	3.01	0.0033
V2t	1	10.67513	0.978912	10.91	<.0001
V3t	1	23.40331	1.376849	17	<.0001
V4t	1	26.84569	1.171815	22.91	<.0001
V1t1	1	20.62778	1.37776	14.97	<.0001
V2t1	1	12.19419	0.978883	12.46	<.0001
V3t1	1	12.20515	1.370534	8.91	<.0001
V4t1	1	5.676882	1.116056	5.09	<.0001

Lampiran 9. Output SAS Pemodelan TSR data Simulasi 8 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.210248	0.004087	51.45	<.0001
S1	1	15.57977	0.582532	26.74	<.0001
S2	1	18.14239	0.584293	31.05	<.0001
S3	1	18.40332	0.586077	31.4	<.0001
S4	1	17.82509	0.587883	30.32	<.0001
S5	1	15.26778	0.589713	25.89	<.0001
S6	1	12.2469	0.591565	20.7	<.0001
S7	1	8.627075	0.618395	13.95	<.0001
S8	1	6.786458	0.642998	10.55	<.0001
S9	1	5.422959	0.651681	8.32	<.0001
S10	1	6.539596	0.699146	9.35	<.0001
S11	1	8.619593	0.635703	13.56	<.0001
S12	1	12.27757	0.60314	20.36	<.0001
V1t	1	4.828051	1.314016	3.67	0.0004
V2t	1	15.53409	0.937949	16.56	<.0001
V3t	1	34.13037	1.319234	25.87	<.0001
V4t	1	33.54946	1.122779	29.88	<.0001
V1t1	1	29.66946	1.320107	22.48	<.0001
V2t1	1	18.99634	0.93792	20.25	<.0001
V3t1	1	18.14925	1.313182	13.82	<.0001
V4t1	1	12.72643	1.069353	11.9	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.138798	0.004356	31.87	<.0001
S1	1	14.32221	0.620867	23.07	<.0001
S2	1	16.65593	0.622744	26.75	<.0001
S3	1	17.37679	0.624645	27.82	<.0001
S4	1	16.51282	0.62657	26.35	<.0001
S5	1	14.39502	0.62852	22.9	<.0001
S6	1	11.92095	0.630494	18.91	<.0001
S7	1	10.02113	0.65909	15.2	<.0001
S8	1	8.304513	0.685312	12.12	<.0001
S9	1	7.590987	0.694566	10.93	<.0001
S10	1	8.742173	0.745155	11.73	<.0001
S11	1	9.536468	0.677536	14.08	<.0001
S12	1	12.22839	0.642831	19.02	<.0001
V1t	1	3.570412	1.400489	2.55	0.0122
V2t	1	7.077924	0.999673	7.08	<.0001
V3t	1	14.45561	1.406049	10.28	<.0001
V4t	1	15.60492	1.196666	13.04	<.0001
V1t1	1	15.03273	1.406979	10.68	<.0001
V2t1	1	9.390674	0.999643	9.39	<.0001
V3t1	1	11.17806	1.3996	7.99	<.0001
V4t1	1	5.492984	1.139725	4.82	<.0001

Lampiran 10. Output SAS Pemodelan TSR data Simulasi 9 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.314704	0.00429	73.35	<.0001
S1	1	15.72428	0.611536	25.71	<.0001
S2	1	18.96344	0.613384	30.92	<.0001
S3	1	20.31882	0.615257	33.02	<.0001
S4	1	19.35326	0.617153	31.36	<.0001
S5	1	16.35249	0.619074	26.41	<.0001
S6	1	11.88049	0.621018	19.13	<.0001
S7	1	6.987255	0.649184	10.76	<.0001
S8	1	3.747656	0.675012	5.55	<.0001
S9	1	2.321648	0.684127	3.39	0.001
S10	1	4.01746	0.733955	5.47	<.0001
S11	1	6.346425	0.667353	9.51	<.0001
S12	1	10.62006	0.63317	16.77	<.0001
V1t	1	7.259018	1.37944	5.26	<.0001
V2t	1	47.46992	0.984648	48.21	<.0001
V3t	1	66.92661	1.384917	48.33	<.0001
V4t	1	82.7698	1.178681	70.22	<.0001
V1t1	1	59.95039	1.385833	43.26	<.0001
V2t1	1	48.15475	0.984618	48.91	<.0001
V3t1	1	33.27891	1.378564	24.14	<.0001
V4t1	1	33.23008	1.122595	29.6	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.186795	0.004873	38.33	<.0001
S1	1	13.11132	0.694644	18.87	<.0001
S2	1	14.43805	0.696744	20.72	<.0001
S3	1	15.12099	0.698871	21.64	<.0001
S4	1	14.84144	0.701025	21.17	<.0001
S5	1	13.54908	0.703207	19.27	<.0001
S6	1	11.68051	0.705416	16.56	<.0001
S7	1	9.064088	0.737409	12.29	<.0001
S8	1	7.782572	0.766747	10.15	<.0001
S9	1	7.315139	0.777101	9.41	<.0001
S10	1	7.895463	0.833701	9.47	<.0001
S11	1	8.958706	0.758048	11.82	<.0001
S12	1	10.90739	0.719218	15.17	<.0001
V1t	1	1.992263	1.566908	1.27	0.2062
V2t	1	11.30237	1.118464	10.11	<.0001
V3t	1	23.18907	1.573129	14.74	<.0001
V4t	1	30.14897	1.338865	22.52	<.0001
V1t1	1	17.67094	1.57417	11.23	<.0001
V2t1	1	12.90287	1.118429	11.54	<.0001
V3t1	1	11.88995	1.565913	7.59	<.0001
V4t1	1	9.938501	1.275158	7.79	<.0001

Lampiran 10. Output SAS Pemodelan TSR data Simulasi 9 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.237857	0.004908	48.46	<.0001
S1	1	13.89251	0.699651	19.86	<.0001
S2	1	16.73517	0.701766	23.85	<.0001
S3	1	18.35151	0.703908	26.07	<.0001
S4	1	17.13846	0.706078	24.27	<.0001
S5	1	14.99304	0.708276	21.17	<.0001
S6	1	11.24255	0.7105	15.82	<.0001
S7	1	7.387154	0.742724	9.95	<.0001
S8	1	5.170776	0.772274	6.7	<.0001
S9	1	4.144718	0.782702	5.3	<.0001
S10	1	4.941525	0.83971	5.88	<.0001
S11	1	7.257227	0.763512	9.51	<.0001
S12	1	10.95368	0.724402	15.12	<.0001
V1t	1	3.552046	1.578202	2.25	0.0264
V2t	1	15.70682	1.126525	13.94	<.0001
V3t	1	34.8038	1.584468	21.97	<.0001
V4t	1	36.77276	1.348516	27.27	<.0001
V1t1	1	27.62164	1.585516	17.42	<.0001
V2t1	1	20.39268	1.126491	18.1	<.0001
V3t1	1	18.60477	1.5772	11.8	<.0001
V4t1	1	16.84325	1.284349	13.11	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.167112	0.004827	34.62	<.0001
S1	1	13.32992	0.688054	19.37	<.0001
S2	1	15.12128	0.690134	21.91	<.0001
S3	1	16.03715	0.692241	23.17	<.0001
S4	1	15.62874	0.694375	22.51	<.0001
S5	1	14.08517	0.696536	20.22	<.0001
S6	1	11.71918	0.698723	16.77	<.0001
S7	1	8.782672	0.730413	12.02	<.0001
S8	1	7.485819	0.759473	9.86	<.0001
S9	1	5.897734	0.769729	7.66	<.0001
S10	1	7.562214	0.825791	9.16	<.0001
S11	1	8.249269	0.750856	10.99	<.0001
S12	1	10.85213	0.712395	15.23	<.0001
V1t	1	0.656031	1.552042	0.42	0.6733
V2t	1	7.430681	1.107852	6.71	<.0001
V3t	1	15.01416	1.558204	9.64	<.0001
V4t	1	18.61763	1.326163	14.04	<.0001
V1t1	1	11.74037	1.559235	7.53	<.0001
V2t1	1	10.37592	1.107819	9.37	<.0001
V3t1	1	10.49172	1.551057	6.76	<.0001
V4t1	1	9.943726	1.26306	7.87	<.0001

Lampiran 11. Output SAS Pemodelan TSR data Simulasi 10 Skenario 1

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.343247	0.004508	76.14	<.0001
S1	1	12.02187	0.64259	18.71	<.0001
S2	1	15.46826	0.644532	24	<.0001
S3	1	16.45128	0.646499	25.45	<.0001
S4	1	15.52136	0.648492	23.93	<.0001
S5	1	11.88333	0.65051	18.27	<.0001
S6	1	7.424735	0.652554	11.38	<.0001
S7	1	2.847253	0.68215	4.17	<.0001
S8	1	-0.38235	0.709289	-0.54	0.5909
S9	1	-2.09765	0.718867	-2.92	0.0043
S10	1	-0.11352	0.771225	-0.15	0.8833
S11	1	2.389552	0.701242	3.41	0.0009
S12	1	7.077203	0.665322	10.64	<.0001
V1t	1	5.439447	1.449488	3.75	0.0003
V2t	1	46.16016	1.034649	44.61	<.0001
V3t	1	67.74029	1.455243	46.55	<.0001
V4t	1	83.0129	1.238534	67.03	<.0001
V1t1	1	60.24389	1.456206	41.37	<.0001
V2t1	1	47.09006	1.034617	45.51	<.0001
V3t1	1	33.41085	1.448568	23.06	<.0001
V4t1	1	33.43809	1.179601	28.35	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.216372	0.005373	40.27	<.0001
S1	1	9.057942	0.765918	11.83	<.0001
S2	1	10.34066	0.768232	13.46	<.0001
S3	1	11.72211	0.770578	15.21	<.0001
S4	1	10.81676	0.772953	13.99	<.0001
S5	1	9.017082	0.775359	11.63	<.0001
S6	1	6.834598	0.777794	8.79	<.0001
S7	1	5.339466	0.81307	6.57	<.0001
S8	1	3.618494	0.845419	4.28	<.0001
S9	1	2.559808	0.856835	2.99	0.0035
S10	1	3.216338	0.919242	3.5	0.0007
S11	1	4.932117	0.835826	5.9	<.0001
S12	1	6.430601	0.793013	8.11	<.0001
V1t	1	0.729319	1.727679	0.42	0.6737
V2t	1	9.895554	1.233222	8.02	<.0001
V3t	1	23.096	1.734538	13.32	<.0001
V4t	1	30.81234	1.476238	20.87	<.0001
V1t1	1	17.94241	1.735686	10.34	<.0001
V2t1	1	12.10822	1.233185	9.82	<.0001
V3t1	1	12.51868	1.726582	7.25	<.0001
V4t1	1	9.830113	1.405994	6.99	<.0001

Lampiran 10. Output SAS Pemodelan TSR data Simulasi 9 Skenario 1 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.267129	0.005333	50.09	<.0001
S1	1	10.50815	0.760188	13.82	<.0001
S2	1	12.80641	0.762485	16.8	<.0001
S3	1	14.62095	0.764813	19.12	<.0001
S4	1	12.90079	0.767171	16.82	<.0001
S5	1	10.60088	0.769558	13.78	<.0001
S6	1	6.922661	0.771975	8.97	<.0001
S7	1	3.553444	0.806988	4.4	<.0001
S8	1	0.812647	0.839094	0.97	0.3349
S9	1	-0.31159	0.850425	-0.37	0.7148
S10	1	0.699683	0.912365	0.77	0.4448
S11	1	3.088333	0.829574	3.72	0.0003
S12	1	6.651525	0.787081	8.45	<.0001
V1t	1	2.240821	1.714754	1.31	0.194
V2t	1	14.16369	1.223997	11.57	<.0001
V3t	1	33.6648	1.721562	19.55	<.0001
V4t	1	36.89683	1.465195	25.18	<.0001
V1t1	1	27.67382	1.722701	16.06	<.0001
V2t1	1	19.71768	1.223959	16.11	<.0001
V3t1	1	18.11121	1.713666	10.57	<.0001
V4t1	1	17.28681	1.395476	12.39	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.197457	0.005443	36.28	<.0001
S1	1	9.806227	0.775868	12.64	<.0001
S2	1	11.42851	0.778213	14.69	<.0001
S3	1	12.37777	0.780588	15.86	<.0001
S4	1	11.83921	0.782995	15.12	<.0001
S5	1	9.676739	0.785432	12.32	<.0001
S6	1	6.725981	0.787898	8.54	<.0001
S7	1	4.302048	0.823633	5.22	<.0001
S8	1	2.700608	0.856402	3.15	0.0021
S9	1	1.533446	0.867966	1.77	0.08
S10	1	2.756476	0.931184	2.96	0.0038
S11	1	4.089988	0.846685	4.83	<.0001
S12	1	6.282765	0.803315	7.82	<.0001
V1t	1	-0.46459	1.750123	-0.27	0.7911
V2t	1	6.533146	1.249243	5.23	<.0001
V3t	1	15.00631	1.757072	8.54	<.0001
V4t	1	19.0841	1.495416	12.76	<.0001
V1t1	1	13.54716	1.758234	7.7	<.0001
V2t1	1	9.343727	1.249205	7.48	<.0001
V3t1	1	10.82906	1.749012	6.19	<.0001
V4t1	1	10.42167	1.424259	7.32	<.0001

Lampiran 12. Output SAS Pemodelan TSR data Simulasi 1 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.287164	0.007765	36.98	<.0001
S1	1	17.15925	1.106818	15.5	<.0001
S2	1	21.23578	1.110163	19.13	<.0001
S3	1	21.79175	1.113552	19.57	<.0001
S4	1	19.26642	1.116985	17.25	<.0001
S5	1	15.03387	1.120461	13.42	<.0001
S6	1	12.85563	1.12398	11.44	<.0001
S7	1	8.832801	1.174958	7.52	<.0001
S8	1	5.325283	1.221704	4.36	<.0001
S9	1	3.668705	1.238201	2.96	0.0037
S10	1	4.511394	1.328385	3.4	0.0009
S11	1	7.943979	1.207842	6.58	<.0001
S12	1	12.24186	1.145973	10.68	<.0001
V1t	1	4.267255	2.496646	1.71	0.0902
V2t	1	50.03119	1.782114	28.07	<.0001
V3t	1	69.56763	2.506559	27.75	<.0001
V4t	1	81.60583	2.133293	38.25	<.0001
V1t1	1	61.461	2.508218	24.5	<.0001
V2t1	1	50.03653	1.78206	28.08	<.0001
V3t1	1	32.1424	2.495062	12.88	<.0001
V4t1	1	30.87761	2.031784	15.2	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.158758	0.0084	18.9	<.0001
S1	1	14.518	1.197414	12.12	<.0001
S2	1	15.83038	1.201033	13.18	<.0001
S3	1	15.58715	1.204699	12.94	<.0001
S4	1	14.30416	1.208413	11.84	<.0001
S5	1	12.13566	1.212174	10.01	<.0001
S6	1	12.80458	1.215981	10.53	<.0001
S7	1	10.96953	1.271131	8.63	<.0001
S8	1	9.415139	1.321704	7.12	<.0001
S9	1	7.795678	1.339551	5.82	<.0001
S10	1	8.853269	1.437117	6.16	<.0001
S11	1	9.884424	1.306707	7.56	<.0001
S12	1	11.1114	1.239774	8.96	<.0001
V1t	1	-0.45977	2.701004	-0.17	0.8651
V2t	1	11.64091	1.927985	6.04	<.0001
V3t	1	25.68799	2.711728	9.47	<.0001
V4t	1	27.88597	2.307909	12.08	<.0001
V1t1	1	18.52777	2.713522	6.83	<.0001
V2t1	1	15.65547	1.927926	8.12	<.0001
V3t1	1	10.44453	2.699289	3.87	0.0002
V4t1	1	10.31401	2.198091	4.69	<.0001

Lampiran 12. Output SAS Pemodelan TSR data Simulasi 1 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.208037	0.00919	22.64	<.0001
S1	1	15.84998	1.309893	12.1	<.0001
S2	1	18.53504	1.313852	14.11	<.0001
S3	1	18.54589	1.317863	14.07	<.0001
S4	1	17.44126	1.321925	13.19	<.0001
S5	1	14.13246	1.326039	10.66	<.0001
S6	1	13.42655	1.330204	10.09	<.0001
S7	1	10.93149	1.390535	7.86	<.0001
S8	1	8.887694	1.445858	6.15	<.0001
S9	1	6.571321	1.465382	4.48	<.0001
S10	1	6.817847	1.572112	4.34	<.0001
S11	1	9.133974	1.429453	6.39	<.0001
S12	1	11.61493	1.356232	8.56	<.0001
V1t	1	0.31731	2.954722	0.11	0.9147
V2t	1	15.11005	2.10909	7.16	<.0001
V3t	1	37.17659	2.966454	12.53	<.0001
V4t	1	36.20546	2.524702	14.34	<.0001
V1t1	1	27.8593	2.968416	9.39	<.0001
V2t1	1	20.20462	2.109026	9.58	<.0001
V3t1	1	18.26647	2.952847	6.19	<.0001
V4t1	1	15.99787	2.404568	6.65	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.135937	0.007874	17.26	<.0001
S1	1	15.8517	1.122339	14.12	<.0001
S2	1	17.83285	1.125731	15.84	<.0001
S3	1	17.10858	1.129168	15.15	<.0001
S4	1	15.55956	1.132649	13.74	<.0001
S5	1	13.15898	1.136174	11.58	<.0001
S6	1	13.35468	1.139742	11.72	<.0001
S7	1	11.52263	1.191435	9.67	<.0001
S8	1	9.069268	1.238836	7.32	<.0001
S9	1	7.554885	1.255565	6.02	<.0001
S10	1	8.276871	1.347013	6.14	<.0001
S11	1	10.08452	1.22478	8.23	<.0001
S12	1	12.10063	1.162044	10.41	<.0001
V1t	1	-3.84859	2.531658	-1.52	0.1313
V2t	1	9.470936	1.807105	5.24	<.0001
V3t	1	16.07027	2.54171	6.32	<.0001
V4t	1	17.52963	2.163209	8.1	<.0001
V1t1	1	13.57169	2.543392	5.34	<.0001
V2t1	1	12.90656	1.80705	7.14	<.0001
V3t1	1	10.22918	2.530051	4.04	<.0001
V4t1	1	6.900794	2.060277	3.35	0.0011

Lampiran 13. Output SAS Pemodelan TSR data Simulasi 2 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.317203	0.008061	39.35	<.0001
S1	1	15.13141	1.149097	13.17	<.0001
S2	1	17.89751	1.15257	15.53	<.0001
S3	1	18.86844	1.156088	16.32	<.0001
S4	1	18.86745	1.159653	16.27	<.0001
S5	1	15.19399	1.163261	13.06	<.0001
S6	1	11.42982	1.166915	9.79	<.0001
S7	1	5.886298	1.21984	4.83	<.0001
S8	1	2.189334	1.268371	1.73	0.0871
S9	1	0.618074	1.285499	0.48	0.6316
S10	1	2.626578	1.379127	1.9	0.0594
S11	1	4.521352	1.25398	3.61	0.0005
S12	1	11.00177	1.189748	9.25	<.0001
V1t	1	5.631885	2.592015	2.17	0.0319
V2t	1	45.33207	1.850188	24.5	<.0001
V3t	1	67.26373	2.602307	25.85	<.0001
V4t	1	83.98598	2.214782	37.92	<.0001
V1t1	1	60.18643	2.604028	23.11	<.0001
V2t1	1	49.56313	1.850132	26.79	<.0001
V3t1	1	33.46634	2.59037	12.92	<.0001
V4t1	1	32.57329	2.109395	15.44	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.179621	0.008744	20.54	<.0001
S1	1	12.70553	1.24644	10.19	<.0001
S2	1	13.65606	1.250207	10.92	<.0001
S3	1	14.37403	1.254024	11.46	<.0001
S4	1	15.43125	1.257889	12.27	<.0001
S5	1	13.42653	1.261804	10.64	<.0001
S6	1	11.33545	1.265767	8.96	<.0001
S7	1	8.89357	1.323175	6.72	<.0001
S8	1	6.528008	1.375818	4.74	<.0001
S9	1	6.829003	1.394397	4.9	<.0001
S10	1	7.264392	1.495957	4.86	<.0001
S11	1	7.666697	1.360208	5.64	<.0001
S12	1	11.66734	1.290534	9.04	<.0001
V1t	1	1.592659	2.811591	0.57	0.5722
V2t	1	10.25895	2.006922	5.11	<.0001
V3t	1	24.42829	2.822754	8.65	<.0001
V4t	1	31.80652	2.402402	13.24	<.0001
V1t1	1	16.29093	2.824622	5.77	<.0001
V2t1	1	13.44042	2.006861	6.7	<.0001
V3t1	1	10.99395	2.809806	3.91	0.0002
V4t1	1	10.00096	2.288087	4.37	<.0001

Lampiran 13. Output SAS Pemodelan TSR data Simulasi 2 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.227249	0.009525	23.86	<.0001
S1	1	15.0601	1.357727	11.09	<.0001
S2	1	16.36746	1.361831	12.02	<.0001
S3	1	17.48888	1.365988	12.8	<.0001
S4	1	17.72526	1.370199	12.94	<.0001
S5	1	14.88269	1.374463	10.83	<.0001
S6	1	12.52975	1.37878	9.09	<.0001
S7	1	7.443697	1.441314	5.16	<.0001
S8	1	3.475803	1.498657	2.32	0.0222
S9	1	3.525389	1.518894	2.32	0.0221
S10	1	5.262777	1.629522	3.23	0.0016
S11	1	7.211494	1.481653	4.87	<.0001
S12	1	11.52733	1.405759	8.2	<.0001
V1t	1	0.105143	3.062622	0.03	0.9727
V2t	1	15.17466	2.186109	6.94	<.0001
V3t	1	36.15576	3.074782	11.76	<.0001
V4t	1	36.67541	2.616899	14.01	<.0001
V1t1	1	26.12362	3.076816	8.49	<.0001
V2t1	1	21.95135	2.186042	10.04	<.0001
V3t1	1	19.02776	3.060678	6.22	<.0001
V4t1	1	17.7942	2.492378	7.14	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.161525	0.007837	20.61	<.0001
S1	1	13.71119	1.117115	12.27	<.0001
S2	1	15.08514	1.120491	13.46	<.0001
S3	1	14.60757	1.123912	13	<.0001
S4	1	16.65626	1.127377	14.77	<.0001
S5	1	13.98822	1.130885	12.37	<.0001
S6	1	11.81117	1.134437	10.41	<.0001
S7	1	8.807142	1.185889	7.43	<.0001
S8	1	7.721913	1.23307	6.26	<.0001
S9	1	5.977668	1.249721	4.78	<.0001
S10	1	7.262064	1.340743	5.42	<.0001
S11	1	6.980864	1.219079	5.73	<.0001
S12	1	11.65187	1.156635	10.07	<.0001
V1t	1	-0.09599	2.519874	-0.04	0.9697
V2t	1	6.11237	1.798694	3.4	0.0009
V3t	1	14.94522	2.529879	5.91	<.0001
V4t	1	20.36069	2.15314	9.46	<.0001
V1t1	1	11.0055	2.531553	4.35	<.0001
V2t1	1	11.54254	1.798639	6.42	<.0001
V3t1	1	9.544408	2.518275	3.79	0.0002
V4t1	1	8.945942	2.050687	4.36	<.0001

Lampiran 14. Output SAS Pemodelan TSR data Simulasi 3 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.295844	0.008942	33.08	<.0001
S1	1	16.47705	1.274653	12.93	<.0001
S2	1	21.09099	1.278505	16.5	<.0001
S3	1	21.72661	1.282408	16.94	<.0001
S4	1	20.39105	1.286361	15.85	<.0001
S5	1	17.8608	1.290365	13.84	<.0001
S6	1	12.84278	1.294418	9.92	<.0001
S7	1	8.536166	1.353125	6.31	<.0001
S8	1	4.583303	1.40696	3.26	0.0015
S9	1	1.632341	1.425959	1.14	0.2548
S10	1	3.353054	1.529817	2.19	0.0305
S11	1	8.163883	1.390996	5.87	<.0001
S12	1	12.57166	1.319745	9.53	<.0001
V1t	1	7.592005	2.875231	2.64	0.0095
V2t	1	47.99402	2.052349	23.38	<.0001
V3t	1	66.60984	2.886647	23.08	<.0001
V4t	1	82.28237	2.45678	33.49	<.0001
V1t1	1	66.32243	2.888557	22.96	<.0001
V2t1	1	48.28855	2.052286	23.53	<.0001
V3t1	1	33.01697	2.873406	11.49	<.0001
V4t1	1	33.62578	2.339878	14.37	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.171722	0.009277	18.51	<.0001
S1	1	13.8366	1.322303	10.46	<.0001
S2	1	16.33419	1.3263	12.32	<.0001
S3	1	16.59165	1.330349	12.47	<.0001
S4	1	16.37759	1.33445	12.27	<.0001
S5	1	15.81547	1.338603	11.81	<.0001
S6	1	11.67834	1.342807	8.7	<.0001
S7	1	10.47006	1.403709	7.46	<.0001
S8	1	8.45651	1.459557	5.79	<.0001
S9	1	6.089446	1.479266	4.12	<.0001
S10	1	6.602584	1.587007	4.16	<.0001
S11	1	10.05884	1.442996	6.97	<.0001
S12	1	12.89607	1.369082	9.42	<.0001
V1t	1	7.113161	2.982717	2.38	0.0188
V2t	1	11.83875	2.129072	5.56	<.0001
V3t	1	21.29091	2.994559	7.11	<.0001
V4t	1	30.77647	2.548623	12.08	<.0001
V1t1	1	22.7454	2.996541	7.59	<.0001
V2t1	1	12.87319	2.129008	6.05	<.0001
V3t1	1	13.71846	2.980823	4.6	<.0001
V4t1	1	10.00096	2.288087	4.37	<.0001

Lampiran 14. Output SAS Pemodelan TSR data Simulasi 3 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.221768	0.009885	22.44	<.0001
S1	1	15.17549	1.408966	10.77	<.0001
S2	1	19.25213	1.413225	13.62	<.0001
S3	1	19.12564	1.417539	13.49	<.0001
S4	1	18.76639	1.421909	13.2	<.0001
S5	1	16.93055	1.426334	11.87	<.0001
S6	1	12.06682	1.430814	8.43	<.0001
S7	1	10.29405	1.495707	6.88	<.0001
S8	1	6.011836	1.555215	3.87	0.0002
S9	1	3.323337	1.576216	2.11	0.0372
S10	1	5.268242	1.691018	3.12	0.0023
S11	1	8.184915	1.537569	5.32	<.0001
S12	1	13.82867	1.45881	9.48	<.0001
V1t	1	5.524525	3.178202	1.74	0.0849
V2t	1	16.31398	2.26861	7.19	<.0001
V3t	1	32.89816	3.190821	10.31	<.0001
V4t	1	37.09579	2.715657	13.66	<.0001
V1t1	1	32.29076	3.192932	10.11	<.0001
V2t1	1	19.085	2.268541	8.41	<.0001
V3t1	1	20.00287	3.176184	6.3	<.0001
V4t1	1	17.0798	2.586437	6.6	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.149731	0.008495	17.62	<.0001
S1	1	13.97565	1.21095	11.54	<.0001
S2	1	17.42488	1.21461	14.35	<.0001
S3	1	16.7056	1.218318	13.71	<.0001
S4	1	17.49907	1.222074	14.32	<.0001
S5	1	15.78928	1.225877	12.88	<.0001
S6	1	12.05462	1.229727	9.8	<.0001
S7	1	9.959144	1.285501	7.75	<.0001
S8	1	7.779839	1.336645	5.82	<.0001
S9	1	5.297326	1.354694	3.91	0.0002
S10	1	6.472834	1.453363	4.45	<.0001
S11	1	9.707416	1.321479	7.35	<.0001
S12	1	12.38796	1.253789	9.88	<.0001
V1t	1	3.214717	2.731537	1.18	0.2418
V2t	1	7.833613	1.94978	4.02	0.0001
V3t	1	13.50893	2.742383	4.93	<.0001
V4t	1	18.6571	2.333999	7.99	<.0001
V1t1	1	16.61535	2.744197	6.05	<.0001
V2t1	1	10.51016	1.94972	5.39	<.0001
V3t1	1	11.94886	2.729803	4.38	<.0001
V4t1	1	9.914041	2.222939	4.46	<.0001

Lampiran 15. Output SAS Pemodelan TSR data Simulasi 4 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.2897	0.007668	37.78	<.0001
S1	1	16.42567	1.093024	15.03	<.0001
S2	1	20.71148	1.096327	18.89	<.0001
S3	1	21.54516	1.099674	19.59	<.0001
S4	1	21.06446	1.103064	19.1	<.0001
S5	1	16.71306	1.106497	15.1	<.0001
S6	1	12.91892	1.109972	11.64	<.0001
S7	1	9.678261	1.160314	8.34	<.0001
S8	1	4.75151	1.206478	3.94	0.0001
S9	1	2.568335	1.22277	2.1	0.038
S10	1	4.29518	1.311829	3.27	0.0014
S11	1	8.112833	1.192789	6.8	<.0001
S12	1	11.64515	1.131691	10.29	<.0001
V1t	1	6.618813	2.465531	2.68	0.0084
V2t	1	48.9347	1.759904	27.81	<.0001
V3t	1	64.26939	2.47532	25.96	<.0001
V4t	1	81.95062	2.106706	38.9	<.0001
V1t1	1	70.28819	2.476958	28.38	<.0001
V2t1	1	49.60173	1.75985	28.19	<.0001
V3t1	1	28.93019	2.463966	11.74	<.0001
V4t1	1	33.61507	2.006462	16.75	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.168924	0.008576	19.7	<.0001
S1	1	13.46131	1.222428	11.01	<.0001
S2	1	16.19668	1.226122	13.21	<.0001
S3	1	16.57966	1.229866	13.48	<.0001
S4	1	16.12445	1.233657	13.07	<.0001
S5	1	14.01747	1.237496	11.33	<.0001
S6	1	12.36541	1.241383	9.96	<.0001
S7	1	11.54173	1.297685	8.89	<.0001
S8	1	8.654892	1.349314	6.41	<.0001
S9	1	7.242679	1.367535	5.3	<.0001
S10	1	8.090114	1.467138	5.51	<.0001
S11	1	9.947976	1.334005	7.46	<.0001
S12	1	10.93196	1.265673	8.64	<.0001
V1t	1	3.412594	2.757428	1.24	0.2185
V2t	1	11.99107	1.96826	6.09	<.0001
V3t	1	20.84803	2.768376	7.53	<.0001
V4t	1	28.9252	2.356121	12.28	<.0001
V1t1	1	26.984	2.770208	9.74	<.0001
V2t1	1	14.9952	1.968201	7.62	<.0001
V3t1	1	5.555314	2.755678	2.02	0.0462
V4t1	1	9.095771	2.244009	4.05	<.0001

Lampiran 15. Output SAS Pemodelan TSR data Simulasi 4 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.209046	0.008824	23.69	<.0001
S1	1	16.21503	1.257762	12.89	<.0001
S2	1	20.79672	1.261564	16.48	<.0001
S3	1	20.17837	1.265415	15.95	<.0001
S4	1	20.67655	1.269316	16.29	<.0001
S5	1	17.13266	1.273266	13.46	<.0001
S6	1	12.80743	1.277265	10.03	<.0001
S7	1	10.63202	1.335195	7.96	<.0001
S8	1	5.930523	1.388316	4.27	<.0001
S9	1	4.388377	1.407063	3.12	0.0023
S10	1	6.482404	1.509546	4.29	<.0001
S11	1	9.070678	1.372564	6.61	<.0001
S12	1	11.69925	1.302257	8.98	<.0001
V1t	1	3.159612	2.837131	1.11	0.2678
V2t	1	16.00208	2.025153	7.9	<.0001
V3t	1	33.33458	2.848396	11.7	<.0001
V4t	1	36.48793	2.424225	15.05	<.0001
V1t1	1	36.90531	2.850281	12.95	<.0001
V2t1	1	21.68729	2.025091	10.71	<.0001
V3t1	1	16.65073	2.83533	5.87	<.0001
V4t1	1	17.44489	2.308872	7.56	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.148042	0.008103	18.27	<.0001
S1	1	13.6133	1.155026	11.79	<.0001
S2	1	16.52781	1.158517	14.27	<.0001
S3	1	17.18493	1.162053	14.79	<.0001
S4	1	16.96825	1.165636	14.56	<.0001
S5	1	14.87106	1.169263	12.72	<.0001
S6	1	12.67939	1.172936	10.81	<.0001
S7	1	10.85483	1.226133	8.85	<.0001
S8	1	7.875824	1.274916	6.18	<.0001
S9	1	6.434485	1.292132	4.98	<.0001
S10	1	7.746808	1.386243	5.59	<.0001
S11	1	10.08509	1.26045	8	<.0001
S12	1	10.67391	1.195886	8.93	<.0001
V1t	1	0.993303	2.605389	0.38	0.7037
V2t	1	8.895524	1.859735	4.78	<.0001
V3t	1	12.89377	2.615734	4.93	<.0001
V4t	1	15.78388	2.22621	7.09	<.0001
V1t1	1	20.5608	2.617464	7.86	<.0001
V2t1	1	11.90203	1.859678	6.4	<.0001
V3t1	1	4.715073	2.603735	1.81	0.0729
V4t1	1	9.284043	2.120279	4.38	<.0001

Lampiran 16. Output SAS Pemodelan TSR data Simulasi 5 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.29815	0.008513	35.02	<.0001
S1	1	15.21214	1.213425	12.54	<.0001
S2	1	17.61913	1.217092	14.48	<.0001
S3	1	19.82137	1.220808	16.24	<.0001
S4	1	19.62241	1.224572	16.02	<.0001
S5	1	17.26306	1.228383	14.05	<.0001
S6	1	11.38355	1.232241	9.24	<.0001
S7	1	6.935901	1.288128	5.38	<.0001
S8	1	4.081849	1.339377	3.05	0.0029
S9	1	2.629545	1.357463	1.94	0.0553
S10	1	3.688349	1.456333	2.53	0.0127
S11	1	6.974376	1.32418	5.27	<.0001
S12	1	12.03408	1.256352	9.58	<.0001
V1t	1	13.07495	2.73712	4.78	<.0001
V2t	1	49.93819	1.953765	25.56	<.0001
V3t	1	66.95635	2.747988	24.37	<.0001
V4t	1	83.04653	2.338769	35.51	<.0001
V1t1	1	64.51366	2.749806	23.46	<.0001
V2t1	1	47.13492	1.953705	24.13	<.0001
V3t1	1	37.01892	2.735383	13.53	<.0001
V4t1	1	32.24127	2.227483	14.47	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.183346	0.009368	19.57	<.0001
S1	1	11.92885	1.335317	8.93	<.0001
S2	1	12.50964	1.339353	9.34	<.0001
S3	1	13.90517	1.343442	10.35	<.0001
S4	1	15.00149	1.347583	11.13	<.0001
S5	1	13.54923	1.351777	10.02	<.0001
S6	1	10.69837	1.356023	7.89	<.0001
S7	1	8.507344	1.417524	6	<.0001
S8	1	7.902737	1.473921	5.36	<.0001
S9	1	7.195955	1.493824	4.82	<.0001
S10	1	7.273278	1.602626	4.54	<.0001
S11	1	8.851088	1.457197	6.07	<.0001
S12	1	11.13209	1.382556	8.05	<.0001
V1t	1	8.103542	3.012072	2.69	0.0082
V2t	1	12.68168	2.150026	5.9	<.0001
V3t	1	24.25173	3.024031	8.02	<.0001
V4t	1	30.11105	2.573705	11.7	<.0001
V1t1	1	23.36122	3.026032	7.72	<.0001
V2t1	1	11.71263	2.14996	5.45	<.0001
V3t1	1	15.19824	3.01016	5.05	<.0001
V4t1	1	9.645686	2.451239	3.94	0.0001

Lampiran 16. Output SAS Pemodelan TSR data Simulasi 5 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.217904	0.009685	22.5	<.0001
S1	1	14.86801	1.380465	10.77	<.0001
S2	1	15.8085	1.384637	11.42	<.0001
S3	1	17.84077	1.388864	12.85	<.0001
S4	1	18.27646	1.393146	13.12	<.0001
S5	1	15.18627	1.397481	10.87	<.0001
S6	1	11.42477	1.401871	8.15	<.0001
S7	1	7.964694	1.465451	5.43	<.0001
S8	1	6.113693	1.523755	4.01	0.0001
S9	1	5.477301	1.544331	3.55	0.0006
S10	1	5.48869	1.656812	3.31	0.0012
S11	1	8.101079	1.506466	5.38	<.0001
S12	1	12.86824	1.429301	9	<.0001
V1t	1	9.094519	3.113912	2.92	0.0042
V2t	1	18.6047	2.22272	8.37	<.0001
V3t	1	37.04365	3.126275	11.85	<.0001
V4t	1	36.9545	2.660724	13.89	<.0001
V1t1	1	32.83191	3.128344	10.49	<.0001
V2t1	1	19.28271	2.222652	8.68	<.0001
V3t1	1	23.2598	3.111935	7.47	<.0001
V4t1	1	15.9841	2.534117	6.31	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.163851	0.008799	18.62	<.0001
S1	1	11.91569	1.25427	9.5	<.0001
S2	1	13.26683	1.258061	10.55	<.0001
S3	1	14.23707	1.261901	11.28	<.0001
S4	1	15.44312	1.265792	12.2	<.0001
S5	1	13.6559	1.269731	10.75	<.0001
S6	1	10.13146	1.273719	7.95	<.0001
S7	1	7.830898	1.331487	5.88	<.0001
S8	1	7.13707	1.384461	5.16	<.0001
S9	1	6.160773	1.403156	4.39	<.0001
S10	1	6.08494	1.505354	4.04	<.0001
S11	1	7.974045	1.368753	5.83	<.0001
S12	1	11.40056	1.298641	8.78	<.0001
V1t	1	7.138726	2.829254	2.52	0.013
V2t	1	10.22925	2.01953	5.07	<.0001
V3t	1	14.02367	2.840487	4.94	<.0001
V4t	1	18.86028	2.417494	7.8	<.0001
V1t1	1	17.19758	2.842367	6.05	<.0001
V2t1	1	8.896468	2.019469	4.41	<.0001
V3t1	1	13.37608	2.827458	4.73	<.0001
V4t1	1	9.025624	2.302461	3.92	0.0002

Lampiran 17. Output SAS Pemodelan TSR data Simulasi 6 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.288818	0.007816	36.95	<.0001
S1	1	19.00887	1.114129	17.06	<.0001
S2	1	22.42807	1.117496	20.07	<.0001
S3	1	23.74238	1.120908	21.18	<.0001
S4	1	21.20407	1.124363	18.86	<.0001
S5	1	17.86017	1.127862	15.84	<.0001
S6	1	13.077	1.131405	11.56	<.0001
S7	1	10.60656	1.182719	8.97	<.0001
S8	1	5.884513	1.229774	4.79	<.0001
S9	1	4.947927	1.24638	3.97	0.0001
S10	1	6.199049	1.337159	4.64	<.0001
S11	1	9.639929	1.21582	7.93	<.0001
S12	1	15.11107	1.153543	13.1	<.0001
V1t	1	7.775536	2.513138	3.09	0.0025
V2t	1	45.37449	1.793885	25.29	<.0001
V3t	1	66.43116	2.523116	26.33	<.0001
V4t	1	82.17625	2.147384	38.27	<.0001
V1t1	1	66.5212	2.524785	26.35	<.0001
V2t1	1	45.21219	1.793831	25.2	<.0001
V3t1	1	30.26848	2.511543	12.05	<.0001
V4t1	1	32.3518	2.045205	15.82	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.154226	0.008543	18.05	<.0001
S1	1	16.37923	1.217757	13.45	<.0001
S2	1	18.21431	1.221437	14.91	<.0001
S3	1	18.81468	1.225166	15.36	<.0001
S4	1	16.79637	1.228943	13.67	<.0001
S5	1	15.60141	1.232768	12.66	<.0001
S6	1	13.4471	1.236639	10.87	<.0001
S7	1	13.97491	1.292726	10.81	<.0001
S8	1	11.33172	1.344158	8.43	<.0001
S9	1	9.231956	1.362309	6.78	<.0001
S10	1	11.44567	1.461532	7.83	<.0001
S11	1	12.05369	1.328907	9.07	<.0001
S12	1	15.41225	1.260836	12.22	<.0001
V1t	1	2.268407	2.746891	0.83	0.4107
V2t	1	9.068925	1.960739	4.63	<.0001
V3t	1	24.11221	2.757797	8.74	<.0001
V4t	1	30.07973	2.347118	12.82	<.0001
V1t1	1	24.00619	2.759622	8.7	<.0001
V2t1	1	9.960552	1.960679	5.08	<.0001
V3t1	1	8.563226	2.745147	3.12	0.0023
V4t1	1	8.144198	2.235434	3.64	0.0004

Lampiran 17. Output SAS Pemodelan TSR data Simulasi 6 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.21259	0.008869	23.97	<.0001
S1	1	17.15271	1.264275	13.57	<.0001
S2	1	20.55639	1.268096	16.21	<.0001
S3	1	20.83013	1.271968	16.38	<.0001
S4	1	19.51006	1.275889	15.29	<.0001
S5	1	16.34583	1.27986	12.77	<.0001
S6	1	13.02392	1.283879	10.14	<.0001
S7	1	11.37538	1.342109	8.48	<.0001
S8	1	8.670493	1.395505	6.21	<.0001
S9	1	6.457394	1.41435	4.57	<.0001
S10	1	8.306669	1.517363	5.47	<.0001
S11	1	10.48212	1.379672	7.6	<.0001
S12	1	14.69865	1.309001	11.23	<.0001
V1t	1	1.780859	2.851823	0.62	0.5336
V2t	1	12.75549	2.03564	6.27	<.0001
V3t	1	31.49927	2.863146	11	<.0001
V4t	1	35.50803	2.436779	14.57	<.0001
V1t1	1	34.73178	2.865041	12.12	<.0001
V2t1	1	17.49124	2.035578	8.59	<.0001
V3t1	1	14.03196	2.850013	4.92	<.0001
V4t1	1	16.39988	2.320829	7.07	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.143843	0.007925	18.15	<.0001
S1	1	16.05759	1.129698	14.21	<.0001
S2	1	18.15762	1.133112	16.02	<.0001
S3	1	18.83898	1.136572	16.58	<.0001
S4	1	17.67258	1.140075	15.5	<.0001
S5	1	14.91612	1.143623	13.04	<.0001
S6	1	12.0921	1.147215	10.54	<.0001
S7	1	11.87775	1.199246	9.9	<.0001
S8	1	9.155216	1.246959	7.34	<.0001
S9	1	7.241397	1.263797	5.73	<.0001
S10	1	9.438709	1.355845	6.96	<.0001
S11	1	10.72354	1.232811	8.7	<.0001
S12	1	14.91743	1.169663	12.75	<.0001
V1t	1	1.123621	2.548257	0.44	0.6601
V2t	1	5.518617	1.818954	3.03	0.003
V3t	1	16.08913	2.558375	6.29	<.0001
V4t	1	18.03041	2.177393	8.28	<.0001
V1t1	1	18.56898	2.560068	7.25	<.0001
V2t1	1	7.438991	1.818898	4.09	<.0001
V3t1	1	7.04188	2.54664	2.77	0.0067
V4t1	1	7.982406	2.073785	3.85	0.0002

Lampiran 18. Output SAS Pemodelan TSR data Simulasi 7 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.288818	0.007816	36.95	<.0001
S1	1	19.00887	1.114129	17.06	<.0001
S2	1	22.42807	1.117496	20.07	<.0001
S3	1	23.74238	1.120908	21.18	<.0001
S4	1	21.20407	1.124363	18.86	<.0001
S5	1	17.86017	1.127862	15.84	<.0001
S6	1	13.077	1.131405	11.56	<.0001
S7	1	10.60656	1.182719	8.97	<.0001
S8	1	5.884513	1.229774	4.79	<.0001
S9	1	4.947927	1.24638	3.97	0.0001
S10	1	6.199049	1.337159	4.64	<.0001
S11	1	9.639929	1.21582	7.93	<.0001
S12	1	15.11107	1.153543	13.1	<.0001
V1t	1	7.775536	2.513138	3.09	0.0025
V2t	1	45.37449	1.793885	25.29	<.0001
V3t	1	66.43116	2.523116	26.33	<.0001
V4t	1	82.17625	2.147384	38.27	<.0001
V1t1	1	66.5212	2.524785	26.35	<.0001
V2t1	1	45.21219	1.793831	25.2	<.0001
V3t1	1	30.26848	2.511543	12.05	<.0001
V4t1	1	32.3518	2.045205	15.82	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.154226	0.008543	18.05	<.0001
S1	1	16.37923	1.217757	13.45	<.0001
S2	1	18.21431	1.221437	14.91	<.0001
S3	1	18.81468	1.225166	15.36	<.0001
S4	1	16.79637	1.228943	13.67	<.0001
S5	1	15.60141	1.232768	12.66	<.0001
S6	1	13.4471	1.236639	10.87	<.0001
S7	1	13.97491	1.292726	10.81	<.0001
S8	1	11.33172	1.344158	8.43	<.0001
S9	1	9.231956	1.362309	6.78	<.0001
S10	1	11.44567	1.461532	7.83	<.0001
S11	1	12.05369	1.328907	9.07	<.0001
S12	1	15.41225	1.260836	12.22	<.0001
V1t	1	2.268407	2.746891	0.83	0.4107
V2t	1	9.068925	1.960739	4.63	<.0001
V3t	1	24.11221	2.757797	8.74	<.0001
V4t	1	30.07973	2.347118	12.82	<.0001
V1t1	1	24.00619	2.759622	8.7	<.0001
V2t1	1	9.960552	1.960679	5.08	<.0001
V3t1	1	8.563226	2.745147	3.12	0.0023
V4t1	1	8.144198	2.235434	3.64	0.0004

Lampiran 18. Output SAS Pemodelan TSR data Simulasi 7 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.21259	0.008869	23.97	<.0001
S1	1	17.15271	1.264275	13.57	<.0001
S2	1	20.55639	1.268096	16.21	<.0001
S3	1	20.83013	1.271968	16.38	<.0001
S4	1	19.51006	1.275889	15.29	<.0001
S5	1	16.34583	1.27986	12.77	<.0001
S6	1	13.02392	1.283879	10.14	<.0001
S7	1	11.37538	1.342109	8.48	<.0001
S8	1	8.670493	1.395505	6.21	<.0001
S9	1	6.457394	1.41435	4.57	<.0001
S10	1	8.306669	1.517363	5.47	<.0001
S11	1	10.48212	1.379672	7.6	<.0001
S12	1	14.69865	1.309001	11.23	<.0001
V1t	1	1.780859	2.851823	0.62	0.5336
V2t	1	12.75549	2.03564	6.27	<.0001
V3t	1	31.49927	2.863146	11	<.0001
V4t	1	35.50803	2.436779	14.57	<.0001
V1t1	1	34.73178	2.865041	12.12	<.0001
V2t1	1	17.49124	2.035578	8.59	<.0001
V3t1	1	14.03196	2.850013	4.92	<.0001
V4t1	1	16.39988	2.320829	7.07	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.143843	0.007925	18.15	<.0001
S1	1	16.05759	1.129698	14.21	<.0001
S2	1	18.15762	1.133112	16.02	<.0001
S3	1	18.83898	1.136572	16.58	<.0001
S4	1	17.67258	1.140075	15.5	<.0001
S5	1	14.91612	1.143623	13.04	<.0001
S6	1	12.0921	1.147215	10.54	<.0001
S7	1	11.87775	1.199246	9.9	<.0001
S8	1	9.155216	1.246959	7.34	<.0001
S9	1	7.241397	1.263797	5.73	<.0001
S10	1	9.438709	1.355845	6.96	<.0001
S11	1	10.72354	1.232811	8.7	<.0001
S12	1	14.91743	1.169663	12.75	<.0001
V1t	1	1.123621	2.548257	0.44	0.6601
V2t	1	5.518617	1.818954	3.03	0.003
V3t	1	16.08913	2.558375	6.29	<.0001
V4t	1	18.03041	2.177393	8.28	<.0001
V1t1	1	18.56898	2.560068	7.25	<.0001
V2t1	1	7.438991	1.818898	4.09	<.0001
V3t1	1	7.04188	2.54664	2.77	0.0067
V4t1	1	7.982406	2.073785	3.85	0.0002

Lampiran 19. Output SAS Pemodelan TSR data Simulasi 8 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.296241	0.008459	35.02	<.0001
S1	1	17.21731	1.205708	14.28	<.0001
S2	1	21.30185	1.209352	17.61	<.0001
S3	1	21.65937	1.213044	17.86	<.0001
S4	1	21.37058	1.216783	17.56	<.0001
S5	1	17.54213	1.22057	14.37	<.0001
S6	1	12.22768	1.224403	9.99	<.0001
S7	1	7.632112	1.279935	5.96	<.0001
S8	1	4.458784	1.330858	3.35	0.0011
S9	1	2.526768	1.34883	1.87	0.0637
S10	1	5.127378	1.447071	3.54	0.0006
S11	1	7.189316	1.315758	5.46	<.0001
S12	1	13.51972	1.248361	10.83	<.0001
V1t	1	7.736844	2.719712	2.84	0.0053
V2t	1	46.63722	1.941339	24.02	<.0001
V3t	1	64.58443	2.73051	23.65	<.0001
V4t	1	80.11981	2.323894	34.48	<.0001
V1t1	1	60.53108	2.732317	22.15	<.0001
V2t1	1	49.53131	1.94128	25.51	<.0001
V3t1	1	36.11485	2.717985	13.29	<.0001
V4t1	1	30.58622	2.213316	13.82	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.166531	0.008975	18.55	<.0001
S1	1	15.13637	1.279338	11.83	<.0001
S2	1	16.4145	1.283204	12.79	<.0001
S3	1	16.28812	1.287121	12.65	<.0001
S4	1	15.56722	1.291089	12.06	<.0001
S5	1	13.79408	1.295107	10.65	<.0001
S6	1	11.8412	1.299175	9.11	<.0001
S7	1	10.47684	1.358098	7.71	<.0001
S8	1	9.195467	1.412131	6.51	<.0001
S9	1	7.879641	1.4312	5.51	<.0001
S10	1	10.35485	1.53544	6.74	<.0001
S11	1	9.832724	1.396108	7.04	<.0001
S12	1	13.63724	1.324596	10.3	<.0001
V1t	1	2.368189	2.885799	0.82	0.4136
V2t	1	11.17447	2.059892	5.42	<.0001
V3t	1	22.9798	2.897256	7.93	<.0001
V4t	1	25.41406	2.46581	10.31	<.0001
V1t1	1	19.09883	2.899173	6.59	<.0001
V2t1	1	13.52553	2.059829	6.57	<.0001
V3t1	1	13.85816	2.883967	4.81	<.0001
V4t1	1	5.248768	2.348478	2.23	0.0274

Lampiran 19. Output SAS Pemodelan TSR data Simulasi 8 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.215801	0.009137	23.62	<.0001
S1	1	16.51768	1.302379	12.68	<.0001
S2	1	19.56073	1.306315	14.97	<.0001
S3	1	19.57424	1.310303	14.94	<.0001
S4	1	18.09958	1.314342	13.77	<.0001
S5	1	15.82584	1.318433	12	<.0001
S6	1	11.22029	1.322574	8.48	<.0001
S7	1	8.518975	1.382558	6.16	<.0001
S8	1	7.322663	1.437564	5.09	<.0001
S9	1	5.280186	1.456976	3.62	0.0004
S10	1	7.426505	1.563094	4.75	<.0001
S11	1	8.091832	1.421253	5.69	<.0001
S12	1	13.92924	1.348452	10.33	<.0001
V1t	1	4.809291	2.937773	1.64	0.1045
V2t	1	16.35049	2.096991	7.8	<.0001
V3t	1	32.02975	2.949437	10.86	<.0001
V4t	1	32.14801	2.51022	12.81	<.0001
V1t1	1	26.56578	2.951389	9	<.0001
V2t1	1	19.49508	2.096927	9.3	<.0001
V3t1	1	20.62012	2.935908	7.02	<.0001
V4t1	1	12.7542	2.390775	5.33	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.143371	0.008604	16.66	<.0001
S1	1	15.19537	1.226469	12.39	<.0001
S2	1	17.35052	1.230176	14.1	<.0001
S3	1	18.19014	1.233931	14.74	<.0001
S4	1	17.42154	1.237735	14.08	<.0001
S5	1	14.88975	1.241587	11.99	<.0001
S6	1	11.67219	1.245487	9.37	<.0001
S7	1	10.10109	1.301975	7.76	<.0001
S8	1	8.256417	1.353775	6.1	<.0001
S9	1	7.240567	1.372055	5.28	<.0001
S10	1	9.653468	1.471988	6.56	<.0001
S11	1	8.913675	1.338414	6.66	<.0001
S12	1	13.71824	1.269857	10.8	<.0001
V1t	1	2.155291	2.766543	0.78	0.4376
V2t	1	7.62004	1.974767	3.86	0.0002
V3t	1	14.05751	2.777527	5.06	<.0001
V4t	1	15.56446	2.36391	6.58	<.0001
V1t1	1	13.34195	2.779365	4.8	<.0001
V2t1	1	10.55857	1.974707	5.35	<.0001
V3t1	1	13.01632	2.764787	4.71	<.0001
V4t1	1	6.08928	2.251427	2.7	0.0079

Lampiran 20. Output SAS Pemodelan TSR data Simulasi 9 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.302433	0.008619	35.09	<.0001
S1	1	15.88931	1.228514	12.93	<.0001
S2	1	19.80273	1.232227	16.07	<.0001
S3	1	21.69184	1.235989	17.55	<.0001
S4	1	21.02749	1.239799	16.96	<.0001
S5	1	17.25278	1.243658	13.87	<.0001
S6	1	13.09146	1.247564	10.49	<.0001
S7	1	7.074245	1.304146	5.42	<.0001
S8	1	4.228532	1.356032	3.12	0.0023
S9	1	3.211357	1.374344	2.34	0.0213
S10	1	4.998876	1.474443	3.39	0.001
S11	1	7.20645	1.340647	5.38	<.0001
S12	1	12.73418	1.271975	10.01	<.0001
V1t	1	3.785719	2.771157	1.37	0.1747
V2t	1	47.55693	1.97806	24.04	<.0001
V3t	1	65.58974	2.78216	23.58	<.0001
V4t	1	82.75707	2.367853	34.95	<.0001
V1t1	1	57.84189	2.784001	20.78	<.0001
V2t1	1	49.01781	1.978	24.78	<.0001
V3t1	1	35.41341	2.769398	12.79	<.0001
V4t1	1	32.6771	2.255182	14.49	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.176016	0.009534	18.46	<.0001
S1	1	13.35951	1.35904	9.83	<.0001
S2	1	16.12311	1.363147	11.83	<.0001
S3	1	16.2028	1.367308	11.85	<.0001
S4	1	15.82088	1.371524	11.54	<.0001
S5	1	14.63458	1.375792	10.64	<.0001
S6	1	12.141	1.380113	8.8	<.0001
S7	1	9.953669	1.442707	6.9	<.0001
S8	1	7.946903	1.500106	5.3	<.0001
S9	1	7.954433	1.520363	5.23	<.0001
S10	1	9.068187	1.631097	5.56	<.0001
S11	1	8.487206	1.483085	5.72	<.0001
S12	1	12.61345	1.407117	8.96	<.0001
V1t	1	0.318252	3.065582	0.1	0.9175
V2t	1	13.76289	2.188222	6.29	<.0001
V3t	1	22.86831	3.077754	7.43	<.0001
V4t	1	30.41165	2.619428	11.61	<.0001
V1t1	1	15.00829	3.07979	4.87	<.0001
V2t1	1	14.60724	2.188155	6.68	<.0001
V3t1	1	13.00088	3.063636	4.24	<.0001
V4t1	1	5.248768	2.348478	2.23	0.0274

Lampiran 20. Output SAS Pemodelan TSR data Simulasi 9 Skenario 2 (lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.226603	0.009373	24.18	<.0001
S1	1	14.92374	1.336087	11.17	<.0001
S2	1	18.84735	1.340125	14.06	<.0001
S3	1	17.97527	1.344217	13.37	<.0001
S4	1	18.923	1.348361	14.03	<.0001
S5	1	15.2011	1.352557	11.24	<.0001
S6	1	12.34321	1.356805	9.1	<.0001
S7	1	7.661686	1.418342	5.4	<.0001
S8	1	6.693281	1.474771	4.54	<.0001
S9	1	5.221293	1.494686	3.49	0.0007
S10	1	7.075787	1.60355	4.41	<.0001
S11	1	7.069586	1.458038	4.85	<.0001
S12	1	13.37575	1.383353	9.67	<.0001
V1t	1	-0.05405	3.013809	-0.02	0.9857
V2t	1	18.42054	2.151266	8.56	<.0001
V3t	1	33.18216	3.025775	10.97	<.0001
V4t	1	36.7306	2.57519	14.26	<.0001
V1t1	1	24.08935	3.027777	7.96	<.0001
V2t1	1	21.68016	2.151201	10.08	<.0001
V3t1	1	22.56285	3.011896	7.49	<.0001
V4t1	1	17.074	2.452653	6.96	<.0001

Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.157864	0.008591	18.38	<.0001
S1	1	13.56954	1.224509	11.08	<.0001
S2	1	16.62908	1.22821	13.54	<.0001
S3	1	17.2631	1.23196	14.01	<.0001
S4	1	16.73818	1.235757	13.54	<.0001
S5	1	14.90704	1.239603	12.03	<.0001
S6	1	12.34057	1.243497	9.92	<.0001
S7	1	9.138717	1.299894	7.03	<.0001
S8	1	7.395402	1.351611	5.47	<.0001
S9	1	7.135399	1.369863	5.21	<.0001
S10	1	8.357363	1.469636	5.69	<.0001
S11	1	7.795146	1.336276	5.83	<.0001
S12	1	12.42546	1.267828	9.8	<.0001
V1t	1	-1.57691	2.762122	-0.57	0.5692
V2t	1	10.35203	1.971611	5.25	<.0001
V3t	1	13.47845	2.773089	4.86	<.0001
V4t	1	17.78376	2.360133	7.54	<.0001
V1t1	1	11.73208	2.774924	4.23	<.0001
V2t1	1	11.31652	1.971551	5.74	<.0001
V3t1	1	11.69118	2.760369	4.24	<.0001
V4t1	1	9.434287	2.24783	4.2	<.0001

Lampiran 21. Output SAS Pemodelan TSR data Simulasi 10 Skenario 2

Lokasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.296397	0.008241	35.97	<.0001
S1	1	16.34557	1.174686	13.91	<.0001
S2	1	18.33767	1.178236	15.56	<.0001
S3	1	20.56736	1.181833	17.4	<.0001
S4	1	18.28339	1.185476	15.42	<.0001
S5	1	15.05649	1.189166	12.66	<.0001
S6	1	11.8897	1.1929	9.97	<.0001
S7	1	4.550393	1.247004	3.65	0.0004
S8	1	1.849876	1.296616	1.43	0.1565
S9	1	0.967406	1.314125	0.74	0.4632
S10	1	3.666719	1.409839	2.6	0.0106
S11	1	7.387331	1.281905	5.76	<.0001
S12	1	9.741086	1.216242	8.01	<.0001
V1t	1	9.150904	2.649736	3.45	0.0008
V2t	1	47.05236	1.891389	24.88	<.0001
V3t	1	68.41781	2.660256	25.72	<.0001
V4t	1	83.52328	2.264102	36.89	<.0001
V1t1	1	63.85494	2.662016	23.99	<.0001
V2t1	1	49.28337	1.891332	26.06	<.0001
V3t1	1	36.11671	2.648054	13.64	<.0001
V4t1	1	32.69886	2.156369	15.16	<.0001
Lokasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.165352	0.009091	18.19	<.0001
S1	1	14.18471	1.295828	10.95	<.0001
S2	1	13.90024	1.299745	10.69	<.0001
S3	1	16.23846	1.303713	12.46	<.0001
S4	1	14.42934	1.307732	11.03	<.0001
S5	1	12.32646	1.311802	9.4	<.0001
S6	1	11.56022	1.315922	8.78	<.0001
S7	1	7.300374	1.375604	5.31	<.0001
S8	1	6.947178	1.430333	4.86	<.0001
S9	1	5.970798	1.449648	4.12	<.0001
S10	1	8.054914	1.555232	5.18	<.0001
S11	1	10.03173	1.414105	7.09	<.0001
S12	1	10.22347	1.34167	7.62	<.0001
V1t	1	6.651907	2.922997	2.28	0.0248
V2t	1	12.27837	2.086444	5.88	<.0001
V3t	1	24.81494	2.934603	8.46	<.0001
V4t	1	29.06936	2.497594	11.64	<.0001
V1t1	1	23.80786	2.936544	8.11	<.0001
V2t1	1	14.05766	2.086381	6.74	<.0001
V3t1	1	14.29447	2.921142	4.89	<.0001
V4t1	1	8.697731	2.37875	3.66	0.0004

Lampiran 21. Output SAS Pemodelan TSR data Simulasi 10 Skenario 2
(lanjutan)

Lokasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.220578	0.008906	24.77	<.0001
S1	1	14.95339	1.269453	11.78	<.0001
S2	1	15.27954	1.27329	12	<.0001
S3	1	18.71257	1.277177	14.65	<.0001
S4	1	16.5975	1.281115	12.96	<.0001
S5	1	14.49129	1.285102	11.28	<.0001
S6	1	11.56153	1.289138	8.97	<.0001
S7	1	5.036173	1.347606	3.74	0.0003
S8	1	3.532727	1.401221	2.52	0.0131
S9	1	3.057016	1.420142	2.15	0.0335
S10	1	5.294973	1.523577	3.48	0.0007
S11	1	8.048318	1.385322	5.81	<.0001
S12	1	9.057176	1.314362	6.89	<.0001
V1t	1	7.573635	2.863503	2.64	0.0094
V2t	1	16.99016	2.043977	8.31	<.0001
V3t	1	33.33016	2.874872	11.59	<.0001
V4t	1	34.85949	2.446759	14.25	<.0001
V1t1	1	31.22272	2.876775	10.85	<.0001
V2t1	1	20.45849	2.043915	10.01	<.0001
V3t1	1	20.55264	2.861685	7.18	<.0001
V4t1	1	14.99308	2.330334	6.43	<.0001
Lokasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
t	1	0.142766	0.008292	17.22	<.0001
S1	1	14.98114	1.181919	12.68	<.0001
S2	1	14.99349	1.185491	12.65	<.0001
S3	1	17.25325	1.18911	14.51	<.0001
S4	1	15.20136	1.192776	12.74	<.0001
S5	1	13.51507	1.196488	11.3	<.0001
S6	1	12.14406	1.200246	10.12	<.0001
S7	1	6.644956	1.254682	5.3	<.0001
S8	1	5.829528	1.3046	4.47	<.0001
S9	1	5.533759	1.322217	4.19	<.0001
S10	1	7.347459	1.41852	5.18	<.0001
S11	1	9.721204	1.289798	7.54	<.0001
S12	1	10.39161	1.223731	8.49	<.0001
V1t	1	2.557649	2.666051	0.96	0.3395
V2t	1	9.267462	1.903035	4.87	<.0001
V3t	1	15.43354	2.676636	5.77	<.0001
V4t	1	20.12418	2.278043	8.83	<.0001
V1t1	1	17.01354	2.678407	6.35	<.0001
V2t1	1	11.52985	1.902977	6.06	<.0001
V3t1	1	12.23568	2.664359	4.59	<.0001
V4t1	1	9.361967	2.169646	4.31	<.0001

Lampiran 22. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 1

Replikasi 1													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	+++
yresid2	++++	++++	++++	++++	++++	++++	++++	-..
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++..
yresid4	++++	++++	++++	++++	++++	++++	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++..	-....
yresid2	.+++
yresid3	+..+	...+	-..-
yresid4	+..+

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 2													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	+++.	++++	++++	++..	..++	..++	..++
yresid2	++++	++++	++++	++++	++++	++..	+....
yresid3	++++	++++	++++	++++	++++	++++
yresid4	++++	++++	++++	++++	++++	++++	++..+	++++	++++	++..	..++	..++	..++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	...+
yresid2	++++)	-..
yresid3	...+.	-..-	-..-
yresid4	.+..	-.+.

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 22. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 1 (lanjutan)

Replikasi 3													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	...++
yresid2	++++	++++	++++	++++++++
yresid3	++++	++++	++++	++++++++
yresid4	++++	++++	++++	++++++++

+ is $> 2\text{std error}$, - is $< -2\text{std error}$, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	++..	+....
yresid2	++..	-..	-..
yresid3	...++	+....	-..	+
yresid4	...+

+ is $> 2\text{std error}$, - is $< -2\text{std error}$, . is between

Replikasi 4													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	+++	...++	...++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++..	...++	...++
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	+++
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++..	...++	...++

+ is $> 2\text{std error}$, - is $< -2\text{std error}$, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	+..	+..
yresid2	+..	+..	+..	-..
yresid3	+..	-..
yresid4	...+	...+	+

+ is $> 2\text{std error}$, - is $< -2\text{std error}$, . is between

Lampiran 22. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 1 (lanjutan)

Replikasi 5													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++	+++++.	...+.
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	++++

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	+.	-
yresid2	.++.
yresid3	.++.	-.	+.+.
yresid4	+++.

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 6													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++	+++++.	...+.
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	++++

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++.
yresid2	++.
yresid3	++.
yresid4	...++

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 22. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 1 (lanjutan)

Replikasi 7													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	.+++	.+++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	.+++	.+++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	+..-
yresid2	.++-
yresid3	+..	-...
yresid4	...+-

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 8													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	++++	++++	++++	.++.	.++.	.++.	.+..
yresid2	++++	++++	++++	++++	++++	++++	++++	++++	++++	.+..	.+..	.+..	.+..
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++	.++.	.+..
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++...	.++.

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Autoregression												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	+..+	-...	.+..	...+
yresid2	.+..	-...
yresid3	...+
yresid4	...++	-...

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 22. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 1 (lanjutan)

Replikasi 9													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++	+++++
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++..+..+
yresid2	.+..
yresid3	+..+
yresid4	+..+-

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 10													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid2	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid3	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++
yresid4	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++..+..
yresid2	++..	+
yresid3	...++
yresid4	.+..	+

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 23. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 2

Replikasi 1													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	+. . .	+. +
yresid2	++++	++++	++++	++ . . .	+
yresid3	++++	++++	++++	+. . .	+.	--
yresid4	++++	++++	++++	++ . . .	++ . +

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	+ . . .	+
yresid2	. +	-
yresid3	... + + - +
yresid4	+ . . .	+ +	-

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 2													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	+. . .	. + . +	+. + .	++. +
yresid2	++++	++++	++++	++++	++++	++++	++ . +	++ . +	+. + .	+. +
yresid3	++++	++++	++++	++++	++++	++++	++ . +	+. +
yresid4	++++	++++	++++	++++	++++	++++	++ . +	+. +	++ . +

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	+ . . .	+ + -
yresid2	. + . .	. + - +
yresid3	... + + - - +
yresid4	+

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 23. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 2 (lanjutan)

Replikasi 3													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	...+	++++
yresid2	++++	++++	+++++
yresid3	++++	++++	++++
yresid4	++++	++++	++++	...+	...++	...+

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	+...	+...
yresid2+
yresid3	...+	-...+..
yresid4	+...

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 4													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++
yresid2	++++	++++	++++
yresid3	++++	++++	++++	-	-
yresid4	++++	++++	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	+..
yresid2	.+..	-..	-..	...++	-..
yresid3	+.-	-	-	-	-
yresid4	.+-++..

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 23. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 2 (lanjutan)

Replikasi 5													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	...+	++++
yresid2	++++	++++	+++++
yresid3	++++	++++	++++
yresid4	++++	++++	++++	...+	...++	...+	.

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	+...	+...
yresid2+
yresid3	...+	-....+
yresid4	+...

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 6													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	++++	++++	+++
yresid2	++++	++++	++++	++++	++++	++++	+++
yresid3	++++	++++	++++	++++	++++	++++	+++
yresid4	++++	++++	++++	++++	++++	+++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	.++.	.+.
yresid2	++..
yresid3	...+.	.+..+
yresid4	...+.	.+..

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 23. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 2 (lanjutan)

Replikasi 7													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	...+	++++	+++
yresid2	++++	++++	++++	...+	++++	++.
yresid3	++++	++.	+++	...+	+++.+.
yresid4	++++	++++	++++	...+	++++	+++	+...

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	+.+	...+	-....
yresid2	.+..	-....
yresid3	...+-	...+
yresid4	+...	-...

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 8													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	...+
yresid2	++++	++++	++++	++.	---	-	-	-	-
yresid3	++++	++++	++++	++++	-	-	-	-	-	-
yresid4	++++	++++	++++	-	-	-	-	-	-

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Lag	1	2	3	4	5	6	7	8	9	10	11	12	
yresid1	+...	...-	-	+...	-	+...	...	-
yresid2	.+..	.+..+.
yresid3	...+-	-	-	-
yresid4	-	-

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 23. Output SAS MCCF dan MPCCF Residual Model TSR Data Simulasi Skenario 2 (lanjutan)

Replikasi 9													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	++++	-..	-..	-..	-..
yresid2	++++	++++	++++	++++	+	-..	-..
yresid3	++++	++++	++++	++++	-..	-..
yresid4	++++	++++	++++	++++	-..	-..

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Autoregression												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1+..
yresid2	+...	.+..
yresid3+..
yresid4+..	-..

+ is > 2*std error, - is < -2*std error, . is between

Replikasi 10													
Schematic Representation of Cross Correlations													
Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	++++	++++	++++	.+	-..	-..	-..	-..
yresid2	++++	++++	++++	-..	-..	-..	-..	-..
yresid3	++++	++++	+++.	-..	-..	-..	-..	-..
yresid4	++++	++++	++++	-..	-..	-..	-..

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations												
Lag	1	2	3	4	5	6	7	8	9	10	11	12
yresid1	.+..	+...	-..	-..
yresid2	+..	-..	-..	-..	-..
yresid3	...+	-..	-..
yresid4+..	-..	-..

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 24. Output SAS Pemodelan GSTARX pada Residual Model TSR Data Simulasi Skenario 1

Replikasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.208172	0.082875	2.51	0.0132
w1	1	0.600227	0.085226	7.04	<.0001
lagresi2	1	0.383672	0.086153	4.45	<.0001
w2	1	0.488552	0.095063	5.14	<.0001
lagresi3	1	0.384793	0.084302	4.56	<.0001
w3	1	0.477474	0.098485	4.85	<.0001
lagresi4	1	0.260740	0.086670	3.01	0.0032
w4	1	0.648223	0.097241	6.67	<.0001
Replikasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.192279	0.088507	2.17	0.0316
w1	1	0.448981	0.090586	4.96	<.0001
lagresi2	1	0.226334	0.089748	2.52	0.0129
w2	1	0.603705	0.112618	5.36	<.0001
lagresi3	1	0.534826	0.078035	6.85	<.0001
w3	1	0.367970	0.100821	3.65	0.0004
lagresi4	1	0.199009	0.082399	2.42	0.0171
w4	1	0.584917	0.090386	6.47	<.0001
Replikasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.232058	0.089381	2.60	0.0105
w1	1	0.562221	0.101517	5.54	<.0001
lagresi2	1	0.254344	0.090540	2.81	0.0057
w2	1	0.510678	0.098800	5.17	<.0001
lagresi3	1	0.264588	0.080120	3.30	0.0012
w3	1	0.559796	0.086721	6.46	<.0001
lagresi4	1	0.257881	0.083633	3.08	0.0025
w4	1	0.607355	0.102824	5.91	<.0001
Replikasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.324233	0.085408	3.80	0.0002
w1	1	0.468565	0.081009	5.78	<.0001
lagresi2	1	0.372743	0.084748	4.40	<.0001
w2	1	0.598451	0.098879	6.05	<.0001
lagresi3	1	0.302070	0.086642	3.49	0.0007
w3	1	0.614096	0.092790	6.62	<.0001
lagresi4	1	0.522495	0.079616	6.56	<.0001
w4	1	0.430547	0.092174	4.67	<.0001
Replikasi 5					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.140827	0.088127	1.60	0.1125
w1	1	0.504742	0.075396	6.69	<.0001
lagresi2	1	0.362353	0.089287	4.06	<.0001
w2	1	0.498250	0.104264	4.78	<.0001
lagresi3	1	0.230192	0.083547	2.76	0.0067
w3	1	0.722256	0.099607	7.25	<.0001
lagresi4	1	0.284773	0.093886	3.03	0.0029
w4	1	0.667658	0.119673	5.58	<.0001

Lampiran 24. Output SAS Pemodelan GSTARX pada Residual Model TSR Data

Simulasi Skenario 1 (lanjutan)

Replikasi 6					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.218130	0.087976	2.48	0.0144
w1	1	0.554314	0.087810	6.31	<.0001
lagresi2	1	0.242747	0.089467	2.71	0.0076
w2	1	0.618066	0.101084	6.11	<.0001
lagresi3	1	0.214338	0.086589	2.48	0.0146
w3	1	0.614783	0.091679	6.71	<.0001
lagresi4	1	0.349179	0.085447	4.09	<.0001
w4	1	0.607260	0.106427	5.71	<.0001
Replikasi 7					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.261531	0.086901	3.01	0.0031
w1	1	0.409899	0.083219	4.93	<.0001
lagresi2	1	0.517268	0.081354	6.36	<.0001
w2	1	0.379631	0.094868	4.00	0.0001
lagresi3	1	0.379764	0.078970	4.81	<.0001
w3	1	0.593585	0.096065	6.18	<.0001
lagresi4	1	0.333087	0.082352	4.04	<.0001
w4	1	0.588222	0.097020	6.06	<.0001
Replikasi 8					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.405653	0.081504	4.98	<.0001
w1	1	0.403374	0.085324	4.73	<.0001
lagresi2	1	0.275193	0.088594	3.11	0.0023
w2	1	0.593528	0.104499	5.68	<.0001
lagresi3	1	0.209272	0.087025	2.40	0.0176
w3	1	0.595691	0.094662	6.29	<.0001
lagresi4	1	0.237309	0.086661	2.74	0.0070
w4	1	0.626141	0.103785	6.03	<.0001
Replikasi 9					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.300213	0.090105	3.35	0.0011
w1	1	0.536951	0.086819	6.18	<.0001
lagresi2	1	0.261774	0.090454	2.89	0.0045
w2	1	0.690445	0.102873	6.71	<.0001
lagresi3	1	0.467488	0.083082	5.63	<.0001
w3	1	0.493420	0.093178	5.30	<.0001
lagresi4	1	0.177123	0.082002	2.16	0.0326
w4	1	0.793130	0.089532	8.86	<.0001
Replikasi 10					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi1	1	0.268888	0.089839	2.99	0.0033
w1	1	0.496061	0.081004	6.12	<.0001
lagresi2	1	0.250569	0.089638	2.80	0.0060
w2	1	0.678294	0.101482	6.68	<.0001
lagresi3	1	0.469916	0.083364	5.64	<.0001
w3	1	0.438976	0.093119	4.71	<.0001
lagresi4	1	0.364500	0.088674	4.11	<.0001
w4	1	0.548673	0.101933	5.38	<.0001

Lampiran 25. Output SAS Pemodelan GSTARX pada Residual Model TSR Data Simulasi Skenario 2

Replikasi 1					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.088348	0.078626	1.12	0.2633
w11	1	0.246913	0.088755	2.78	0.0062
lagresi21	1	0.233774	0.074373	3.14	0.0021
w21	1	0.105390	0.087464	1.20	0.2305
lagresi12	1	0.172719	0.096433	1.79	0.0757
w12	1	0.129323	0.121524	1.06	0.2893
lagresi22	1	0.102190	0.096915	1.05	0.2937
w22	1	0.156601	0.121979	1.28	0.2016
lagresi13	1	0.273748	0.089110	3.07	0.0026
w13	1	-0.03949	0.124050	-0.32	0.7508
lagresi23	1	0.274552	0.088633	3.10	0.0024
w23	1	0.000847	0.123231	0.01	0.9945
lagresi14	1	0.122900	0.086576	1.42	0.1582
w14	1	0.127816	0.107276	1.19	0.2357
lagresi24	1	0.066709	0.086777	0.77	0.4435
w24	1	0.176840	0.107340	1.65	0.1020
Replikasi 2					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.217846	0.078178	2.79	0.0062
w11	1	0.085580	0.089660	0.95	0.3417
lagresi21	1	0.229866	0.077531	2.96	0.0036
w21	1	0.177260	0.090183	1.97	0.0515
lagresi12	1	0.226731	0.087120	2.60	0.0104
w12	1	0.024316	0.111455	0.22	0.8277
lagresi22	1	0.213842	0.086778	2.46	0.0151
w22	1	0.300033	0.111554	2.69	0.0081
lagresi13	1	0.224330	0.087010	2.58	0.0111
w13	1	0.016366	0.120208	0.14	0.8919
lagresi23	1	0.311042	0.088336	3.52	0.0006
w23	1	0.199220	0.120553	1.65	0.1009
lagresi14	1	0.158039	0.076875	2.06	0.0419
w14	1	0.073883	0.092967	0.79	0.4283
lagresi24	1	0.063882	0.077405	0.83	0.4108
w24	1	0.340766	0.093207	3.66	0.0004
Replikasi 3					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.266454	0.084695	3.15	0.0021
w11	1	0.064047	0.104374	0.61	0.5406
lagresi21	1	0.189547	0.083825	2.26	0.0255
w21	1	-0.01770	0.103797	-0.17	0.8648
lagresi12	1	0.196046	0.094344	2.08	0.0397
w12	1	0.110436	0.120808	0.91	0.3624
lagresi22	1	0.097672	0.093716	1.04	0.2993
w22	1	0.050516	0.119958	0.42	0.6744
lagresi13	1	0.085692	0.081983	1.05	0.2979
w13	1	0.233241	0.113733	2.05	0.0424
lagresi23	1	0.205986	0.082439	2.50	0.0138
w23	1	0.013909	0.113517	0.12	0.9027
lagresi14	1	0.149563	0.082541	1.81	0.0724
w14	1	0.168605	0.098068	1.72	0.0880
lagresi24	1	0.077206	0.083167	0.93	0.3550
w24	1	0.037648	0.098943	0.38	0.7042

Lampiran 25. Output SAS Pemodelan GSTARX pada Residual Model TSR Data

Simulasi Skenario 2 (lanjutan)

Replikasi 4					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.234169	0.092909	2.52	0.0130
w11	1	0.079417	0.102851	0.77	0.4415
lagresi21	1	0.040976	0.093339	0.44	0.6614
w21	1	0.153016	0.103191	1.48	0.1406
lagresi12	1	0.271600	0.093429	2.91	0.0043
w12	1	0.000545	0.120862	0.00	0.9964
lagresi22	1	0.100062	0.094371	1.06	0.2910
w22	1	0.251286	0.121712	2.06	0.0410
lagresi13	1	0.199533	0.088284	2.26	0.0255
w13	1	0.080905	0.115147	0.70	0.4836
lagresi23	1	0.429736	0.088586	4.85	<.0001
w23	1	-0.15012	0.115976	-1.29	0.1979
lagresi14	1	0.303225	0.096528	3.14	0.0021
w14	1	-0.04162	0.116214	-0.36	0.7209
lagresi24	1	-0.01232	0.096588	-0.13	0.8987
w24	1	0.239884	0.116877	2.05	0.0422
Replikasi 5					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.421586	0.096422	4.37	<.0001
w11	1	-0.18900	0.107586	-1.76	0.0814
lagresi21	1	0.109935	0.097257	1.13	0.2605
w21	1	-0.00904	0.109326	-0.08	0.9342
lagresi12	1	0.270474	0.090303	3.00	0.0033
w12	1	-0.03607	0.117928	-0.31	0.7602
lagresi22	1	0.348373	0.091736	3.80	0.0002
w22	1	-0.30573	0.119034	-2.57	0.0114
lagresi13	1	0.222837	0.095968	2.32	0.0218
w13	1	0.053769	0.128068	0.42	0.6753
lagresi23	1	0.210843	0.096644	2.18	0.0310
w23	1	-0.08606	0.127300	-0.68	0.5002
lagresi14	1	0.392848	0.093498	4.20	<.0001
w14	1	-0.18749	0.110079	-1.70	0.0910
lagresi24	1	0.081795	0.092646	0.88	0.3790
w24	1	0.039837	0.110295	0.36	0.7186
Replikasi 6					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	-0.06429	0.099032	-0.65	0.5174
w11	1	0.306490	0.108947	2.81	0.0057
lagresi21	1	0.086272	0.099129	0.87	0.3858
w21	1	0.360495	0.108697	3.32	0.0012
lagresi12	1	0.241931	0.094642	2.56	0.0118
w12	1	-0.01604	0.116823	-0.14	0.8910
lagresi22	1	0.037934	0.095083	0.40	0.6906
w22	1	0.504628	0.117339	4.30	<.0001
lagresi13	1	-0.13068	0.087495	-1.49	0.1378
w13	1	0.397677	0.114205	3.48	0.0007
lagresi23	1	0.139909	0.087715	1.60	0.1132
w23	1	0.352627	0.114214	3.09	0.0025
lagresi14	1	0.239012	0.084810	2.82	0.0056
w14	1	-0.02601	0.099890	-0.26	0.7950
lagresi24	1	0.209299	0.085066	2.46	0.0152
w24	1	0.269925	0.100180	2.69	0.0080

Lampiran 25. Output SAS Pemodelan GSTARX pada Residual Model TSR Data Simulasi Skenario 2 (lanjutan)

Replikasi 7					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	-0.06429	0.099032	-0.65	0.5174
w11	1	0.306490	0.108947	2.81	0.0057
lagresi21	1	0.086272	0.099129	0.87	0.3858
w21	1	0.360495	0.108697	3.32	0.0012
lagresi12	1	0.241931	0.094642	2.56	0.0118
w12	1	-0.01604	0.116823	-0.14	0.8910
lagresi22	1	0.037934	0.095083	0.40	0.6906
w22	1	0.504628	0.117339	4.30	<.0001
lagresi13	1	-0.13068	0.087495	-1.49	0.1378
w13	1	0.397677	0.114205	3.48	0.0007
lagresi23	1	0.139909	0.087715	1.60	0.1132
w23	1	0.352627	0.114214	3.09	0.0025
lagresi14	1	0.239012	0.084810	2.82	0.0056
w14	1	-0.02601	0.099890	-0.26	0.7950
lagresi24	1	0.209299	0.085066	2.46	0.0152
w24	1	0.269925	0.100180	2.69	0.0080
Replikasi 8					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.268906	0.093824	2.87	0.0049
w11	1	0.073520	0.105393	0.70	0.4867
lagresi21	1	0.149355	0.093093	1.60	0.1111
w21	1	0.103140	0.105179	0.98	0.3287
lagresi12	1	0.325693	0.089789	3.63	0.0004
w12	1	0.003923	0.114844	0.03	0.9728
lagresi22	1	0.319437	0.089746	3.56	0.0005
w22	1	-0.06870	0.114760	-0.60	0.5505
lagresi13	1	0.194527	0.094029	2.07	0.0406
w13	1	0.123121	0.120406	1.02	0.3085
lagresi23	1	0.091873	0.094299	0.97	0.3318
w23	1	0.176433	0.119959	1.47	0.1438
lagresi14	1	0.197636	0.093290	2.12	0.0361
w14	1	0.112039	0.115974	0.97	0.3359
lagresi24	1	0.065554	0.093035	0.70	0.4824
w24	1	0.154940	0.115886	1.34	0.1836
Replikasi 9					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.108366	0.106833	1.01	0.3124
w11	1	0.169223	0.116192	1.46	0.1478
lagresi21	1	0.319943	0.108484	2.95	0.0038
w21	1	0.008014	0.116508	0.07	0.9453
lagresi12	1	0.136886	0.096499	1.42	0.1585
w12	1	0.165284	0.126916	1.30	0.1952
lagresi22	1	0.143351	0.096803	1.48	0.1411
w22	1	0.176607	0.127585	1.38	0.1687
lagresi13	1	0.271942	0.093227	2.92	0.0042
w13	1	0.027578	0.115766	0.24	0.8121
lagresi23	1	0.192150	0.093095	2.06	0.0411
w23	1	0.135294	0.116103	1.17	0.2461
lagresi14	1	0.135511	0.101078	1.34	0.1824
w14	1	0.118247	0.116842	1.01	0.3135
lagresi24	1	0.157485	0.100485	1.57	0.1196
w24	1	0.133337	0.115837	1.15	0.2519

Lampiran 25. Output SAS Pemodelan GSTARX pada Residual Model TSR Data

Simulasi Skenario 2 (lanjutan)

Replikasi 10					
Variable	DF	Estimate	Error	t Value	Pr > t
lagresi11	1	0.215903	0.090487	2.39	0.0185
w11	1	-0.01840	0.101991	-0.18	0.8571
lagresi21	1	0.238215	0.091660	2.60	0.0105
w21	1	0.173985	0.102292	1.70	0.0914
lagresi12	1	-0.00902	0.094312	-0.10	0.9240
w12	1	0.243338	0.123062	1.98	0.0502
lagresi22	1	0.203803	0.095435	2.14	0.0347
w22	1	0.283722	0.125228	2.27	0.0252
lagresi13	1	0.294164	0.077647	3.79	0.0002
w13	1	-0.12302	0.102486	-1.20	0.2323
lagresi23	1	0.254209	0.077384	3.29	0.0013
w23	1	0.238935	0.102210	2.34	0.0210
lagresi14	1	0.112736	0.085243	1.32	0.1884
w14	1	0.105200	0.099749	1.05	0.2936
lagresi24	1	0.259911	0.084384	3.08	0.0025
w24	1	0.181702	0.099417	1.83	0.0700

Lampiran 26. Output SAS Pemodelan GSTAR Data Simulasi Skenario 1

Replikasi 1-GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.22735	0.106594	-2.13	0.0350
w1	1	-0.86815	0.318881	-2.72	0.0075
lag2	1	-0.56063	0.100148	-5.60	<.0001
w2	1	0.071060	0.074948	0.95	0.3450
lag3	1	-0.58336	0.088780	-6.57	<.0001
w3	1	0.086091	0.093713	0.92	0.3602
lag4	1	-0.52320	0.090528	-5.78	<.0001
w4	1	0.010171	0.045379	0.22	0.8230
Replikasi 2- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.18662	0.119335	-1.56	0.1206
w1	1	-1.00959	0.358787	-2.81	0.0058
lag2	1	-0.70627	0.093849	-7.53	<.0001
w2	1	0.174923	0.072872	2.40	0.0180
lag3	1	-0.28955	0.093605	-3.09	0.0025
w3	1	-0.18703	0.096923	-1.93	0.0561
lag4	1	-0.21108	0.111572	-1.89	0.0610
w4	1	-0.11640	0.048104	-2.42	0.0171
Replikasi 3- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.49817	0.066247	-7.52	<.0001
w1	1	0.470112	0.202725	2.32	0.0221
lag2	1	-0.44965	0.077480	-5.80	<.0001
w2	1	0.156733	0.072482	2.16	0.0326
lag3	1	-0.43210	0.084735	-5.10	<.0001
w3	1	0.142733	0.117328	1.22	0.2263
lag4	1	-0.36315	0.080359	-4.52	<.0001
w4	1	0.051187	0.056750	0.90	0.3689
Replikasi 4- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.27180	0.107378	-2.53	0.0127
w1	1	-0.67936	0.320602	-2.12	0.0362
lag2	1	-0.52753	0.097494	-5.41	<.0001
w2	1	0.087729	0.076017	1.15	0.2508
lag3	1	-0.39659	0.097452	-4.07	<.0001
w3	1	-0.06597	0.099395	-0.66	0.5082
lag4	1	-0.46330	0.088808	-5.22	<.0001
w4	1	0.017016	0.044897	0.38	0.7054
Replikasi 5- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.14391	0.103369	-1.39	0.1665
w1	1	-1.13762	0.306898	-3.71	0.0003
lag2	1	-0.52721	0.098080	-5.38	<.0001
w2	1	0.042053	0.075767	0.56	0.5799
lag3	1	-0.56663	0.088958	-6.37	<.0001
w3	1	0.082209	0.094360	0.87	0.3854
lag4	1	-0.44196	0.098868	-4.47	<.0001
w4	1	-0.02515	0.046427	-0.54	0.5890

Lampiran 26. Output SAS Pemodelan GSTAR Data Simulasi Skenario 1
(lanjutan)

Replikasi 6-GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.21114	0.102264	-2.06	0.0412
w1	1	-0.92292	0.297249	-3.10	0.0024
lag2	1	-0.53401	0.090315	-5.91	<.0001
w2	1	0.071303	0.072609	0.98	0.3281
lag3	1	-0.48132	0.088154	-5.46	<.0001
w3	1	-0.61223	0.093623	-0.13	0.8963
lag4	1	-0.43494	0.094782	-4.59	<.0001
w4	1	-0.04521	0.046668	-0.97	0.3347
Replikasi 7- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.30425	0.104681	-2.91	0.0044
w1	1	-0.66692	0.314048	-2.12	0.0358
lag2	1	-0.58653	0.090658	-6.47	<.0001
w2	1	0.087594	0.070316	1.25	0.2154
lag3	1	-0.41548	0.094240	-4.41	<.0001
w3	1	-0.08075	0.097546	-0.83	0.4095
lag4	1	-0.41392	0.087285	-4.74	<.0001
w4	1	-0.01257	0.044265	-0.28	0.7770
Replikasi 8- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.11871	0.106805	-1.11	0.2687
w1	1	-1.22377	0.322297	-3.80	0.0002
lag2	1	-0.56289	0.091220	-6.17	<.0001
w2	1	0.068431	0.072568	0.94	0.3476
lag3	1	-0.53372	0.089294	-5.98	<.0001
w3	1	0.051322	0.094775	0.54	0.5892
lag4	1	-0.45534	0.094283	-4.83	<.0001
w4	1	-0.02202	0.042888	-0.51	0.6086
Replikasi 9- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.15433	0.109835	-1.41	0.1627
w1	1	-1.09620	0.330901	-3.31	0.0012
lag2	1	-0.48847	0.101520	-4.81	<.0001
w2	1	0.052007	0.081154	0.64	0.5229
lag3	1	-0.59055	0.095900	-6.16	<.0001
w3	1	0.111967	0.096402	1.16	0.2478
lag4	1	-0.33114	0.089828	-3.69	0.0003
w4	1	-0.04565	0.043101	-1.06	0.2917
Replikasi 10- GSTAR(1 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.12863	0.112467	-1.14	0.2551
w1	1	-1.15483	0.339591	-3.40	0.0009
lag2	1	-0.50313	0.094081	-5.35	<.0001
w2	1	0.054308	0.073219	0.74	0.4598
lag3	1	-0.45400	0.097743	-4.64	<.0001
w3	1	-0.04353	0.097368	-0.45	0.6556
lag4	1	-0.53469	0.081859	-6.53	<.0001
w4	1	0.007456	0.043719	0.17	0.8649

Lampiran 27. Output SAS Pemodelan GSTAR Data Simulasi Skenario 2

Replikasi 1-GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.51358	0.085694	-5.99	<.0001
w1	1	-0.06120	0.200860	-0.30	0.7611
lag2	1	-0.60282	0.067577	-8.92	<.0001
w2	1	0.065483	0.067368	0.97	0.3331
lag3	1	-0.50156	0.078526	-6.39	<.0001
w3	1	-0.04406	0.094429	-0.47	0.6417
lag4	1	-0.57084	0.062923	-9.07	<.0001
w4	1	0.003311	0.050559	0.07	0.9479
Replikasi 2- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.48806	0.091506	-5.33	<.0001
w1	1	-0.17254	0.224019	-0.77	0.4428
lag2	1	-0.60954	0.074572	-8.17	<.0001
w2	1	0.043680	0.070621	0.62	0.5374
lag3	1	-0.49638	0.084780	-5.85	<.0001
w3	1	-0.10053	0.095188	-1.06	0.2931
lag4	1	-0.44005	0.073405	-5.99	<.0001
w4	1	-0.09250	0.049882	-1.85	0.0662
Replikasi 3- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.42592	0.083974	-5.07	<.0001
w1	1	-0.07103	0.209198	-0.34	0.7348
lag2	1	-0.43361	0.070352	-6.16	<.0001
w2	1	0.105670	0.072290	1.46	0.1465
lag3	1	-0.58053	0.073874	-7.86	<.0001
w3	1	0.206257	0.090190	2.29	0.0240
lag4	1	-0.52090	0.065301	-7.98	<.0001
w4	1	0.090084	0.055463	1.62	0.1070
Replikasi 4- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.44386	0.092032	-4.82	<.0001
w1	1	-0.14703	0.223152	-0.66	0.5113
lag2	1	-0.51604	0.093828	-5.50	<.0001
w2	1	0.047395	0.082627	0.57	0.5674
lag3	1	-0.37627	0.090673	-4.15	<.0001
w3	1	-0.11911	0.101283	-1.18	0.2420
lag4	1	-0.33898	0.087106	-3.89	0.0002
w4	1	-0.11299	0.057749	-1.96	0.0528
Replikasi 5- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.42444	0.080346	-5.28	<.0001
w1	1	-0.35372	0.180363	-1.96	0.0523
lag2	1	-0.54621	0.075997	-7.19	<.0001
w2	1	0.031258	0.074451	0.42	0.6754
lag3	1	-0.49207	0.085951	-5.73	<.0001
w3	1	-0.01314	0.098596	-0.13	0.8942
lag4	1	-0.55248	0.066328	-8.33	<.0001
w4	1	-0.00820	0.056206	-0.15	0.8843

Lampiran 27. Output SAS Pemodelan GSTAR Data Simulasi Skenario 2
(lanjutan)

Replikasi 6-GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.46793	0.087119	-5.37	<.0001
w1	1	-0.27151	0.196613	-1.38	0.1700
lag2	1	-0.55712	0.080647	-6.91	<.0001
w2	1	-0.01417	0.076868	-0.18	0.8541
lag3	1	-0.59805	0.081246	-7.36	<.0001
w3	1	0.014987	0.093098	0.16	0.8724
lag4	1	-0.55145	0.060980	-9.04	<.0001
w4	1	-0.04586	0.047363	-0.97	0.3349
Replikasi 7- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.55455	0.083460	-6.64	<.0001
w1	1	0.055160	0.200715	0.27	0.7839
lag2	1	-0.61527	0.066498	-9.25	<.0001
w2	1	0.089863	0.067647	1.33	0.1867
lag3	1	-0.40843	0.082257	-4.97	<.0001
w3	1	-0.11472	0.093621	-1.23	0.2229
lag4	1	-0.50013	0.069941	-7.15	<.0001
w4	1	-0.02215	0.053334	-0.42	0.6787
Replikasi 8- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.51944	0.083860	-6.19	<.0001
w1	1	0.142919	0.203675	0.70	0.4843
lag2	1	-0.42933	0.082470	-5.21	<.0001
w2	1	0.008773	0.079093	0.11	0.9119
lag3	1	-0.38971	0.087504	-4.45	<.0001
w3	1	-0.05745	0.097894	-0.59	0.5585
lag4	1	-0.54229	0.066969	-8.10	<.0001
w4	1	0.019606	0.056106	0.35	0.7274
Replikasi 9- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.42587	0.085282	-4.99	<.0001
w1	1	-0.02815	0.210355	-0.13	0.8938
lag2	1	-0.50208	0.081268	-6.18	<.0001
w2	1	0.093301	0.080845	1.15	0.2508
lag3	1	-0.31871	0.093961	-3.39	0.0009
w3	1	-0.07324	0.090902	-0.74	0.4613
lag4	1	-0.57806	0.074088	-7.80	<.0001
w4	1	0.071122	0.058111	1.22	0.2235
Replikasi 10- GSTAR(2 ₁)					
Variable	DF	Estimate	Error	t Value	Pr > t
lag1	1	-0.45712	0.084594	-5.40	<.0001
w1	1	0.006165	0.207826	0.03	0.9764
lag2	1	-0.41209	0.071240	-5.78	<.0001
w2	1	0.006944	0.070612	0.10	0.9218
lag3	1	-0.38798	0.084067	-4.62	<.0001
w3	1	-0.06553	0.096899	-0.68	0.5002
lag4	1	-0.48857	0.068943	-7.09	<.0001
w4	1	0.003291	0.056137	0.06	0.9533

Lampiran 28. Output Model Terbaik Jordan RNN Data Simulasi Skenario 1

Replikasi 1-Jordan RNN(4,1,1)							
unit definition section :							
no.	unitName	act	bias	st	position	act func	
1	inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2	inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3	inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4	inp4	0.44919	-0.38620	i	1, 4, 0	Act_Identity	
5	hid1	0.92915	-2.80022	h	7, 1, 0		
6	out1	0.92219	-15720.96680	o	12, 1, 0		
7	con1	1.31278	0.50000	sh	4, 5, 0		
connection definition section :							
target	site	source:weight					
5		7: 3.37717, 4: 2.17503, 3: 3.45305, 2: 1.82433, 1: 14.62953					
6		5: 0.99251					
7		7: 0.30000, 6: 1.00000					

Replikasi 2- Jordan RNN(4,2,1)							
unit definition section :							
no.	typeName	unitName	act	bias	st	position	act func
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity
4		inp4	1.01712	-0.38620	i	1, 4, 0	Act_Identity
5		hid1	0.57216	0.19816	h	7, 1, 0	
6		hid2	0.97964	0.98365	h	7, 2, 0	
7		out1	1.17051	-719.98615	o	12, 1, 0	
8		con1	1.64478	0.50000	sh	4, 5, 0	
connection definition section :							
target	site	source:weight					
5		8: 0.00620, 4: 0.08131, 3: 0.62451, 2: 0.33997, 1: 0.88267					
6		8:-1.35511, 4: 4.94762, 3: 5.86771, 2: 5.11977, 1: 6.31277					
7		6: 1.76057, 5:-0.96863					
8		8: 0.30000, 7: 1.00000					

Lampiran 28. Output Model Terbaik Jordan RNN Data Simulasi Skenario 1
(lanjutan)

Replikasi 3- Jordan RNN(4,4,1)								
unit definition section :								
no. typeName unitName act bias st position act func								
no.	out func	sites	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.87755	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.95942	-2.81745	h	7, 1, 0		
6		hid2	0.01549	-8.28903	h	7, 2, 0		
7		hid3	0.00731	-1.82360	h	7, 3, 0		
8		hid4	0.00028	-5.31249	h	7, 4, 0		
9		out1	1.02702	146.93640	o	12, 1, 0		
10		con1	1.43972	0.50000	sh	4, 5, 0		

connection definition section :								
target source:weight								

5	10:	3.42358,	4:	1.44808,	3:	1.38787,	2:	0.54692, 1: 2.10800
6	10:	4.01319,	4:	-1.57700,	3:	-1.33127,	2:	-0.79847, 1:-1.18269
7	10:	-0.54328,	4:	-2.66662,	3:	-3.24257,	2:	-2.52840, 1:-2.48708
8	10:	1.99970,	4:	-6.39232,	3:	-5.85099,	2:	-6.82136, 1:-4.11614
9	8:	-0.88952,	7:	-0.62300,	6:	-1.69565,	5:	1.10285
10	10:	0.30000,	9:	1.00000				

Replikasi 4- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.87755	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.01525	-2.40325	h	7, 1, 0		
6		hid2	0.98101	-2.76241	h	7, 2, 0		
7		out1	0.98280	-3.67950	o	12, 1, 0	Act_Identity	
8		con1	1.37234	0.50000	sh	4, 5, 0		

connection definition section :								
target site source:weight								

5	8:	0.66897,	4:-3.00047,	3:-3.00399,	2:-3.32904,	1:-2.87110		
6	8:	3.69701,	4:	2.17274,	3:	2.49623,	2:	0.90790, 1: 2.81356
7	6:	1.02649,	5:-1.58637					
8	8:	0.30000,	7:	1.00000				

Lampiran 28. Output Model Terbaik Jordan RNN Data Simulasi Skenario 1
(lanjutan)

Replikasi 5- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.27759	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.56786	0.42664	h	7, 1, 0		
6		hid2	0.64905	1.02571	h	7, 2, 0		
7		out1	0.48590	-581.00482	o	12, 1, 0		
8		con1	0.76220	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		8:-0.22558, 4: 0.19539, 3: 0.75605, 2: 0.55079, 1: 1.24019						
6		8:-2.40792, 4: 6.50895, 3: 6.52628, 2: 6.56749, 1: 7.60379						
7		6: 1.58827, 5:-0.95969						
8		8: 0.30000, 7: 1.00000						

Replikasi 6- Jordan RNN(4,3,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.26533	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.33170	-1.02650	h	7, 1, 0		
6		hid2	0.00000	-20.63169	h	7, 2, 0		
7		hid3	0.07956	-1.78112	h	7, 3, 0		
8		out1	0.36146	45.36975	o	12, 1, 0	Act_Identity	
9		con1	0.43593	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		9: 1.61907, 4:-0.28608, 3: 0.43201, 2: 0.21135, 1: 6.89576						
6		9: 6.62765, 4: 2.61865, 3: 5.35911, 2: 3.96088, 1: 1.46756						
7		9: 2.14095, 4:-4.51787, 3:-4.77441, 2:-4.71365, 1:-3.35951						
8		7:-1.12468, 6:-1.37370, 5: 1.35946						
9		9: 0.30000, 8: 1.00000						

Lampiran 28. Output Model Terbaik Jordan RNN Data Simulasi Skenario 1
(lanjutan)

Replikasi 5- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.27759	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.56786	0.42664	h	7, 1, 0		
6		hid2	0.64905	1.02571	h	7, 2, 0		
7		out1	0.48590	-581.00482	o	12, 1, 0		
8		con1	0.76220	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		8:-0.22558, 4: 0.19539, 3: 0.75605, 2: 0.55079, 1: 1.24019						
6		8:-2.40792, 4: 6.50895, 3: 6.52628, 2: 6.56749, 1: 7.60379						
7		6: 1.58827, 5:-0.95969						
8		8: 0.30000, 7: 1.00000						

Replikasi 6- Jordan RNN(4,3,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.26533	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.33170	-1.02650	h	7, 1, 0		
6		hid2	0.00000	-20.63169	h	7, 2, 0		
7		hid3	0.07956	-1.78112	h	7, 3, 0		
8		out1	0.36146	45.36975	o	12, 1, 0	Act_Identity	
9		con1	0.43593	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		9: 1.61907, 4:-0.28608, 3: 0.43201, 2: 0.21135, 1: 6.89576						
6		9: 6.62765, 4: 2.61865, 3: 5.35911, 2: 3.96088, 1: 1.46756						
7		9: 2.14095, 4:-4.51787, 3:-4.77441, 2:-4.71365, 1:-3.35951						
8		7:-1.12468, 6:-1.37370, 5: 1.35946						
9		9: 0.30000, 8: 1.00000						

Lampiran 28. Output Model Terbaik Jordan RNN Data Simulasi Skenario 1
 (lanjutan)

Replikasi 7- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.39779	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.48091	0.12514	h	7, 1, 0		
6		hid2	0.86754	0.95745	h	7, 2, 0		
7		out1	0.93042	-782.85175	o	12, 1, 0		
8		con1	1.13174	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		8:-0.72025, 4: 0.70844, 3: 1.31186, 2: 1.10474, 1: 1.65985
6		8:-3.59073, 4: 8.37519, 3: 8.77128, 2: 8.31814, 1: 9.82701
7		6: 1.57704, 5:-0.91019
8		8: 0.30000, 7: 1.00000

Replikasi 8- Jordan RNN(4,1,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.79046	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.97608	-1.65758	h	7, 1, 0		
6		out1	0.80721	-15978.25195	o	12, 1, 0		
7		con1	1.13149	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		7: 2.26797, 4: 3.68758, 3: 7.20392, 2: 6.11782, 1: 10.88548
6		5: 0.82700
7		7: 0.30000, 6: 1.00000

Lampiran 28. Output Model Terbaik Jordan RNN Data Simulasi Skenario 1
(lanjutan)

Replikasi 8- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	1.05709	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.41588	-0.02160	h	7, 1, 0		
6		hid2	0.97148	0.50888	h	7, 2, 0		
7		out1	1.28885	-746.51166	o	12, 1, 0		
8		con1	1.81095	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		8:-0.49261, 4: 0.51009, 3: 1.09179, 2: 0.86837, 1: 1.38458
6		8:-1.54747, 4: 5.40404, 3: 5.69212, 2: 5.52234, 1: 6.12565
7		6: 1.77000, 5:-1.03558
8		8: 0.30000, 7: 1.00000

Replikasi 8- Jordan RNN(4,1,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.54166	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.96233	-3.20638	h	7, 1, 0		
6		out1	1.01200	-18944.17188	o	12, 1, 0		
7		con1	1.44100	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		7: 3.43663, 4: 2.82899, 3: 4.60628, 2: 7.17018, 1: 9.96180
6		5: 1.05162
7		7: 0.30000, 6: 1.00000

Lampiran 29. Output Model Terbaik Jordan RNN Data Simulasi Skenario 2

Replikasi 1- Jordan RNN(4,1,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	-0.02556	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.57656	-1.56770	h	7, 1, 0		
6		out1	0.49434	-14308.65430	o	12, 1, 0		
7		con1	0.77241	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		7: 2.07994, 4: 2.01724, 3: 6.87897, 2: 1.59366, 1: 13.82273						
6		5: 0.85740						
7		7: 0.30000, 6: 1.00000						

Replikasi 2- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.70051	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.16592	-0.71831	h	7, 1, 0		
6		hid2	0.85833	-0.99067	h	7, 2, 0		
7		out1	1.13672	-1276.60364	o	12, 1, 0		
8		con1	1.60436	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		8:-0.89827, 4: 0.71913, 3: 1.26088, 2: 1.13438, 1: 1.61823						
6		8: 0.91392, 4: 1.95216, 3: 3.07454, 2: 4.98815, 1: 4.55954						
7		6: 1.48945, 5:-0.85413						
8		8: 0.30000, 7: 1.00000						

Lampiran 29. Output Model Terbaik Jordan RNN Data Simulasi Skenario 2
(lanjutan)

Replikasi 3- Jordan RNN(4,4,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.63695	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.00000	-2.45014	h	7, 1, 0		
6		hid2	1.00000	-7.37737	h	7, 2, 0		
7		hid3	0.00000	-1.97485	h	7, 3, 0		
8		hid4	0.00000	-7.03245	h	7, 4, 0		
9		out1	-2.31495	1315.53040	o	12, 1, 0		
10		con1	-3.30707	0.50000	sh	4, 5, 0		

connection definition section :								
target	source:weight							
5	10: 4.60803, 4:-2.90250, 3:-3.12288, 2:-2.82879, 1:-3.15392							
6	10:-5.55770, 4: 8.36429, 3: 8.19760, 2: 8.51274, 1: 6.37808							
7	10: 2.92328, 4:-8.11460, 3:-6.89417, 2:-7.25430, 1:-8.83104							
8	10: 8.60723, 4:-7.52688, 3:-7.33091, 2:-7.43277, 1:-7.60953							
9	8:-2.74568, 7:-0.48619, 6:-2.31495, 5: 1.86689							
10	10: 0.30000, 9: 1.00000							

Replikasi 4- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.94151	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.51621	-0.37160	h	7, 1, 0		
6		hid2	0.96246	0.57559	h	7, 2, 0		
7		out1	1.03050	-1305.31946	o	12, 1, 0		
8		con1	1.43911	0.50000	sh	4, 5, 0		

connection definition section :								
target	site	source:weight						
5		8: 0.26228, 4: 0.08417, 3: 0.54411, 2: 0.36769, 1: 0.46318						
6		8:-0.41819, 4: 3.43915, 3: 5.37623, 2: 4.14295, 1: 5.15456						
7		6: 1.69890, 5:-1.17125						
8		8: 0.30000, 7: 1.00000						

Lampiran 29. Output Model Terbaik Jordan RNN Data Simulasi Skenario 2
(lanjutan)

Replikasi 5- Jordan RNN(4,4,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.36360	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.64043	-0.28772	h	7, 1, 0		
6		hid2	0.98511	0.28950	h	7, 2, 0		
7		out1	0.78118	-1317.62927	o	12, 1, 0		
8		con1	0.77391	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		8:-1.77412, 4: 2.26059, 3: 2.47316, 2: 2.42657, 1: 2.82244						
6		8:-2.77122, 4:10.54864, 3: 7.35434, 2: 8.59394, 1: 8.34606						
7		6: 1.36684, 5:-0.88272						
8		8: 0.30000, 7: 1.00000						

Replikasi 6- Jordan RNN(4,3,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.45946	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.21751	-1.02830	h	7, 1, 0		
6		hid2	1.00000	-9.85091	h	7, 2, 0		
7		hid3	0.02561	-0.11807	h	7, 3, 0		
8		out1	-1.62281	-507.29239	o	12, 1, 0		
9		con1	-2.35778	0.50000	sh	4, 5, 0		
connection definition section :								
target	site	source:weight						
5		9: 0.36700, 4: 1.40860, 3: 1.80224, 2: 1.78179, 1: 2.73476						
6		9:-9.67628, 4:16.79488, 3:16.39830, 2:16.50545, 1:14.17633						
7		9: 1.04560, 4:-2.08780, 3:-1.87376, 2:-1.84144, 1:-0.85893						
8		7:-0.59255, 6:-2.01388, 5: 1.86770						
9		9: 0.30000, 8: 1.00000						

Lampiran 29. Output Model Terbaik Jordan RNN Data Simulasi Skenario 2
(lanjutan)

Replikasi 7- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.32118	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.48785	-0.16637	h	7, 1, 0		
6		hid2	0.81490	0.14595	h	7, 2, 0		
7		out1	0.79498	-939.57562	o	12, 1, 0		
8		con1	0.88484	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		8: 0.00955, 4: 0.35770, 3: 0.54955, 2: 0.49659, 1: 0.64674
6		8:-1.11158, 4: 5.19711, 3: 5.01942, 2: 5.36067, 1: 4.97727
7		6: 1.60600, 5:-1.05310
8		8: 0.30000, 7: 1.00000

Replikasi 8- Jordan RNN(4,1,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.60953	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.95018	-3.32752	h	7, 1, 0		
6		out1	0.80644	-13483.70801	o	12, 1, 0		
7		con1	1.15974	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		7: 3.41137, 4: 3.70485, 3: 3.41215, 2: 2.03500, 1: 10.48063
6		5: 0.84872
7		7: 0.30000, 6: 1.00000

Lampiran 29. Output Model Terbaik Jordan RNN Data Simulasi Skenario 2

(lanjutan)

Replikasi 9- Jordan RNN(4,2,1)								
unit definition section :								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.41846	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.47505	-0.34923	h	7, 1, 0		
6		hid2	0.80376	-0.47746	h	7, 2, 0		
7		out1	0.81776	-1164.58826	o	12, 1, 0		
8		con1	1.11723	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		8: 0.35882, 4: -0.26012, 3: 0.06296, 2: 0.03235, 1: 0.38644
6		8: 1.39132, 4: 1.19138, 3: 1.47842, 2: 1.49049, 1: 5.83725
7		6: 1.57913, 5: -0.95042
8		8: 0.30000, 7: 1.00000

Replikasi 10- Jordan RNN(4,1,1)								
no.	typeName	unitName	act	bias	st	position	act func	
1		inp1	0.00000	-0.01496	i	1, 1, 0	Act_Identity	
2		inp2	0.00000	0.38646	i	1, 2, 0	Act_Identity	
3		inp3	0.00000	0.14618	i	1, 3, 0	Act_Identity	
4		inp4	0.53708	-0.38620	i	1, 4, 0	Act_Identity	
5		hid1	0.71880	-2.17947	h	7, 1, 0		
6		out1	0.69232	-15629.87598	o	12, 1, 0		
7		con1	0.86814	0.50000	sh	4, 5, 0		

connection definition section :		
target	site	source:weight
5		7: 2.09914, 4: 3.51478, 3: 4.41751, 2: 1.97730, 1: 12.74073
6		5: 0.96316
7		7: 0.30000, 6: 1.00000

Lampiran 30. Nilai sMAPE Model Terbaik Data Simulasi Skenario 1 dan 2

Skenario	Model	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 4
1	TSR	61.6%	18.7%	21.1%	16.1%
	GSTAR	76.3%	22.2%	25.9%	18.9%
	Jordan RNN	17.1%	11.3%	13.3%	12.0%
	GSTARX	1.9%	3.3%	3.0%	4.1%
	GSTARX-FFNN	1.6%	2.4%	2.1%	2.9%
	GSTARX-DLNN	1.4%	2.1%	1.9%	2.8%
	GSTARX-Jordan RNN	1.6%	2.6%	2.4%	3.3%
	TSR	64.4%	34.1%	36.9%	33.8%
2	GSTAR	64.4%	34.1%	36.9%	33.8%
	Jordan RNN	19.6%	14.9%	15.9%	15.1%
	GSTARX	5.5%	9.6%	8.1%	10.0%
	GSTARX-FFNN	1.0%	1.9%	1.5%	1.8%
	GSTARX-DLNN	1.0%	1.9%	1.5%	1.9%
	GSTARX-Jordan RNN	1.0%	1.9%	1.5%	1.8%

Lampiran 31. Output Pemodelan Time Series Regression Data Inflow

KP BI Surabaya - Rp. 100.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	6.729e+00	2.006e+00	3.355	0.000958	***	
xV6	-4.931e+02	5.156e+02	-0.956	0.340122		
xV7	-2.518e+03	3.641e+02	-6.916	6.81e-11	***	
xV8	3.894e-04	5.048e+00	0.000	0.999939		
xV9	1.472e+01	2.805e+00	5.246	4.11e-07	***	
xV10	6.119e+02	1.396e+02	4.382	1.94e-05	***	
xV11	1.641e+02	1.382e+02	1.187	0.236533		
xV12	3.901e+01	1.377e+02	0.283	0.777315		
xV13	2.369e+01	1.382e+02	0.171	0.864056		
xV14	9.536e+01	1.386e+02	0.688	0.492406		
xV15	-3.673e+01	1.395e+02	-0.263	0.792649		
xV16	4.289e+02	1.419e+02	3.022	0.002857	**	
xV17	3.616e+02	1.444e+02	2.504	0.013103	*	
xV18	5.078e+01	1.448e+02	0.351	0.726225		
xV19	2.484e+02	1.449e+02	1.715	0.088050	.	
xV20	-4.411e+01	1.455e+02	-0.303	0.762152		
xV21	-2.389e+02	1.460e+02	-1.636	0.103502		
xV22	1.284e+03	2.283e+02	5.624	6.54e-08	***	
xV23	7.600e+02	2.050e+02	3.708	0.000274	***	
xV24	6.083e+02	2.284e+02	2.663	0.008398	**	
xV25	-4.361e+02	1.869e+02	-2.334	0.020652	*	
xV26	1.385e+02	2.286e+02	0.606	0.545371		
xV27	1.170e+02	2.047e+02	0.572	0.568330		
xV28	3.412e+02	2.284e+02	1.494	0.136830		
xV29	1.780e+03	1.871e+02	9.513	< 2e-16	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang - Rp. 100.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	2.6852	0.6901	3.891	0.000138	***	
xV6	-144.1644	177.3790	-0.813	0.417375		
xV7	-158.0402	125.2422	-1.262	0.208532		
xV8	-0.1367	1.7365	-0.079	0.937318		
xV9	1.5223	0.9651	1.577	0.116374		
xV10	188.9740	48.0408	3.934	0.000117	***	
xV11	60.3895	47.5456	1.270	0.205580		
xV12	13.4354	47.3862	0.284	0.777077		
xV13	-14.9817	47.5377	-0.315	0.752989		
xV14	6.0641	47.6945	0.127	0.898959		
xV15	-54.6037	48.0023	-1.138	0.256745		
xV16	81.4805	48.8257	1.669	0.096795	.	
xV17	67.7563	49.6649	1.364	0.174088		
xV18	-39.5915	49.8209	-0.795	0.427788		
xV19	11.3090	49.8488	0.227	0.820770		
xV20	-44.2082	50.0640	-0.883	0.378328		
xV21	-100.9020	50.2407	-2.008	0.046012	*	
xV22	419.5603	78.5531	5.341	2.61e-07	***	
xV23	238.4628	70.5140	3.382	0.000873	***	
xV24	207.5763	78.5761	2.642	0.008932	**	
xV25	-160.3724	64.2854	-2.495	0.013455	*	
xV26	-38.8870	78.6333	-0.495	0.621496		
xV27	35.9063	70.4054	0.510	0.610645		
xV28	76.9913	78.5611	0.980	0.328317		
xV29	539.0892	64.3812	8.373	1.18e-14	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 100.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	3.1263	0.7301	4.282	2.93e-05	***	
xV6	155.7135	187.6709	0.830	0.407735		
xV7	-1309.6957	132.5089	-9.884	< 2e-16	***	
xV8	-4.3907	1.8372	-2.390	0.017830	*	
xV9	6.8035	1.0211	6.663	2.79e-10	***	
xV10	273.2722	50.8282	5.376	2.20e-07	***	
xV11	86.4042	50.3043	1.718	0.087485	.	
xV12	55.6999	50.1356	1.111	0.267971		
xV13	79.1460	50.2960	1.574	0.117234		
xV14	94.2136	50.4618	1.867	0.063430	.	
xV15	17.5898	50.7875	0.346	0.729467		
xV16	183.6692	51.6587	3.555	0.000476	***	
xV17	161.1426	52.5466	3.067	0.002479	**	
xV18	75.4199	52.7116	1.431	0.154121		
xV19	61.2143	52.7411	1.161	0.247230		
xV20	8.2348	52.9688	0.155	0.876619		
xV21	-55.7601	53.1558	-1.049	0.295506		
xV22	582.6221	83.1109	7.010	3.99e-11	***	
xV23	291.9773	74.6054	3.914	0.000126	***	
xV24	268.5918	83.1353	3.231	0.001454	**	
xV25	-86.3063	68.0153	-1.269	0.206012		
xV26	-54.8044	83.1957	-0.659	0.510856		
xV27	58.9204	74.4904	0.791	0.429937		
xV28	156.5197	83.1193	1.883	0.061211	.	
xV29	657.0695	68.1167	9.646	< 2e-16	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Jember - Rp. 100.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	2.111e+00	4.411e-01	4.785	3.41e-06	***	
xV6	-4.490e+00	1.134e+02	-0.040	0.96845		
xV7	-1.035e+03	8.005e+01	-12.925	< 2e-16	***	
xV8	-1.256e+00	1.110e+00	-1.131	0.25932		
xV9	6.126e+00	6.168e-01	9.932	< 2e-16	***	
xV10	1.694e+02	3.070e+01	5.516	1.11e-07	***	
xV11	5.214e+01	3.039e+01	1.716	0.08783	.	
xV12	-8.692e+00	3.029e+01	-0.287	0.77442		
xV13	-6.789e-02	3.038e+01	-0.002	0.99822		
xV14	4.880e+01	3.048e+01	1.601	0.11107		
xV15	1.678e+01	3.068e+01	0.547	0.58499		
xV16	7.550e+01	3.121e+01	2.419	0.01649	*	
xV17	7.307e+00	3.174e+01	0.230	0.81818		
xV18	-2.071e+01	3.184e+01	-0.650	0.51629		
xV19	1.300e+01	3.186e+01	0.408	0.68365		
xV20	-1.155e+01	3.200e+01	-0.361	0.71863		
xV21	-3.235e+01	3.211e+01	-1.008	0.31493		
xV22	2.968e+02	5.021e+01	5.911	1.54e-08	***	
xV23	1.369e+02	4.507e+01	3.038	0.00271	**	
xV24	2.839e+02	5.022e+01	5.654	5.65e-08	***	
xV25	-7.882e+01	4.109e+01	-1.918	0.05657	.	
xV26	-3.862e+01	5.026e+01	-0.768	0.44319		
xV27	-7.698e+00	4.500e+01	-0.171	0.86435		
xV28	1.875e+00	5.021e+01	0.037	0.97026		
xV29	3.220e+02	4.115e+01	7.825	3.38e-13	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Surabaya – Rp. 50.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	7.00854	1.13601	6.169	4.01e-09	***	
xV6	-480.52107	291.99611	-1.646	0.101482		
xV7	-682.02745	206.16996	-3.308	0.001123	**	
xV8	-1.22427	2.85855	-0.428	0.668928		
xV9	0.07073	1.58871	0.045	0.964534		
xV10	564.76878	79.08339	7.141	1.88e-11	***	
xV11	296.28700	78.26817	3.786	0.000205	***	
xV12	221.50577	78.00575	2.840	0.005006	**	
xV13	245.32245	78.25520	3.135	0.001991	**	
xV14	262.43082	78.51328	3.343	0.000999	***	
xV15	191.09752	79.01995	2.418	0.016530	*	
xV16	417.63499	80.37544	5.196	5.20e-07	***	
xV17	393.70125	81.75691	4.816	2.98e-06	***	
xV18	280.33442	82.01375	3.418	0.000771	***	
xV19	428.60077	82.05954	5.223	4.58e-07	***	
xV20	235.77272	82.41383	2.861	0.004696	**	
xV21	96.88956	82.70478	1.172	0.242853		
xV22	913.93242	129.31176	7.068	2.88e-11	***	
xV23	743.19948	116.07810	6.403	1.16e-09	***	
xV24	158.76343	129.34972	1.227	0.221184		
xV25	-250.71310	105.82468	-2.369	0.018827	*	
xV26	110.01525	129.44380	0.850	0.396441		
xV27	182.15725	115.89929	1.572	0.117679		
xV28	503.86486	129.32493	3.896	0.000135	***	
xV29	1090.45282	105.98241	10.289	< 2e-16	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 50.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	2.2276	0.3904	5.705	4.36e-08	***	
xV6	-211.8115	100.3552	-2.111	0.036106	*	
xV7	68.7704	70.8579	0.971	0.333004		
xV8	0.1719	0.9824	0.175	0.861265		
xV9	-0.6840	0.5460	-1.253	0.211821		
xV10	227.7835	27.1799	8.381	1.13e-14	***	
xV11	131.5307	26.8997	4.890	2.14e-06	***	
xV12	120.6293	26.8095	4.499	1.18e-05	***	
xV13	113.6597	26.8953	4.226	3.68e-05	***	
xV14	110.2656	26.9840	4.086	6.45e-05	***	
xV15	74.7674	27.1581	2.753	0.006474	**	
xV16	141.9005	27.6240	5.137	6.86e-07	***	
xV17	146.2459	28.0988	5.205	4.99e-07	***	
xV18	88.9057	28.1870	3.154	0.001870	**	
xV19	121.9274	28.2028	4.323	2.47e-05	***	
xV20	84.5811	28.3245	2.986	0.003195	**	
xV21	42.6590	28.4245	1.501	0.135064		
xV22	268.44489	44.4427	6.040	7.88e-09	***	
xV23	204.0085	39.8945	5.114	7.65e-07	***	
xV24	75.3055	44.4558	1.694	0.091906	.	
xV25	-129.9886	36.3705	-3.574	0.000445	***	
xV26	-18.4140	44.4881	-0.414	0.679405		
xV27	63.8633	39.8330	1.603	0.110526		
xV28	84.1365	44.4472	1.893	0.059877	.	
xV29	367.6710	36.4247	10.094	< 2e-16	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 50.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	2.4991	0.3514	7.111	2.24e-11	***
xV6	233.6245	90.3345	2.586	0.010448	*
xV7	-543.1966	63.7826	-8.516	4.84e-15	***
xV8	-4.7099	0.8843	-5.326	2.81e-07	***
xV9	1.7731	0.4915	3.607	0.000395	***
xV10	272.6343	24.4659	11.143	< 2e-16	***
xV11	135.9909	24.2137	5.616	6.81e-08	***
xV12	106.2916	24.1326	4.404	1.76e-05	***
xV13	115.6719	24.2097	4.778	3.52e-06	***
xV14	123.9847	24.2896	5.104	7.98e-07	***
xV15	73.2816	24.4463	2.998	0.003082	**
xV16	138.3759	24.8657	5.565	8.78e-08	***
xV17	177.3559	25.2930	7.012	3.95e-11	***
xV18	119.4457	25.3725	4.708	4.80e-06	***
xV19	113.6665	25.3867	4.477	1.30e-05	***
xV20	91.9963	25.4963	3.608	0.000394	***
xV21	46.7916	25.5863	1.829	0.068993	.
xV22	345.0562	40.0050	8.625	2.44e-15	***
xV23	260.1675	35.9110	7.245	1.04e-11	***
xV24	85.1742	40.0168	2.128	0.034580	*
xV25	-85.4291	32.7389	-2.609	0.009788	**
xV26	-39.2337	40.0459	-0.980	0.328465	
xV27	101.1063	35.8556	2.820	0.005312	**
xV28	102.9499	40.0091	2.573	0.010836	*
xV29	354.6611	32.7877	10.817	< 2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 50.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	1.5298	0.2201	6.950	5.60e-11	***
xV6	-9.4686	56.5743	-0.167	0.867260	
xV7	-559.8670	39.9455	-14.016	< 2e-16	***
xV8	-1.0795	0.5538	-1.949	0.052743	.
xV9	2.9116	0.3078	9.459	< 2e-16	***
xV10	178.1920	15.3224	11.629	< 2e-16	***
xV11	91.9586	15.1645	6.064	6.97e-09	***
xV12	57.6961	15.1136	3.817	0.000182	***
xV13	61.2741	15.1620	4.041	7.70e-05	***
xV14	97.2454	15.2120	6.393	1.22e-09	***
xV15	69.3200	15.3101	4.528	1.05e-05	***
xV16	89.1553	15.5728	5.725	3.95e-08	***
xV17	73.0915	15.8404	4.614	7.22e-06	***
xV18	55.4104	15.8902	3.487	0.000606	***
xV19	86.9952	15.8991	5.472	1.39e-07	***
xV20	65.3831	15.9677	4.095	6.24e-05	***
xV21	40.1103	16.0241	2.503	0.013149	*
xV22	212.2651	25.0542	8.472	6.38e-15	***
xV23	148.2559	22.4902	6.592	4.13e-10	***
xV24	97.4816	25.0615	3.890	0.000138	***
xV25	-29.5368	20.5036	-1.441	0.151344	
xV26	-8.4105	25.0798	-0.335	0.737729	
xV27	18.7160	22.4555	0.833	0.405620	
xV28	-0.9694	25.0567	-0.039	0.969181	
xV29	199.7393	20.5341	9.727	< 2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Surabaya – Rp. 20.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.7493	0.1147	-6.531	5.77e-10	***	
xV6	-110.9456	29.4932	-3.762	0.000224	***	
xV7	-129.3169	20.8243	-6.210	3.24e-09	***	
xV8	0.9982	0.2887	3.457	0.000672	***	
xV9	1.0810	0.1605	6.737	1.86e-10	***	
xV10	136.6917	7.9878	17.112	< 2e-16	***	
xV11	115.5785	7.9055	14.620	< 2e-16	***	
xV12	111.2888	7.8790	14.125	< 2e-16	***	
xV13	109.0711	7.9042	13.799	< 2e-16	***	
xV14	107.8110	7.9303	13.595	< 2e-16	***	
xV15	103.3494	7.9814	12.949	< 2e-16	***	
xV16	120.4382	8.1183	14.835	< 2e-16	***	
xV17	134.0914	8.2579	16.238	< 2e-16	***	
xV18	120.8185	8.2838	14.585	< 2e-16	***	
xV19	121.1135	8.2884	14.612	< 2e-16	***	
xV20	124.9002	8.3242	15.004	< 2e-16	***	
xV21	108.0547	8.3536	12.935	< 2e-16	***	
xV22	37.8173	13.0612	2.895	0.004228	**	
xV23	24.1819	11.7245	2.063	0.040512	*	
xV24	-16.6345	13.0650	-1.273	0.204491		
xV25	-31.9163	10.6889	-2.986	0.003197	**	
xV26	48.6982	13.0745	3.725	0.000257	***	
xV27	33.4343	11.7064	2.856	0.004764	**	
xV28	43.2555	13.0625	3.311	0.001110	**	
xV29	86.5979	10.7048	8.090	6.78e-14	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 20.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.53695	0.03250	-16.523	< 2e-16	***	
xV6	-50.28772	8.35273	-6.021	8.74e-09	***	
xV7	-63.20623	5.89762	-10.717	< 2e-16	***	
xV8	0.55421	0.08177	6.778	1.48e-10	***	
xV9	0.63251	0.04545	13.918	< 2e-16	***	
xV10	69.06135	2.26223	30.528	< 2e-16	***	
xV11	61.74642	2.23891	27.579	< 2e-16	***	
xV12	61.95889	2.23140	27.767	< 2e-16	***	
xV13	59.47468	2.23854	26.569	< 2e-16	***	
xV14	58.86021	2.24592	26.208	< 2e-16	***	
xV15	56.44239	2.26041	24.970	< 2e-16	***	
xV16	60.53040	2.29919	26.327	< 2e-16	***	
xV17	64.26917	2.33871	27.481	< 2e-16	***	
xV18	61.19397	2.34605	26.084	< 2e-16	***	
xV19	62.40198	2.34736	26.584	< 2e-16	***	
xV20	61.49007	2.35750	26.083	< 2e-16	***	
xV21	58.66600	2.36582	24.797	< 2e-16	***	
xV22	13.23345	3.69904	3.578	0.000440	***	
xV23	7.96874	3.32049	2.400	0.017361	*	
xV24	-6.07283	3.70013	-1.641	0.102391		
xV25	-12.28684	3.02718	-4.059	7.19e-05	***	
xV26	13.56491	3.70282	3.663	0.000322	***	
xV27	4.91371	3.31537	1.482	0.139961		
xV28	17.41406	3.69942	4.707	4.81e-06	***	
xV29	32.40367	3.03169	10.688	< 2e-16	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 20.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-0.33953	0.04107	-8.268	2.27e-14 ***	
xV6	-15.30233	10.55546	-1.450	0.148780	
xV7	-71.25301	7.45290	-9.560	< 2e-16 ***	
xV8	0.14778	0.10333	1.430	0.154328	
xV9	0.56264	0.05743	9.797	< 2e-16 ***	
xV10	62.75213	2.85881	21.950	< 2e-16 ***	
xV11	52.31891	2.82934	18.492	< 2e-16 ***	
xV12	49.86788	2.81985	17.685	< 2e-16 ***	
xV13	48.65807	2.82887	17.201	< 2e-16 ***	
xV14	47.45624	2.83820	16.721	< 2e-16 ***	
xV15	42.57391	2.85652	14.904	< 2e-16 ***	
xV16	47.91190	2.90552	16.490	< 2e-16 ***	
xV17	54.40013	2.95546	18.407	< 2e-16 ***	
xV18	52.26698	2.96474	17.630	< 2e-16 ***	
xV19	51.51948	2.96640	17.368	< 2e-16 ***	
xV20	49.30261	2.97920	16.549	< 2e-16 ***	
xV21	50.75409	2.98972	16.976	< 2e-16 ***	
xV22	14.58243	4.67453	3.120	0.002092 **	
xV23	15.11960	4.19614	3.603	0.000401 ***	
xV24	-7.14115	4.67590	-1.527	0.128360	
xV25	-12.16793	3.82549	-3.181	0.001714 **	
xV26	19.47852	4.67931	4.163	4.75e-05 ***	
xV27	16.27128	4.18968	3.884	0.000142 ***	
xV28	18.81914	4.67501	4.025	8.19e-05 ***	
xV29	39.83505	3.83119	10.398	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 20.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-0.24230	0.02844	-8.519	4.75e-15 ***	
xV6	-10.57507	7.31047	-1.447	0.149658	
xV7	-48.24174	5.16171	-9.346	< 2e-16 ***	
xV8	0.09196	0.07157	1.285	0.200349	
xV9	0.35893	0.03978	9.024	< 2e-16 ***	
xV10	48.07442	1.97995	24.281	< 2e-16 ***	
xV11	40.67175	1.95954	20.756	< 2e-16 ***	
xV12	37.44881	1.95297	19.175	< 2e-16 ***	
xV13	37.00964	1.95921	18.890	< 2e-16 ***	
xV14	38.21130	1.96567	19.439	< 2e-16 ***	
xV15	36.06407	1.97836	18.229	< 2e-16 ***	
xV16	36.52786	2.01230	18.152	< 2e-16 ***	
xV17	40.04470	2.04688	19.564	< 2e-16 ***	
xV18	38.18988	2.05331	18.599	< 2e-16 ***	
xV19	39.13793	2.05446	19.050	< 2e-16 ***	
xV20	37.64004	2.06333	18.242	< 2e-16 ***	
xV21	38.78632	2.07061	18.732	< 2e-16 ***	
xV22	12.26868	3.23747	3.790	0.000202 ***	
xV23	14.73730	2.90615	5.071	9.32e-07 ***	
xV24	-0.11579	3.23842	-0.036	0.971516	
xV25	-5.41400	2.64945	-2.043	0.042382 *	
xV26	4.05041	3.24078	1.250	0.212893	
xV27	7.02001	2.90168	2.419	0.016488 *	
xV28	11.75331	3.23780	3.630	0.000364 ***	
xV29	23.76926	2.65340	8.958	2.97e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Surabaya – Rp. 10.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.41056	0.09593	-4.280	2.96e-05	***	
xV6	-21.72044	24.65806	-0.881	0.37950		
xV7	-53.00059	17.41034	-3.044	0.00266	**	
xV8	0.37175	0.24139	1.540	0.12521		
xV9	0.68901	0.13416	5.136	6.90e-07	***	
xV10	62.40377	6.67832	9.344	< 2e-16	***	
xV11	48.73917	6.60947	7.374	4.90e-12	***	
xV12	44.45912	6.58731	6.749	1.73e-10	***	
xV13	40.15493	6.60838	6.076	6.53e-09	***	
xV14	40.05378	6.63017	6.041	7.85e-09	***	
xV15	36.37166	6.67296	5.451	1.54e-07	***	
xV16	47.26515	6.78743	6.964	5.19e-11	***	
xV17	63.81800	6.90409	9.244	< 2e-16	***	
xV18	58.67130	6.92578	8.471	6.41e-15	***	
xV19	53.92685	6.92964	7.782	4.37e-13	***	
xV20	52.05272	6.95956	7.479	2.64e-12	***	
xV21	46.22104	6.98413	6.618	3.58e-10	***	
xV22	7.32703	10.91993	0.671	0.50305		
xV23	-2.57100	9.80239	-0.262	0.79339		
xV24	-17.79594	10.92313	-1.629	0.10492		
xV25	-22.86972	8.93653	-2.559	0.01127	*	
xV26	44.13130	10.93108	4.037	7.82e-05	***	
xV27	22.89227	9.78729	2.339	0.02037	*	
xV28	33.29289	10.92104	3.049	0.00263	**	
xV29	42.81671	8.94985	4.784	3.43e-06	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 10.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.22853	0.02575	-8.874	5.08e-16	***	
xV6	-16.30688	6.61966	-2.463	0.014648	*	
xV7	-25.40342	4.67395	-5.435	1.66e-07	***	
xV8	0.22134	0.06480	3.416	0.000778	***	
xV9	0.30599	0.03602	8.496	5.50e-15	***	
xV10	28.33871	1.79285	15.807	< 2e-16	***	
xV11	27.01913	1.77437	15.227	< 2e-16	***	
xV12	26.58668	1.76842	15.034	< 2e-16	***	
xV13	24.44013	1.77407	13.776	< 2e-16	***	
xV14	23.31070	1.77992	13.096	< 2e-16	***	
xV15	21.54591	1.79141	12.027	< 2e-16	***	
xV16	23.85292	1.82214	13.091	< 2e-16	***	
xV17	29.21223	1.85346	15.761	< 2e-16	***	
xV18	27.28310	1.85928	14.674	< 2e-16	***	
xV19	27.53347	1.86032	14.800	< 2e-16	***	
xV20	27.34010	1.86835	14.633	< 2e-16	***	
xV21	24.90057	1.87495	13.281	< 2e-16	***	
xV22	4.99435	2.93154	1.704	0.090071	.	
xV23	-0.50368	2.63153	-0.191	0.848413		
xV24	-6.58605	2.93241	-2.246	0.025852	*	
xV25	-8.75171	2.39908	-3.648	0.000341	***	
xV26	13.78269	2.93454	4.697	5.04e-06	***	
xV27	5.44518	2.62748	2.072	0.039571	*	
xV28	14.27205	2.93184	4.868	2.36e-06	***	
xV29	14.99105	2.40266	6.239	2.77e-09	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 10.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.09745	0.04285	-2.274	0.024062 *		
xV6	5.90146	11.01417	0.536	0.592716		
xV7	-41.46295	7.77679	-5.332	2.73e-07 ***		
xV8	-0.04728	0.10783	-0.438	0.661535		
xV9	0.32518	0.05993	5.426	1.73e-07 ***		
xV10	25.87278	2.98305	8.673	1.81e-15 ***		
xV11	21.30262	2.95230	7.216	1.23e-11 ***		
xV12	19.11035	2.94240	6.495	7.02e-10 ***		
xV13	17.49373	2.95181	5.926	1.42e-08 ***		
xV14	16.05254	2.96154	5.420	1.78e-07 ***		
xV15	13.11502	2.98065	4.400	1.80e-05 ***		
xV16	17.28661	3.03178	5.702	4.45e-08 ***		
xV17	26.13765	3.08389	8.476	6.25e-15 ***		
xV18	24.46802	3.09358	7.909	2.03e-13 ***		
xV19	23.19869	3.09531	7.495	2.41e-12 ***		
xV20	19.73277	3.10867	6.348	1.55e-09 ***		
xV21	21.54080	3.11965	6.905	7.24e-11 ***		
xV22	5.24790	4.87768	1.076	0.283329		
xV23	0.38379	4.37850	0.088	0.930243		
xV24	-11.04094	4.87911	-2.263	0.024767 *		
xV25	-11.23463	3.99174	-2.814	0.005398 **		
xV26	21.07579	4.88266	4.316	2.54e-05 ***		
xV27	14.42590	4.37175	3.300	0.001154 **		
xV28	17.70290	4.87817	3.629	0.000365 ***		
xV29	19.28209	3.99769	4.823	2.88e-06 ***		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Jember – Rp. 10.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.095952	0.021758	-4.410	1.72e-05 ***		
xV6	2.544989	5.592588	0.455	0.649580		
xV7	-25.740118	3.948764	-6.519	6.17e-10 ***		
xV8	-0.007841	0.054750	-0.143	0.886275		
xV9	0.211027	0.030429	6.935	6.10e-11 ***		
xV10	20.229847	1.514681	13.356	< 2e-16 ***		
xV11	18.170079	1.499067	12.121	< 2e-16 ***		
xV12	15.752092	1.494041	10.543	< 2e-16 ***		
xV13	14.414311	1.498818	9.617	< 2e-16 ***		
xV14	14.816497	1.503761	9.853	< 2e-16 ***		
xV15	13.392539	1.513465	8.849	5.95e-16 ***		
xV16	14.020499	1.539427	9.108	< 2e-16 ***		
xV17	19.007994	1.565886	12.139	< 2e-16 ***		
xV18	18.864892	1.570806	12.010	< 2e-16 ***		
xV19	17.012141	1.571683	10.824	< 2e-16 ***		
xV20	15.799414	1.578468	10.009	< 2e-16 ***		
xV21	16.398668	1.584041	10.352	< 2e-16 ***		
xV22	7.376770	2.476702	2.978	0.003273 **		
xV23	4.526435	2.223239	2.036	0.043135 *		
xV24	-3.434612	2.477429	-1.386	0.167253		
xV25	-5.136123	2.026855	-2.534	0.012079 *		
xV26	5.358808	2.479231	2.161	0.031903 *		
xV27	7.390033	2.219814	3.329	0.001045 **		
xV28	9.425535	2.476955	3.805	0.000191 ***		
xV29	9.937782	2.029876	4.896	2.08e-06 ***		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Surabaya – Rp. 5.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.11694	0.07784	1.502	0.134683		
xV6	-6.73028	20.00892	-0.336	0.736966		
xV7	-22.68194	14.12772	-1.605	0.110038		
xV8	0.03405	0.19588	0.174	0.862179		
xV9	0.17282	0.10887	1.587	0.114062		
xV10	19.81327	5.41916	3.656	0.000331 ***		
xV11	12.34553	5.36330	2.302	0.022422 *		
xV12	7.14576	5.34531	1.337	0.182869		
xV13	4.68128	5.36241	0.873	0.383770		
xV14	2.22374	5.38009	0.413	0.679831		
xV15	-0.06958	5.41481	-0.013	0.989761		
xV16	5.46538	5.50770	0.992	0.322298		
xV17	17.33849	5.60236	3.095	0.002265 **		
xV18	20.19787	5.61996	3.594	0.000414 ***		
xV19	19.41472	5.62310	3.453	0.000683 ***		
xV20	14.76631	5.64738	2.615	0.009643 **		
xV21	12.64553	5.66731	2.231	0.026824 *		
xV22	-2.79386	8.86104	-0.315	0.752880		
xV23	-12.89146	7.95421	-1.621	0.106730		
xV24	-14.77202	8.86364	-1.667	0.097236 .		
xV25	-19.51798	7.25159	-2.692	0.007743 **		
xV26	30.70786	8.87009	3.462	0.000662 ***		
xV27	13.47509	7.94195	1.697	0.091383 .		
xV28	21.03621	8.86194	2.374	0.018599 *		
xV29	17.57899	7.26240	2.421	0.016433 *		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 5.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.01806	0.02495	0.724	0.469899		
xV6	-8.77755	6.41197	-1.369	0.172628		
xV7	-6.95788	4.52730	-1.537	0.125980		
xV8	0.06872	0.06277	1.095	0.275003		
xV9	0.05186	0.03489	1.486	0.138805		
xV10	8.49779	1.73660	4.893	2.10e-06 ***		
xV11	7.44818	1.71870	4.334	2.37e-05 ***		
xV12	6.64670	1.71293	3.880	0.000144 ***		
xV13	5.31758	1.71841	3.094	0.002268 **		
xV14	4.04518	1.72408	2.346	0.019987 *		
xV15	3.31299	1.73521	1.909	0.057725 .		
xV16	3.66863	1.76497	2.079	0.038992 *		
xV17	7.34839	1.79531	4.093	6.28e-05 ***		
xV18	10.78265	1.80095	5.987	1.04e-08 ***		
xV19	9.19146	1.80195	5.101	8.12e-07 ***		
xV20	7.16445	1.80973	3.959	0.000106 ***		
xV21	6.55005	1.81612	3.607	0.000396 ***		
xV22	1.26297	2.83957	0.445	0.656986		
xV23	-4.05897	2.54897	-1.592	0.112949		
xV24	-7.18091	2.84040	-2.528	0.012277 *		
xV25	-6.69599	2.32381	-2.881	0.004411 **		
xV26	13.02826	2.84247	4.583	8.25e-06 ***		
xV27	3.29119	2.54504	1.293	0.197511		
xV28	3.53199	2.83986	1.244	0.215127		
xV29	4.29340	2.32728	1.845	0.066612 .		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 5.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.05597	0.03896	1.437	0.152491	
xV6	-1.45403	10.01420	-0.145	0.884709	
xV7	-24.27793	7.07073	-3.434	0.000730 ***	
xV8	-0.02360	0.09804	-0.241	0.810036	
xV9	0.13740	0.05449	2.522	0.012493 *	
xV10	9.65485	2.71222	3.560	0.000468 ***	
xV11	8.22271	2.68426	3.063	0.002505 **	
xV12	5.27994	2.67526	1.974	0.049867 *	
xV13	3.51229	2.68381	1.309	0.192210	
xV14	1.91226	2.69266	0.710	0.478462	
xV15	0.52068	2.71004	0.192	0.847846	
xV16	1.78983	2.75653	0.649	0.516920	
xV17	9.63982	2.80391	3.438	0.000719 ***	
xV18	14.31407	2.81271	5.089	8.58e-07 ***	
xV19	12.04238	2.81428	4.279	2.97e-05 ***	
xV20	7.88371	2.82644	2.789	0.005818 **	
xV21	7.41990	2.83641	2.616	0.009609 **	
xV22	-2.41705	4.43483	-0.545	0.586378	
xV23	-5.56177	3.98097	-1.397	0.164008	
xV24	-10.67693	4.43613	-2.407	0.017045 *	
xV25	-9.82186	3.62933	-2.706	0.007421 **	
xV26	22.64827	4.43936	5.102	8.09e-07 ***	
xV27	9.89704	3.97484	2.490	0.013631 *	
xV28	-0.05126	4.43528	-0.012	0.990790	
xV29	6.01789	3.63474	1.656	0.099433 .	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 5.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.03473	0.01715	2.025	0.044227 *	
xV6	2.24635	4.40734	0.510	0.610861	
xV7	-15.33258	3.11189	-4.927	1.80e-06 ***	
xV8	-0.04601	0.04315	-1.066	0.287627	
xV9	0.07266	0.02398	3.030	0.002783 **	
xV10	6.60412	1.19367	5.533	1.03e-07 ***	
xV11	5.91403	1.18137	5.006	1.26e-06 ***	
xV12	4.06055	1.17740	3.449	0.000693 ***	
xV13	3.19999	1.18117	2.709	0.007358 **	
xV14	3.09669	1.18506	2.613	0.009687 **	
xV15	2.32109	1.19271	1.946	0.053115 .	
xV16	2.49748	1.21317	2.059	0.040887 *	
xV17	5.80202	1.23402	4.702	4.93e-06 ***	
xV18	7.20185	1.23790	5.818	2.48e-08 ***	
xV19	6.54382	1.23859	5.283	3.44e-07 ***	
xV20	4.74549	1.24394	3.815	0.000184 ***	
xV21	4.62934	1.24833	3.708	0.000273 ***	
xV22	1.59652	1.95181	0.818	0.414393	
xV23	-0.78666	1.75206	-0.449	0.653946	
xV24	-4.01912	1.95238	-2.059	0.040893 *	
xV25	-4.12923	1.59730	-2.585	0.010479 *	
xV26	6.51715	1.95380	3.336	0.001023 **	
xV27	3.20169	1.74936	1.830	0.068778 .	
xV28	3.43777	1.95201	1.761	0.079814 .	
xV29	4.21018	1.59968	2.632	0.009185 **	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Surabaya – Rp. 2.000,-						
Coefficients: (2 not defined because of singularities)						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.12668	0.03661	3.460	0.000906 ***		
xV6	-148.09074	92.90317	-1.594	0.115249		
xV7	1.39454	7.17153	0.194	0.846360		
xV8	1.11892	0.73073	1.531	0.130033		
xV9	NA	NA	NA	NA		
xV10	-1.95318	4.10335	-0.476	0.635498		
xV11	-2.40733	4.07879	-0.590	0.556874		
xV12	-5.05920	4.05645	-1.247	0.216311		
xV13	-10.08869	4.03635	-2.499	0.014687 *		
xV14	-12.15556	4.01854	-3.025	0.003433 **		
xV15	-12.24090	4.05299	-3.020	0.003480 **		
xV16	-6.91658	4.43442	-1.560	0.123145		
xV17	4.89918	4.77813	1.025	0.308592		
xV18	17.26092	4.38182	3.939	0.000185 ***		
xV19	18.82606	4.04841	4.650	1.44e-05 ***		
xV20	4.24119	3.96099	1.071	0.287814		
xV21	NA	NA	NA	NA		
xV22	-11.87878	8.69297	-1.366	0.175982		
xV23	-24.46524	6.43864	-3.800	0.000298 ***		
xV24	-14.28567	6.30832	-2.265	0.026508 *		
xV25	-13.34489	5.09761	-2.618	0.010751 *		
xV26	10.74094	8.86307	1.212	0.229468		
xV27	-16.35229	6.29200	-2.599	0.011309 *		
xV28	-11.86889	6.29574	-1.885	0.063379 .		
xV29	-9.32078	5.19163	-1.795	0.076737 .		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 2.000,-						
Coefficients: (2 not defined because of singularities)						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.034016	0.008993	3.782	0.000315 ***		
xV6	-26.708026	22.819310	-1.170	0.245641		
xV7	-0.358453	1.761505	-0.203	0.839316		
xV8	0.188802	0.179485	1.052	0.296312		
xV9	NA	NA	NA	NA		
xV10	1.390343	1.007883	1.379	0.171962		
xV11	-0.001002	1.001852	-0.001	0.999205		
xV12	-0.576433	0.996364	-0.579	0.564683		
xV13	-1.534859	0.991428	-1.548	0.125916		
xV14	-2.282139	0.987052	-2.312	0.023597 *		
xV15	-2.835935	0.995514	-2.849	0.005700 **		
xV16	-1.924563	1.089204	-1.767	0.081417 .		
xV17	-0.783026	1.173627	-0.667	0.506758		
xV18	1.527262	1.076283	1.419	0.160150		
xV19	2.134278	0.994389	2.146	0.035171 *		
xV20	0.939964	0.972917	0.966	0.337169		
xV21	NA	NA	NA	NA		
xV22	-0.988541	2.135208	-0.463	0.644762		
xV23	-3.107541	1.581488	-1.965	0.053226 .		
xV24	-3.109093	1.549480	-2.007	0.048503 *		
xV25	-2.818323	1.252099	-2.251	0.027405 *		
xV26	5.937518	2.176988	2.727	0.007990 **		
xV27	-2.206891	1.545470	-1.428	0.157564		
xV28	-0.180328	1.546389	-0.117	0.907487		
xV29	0.020802	1.275193	0.016	0.987030		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 2.000,-					
Coefficients: (2 not defined because of singularities)					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.07800	0.01755	4.445	3.07e-05	***
xV6	21.82269	44.52502	0.490	0.62552	
xV7	-4.60907	3.43705	-1.341	0.18408	
xV8	-0.22375	0.35021	-0.639	0.52489	
xV9	NA	NA	NA	NA	
xV10	-2.69399	1.96658	-1.370	0.17492	
xV11	-2.21755	1.95481	-1.134	0.26034	
xV12	-4.11679	1.94411	-2.118	0.03762	*
xV13	-5.21804	1.93447	-2.697	0.00867	**
xV14	-5.28084	1.92594	-2.742	0.00768	**
xV15	-5.86668	1.94245	-3.020	0.00348	**
xV16	-4.31571	2.12525	-2.031	0.04593	*
xV17	0.44013	2.28998	0.192	0.84812	
xV18	2.70737	2.10004	1.289	0.20140	
xV19	4.45270	1.94025	2.295	0.02461	*
xV20	2.98273	1.89836	1.571	0.12046	
xV21	NA	NA	NA	NA	
xV22	-4.32909	4.16622	-1.039	0.30219	
xV23	-6.05361	3.08580	-1.962	0.05360	.
xV24	-5.89436	3.02334	-1.950	0.05506	.
xV25	-5.26944	2.44309	-2.157	0.03431	*
xV26	1.35672	4.24774	0.319	0.75034	
xV27	-1.06786	3.01552	-0.354	0.72427	
xV28	-5.09262	3.01731	-1.688	0.09572	.
xV29	-3.72060	2.48815	-1.495	0.13914	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 2.000,-					
Coefficients: (2 not defined because of singularities)					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.04414	0.00914	4.829	7.34e-06	***
xV6	0.42656	23.19248	0.018	0.9854	
xV7	-4.37548	1.79031	-2.444	0.0169	*
xV8	-0.04120	0.18242	-0.226	0.8220	
xV9	NA	NA	NA	NA	
xV10	-0.03084	1.02436	-0.030	0.9761	
xV11	-0.48460	1.01824	-0.476	0.6355	
xV12	-0.64541	1.01266	-0.637	0.5259	
xV13	-1.18906	1.00764	-1.180	0.2418	
xV14	-1.66590	1.00319	-1.661	0.1011	
xV15	-1.62145	1.01179	-1.603	0.1134	
xV16	-0.73192	1.10702	-0.661	0.5106	
xV17	0.41024	1.19282	0.344	0.7319	
xV18	2.64612	1.09388	2.419	0.0181	*
xV19	3.33474	1.01065	3.300	0.0015	**
xV20	1.52174	0.98883	1.539	0.1281	
xV21	NA	NA	NA	NA	
xV22	-1.32414	2.17013	-0.610	0.5436	
xV23	-2.34794	1.60735	-1.461	0.1484	
xV24	-1.65837	1.57482	-1.053	0.2958	
xV25	-2.05999	1.27257	-1.619	0.1098	
xV26	5.06273	2.21259	2.288	0.0250	*
xV27	-1.35408	1.57074	-0.862	0.3915	
xV28	-1.26023	1.57168	-0.802	0.4252	
xV29	0.08600	1.29605	0.066	0.9473	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Surabaya – Rp. 1.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.05938	0.01134	5.235	4.33e-07	***	
xV6	2.86871	2.91565	0.984	0.326409		
xV7	6.59765	2.05866	3.205	0.001584	**	
xV8	-0.06065	0.02854	-2.125	0.034891	*	
xV9	-0.11075	0.01586	-6.981	4.70e-11	***	
xV10	7.48469	0.78967	9.478	< 2e-16	***	
xV11	7.24654	0.78153	9.272	< 2e-16	***	
xV12	6.18778	0.77891	7.944	1.64e-13	***	
xV13	4.95976	0.78140	6.347	1.56e-09	***	
xV14	4.39832	0.78397	5.610	7.02e-08	***	
xV15	3.79418	0.78903	4.809	3.07e-06	***	
xV16	3.48073	0.80257	4.337	2.34e-05	***	
xV17	2.25059	0.81636	2.757	0.006402	**	
xV18	2.21707	0.81893	2.707	0.007399	**	
xV19	4.00428	0.81938	4.887	2.16e-06	***	
xV20	4.47791	0.82292	5.441	1.61e-07	***	
xV21	6.45481	0.82583	7.816	3.56e-13	***	
xV22	-1.19392	1.29121	-0.925	0.356313		
xV23	-1.07477	1.15907	-0.927	0.354958		
xV24	-1.13666	1.29159	-0.880	0.379939		
xV25	-1.95756	1.05669	-1.853	0.065490	.	
xV26	4.80130	1.29253	3.715	0.000267	***	
xV27	4.11503	1.15728	3.556	0.000475	***	
xV28	1.47891	1.29134	1.145	0.253539		
xV29	1.82313	1.05826	1.723	0.086550	.	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 1.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.016171	0.004322	3.741	0.000242	***	
xV6	2.030946	1.111016	1.828	0.069109	.	
xV7	0.544575	0.784456	0.694	0.488396		
xV8	-0.031553	0.010877	-2.901	0.004156	**	
xV9	-0.027091	0.006045	-4.482	1.27e-05	***	
xV10	3.008633	0.300905	9.999	< 2e-16	***	
xV11	2.623390	0.297803	8.809	7.66e-16	***	
xV12	2.739214	0.296804	9.229	< 2e-16	***	
xV13	2.178236	0.297753	7.316	6.89e-12	***	
xV14	1.797363	0.298735	6.017	8.92e-09	***	
xV15	1.518073	0.300663	5.049	1.03e-06	***	
xV16	1.197511	0.305821	3.916	0.000125	***	
xV17	0.906135	0.311077	2.913	0.004008	**	
xV18	0.970706	0.312054	3.111	0.002153	**	
xV19	1.379446	0.312228	4.418	1.67e-05	***	
xV20	1.796445	0.313577	5.729	3.88e-08	***	
xV21	2.133270	0.314684	6.779	1.47e-10	***	
xV22	0.428057	0.492019	0.870	0.385391		
xV23	-0.392467	0.441666	-0.889	0.375332		
xV24	-0.522252	0.492163	-1.061	0.289968		
xV25	-0.810316	0.402652	-2.012	0.045578	*	
xV26	2.469317	0.492521	5.014	1.21e-06	***	
xV27	2.351572	0.440985	5.333	2.72e-07	***	
xV28	0.702462	0.492069	1.428	0.155049		
xV29	0.995715	0.403253	2.469	0.014419	*	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 31. Output Pemodelan *Time Series Regression Data Inflow* (lanjutan)

KP BI Kediri – Rp. 1.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.020281	0.007896	2.569	0.010972 *		
xV6	0.564149	2.029442	0.278	0.781327		
xV7	-0.728060	1.432930	-0.508	0.611975		
xV8	-0.031313	0.019868	-1.576	0.116657		
xV9	-0.033040	0.011042	-2.992	0.003135 **		
xV10	6.475277	0.549648	11.781	< 2e-16 ***		
xV11	6.075480	0.543982	11.169	< 2e-16 ***		
xV12	4.792566	0.542158	8.840	6.30e-16 ***		
xV13	3.971439	0.543892	7.302	7.46e-12 ***		
xV14	3.266845	0.545686	5.987	1.04e-08 ***		
xV15	2.924234	0.549207	5.324	2.83e-07 ***		
xV16	2.366749	0.558628	4.237	3.53e-05 ***		
xV17	1.884344	0.568230	3.316	0.001092 **		
xV18	1.997273	0.570015	3.504	0.000571 ***		
xV19	2.546928	0.570333	4.466	1.36e-05 ***		
xV20	3.178002	0.572796	5.548	9.53e-08 ***		
xV21	4.130764	0.574818	7.186	1.46e-11 ***		
xV22	-0.149677	0.898747	-0.167	0.867908		
xV23	-1.087356	0.806770	-1.348	0.179323		
xV24	-0.712107	0.899011	-0.792	0.429285		
xV25	-1.340184	0.735507	-1.822	0.070000 .		
xV26	4.937629	0.899665	5.488	1.28e-07 ***		
xV27	3.695195	0.805527	4.587	8.11e-06 ***		
xV28	2.033286	0.898839	2.262	0.024816 *		
xV29	1.218765	0.736603	1.655	0.099653 .		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Jember – Rp. 1.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	0.013591	0.003520	3.861	0.000154 ***		
xV6	1.598955	0.904782	1.767	0.078787 .		
xV7	0.420691	0.638840	0.659	0.510995		
xV8	-0.025221	0.008858	-2.847	0.004889 **		
xV9	-0.022719	0.004923	-4.615	7.19e-06 ***		
xV10	2.793083	0.245049	11.398	< 2e-16 ***		
xV11	2.510947	0.242522	10.353	< 2e-16 ***		
xV12	2.176137	0.241789	9.003	2.23e-16 ***		
xV13	1.618300	0.242482	6.674	2.63e-10 ***		
xV14	1.386690	0.243282	5.700	4.49e-08 ***		
xV15	1.244527	0.244852	5.083	8.83e-07 ***		
xV16	0.899687	0.249052	3.612	0.000388 ***		
xV17	0.657601	0.253333	2.596	0.010171 *		
xV18	0.724894	0.254129	2.852	0.004816 **		
xV19	1.255462	0.254270	4.938	1.72e-06 ***		
xV20	1.605262	0.255368	6.286	2.16e-09 ***		
xV21	1.947131	0.256270	7.598	1.31e-12 ***		
xV22	0.561356	0.400687	1.401	0.162841		
xV23	0.160907	0.359681	0.447	0.655121		
xV24	-0.305331	0.400804	-0.762	0.447122		
xV25	-0.594959	0.327909	-1.814	0.071185 .		
xV26	2.563333	0.401096	6.391	1.23e-09 ***		
xV27	2.291385	0.359127	6.380	1.30e-09 ***		
xV28	1.438037	0.400727	3.589	0.000423 ***		
xV29	1.125415	0.328398	3.427	0.000747 ***		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 32. Output Pemodelan Time Series Regression Data Outflow

KP BI Surabaya – Rp. 100.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	5.943	1.746	3.404	0.000809	***	
xV6	-161.690	449.211	-0.360	0.719288		
xV7	-2295.416	317.671	-7.226	1.16e-11	***	
xV8	-3.799	4.394	-0.865	0.388310		
xV9	12.799	2.448	5.229	4.44e-07	***	
xV10	-103.636	120.067	-0.863	0.389137		
xV11	46.388	119.677	0.388	0.698737		
xV12	277.469	120.046	2.311	0.021881	*	
xV13	283.347	120.429	2.353	0.019649	*	
xV14	283.382	121.190	2.338	0.020404	*	
xV15	464.982	123.271	3.772	0.000216	***	
xV16	355.939	124.937	2.849	0.004867	**	
xV17	343.958	125.241	2.746	0.006602	**	
xV18	192.358	125.282	1.535	0.126340		
xV19	118.347	125.889	0.940	0.348358		
xV20	135.972	126.845	1.072	0.285092		
xV21	740.303	125.483	5.900	1.63e-08	***	
xV22	1157.788	199.110	5.815	2.51e-08	***	
xV23	495.787	199.673	2.483	0.013891	*	
xV24	-20.227	199.140	-0.102	0.919202		
xV25	102.471	162.924	0.629	0.530135		
xV26	-388.319	199.075	-1.951	0.052566	.	
xV27	301.393	178.410	1.689	0.092788	.	
xV28	823.997	199.011	4.140	5.20e-05	***	
xV29	1145.291	163.096	7.022	3.73e-11	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 100.000						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	2.5903	0.6559	3.949	0.000110	***	
xV6	70.5398	168.7884	0.418	0.676476		
xV7	-654.7271	119.3629	-5.485	1.30e-07	***	
xV8	-2.1584	1.6510	-1.307	0.192658		
xV9	3.3069	0.9196	3.596	0.000412	***	
xV10	-130.5813	45.1144	-2.894	0.004240	**	
xV11	-94.7405	44.9678	-2.107	0.036436	*	
xV12	-33.4523	45.1066	-0.742	0.459224		
xV13	-41.5528	45.2504	-0.918	0.359628		
xV14	-8.7276	45.5362	-0.192	0.848211		
xV15	83.9462	46.3183	1.812	0.071498	.	
xV16	62.5746	46.9443	1.333	0.184134		
xV17	-39.8690	47.0586	-0.847	0.397933		
xV18	-37.8913	47.0739	-0.805	0.421860		
xV19	-83.2765	47.3019	-1.761	0.079919	.	
xV20	-65.2100	47.6613	-1.368	0.172858		
xV21	95.0497	47.1495	2.016	0.045209	*	
xV22	511.6472	74.8142	6.839	1.05e-10	***	
xV23	205.7742	75.0260	2.743	0.006673	**	
xV24	51.2353	74.8257	0.685	0.494345		
xV25	43.7623	61.2178	0.715	0.475567		
xV26	-72.0891	74.8012	-0.964	0.336394		
xV27	123.5983	67.0364	1.844	0.066769	.	
xV28	377.9623	74.7772	5.055	1.01e-06	***	
xV29	520.5488	61.2823	8.494	5.56e-15	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 100.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	2.8082	1.0559	2.660	0.00849	**	
xV6	-79.8870	271.7008	-0.294	0.76906		
xV7	-1581.4145	192.1399	-8.231	2.86e-14	***	
xV8	-0.8326	2.6576	-0.313	0.75440		
xV9	10.0171	1.4804	6.767	1.57e-10	***	
xV10	-166.2269	72.6212	-2.289	0.02318	*	
xV11	-57.5908	72.3852	-0.796	0.42724		
xV12	30.1503	72.6086	0.415	0.67843		
xV13	60.4290	72.8402	0.830	0.40779		
xV14	77.5773	73.3003	1.058	0.29123		
xV15	320.7749	74.5591	4.302	2.70e-05	***	
xV16	130.5678	75.5668	1.728	0.08563	.	
xV17	16.3578	75.7509	0.216	0.82926		
xV18	22.1740	75.7755	0.293	0.77012		
xV19	-32.1976	76.1425	-0.423	0.67287		
xV20	-70.2463	76.7210	-0.916	0.36103		
xV21	128.5004	75.8971	1.693	0.09207	.	
xV22	768.4277	120.4293	6.381	1.30e-09	***	
xV23	357.4297	120.7704	2.960	0.00347	**	
xV24	71.3202	120.4478	0.592	0.55447		
xV25	120.8785	98.5431	1.227	0.22146		
xV26	-111.1498	120.4085	-0.923	0.35712		
xV27	201.5366	107.9093	1.868	0.06334	.	
xV28	490.1864	120.3697	4.072	6.81e-05	***	
xV29	891.5047	98.6470	9.037	< 2e-16	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Jember – Rp. 100.000						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.2825	0.5275	-0.536	0.592926		
xV6	-290.4401	135.7291	-2.140	0.033636	*	
xV7	-107.5494	95.9842	-1.120	0.263912		
xV8	3.5848	1.3276	2.700	0.007552	**	
xV9	2.7313	0.7395	3.693	0.000289	***	
xV10	-50.1781	36.2782	-1.383	0.168234		
xV11	1.9383	36.1603	0.054	0.957307		
xV12	18.0579	36.2719	0.498	0.619163		
xV13	41.4145	36.3876	1.138	0.256483		
xV14	74.5637	36.6174	2.036	0.043102	*	
xV15	126.7073	37.2463	3.402	0.000815	***	
xV16	98.6738	37.7497	2.614	0.009665	**	
xV17	19.1533	37.8416	0.506	0.613339		
xV18	38.3095	37.8539	1.012	0.312802		
xV19	32.9727	38.0373	0.867	0.387110		
xV20	42.5826	38.3263	1.111	0.267941		
xV21	164.6497	37.9147	4.343	2.28e-05	***	
xV22	189.3807	60.1609	3.148	0.001908	**	
xV23	97.9708	60.3313	1.624	0.106050		
xV24	-7.6467	60.1701	-0.127	0.899007		
xV25	-16.6517	49.2276	-0.338	0.735539		
xV26	-96.1071	60.1505	-1.598	0.111745		
xV27	112.6564	53.9065	2.090	0.037956	*	
xV28	230.8682	60.1311	3.839	0.000168	***	
xV29	356.6429	49.2794	7.237	1.09e-11	***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Surabaya – Rp. 50.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	7.188	1.452	4.950	1.63e-06	***	
xV6	-91.297	373.638	-0.244	0.807225		
xV7	-1126.650	264.228	-4.264	3.16e-05	***	
xV8	-5.563	3.655	-1.522	0.129607		
xV9	3.065	2.036	1.506	0.133828		
xV10	-41.112	99.867	-0.412	0.681047		
xV11	149.178	99.543	1.499	0.135620		
xV12	319.189	99.850	3.197	0.001627	**	
xV13	292.122	100.169	2.916	0.003966	**	
xV14	273.553	100.801	2.714	0.007261	**	
xV15	467.330	102.532	4.558	9.21e-06	***	
xV16	297.140	103.918	2.859	0.004717	**	
xV17	360.380	104.171	3.459	0.000667	***	
xV18	192.596	104.205	1.848	0.066114	.	
xV19	175.354	104.710	1.675	0.095637	.	
xV20	201.917	105.505	1.914	0.057140	.	
xV21	528.755	104.372	5.066	9.54e-07	***	
xV22	1123.509	165.612	6.784	1.43e-10	***	
xV23	441.623	166.081	2.659	0.008501	**	
xV24	-4.534	165.638	-0.027	0.978189		
xV25	10.688	135.515	0.079	0.937220		
xV26	-341.501	165.584	-2.062	0.040522	*	
xV27	757.920	148.395	5.107	7.87e-07	***	
xV28	946.243	165.530	5.716	4.13e-08	***	
xV29	1169.835	135.658	8.623	2.47e-15	***	

Signif. codes:	0	‘***’	0.001	‘**’	0.01	‘*’
	0.05	‘.’	0.1	‘,’	1	
KP BI Malang – Rp. 50.000						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	1.46117	0.41295	3.538	0.000506	***	
xV6	-16.25785	106.26169	-0.153	0.878561		
xV7	-362.62047	75.14559	-4.826	2.85e-06	***	
xV8	-1.57527	1.03937	-1.516	0.131276		
xV9	1.28702	0.57897	2.223	0.027391	*	
xV10	21.59149	28.40202	0.760	0.448067		
xV11	54.13156	28.30971	1.912	0.057357	.	
xV12	123.95284	28.39710	4.365	2.08e-05	***	
xV13	115.76703	28.48765	4.064	7.05e-05	***	
xV14	116.65437	28.66760	4.069	6.90e-05	***	
xV15	168.56978	29.15993	5.781	2.99e-08	***	
xV16	125.09864	29.55403	4.233	3.58e-05	***	
xV17	108.94671	29.62602	3.677	0.000306	***	
xV18	108.25248	29.63566	3.653	0.000335	***	
xV19	74.82796	29.77921	2.513	0.012807	*	
xV20	79.17158	30.00545	2.639	0.009012	**	
xV21	199.33749	29.68322	6.715	2.09e-10	***	
xV22	307.22561	47.09969	6.523	6.02e-10	***	
xV23	132.51332	47.23308	2.806	0.005544	**	
xV24	0.04797	47.10693	0.001	0.999189		
xV25	13.46052	38.54003	0.349	0.727278		
xV26	-81.17182	47.09153	-1.724	0.086380	.	
xV27	126.14034	42.20315	2.989	0.003168	**	
xV28	210.21924	47.07639	4.465	1.36e-05	***	
xV29	456.26310	38.58065	11.826	< 2e-16	***	

Signif. codes:	0	‘***’	0.001	‘**’	0.01	‘*’
	0.05	‘.’	0.1	‘,’	1	

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 50.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	1.6117	0.5614	2.871	0.004552	**
xV6	67.9955	144.4498	0.471	0.638377	
xV7	-12.9388	102.1512	-0.127	0.899341	
xV8	-1.6232	1.4129	-1.149	0.252062	
xV9	-0.1101	0.7870	-0.140	0.888857	
xV10	-57.8715	38.6091	-1.499	0.135548	
xV11	5.8578	38.4836	0.152	0.879177	
xV12	57.0887	38.6024	1.479	0.140817	
xV13	50.0401	38.7255	1.292	0.197858	
xV14	76.9296	38.9701	1.974	0.049816	*
xV15	201.8607	39.6394	5.092	8.44e-07	***
xV16	127.8967	40.1751	3.183	0.001699	**
xV17	60.8093	40.2730	1.510	0.132714	
xV18	39.8001	40.2861	0.988	0.324433	
xV19	29.7352	40.4812	0.735	0.463519	
xV20	-2.3730	40.7887	-0.058	0.953668	
xV21	150.0513	40.3507	3.719	0.000263	***
xV22	435.0680	64.0263	6.795	1.34e-10	***
xV23	187.2398	64.2076	2.916	0.003968	**
xV24	2.7545	64.0361	0.043	0.965735	
xV25	47.9341	52.3905	0.915	0.361377	
xV26	-104.7555	64.0152	-1.636	0.103399	
xV27	158.0665	57.3700	2.755	0.006433	**
xV28	328.7070	63.9946	5.136	6.88e-07	***
xV29	463.8285	52.4457	8.844	6.14e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 50.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	3.7852	0.3275	11.559	< 2e-16	***
xV6	271.9311	84.2626	3.227	0.001471	**
xV7	-105.6497	59.5884	-1.773	0.077824	.
xV8	-4.8868	0.8242	-5.929	1.40e-08	***
xV9	-2.2184	0.4591	-4.832	2.77e-06	***
xV10	-65.7115	22.5220	-2.918	0.003950	**
xV11	-29.4621	22.4488	-1.312	0.190955	
xV12	6.7237	22.5181	0.299	0.765576	
xV13	7.9166	22.5899	0.350	0.726388	
xV14	14.3587	22.7326	0.632	0.528380	
xV15	75.5549	23.1230	3.268	0.001286	**
xV16	23.8215	23.4355	1.016	0.310691	
xV17	-27.2468	23.4926	-1.160	0.247577	
xV18	6.9781	23.5003	0.297	0.766837	
xV19	-4.3809	23.6141	-0.186	0.853018	
xV20	10.3325	23.7935	0.434	0.664590	
xV21	124.4933	23.5380	5.289	3.35e-07	***
xV22	208.5383	37.3487	5.584	8.01e-08	***
xV23	103.2998	37.4545	2.758	0.006380	**
xV24	-38.0641	37.3545	-1.019	0.309494	
xV25	8.9425	30.5612	0.293	0.770138	
xV26	-102.2457	37.3423	-2.738	0.006764	**
xV27	121.5472	33.4659	3.632	0.000361	***
xV28	111.9016	37.3303	2.998	0.003083	**
xV29	183.1561	30.5934	5.987	1.04e-08	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Surabaya – Rp. 20.000,-						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.2361	0.2142	-1.102	0.271794		
xV6	-82.3964	55.1304	-1.495	0.136676		
xV7	-127.9028	38.9868	-3.281	0.001231 **		
xV8	0.5428	0.5392	1.007	0.315426		
xV9	0.8011	0.3004	2.667	0.008308 **		
xV10	59.0950	14.7355	4.010	8.69e-05 ***		
xV11	63.6651	14.6876	4.335	2.36e-05 ***		
xV12	63.9671	14.7329	4.342	2.29e-05 ***		
xV13	67.9464	14.7799	4.597	7.77e-06 ***		
xV14	79.3269	14.8732	5.334	2.71e-07 ***		
xV15	129.8545	15.1287	8.583	3.18e-15 ***		
xV16	88.5971	15.3331	5.778	3.03e-08 ***		
xV17	78.0031	15.3705	5.075	9.16e-07 ***		
xV18	41.0645	15.3755	2.671	0.008220 **		
xV19	30.4683	15.4500	1.972	0.050046 .		
xV20	32.7592	15.5673	2.104	0.036656 *		
xV21	53.6707	15.4002	3.485	0.000610 ***		
xV22	199.1449	24.4361	8.150	4.70e-14 ***		
xV23	137.7740	24.5053	5.622	6.61e-08 ***		
xV24	152.7964	24.4399	6.252	2.59e-09 ***		
xV25	78.2334	19.9952	3.913	0.000127 ***		
xV26	-0.6952	24.4319	-0.028	0.977329		
xV27	47.7108	21.8957	2.179	0.030556 *		
xV28	77.5881	24.4240	3.177	0.001737 **		
xV29	199.1409	20.0163	9.949	< 2e-16 ***		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						
KP BI Malang – Rp. 20.000						
Coefficients:						
	Estimate	Std. Error	t value	Pr(> t)		
xV5	-0.42977	0.04231	-10.157	< 2e-16 ***		
xV6	-39.19900	10.88816	-3.600	0.000405 ***		
xV7	-61.53825	7.69983	-7.992	1.23e-13 ***		
xV8	0.43409	0.10650	4.076	6.72e-05 ***		
xV9	0.57785	0.05932	9.741	< 2e-16 ***		
xV10	39.88869	2.91023	13.706	< 2e-16 ***		
xV11	40.34230	2.90077	13.907	< 2e-16 ***		
xV12	43.20901	2.90972	14.850	< 2e-16 ***		
xV13	45.76611	2.91900	15.679	< 2e-16 ***		
xV14	50.38251	2.93744	17.152	< 2e-16 ***		
xV15	53.93039	2.98789	18.050	< 2e-16 ***		
xV16	48.29923	3.02827	15.949	< 2e-16 ***		
xV17	43.52967	3.03565	14.340	< 2e-16 ***		
xV18	40.56521	3.03663	13.359	< 2e-16 ***		
xV19	37.01420	3.05134	12.130	< 2e-16 ***		
xV20	37.37538	3.07452	12.156	< 2e-16 ***		
xV21	40.42348	3.04151	13.291	< 2e-16 ***		
xV22	41.49427	4.82609	8.598	2.90e-15 ***		
xV23	30.40627	4.83976	6.283	2.20e-09 ***		
xV24	22.90992	4.82684	4.746	4.05e-06 ***		
xV25	13.74484	3.94902	3.481	0.000620 ***		
xV26	-3.37153	4.82526	-0.699	0.485573		
xV27	1.32432	4.32437	0.306	0.759752		
xV28	24.90376	4.82371	5.163	6.08e-07 ***		
xV29	53.67018	3.95319	13.576	< 2e-16 ***		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1						

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 20.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-0.05870	0.05599	-1.048	0.295826	
xV6	-3.34959	14.40775	-0.232	0.816410	
xV7	-29.04947	10.18880	-2.851	0.004836 **	
xV8	-0.01288	0.14093	-0.091	0.927261	
xV9	0.16975	0.07850	2.162	0.031830 *	
xV10	17.53392	3.85096	4.553	9.40e-06 ***	
xV11	19.32178	3.83844	5.034	1.11e-06 ***	
xV12	22.16319	3.85029	5.756	3.38e-08 ***	
xV13	22.92068	3.86257	5.934	1.37e-08 ***	
xV14	24.54488	3.88697	6.315	1.85e-09 ***	
xV15	39.29750	3.95372	9.939	< 2e-16 ***	
xV16	27.65653	4.00716	6.902	7.37e-11 ***	
xV17	22.82657	4.01692	5.683	4.89e-08 ***	
xV18	17.73255	4.01822	4.413	1.70e-05 ***	
xV19	14.75274	4.03769	3.654	0.000334 ***	
xV20	13.75472	4.06836	3.381	0.000876 ***	
xV21	16.67609	4.02467	4.143	5.14e-05 ***	
xV22	52.22088	6.38613	8.177	3.96e-14 ***	
xV23	30.70429	6.40421	4.794	3.27e-06 ***	
xV24	29.19834	6.38711	4.571	8.69e-06 ***	
xV25	12.74076	5.22555	2.438	0.015677 *	
xV26	-3.18436	6.38502	-0.499	0.618549	
xV27	8.77359	5.72222	1.533	0.126869	
xV28	28.44056	6.38297	4.456	1.42e-05 ***	
xV29	64.23202	5.23105	12.279	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 20.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.22009	0.05013	4.391	1.87e-05 ***	
xV6	9.09732	12.89839	0.705	0.481479	
xV7	-18.97071	9.12142	-2.080	0.038879 *	
xV8	-0.42931	0.12616	-3.403	0.000812 ***	
xV9	-0.17964	0.07028	-2.556	0.011363 *	
xV10	19.98733	3.44753	5.798	2.74e-08 ***	
xV11	17.45475	3.43633	5.079	8.97e-07 ***	
xV12	15.92062	3.44693	4.619	7.08e-06 ***	
xV13	16.88587	3.45793	4.883	2.20e-06 ***	
xV14	18.37718	3.47977	5.281	3.48e-07 ***	
xV15	22.16295	3.53953	6.262	2.46e-09 ***	
xV16	22.21627	3.58736	6.193	3.54e-09 ***	
xV17	17.11091	3.59610	4.758	3.85e-06 ***	
xV18	15.88240	3.59727	4.415	1.69e-05 ***	
xV19	20.53561	3.61470	5.681	4.93e-08 ***	
xV20	18.06313	3.64216	4.959	1.56e-06 ***	
xV21	20.58770	3.60305	5.714	4.18e-08 ***	
xV22	49.21888	5.71712	8.609	2.71e-15 ***	
xV23	16.03830	5.73331	2.797	0.005679 **	
xV24	7.38015	5.71799	1.291	0.198372	
xV25	-1.49236	4.67812	-0.319	0.750069	
xV26	-6.69131	5.71612	-1.171	0.243217	
xV27	4.95473	5.12276	0.967	0.334667	
xV28	9.71698	5.71429	1.700	0.090670 .	
xV29	18.83902	4.68305	4.023	8.28e-05 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Surabaya – Rp. 10.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-0.009413	0.215910	-0.044	0.965273	
xV6	-41.145953	55.558330	-0.741	0.459851	
xV7	-85.235782	39.289449	-2.169	0.031285 *	
xV8	0.342885	0.543431	0.631	0.528818	
xV9	0.580505	0.302709	1.918	0.056641 .	
xV10	19.251603	14.849837	1.296	0.196396	
xV11	20.303736	14.801574	1.372	0.171757	
xV12	23.444604	14.847264	1.579	0.115979	
xV13	29.010305	14.894610	1.948	0.052916 .	
xV14	37.088076	14.988694	2.474	0.014218 *	
xV15	84.154900	15.246104	5.520	1.10e-07 ***	
xV16	37.617073	15.452158	2.434	0.015835 *	
xV17	30.579135	15.489801	1.974	0.049807 *	
xV18	-6.111708	15.494839	-0.394	0.693700	
xV19	-16.742333	15.569892	-1.075	0.283596	
xV20	-14.802819	15.688182	-0.944	0.346584	
xV21	6.916264	15.519703	0.446	0.656359	
xV22	148.218132	24.625810	6.019	8.82e-09 ***	
xV23	154.781800	24.695552	6.268	2.38e-09 ***	
xV24	140.262206	24.629593	5.695	4.60e-08 ***	
xV25	86.644921	20.150438	4.300	2.72e-05 ***	
xV26	5.832148	24.621542	0.237	0.813010	
xV27	43.057647	22.065680	1.951	0.052479 .	
xV28	83.326687	24.613625	3.385	0.000863 ***	
xV29	208.481935	20.171677	10.335	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Malang – Rp. 10.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-0.14688	0.03411	-4.306	2.66e-05 ***	
xV6	-20.76039	8.77834	-2.365	0.019035 *	
xV7	-24.43521	6.20782	-3.936	0.000116 ***	
xV8	0.23668	0.08586	2.756	0.006410 **	
xV9	0.24604	0.04783	5.144	6.63e-07 ***	
xV10	11.78323	2.34631	5.022	1.17e-06 ***	
xV11	12.49537	2.33868	5.343	2.59e-07 ***	
xV12	13.97763	2.34590	5.958	1.21e-08 ***	
xV13	14.98999	2.35338	6.370	1.38e-09 ***	
xV14	18.16194	2.36825	7.669	8.60e-13 ***	
xV15	21.76819	2.40892	9.037	< 2e-16 ***	
xV16	16.65715	2.44147	6.823	1.15e-10 ***	
xV17	15.07173	2.44742	6.158	4.25e-09 ***	
xV18	10.35039	2.44822	4.228	3.66e-05 ***	
xV19	7.45695	2.46008	3.031	0.002774 **	
xV20	8.03134	2.47877	3.240	0.001410 **	
xV21	10.40555	2.45215	4.243	3.43e-05 ***	
xV22	30.56923	3.89093	7.857	2.79e-13 ***	
xV23	28.98006	3.90195	7.427	3.59e-12 ***	
xV24	24.60368	3.89153	6.322	1.78e-09 ***	
xV25	12.50664	3.18381	3.928	0.000120 ***	
xV26	1.22189	3.89026	0.314	0.753795	
xV27	5.71424	3.48643	1.639	0.102860	
xV28	20.54856	3.88901	5.284	3.43e-07 ***	
xV29	45.09000	3.18717	14.147	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 10.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-0.04382	0.03725	-1.176	0.240916	
xV6	-12.95585	9.58647	-1.351	0.178143	
xV7	-8.12039	6.77931	-1.198	0.232472	
xV8	0.13886	0.09377	1.481	0.140275	
xV9	0.08830	0.05223	1.690	0.092566	.
xV10	6.83889	2.56231	2.669	0.008262	**
xV11	6.91102	2.55398	2.706	0.007427	**
xV12	8.04122	2.56186	3.139	0.001966	**
xV13	9.54272	2.57003	3.713	0.000269	***
xV14	10.83878	2.58627	4.191	4.24e-05	***
xV15	18.83202	2.63068	7.159	1.71e-11	***
xV16	12.83853	2.66624	4.815	2.98e-06	***
xV17	11.02263	2.67273	4.124	5.55e-05	***
xV18	4.06805	2.67360	1.522	0.129773	
xV19	2.41488	2.68655	0.899	0.369851	
xV20	2.14679	2.70696	0.793	0.428725	
xV21	3.88066	2.67789	1.449	0.148937	
xV22	35.01781	4.24913	8.241	2.67e-14	***
xV23	28.82978	4.26117	6.766	1.58e-10	***
xV24	21.44580	4.24978	5.046	1.05e-06	***
xV25	13.87230	3.47692	3.990	9.42e-05	***
xV26	-0.19076	4.24840	-0.045	0.964233	
xV27	7.37506	3.80739	1.937	0.054216	.
xV28	18.99878	4.24703	4.473	1.32e-05	***
xV29	49.39435	3.48058	14.191	< 2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 10.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	-2.019e-04	2.018e-02	-0.010	0.99203	
xV6	-7.353e+00	5.192e+00	-1.416	0.15838	
xV7	-1.065e+01	3.672e+00	-2.901	0.00416	**
xV8	2.896e-02	5.079e-02	0.570	0.56915	
xV9	6.013e-02	2.829e-02	2.125	0.03485	*
xV10	8.874e+00	1.388e+00	6.394	1.21e-09	***
xV11	6.702e+00	1.383e+00	4.845	2.61e-06	***
xV12	5.969e+00	1.388e+00	4.301	2.71e-05	***
xV13	6.239e+00	1.392e+00	4.482	1.27e-05	***
xV14	6.762e+00	1.401e+00	4.827	2.83e-06	***
xV15	1.105e+01	1.425e+00	7.753	5.20e-13	***
xV16	8.524e+00	1.444e+00	5.902	1.61e-08	***
xV17	5.978e+00	1.448e+00	4.129	5.44e-05	***
xV18	3.933e+00	1.448e+00	2.716	0.00722	**
xV19	3.593e+00	1.455e+00	2.469	0.01442	*
xV20	4.504e+00	1.466e+00	3.072	0.00244	**
xV21	6.235e+00	1.450e+00	4.299	2.74e-05	***
xV22	2.032e+01	2.302e+00	8.828	6.79e-16	***
xV23	1.462e+01	2.308e+00	6.333	1.68e-09	***
xV24	7.029e+00	2.302e+00	3.054	0.00258	**
xV25	1.309e+00	1.883e+00	0.695	0.48771	
xV26	-2.638e-01	2.301e+00	-0.115	0.90884	
xV27	2.827e+00	2.062e+00	1.371	0.17207	
xV28	1.153e+01	2.300e+00	5.013	1.22e-06	***
xV29	2.251e+01	1.885e+00	11.940	< 2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression* Data *Outflow* (lanjutan)

KP BI Surabaya – Rp. 5.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.23800	0.20493	1.161	0.246939	
xV6	5.84127	52.73206	0.111	0.911913	
xV7	-12.50421	37.29079	-0.335	0.737755	
xV8	-0.16272	0.51579	-0.315	0.752746	
xV9	0.01452	0.28731	0.051	0.959734	
xV10	-5.54934	14.09442	-0.394	0.694222	
xV11	-2.85560	14.04861	-0.203	0.839144	
xV12	-2.96163	14.09198	-0.210	0.833763	
xV13	-0.38709	14.13692	-0.027	0.978184	
xV14	10.39948	14.22622	0.731	0.465670	
xV15	43.41111	14.47053	3.000	0.003060 **	
xV16	15.78063	14.66610	1.076	0.283287	
xV17	9.46857	14.70183	0.644	0.520322	
xV18	-26.24586	14.70661	-1.785	0.075909 .	
xV19	-30.33852	14.77785	-2.053	0.041439 *	
xV20	-34.14612	14.89012	-2.293	0.022925 *	
xV21	-15.18546	14.73021	-1.031	0.303889	
xV22	192.92253	23.37309	8.254	2.47e-14 ***	
xV23	176.63975	23.43928	7.536	1.89e-12 ***	
xV24	145.25440	23.37668	6.214	3.17e-09 ***	
xV25	69.70816	19.12538	3.645	0.000345 ***	
xV26	14.57088	23.36904	0.624	0.533692	
xV27	33.48559	20.94319	1.599	0.111501	
xV28	107.33130	23.36152	4.594	7.87e-06 ***	
xV29	123.87254	19.14554	6.470	8.03e-10 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Malang – Rp. 5.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.01654	0.03184	0.519	0.60406	
xV6	-5.21578	8.19381	-0.637	0.52518	
xV7	-5.89567	5.79446	-1.017	0.31022	
xV8	0.03392	0.08015	0.423	0.67263	
xV9	0.04140	0.04464	0.927	0.35487	
xV10	0.22537	2.19007	0.103	0.91815	
xV11	0.68537	2.18295	0.314	0.75389	
xV12	1.61961	2.18969	0.740	0.46042	
xV13	2.28184	2.19668	1.039	0.30023	
xV14	5.85108	2.21055	2.647	0.00880 **	
xV15	7.42757	2.24851	3.303	0.00114 **	
xV16	6.08760	2.27890	2.671	0.00821 **	
xV17	2.42253	2.28445	1.060	0.29028	
xV18	-1.09132	2.28520	-0.478	0.63351	
xV19	-3.29557	2.29627	-1.435	0.15287	
xV20	-3.80169	2.31371	-1.643	0.10200	
xV21	-2.56451	2.28886	-1.120	0.26394	
xV22	41.05293	3.63184	11.304 < 2e-16 ***		
xV23	30.25324	3.64213	8.306 1.79e-14 ***		
xV24	12.09596	3.63240	3.330 0.00104 **		
xV25	7.84891	2.97181	2.641 0.00895 **		
xV26	1.59874	3.63121	0.440 0.66023		
xV27	7.19870	3.25427	2.212 0.02815 *		
xV28	25.76880	3.63005	7.099 2.41e-11 ***		
xV29	31.29595	2.97494	10.520 < 2e-16 ***		

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 5.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.04541	0.03109	1.460	0.145842	
xV6	-7.69480	8.00078	-0.962	0.337388	
xV7	2.90544	5.65795	0.514	0.608185	
xV8	0.05419	0.07826	0.692	0.489477	
xV9	-0.03050	0.04359	-0.700	0.485028	
xV10	-1.39564	2.13848	-0.653	0.514779	
xV11	-0.92647	2.13153	-0.435	0.664306	
xV12	-0.31518	2.13811	-0.147	0.882965	
xV13	1.05613	2.14493	0.492	0.623011	
xV14	2.39866	2.15847	1.111	0.267847	
xV15	8.81734	2.19554	4.016	8.50e-05 ***	
xV16	4.85525	2.22522	2.182	0.030336 *	
xV17	2.62525	2.23064	1.177	0.240698	
xV18	-2.35584	2.23136	-1.056	0.292400	
xV19	-5.17889	2.24217	-2.310	0.021970 *	
xV20	-5.25446	2.25921	-2.326	0.021079 *	
xV21	-4.35490	2.23494	-1.949	0.052814 .	
xV22	40.25315	3.54629	11.351	< 2e-16 ***	
xV23	32.53868	3.55633	9.150	< 2e-16 ***	
xV24	12.61260	3.54683	3.556	0.000475 ***	
xV25	9.80594	2.90180	3.379	0.000881 ***	
xV26	0.89221	3.54567	0.252	0.801595	
xV27	7.41045	3.17761	2.332	0.020738 *	
xV28	27.79487	3.54453	7.842	3.06e-13 ***	
xV29	34.90805	2.90486	12.017	< 2e-16 ***	

Signif. codes:	0	****	0.001	***	0.01 ** 0.05 *
KP BI Jember – Rp. 5.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.003509	0.012330	0.285	0.77626	
xV6	-3.016526	3.172853	-0.951	0.34294	
xV7	-4.938142	2.243762	-2.201	0.02895 *	
xV8	0.018026	0.031035	0.581	0.56204	
xV9	0.035368	0.017287	2.046	0.04214 *	
xV10	3.425425	0.848052	4.039	7.76e-05 ***	
xV11	2.487351	0.845296	2.943	0.00366 **	
xV12	1.870193	0.847905	2.206	0.02860 *	
xV13	2.208914	0.850689	2.597	0.01014 *	
xV14	2.455520	0.855982	2.869	0.00459 **	
xV15	4.832956	0.870682	5.551	9.41e-08 ***	
xV16	3.569888	0.882450	4.045	7.58e-05 ***	
xV17	1.566329	0.884599	1.771	0.07821 .	
xV18	0.534008	0.884887	0.603	0.54691	
xV19	0.479838	0.889173	0.540	0.59007	
xV20	0.526451	0.895929	0.588	0.55749	
xV21	2.058642	0.886387	2.323	0.02125 *	
xV22	13.853308	1.406343	9.851	< 2e-16 ***	
xV23	9.558098	1.410326	6.777	1.48e-10 ***	
xV24	5.623513	1.406559	3.998	9.12e-05 ***	
xV25	1.477216	1.150761	1.284	0.20081	
xV26	-0.563487	1.406099	-0.401	0.68906	
xV27	1.925136	1.260138	1.528	0.12824	
xV28	10.207352	1.405647	7.262	9.42e-12 ***	
xV29	16.013181	1.151974	13.901	< 2e-16 ***	

Signif. codes:	0	****	0.001	***	0.01 ** 0.05 *

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Surabaya – Rp. 2.000,-					
Coefficients: (2 not defined because of singularities)					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.17106	0.06264	2.731	0.00791	**
xV6	68.42238	156.51464	0.437	0.66328	
xV7	-24.60301	12.27390	-2.004	0.04873	*
xV8	-0.69695	1.22975	-0.567	0.57263	
xV9	NA	NA	NA	NA	
xV10	-1.19987	7.01533	-0.171	0.86467	
xV11	-1.13076	6.97426	-0.162	0.87165	
xV12	-0.47862	6.93689	-0.069	0.94518	
xV13	1.00277	6.90328	0.145	0.88491	
xV14	11.87690	6.96336	1.706	0.09233	.
xV15	13.65860	7.62219	1.792	0.07728	.
xV16	-12.78051	8.20183	-1.558	0.12350	
xV17	-10.70255	7.50381	-1.426	0.15805	
xV18	-5.60640	6.93408	-0.809	0.42141	
xV19	-4.61447	6.78335	-0.680	0.49849	
xV20	-4.32934	6.77729	-0.639	0.52495	
xV21	NA	NA	NA	NA	
xV22	240.25097	14.87275	16.154	< 2e-16	***
xV23	247.42227	10.94756	22.601	< 2e-16	***
xV24	153.42885	10.79337	14.215	< 2e-16	***
xV25	51.35350	8.72301	5.887	1.11e-07	***
xV26	4.28478	15.16450	0.283	0.77832	
xV27	19.38909	10.65512	1.820	0.07291	.
xV28	99.27754	10.77279	9.216	7.35e-14	***
xV29	189.27913	8.88334	21.307	< 2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Malang – Rp. 2.000					
Coefficients: (2 not defined because of singularities)					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.02390	0.01091	2.191	0.031679	*
xV6	-4.74182	27.26258	-0.174	0.862401	
xV7	-3.66864	2.13793	-1.716	0.090408	.
xV8	0.01354	0.21420	0.063	0.949773	
xV9	NA	NA	NA	NA	
xV10	0.37220	1.22197	0.305	0.761542	
xV11	0.35689	1.21481	0.294	0.769759	
xV12	0.68027	1.20831	0.563	0.575166	
xV13	1.01451	1.20245	0.844	0.401592	
xV14	5.45901	1.21292	4.501	2.51e-05	***
xV15	1.76192	1.32768	1.327	0.188621	
xV16	-0.58765	1.42864	-0.411	0.682032	
xV17	-0.88239	1.30705	-0.675	0.501748	
xV18	-0.02612	1.20782	-0.022	0.982805	
xV19	-0.14144	1.18156	-0.120	0.905045	
xV20	-0.10432	1.18051	-0.088	0.929825	
xV21	NA	NA	NA	NA	
xV22	33.70975	2.59062	13.012	< 2e-16	***
xV23	25.33271	1.90691	13.285	< 2e-16	***
xV24	14.63664	1.88005	7.785	3.56e-11	***
xV25	6.00743	1.51942	3.954	0.000176	***
xV26	0.73821	2.64144	0.279	0.780671	
xV27	3.78916	1.85597	2.042	0.044805	*
xV28	13.39949	1.87646	7.141	5.71e-10	***
xV29	24.64543	1.54735	15.928	< 2e-16	***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 2.000,-					
Coefficients: (2 not defined because of singularities)					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.002768	0.007332	0.377	0.7069	
xV6	-2.090819	18.321089	-0.114	0.9095	
xV7	0.122197	1.436742	0.085	0.9325	
xV8	0.017234	0.143950	0.120	0.9050	
xV9	NA	NA	NA	NA	
xV10	-0.008651	0.821191	-0.011	0.9916	
xV11	0.021641	0.816384	0.027	0.9789	
xV12	0.210707	0.812009	0.259	0.7960	
xV13	0.746944	0.808076	0.924	0.3584	
xV14	1.885492	0.815108	2.313	0.0235 *	
xV15	2.338325	0.892229	2.621	0.0107 *	
xV16	0.327659	0.960079	0.341	0.7339	
xV17	0.079184	0.878371	0.090	0.9284	
xV18	-0.086441	0.811680	-0.106	0.9155	
xV19	-0.338414	0.794036	-0.426	0.6712	
xV20	-0.270705	0.793328	-0.341	0.7339	
xV21	NA	NA	NA	NA	
xV22	26.324047	1.740956	15.120	< 2e-16 ***	
xV23	27.299075	1.281486	21.303	< 2e-16 ***	
xV24	9.017585	1.263436	7.137	5.79e-10 ***	
xV25	5.015777	1.021087	4.912	5.35e-06 ***	
xV26	-0.742440	1.775106	-0.418	0.6770	
xV27	2.241958	1.247253	1.798	0.0764 .	
xV28	12.259852	1.261027	9.722	8.35e-15 ***	
xV29	27.196130	1.039855	26.154	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 2.000					
Coefficients: (2 not defined because of singularities)					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.021948	0.002852	7.697	5.22e-11 ***	
xV6	3.607097	7.124926	0.506	0.614197	
xV7	-1.977891	0.558738	-3.540	0.000701 ***	
xV8	-0.044132	0.055981	-0.788	0.433053	
xV9	NA	NA	NA	NA	
xV10	0.700860	0.319355	2.195	0.031373 *	
xV11	-0.235808	0.317485	-0.743	0.460025	
xV12	-0.313633	0.315784	-0.993	0.323899	
xV13	-0.280674	0.314254	-0.893	0.374715	
xV14	0.018499	0.316989	0.058	0.953622	
xV15	0.568173	0.346981	1.637	0.105835	
xV16	-0.387771	0.373367	-1.039	0.302429	
xV17	-2.098598	0.341592	-6.144	3.85e-08 ***	
xV18	-1.119388	0.315656	-3.546	0.000687 ***	
xV19	-0.729153	0.308794	-2.361	0.020883 *	
xV20	-0.626644	0.308519	-2.031	0.045883 *	
xV21	NA	NA	NA	NA	
xV22	9.581093	0.677044	14.151	< 2e-16 ***	
xV23	8.294059	0.498360	16.643	< 2e-16 ***	
xV24	2.644868	0.491340	5.383	8.50e-07 ***	
xV25	0.660578	0.397093	1.664	0.100493	
xV26	-1.395679	0.690325	-2.022	0.046866 *	
xV27	1.680752	0.485047	3.465	0.000891 ***	
xV28	5.775163	0.490403	11.776	< 2e-16 ***	
xV29	8.980259	0.404391	22.207	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression* Data *Outflow* (lanjutan)

KP BI Surabaya – Rp. 1.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.06325	0.02701	2.342	0.020212 *	
xV6	24.52247	6.94968	3.529	0.000523 ***	
xV7	-5.86456	4.91464	-1.193	0.234239	
xV8	-0.32083	0.06798	-4.720	4.56e-06 ***	
xV9	-0.08085	0.03787	-2.135	0.034027 *	
xV10	6.76125	1.85754	3.640	0.000351 ***	
xV11	6.66657	1.85150	3.601	0.000405 ***	
xV12	7.29988	1.85721	3.931	0.000118 ***	
xV13	7.18556	1.86314	3.857	0.000157 ***	
xV14	6.94494	1.87491	3.704	0.000278 ***	
xV15	4.66981	1.90711	2.449	0.015242 *	
xV16	6.94281	1.93288	3.592	0.000417 ***	
xV17	7.97041	1.93759	4.114	5.79e-05 ***	
xV18	9.03162	1.93822	4.660	5.93e-06 ***	
xV19	13.42694	1.94761	6.894	7.69e-11 ***	
xV20	9.90603	1.96240	5.048	1.04e-06 ***	
xV21	8.62150	1.94133	4.441	1.51e-05 ***	
xV22	19.05234	3.08039	6.185	3.69e-09 ***	
xV23	10.66414	3.08912	3.452	0.000685 ***	
xV24	8.32147	3.08087	2.701	0.007534 **	
xV25	3.68990	2.52058	1.464	0.144863	
xV26	-2.44822	3.07986	-0.795	0.427651	
xV27	9.00088	2.76015	3.261	0.001315 **	
xV28	10.95598	3.07887	3.558	0.000471 ***	
xV29	23.15458	2.52324	9.177	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Malang – Rp. 1.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.009250	0.003524	2.625	0.009377 **	
xV6	3.364622	0.906910	3.710	0.000272 ***	
xV7	0.381591	0.641344	0.595	0.552557	
xV8	-0.040485	0.008871	-4.564	8.97e-06 ***	
xV9	-0.015803	0.004941	-3.198	0.001620 **	
xV10	0.409063	0.242402	1.688	0.093132 .	
xV11	0.486566	0.241615	2.014	0.045433 *	
xV12	0.589071	0.242360	2.431	0.016000 *	
xV13	0.694678	0.243133	2.857	0.004748 **	
xV14	0.630867	0.244669	2.578	0.010677 *	
xV15	0.267029	0.248871	1.073	0.284642	
xV16	0.452017	0.252234	1.792	0.074707 .	
xV17	1.079764	0.252849	4.270	3.07e-05 ***	
xV18	1.221406	0.252931	4.829	2.81e-06 ***	
xV19	1.256509	0.254156	4.944	1.67e-06 ***	
xV20	0.986472	0.256087	3.852	0.000160 ***	
xV21	0.586062	0.253337	2.313	0.021767 *	
xV22	4.419959	0.401981	10.995	< 2e-16 ***	
xV23	3.378034	0.403120	8.380	1.13e-14 ***	
xV24	0.316495	0.402043	0.787	0.432130	
xV25	0.845287	0.328927	2.570	0.010937 *	
xV26	-0.211429	0.401912	-0.526	0.599458	
xV27	1.410274	0.360191	3.915	0.000126 ***	
xV28	1.256887	0.401782	3.128	0.002034 **	
xV29	3.438866	0.329274	10.444	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 32. Output Pemodelan *Time Series Regression Data Outflow* (lanjutan)

KP BI Kediri – Rp. 1.000,-					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.009971	0.004190	2.380	0.018311 *	
xV6	3.534899	1.078158	3.279	0.001239 **	
xV7	1.154677	0.762446	1.514	0.131568	
xV8	-0.044020	0.010546	-4.174	4.54e-05 ***	
xV9	-0.021937	0.005874	-3.734	0.000248 ***	
xV10	0.536480	0.288174	1.862	0.064188 .	
xV11	0.633459	0.287238	2.205	0.028623 *	
xV12	0.692446	0.288124	2.403	0.017205 *	
xV13	0.820023	0.289043	2.837	0.005045 **	
xV14	0.863631	0.290869	2.969	0.003369 **	
xV15	0.468224	0.295864	1.583	0.115175	
xV16	0.599327	0.299863	1.999	0.047062 *	
xV17	1.463632	0.300593	4.869	2.34e-06 ***	
xV18	1.402218	0.300691	4.663	5.83e-06 ***	
xV19	1.539718	0.302147	5.096	8.31e-07 ***	
xV20	1.499075	0.304443	4.924	1.83e-06 ***	
xV21	0.715163	0.301174	2.375	0.018560 *	
xV22	5.127277	0.477886	10.729	< 2e-16 ***	
xV23	2.584385	0.479239	5.393	2.04e-07 ***	
xV24	1.364978	0.477959	2.856	0.004767 **	
xV25	0.620166	0.391037	1.586	0.114404	
xV26	-0.306506	0.477803	-0.641	0.521973	
xV27	1.336852	0.428204	3.122	0.002075 **	
xV28	2.312826	0.477649	4.842	2.65e-06 ***	
xV29	4.822301	0.391449	12.319	< 2e-16 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					
KP BI Jember – Rp. 1.000					
Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
xV5	0.010333	0.001467	7.045	3.28e-11 ***	
xV6	3.403408	0.377438	9.017	< 2e-16 ***	
xV7	0.121876	0.266915	0.457	0.648469	
xV8	-0.040434	0.003692	-10.952	< 2e-16 ***	
xV9	-0.013663	0.002056	-6.644	3.10e-10 ***	
xV10	0.620836	0.100883	6.154	4.35e-09 ***	
xV11	0.548541	0.100555	5.455	1.50e-07 ***	
xV12	0.546199	0.100866	5.415	1.83e-07 ***	
xV13	0.525957	0.101187	5.198	5.16e-07 ***	
xV14	0.541599	0.101826	5.319	2.90e-07 ***	
xV15	0.538448	0.103575	5.199	5.14e-07 ***	
xV16	0.595848	0.104975	5.676	5.06e-08 ***	
xV17	0.659880	0.105231	6.271	2.34e-09 ***	
xV18	0.677491	0.105265	6.436	9.65e-10 ***	
xV19	0.737280	0.105775	6.970	5.00e-11 ***	
xV20	0.589619	0.106578	5.532	1.03e-07 ***	
xV21	0.479683	0.105434	4.550	9.54e-06 ***	
xV22	0.975843	0.167297	5.833	2.29e-08 ***	
xV23	0.273070	0.167770	1.628	0.105249	
xV24	0.121478	0.167322	0.726	0.468721	
xV25	0.008489	0.136893	0.062	0.950618	
xV26	-0.138259	0.167268	-0.827	0.409509	
xV27	0.368497	0.149904	2.458	0.014854 *	
xV28	0.603379	0.167214	3.608	0.000393 ***	
xV29	1.026679	0.137037	7.492	2.45e-12 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Lampiran 33. Output Hasil Pengujian Asumsi *White Noise* Pada Residual Model TSR Data *Inflow*

Total Semua Pecahan	Pecahan Rp. 50.000,-	Pecahan Rp. 10.000,-
> LB.TSR1 statistics p.value 6 5.731277 0.4539557270 12 37.149809 0.0002112468 18 40.892125 0.0015754146 24 48.061354 0.0024803467 30 62.464349 0.0004585070	> LB.TSR1 statistics p.value 6 36.60617 2.101162e-06 12 53.64789 3.158107e-07 18 56.57515 7.228401e-06 24 75.54482 3.068158e-07 30 119.67171 1.157963e-12	> LB.TSR1 statistics p.value 6 45.16627 4.337332e-08 12 131.86792 0.000000e+00 18 157.13045 0.000000e+00 24 213.08079 0.000000e+00 30 250.59135 0.000000e+00
> LB.TSR2 statistics p.value 6 10.34787 1.107463e-01 12 52.59878 4.854549e-07 18 56.18501 8.332485e-06 24 62.34720 2.956596e-05 30 73.76284 1.495030e-05	> LB.TSR2 statistics p.value 6 27.70820 1.066270e-04 12 60.79473 1.616435e-08 18 62.61817 7.671635e-07 24 68.51654 3.659621e-06 30 84.45202 4.438422e-07	> LB.TSR2 statistics p.value 6 22.93264 8.193545e-04 12 86.48231 2.360334e-13 18 106.98159 1.143530e-14 24 148.82129 0.000000e+00 30 167.63137 0.000000e+00
> LB.TSR3 statistics p.value 6 8.983191 1.745256e-01 12 36.917561 2.303867e-04 18 52.165866 3.528248e-05 24 61.305147 4.169614e-05 30 67.851323 9.360156e-05	> LB.TSR3 statistics p.value 6 15.19356 0.018803522 12 24.29631 0.018532945 18 32.84835 0.017409505 24 40.11771 0.020772626 30 51.04355 0.009637913	> LB.TSR3 statistics p.value 6 33.92984 6.940537e-06 12 106.20597 0.000000e+00 18 129.38384 0.000000e+00 24 166.37109 0.000000e+00 30 180.42454 0.000000e+00
> LB.TSR4 statistics p.value 6 18.58484 4.925359e-03 12 47.87971 3.279977e-06 18 61.98315 9.744233e-07 24 71.24273 1.415297e-06 30 80.55279 1.644716e-06	> LB.TSR4 statistics p.value 6 18.78704 0.004538819 12 29.27744 0.003582796 18 32.28449 0.020341506 24 36.89132 0.044864547 30 48.77176 0.016580173	> LB.TSR4 statistics p.value 6 34.19686 6.163427e-06 12 84.42499 5.869749e-13 18 102.94725 6.372680e-14 24 151.84937 0.000000e+00 30 159.99085 0.000000e+00
Pecahan Rp. 100.000,-	Pecahan Rp. 20.000,-	Pecahan Rp. 5.000,-
> LB.TSR1 statistics p.value 6 12.85148 4.545607e-02 12 53.21845 3.766629e-07 18 60.58524 1.645113e-06 24 70.00106 2.185691e-06 30 80.84429 1.492801e-06	> LB.TSR1 statistics p.value 6 67.6255 1.253442e-12 12 119.9457 0.000000e+00 18 129.8556 0.000000e+00 24 144.8389 0.000000e+00 30 205.6691 0.000000e+00	> LB.TSR1 statistics p.value 6 78.90633 5.995204e-15 12 227.82884 0.000000e+00 18 273.20433 0.000000e+00 24 386.61207 0.000000e+00 30 426.39831 0.000000e+00
> LB.TSR2 statistics p.value 6 12.94251 4.395796e-02 12 63.37707 5.431872e-09 18 68.51972 8.031655e-08 24 79.31457 7.820678e-08 30 88.71165 1.028275e-07	> LB.TSR2 statistics p.value 6 8.44696 2.071515e-01 12 51.83682 6.626338e-07 18 58.25871 3.899074e-06 24 74.95151 3.796058e-07 30 92.71696 2.529197e-08	> LB.TSR2 statistics p.value 6 25.65875 0.000257699 12 117.76260 0.000000000 18 138.70333 0.000000000 24 207.10337 0.000000000 30 224.44994 0.000000000
> LB.TSR3 statistics p.value 6 18.18991 5.774725e-03 12 47.72761 3.485894e-06 18 60.07993 1.986107e-06 24 71.60149 1.247565e-06 30 76.72723 5.773935e-06	> LB.TSR3 statistics p.value 6 31.17683 2.345273e-05 12 75.64431 2.775191e-11 18 92.76182 4.594325e-12 24 106.26121 2.520650e-12 30 120.53226 8.307799e-13	> LB.TSR3 statistics p.value 6 81.9849 1.44329e-15 12 195.2034 0.00000e+00 18 237.0831 0.00000e+00 24 307.7738 0.00000e+00 30 324.9699 0.00000e+00
> LB.TSR4 statistics p.value 6 22.24774 1.091848e-03 12 56.93642 8.115891e-08 18 75.98255 4.282293e-09 24 91.93175 6.887616e-10 30 106.10426 1.970238e-10	> LB.TSR4 statistics p.value 6 23.41419 6.689868e-04 12 59.92943 2.325203e-08 18 63.14238 6.293684e-07 24 75.22637 3.439818e-07 30 96.51584 6.537787e-09	> LB.TSR4 statistics p.value 6 53.9254 7.637163e-10 12 167.0295 0.00000e+00 18 193.8427 0.00000e+00 24 247.1259 0.00000e+00 30 258.1336 0.00000e+00

Lampiran 33. Output Hasil Pengujian Asumsi *White Noise* Pada Residual Model TSR Data *Inflow* (lanjutan)

Pecahan Rp. 2.000,-	Pecahan Rp. 1.000,-
> LB.TSR1	> LB.TSR1
statistics p.value	statistics p.value
6 25.98390 0.0002241857	6 103.0954 0
12 33.88639 0.0007029318	12 145.7745 0
18 40.23657 0.0019378351	18 165.7987 0
24 53.30359 0.0005274403	24 191.1067 0
30 59.64807 0.0010153910	30 274.8854 0
> LB.TSR2	> LB.TSR2
statistics p.value	statistics p.value
6 8.795437 0.1854136	6 84.38905 4.440892e-16
12 19.360167 0.0801994	12 198.42096 0.000000e+00
18 22.951430 0.1924635	18 252.75574 0.000000e+00
24 27.492266 0.2820355	24 288.07640 0.000000e+00
30 32.065679 0.3644791	30 377.59656 0.000000e+00
> LB.TSR3	> LB.TSR3
statistics p.value	statistics p.value
6 14.34592 0.0260018854	6 70.64023 3.022027e-13
12 34.09775 0.0006510090	12 182.61064 0.000000e+00
18 43.50460 0.0006787394	18 225.44814 0.000000e+00
24 49.98466 0.0014223490	24 281.81630 0.000000e+00
30 53.80342 0.0048348511	30 332.18914 0.000000e+00
> LB.TSR4	> LB.TSR4
statistics p.value	statistics p.value
6 9.941945 0.127118216	6 68.72818 7.452927e-13
12 30.639297 0.002235341	12 187.36005 0.000000e+00
18 33.558473 0.014272458	18 240.86647 0.000000e+00
24 36.378018 0.050419817	24 299.49994 0.000000e+00
30 38.954984 0.126740375	30 371.74245 0.000000e+00

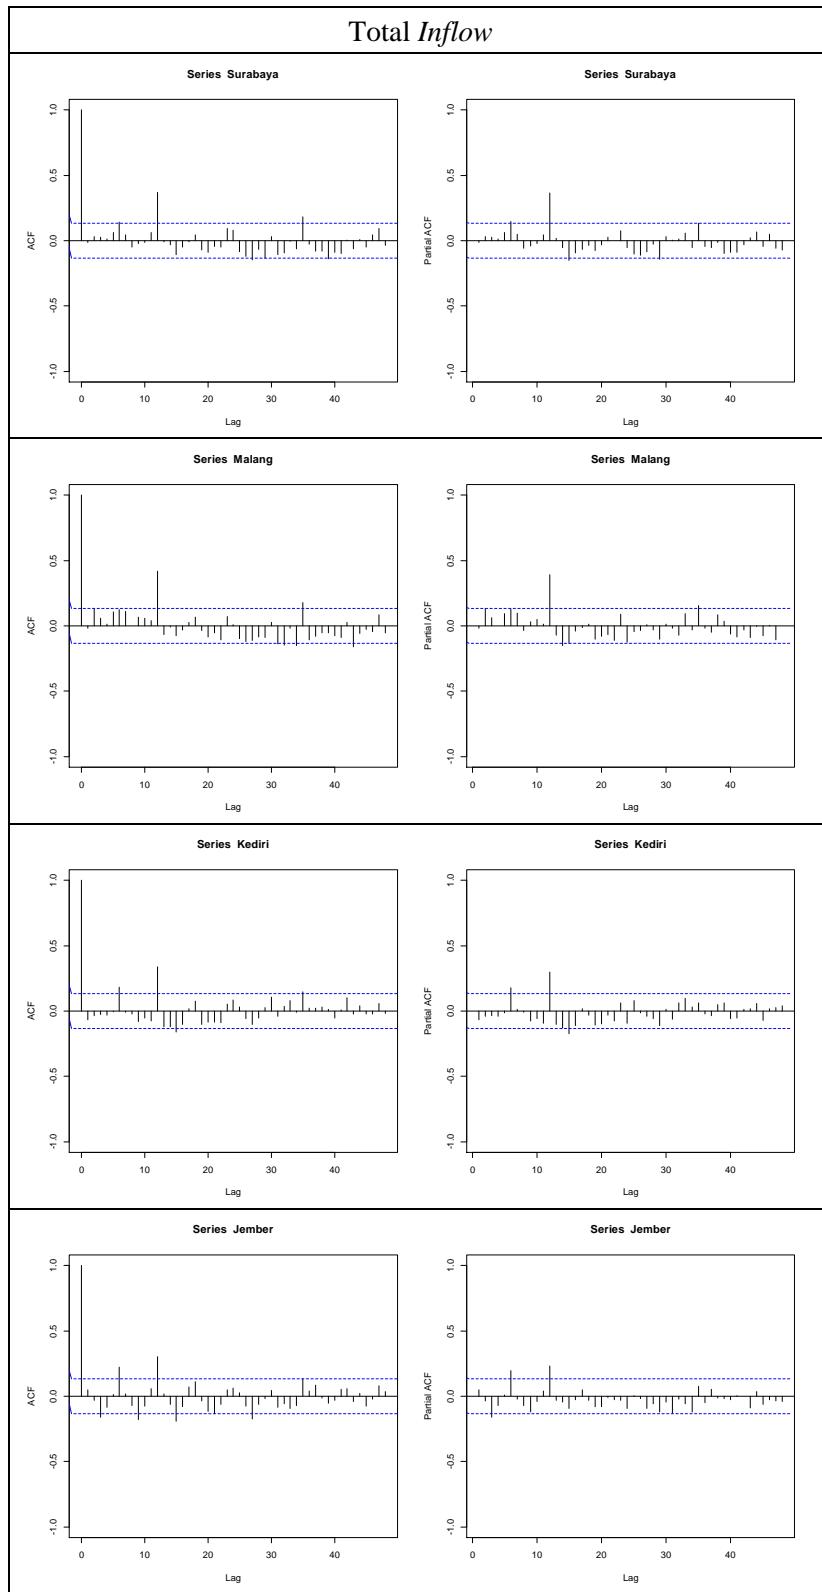
Lampiran 34. Output Hasil Pengujian Asumsi *White Noise* Pada Residual Model TSR Data *Outflow*

Total Semua Pecahan	Pecahan Rp. 50.000,-	Pecahan Rp. 10.000,-
> LB.TSR1 statistics p.value 6 16.94472 9.488563e-03 12 55.21291 1.657599e-07 18 73.94838 9.595491e-09 24 111.31785 3.317346e-13 30 117.07625 3.138823e-12	> LB.TSR1 statistics p.value 6 11.39634 0.076872742 12 17.25656 0.140198423 18 22.30520 0.218716467 24 44.76210 0.006213960 30 51.56062 0.008490553	> LB.TSR1 statistics p.value 6 17.44871 7.768224e-03 12 77.06978 1.489875e-11 18 87.67953 3.758627e-11 24 118.39729 1.865175e-14 30 124.51547 1.770806e-13
> LB.TSR2 statistics p.value 6 23.39777 6.736366e-04 12 70.17326 2.972613e-10 18 85.33521 9.827328e-11 24 115.26452 6.705747e-14 30 121.83268 5.023759e-13	> LB.TSR2 statistics p.value 6 12.49050 5.187927e-02 12 37.99027 1.541239e-04 18 44.69908 4.579582e-04 24 61.38411 4.062794e-05 30 63.74923 3.163369e-04	> LB.TSR2 statistics p.value 6 12.43008 5.303383e-02 12 57.11550 7.53361e-08 18 63.04824 6.521721e-07 24 74.73138 4.107388e-07 30 78.80515 2.930033e-06
> LB.TSR3 statistics p.value 6 23.79346 5.699640e-04 12 66.78333 1.273945e-09 18 79.72894 9.557742e-10 24 105.86829 2.948086e-12 30 113.55509 1.201506e-11	> LB.TSR3 statistics p.value 6 13.33169 3.806089e-02 12 34.41819 5.793298e-04 18 44.03637 5.700368e-04 24 65.60716 9.911149e-06 30 74.81112 1.070351e-05	> LB.TSR3 statistics p.value 6 12.59642 4.991183e-02 12 72.70814 9.949604e-11 18 81.29533 5.079996e-10 24 100.16867 2.811773e-11 30 103.38115 5.390309e-10
> LB.TSR4 statistics p.value 6 7.16671 3.057048e-01 12 44.11682 1.458738e-05 18 58.91160 3.063957e-06 24 87.33653 3.959943e-09 30 100.75752 1.409207e-09	> LB.TSR4 statistics p.value 6 18.26736 0.0055976611 12 26.20484 0.0100397413 18 34.46912 0.0110160081 24 49.38712 0.0016932029 30 63.17823 0.0003733015	> LB.TSR4 statistics p.value 6 6.149332 4.066716e-01 12 44.376196 1.317441e-05 18 50.275324 6.857603e-05 24 74.523479 4.424482e-07 30 85.420824 3.191442e-07
Pecahan Rp. 100.000,-	Pecahan Rp. 20.000,-	Pecahan Rp. 5.000,-
> LB.TSR1 statistics p.value 6 17.23751 8.448880e-03 12 50.81983 1.002202e-06 18 75.59209 5.001714e-09 24 106.52761 2.266520e-12 30 114.56012 8.201329e-12	> LB.TSR1 statistics p.value 6 12.18380 5.799188e-02 12 81.40247 2.227662e-12 18 94.28283 2.438272e-12 24 116.20619 4.574119e-14 30 122.30826 4.177769e-13	> LB.TSR1 statistics p.value 6 11.52327 7.348915e-02 12 86.61860 2.221556e-13 18 103.11179 5.939693e-14 24 152.52216 0.000000e+00 30 160.81031 0.000000e+00
> LB.TSR2 statistics p.value 6 25.09538 3.278438e-04 12 73.74619 6.336887e-11 18 90.66490 1.096745e-11 24 116.98389 3.330669e-14 30 126.18764 9.214851e-14	> LB.TSR2 statistics p.value 6 11.20843 8.214448e-02 12 50.51984 1.131903e-06 18 56.77984 6.708018e-06 24 63.64940 1.916604e-05 30 65.54796 1.865696e-04	> LB.TSR2 statistics p.value 6 15.71807 1.534992e-02 12 71.97207 1.367149e-10 18 90.03778 1.421596e-11 24 116.33864 4.329870e-14 30 120.31725 9.027223e-13
> LB.TSR3 statistics p.value 6 21.32920 1.600714e-03 12 59.59918 2.670643e-08 18 71.65599 2.365884e-08 24 89.92823 1.481530e-09 30 98.55535 3.135466e-09	> LB.TSR3 statistics p.value 6 6.236804 3.971928e-01 12 43.045293 2.218451e-05 18 49.916659 7.770407e-05 24 60.344648 5.709779e-05 30 62.030359 5.191414e-04	> LB.TSR3 statistics p.value 6 13.53992 3.521971e-02 12 72.41459 1.128846e-10 18 86.44233 6.246170e-11 24 134.77555 0.000000e+00 30 140.03650 3.330669e-16
> LB.TSR4 statistics p.value 6 7.79782 2.532930e-01 12 45.76682 7.610225e-06 18 55.43872 1.092540e-05 24 78.53673 1.038922e-07 30 96.72188 6.071628e-09	> LB.TSR4 statistics p.value 6 84.61297 4.440892e-16 12 88.83379 8.304468e-14 18 94.68042 2.065459e-12 24 99.85167 3.184486e-11 30 130.30158 1.831868e-14	> LB.TSR4 statistics p.value 6 5.216262 5.163902e-01 12 41.443672 4.129993e-05 18 54.770833 1.390785e-05 24 88.823038 2.255576e-09 30 95.339306 9.962656e-09

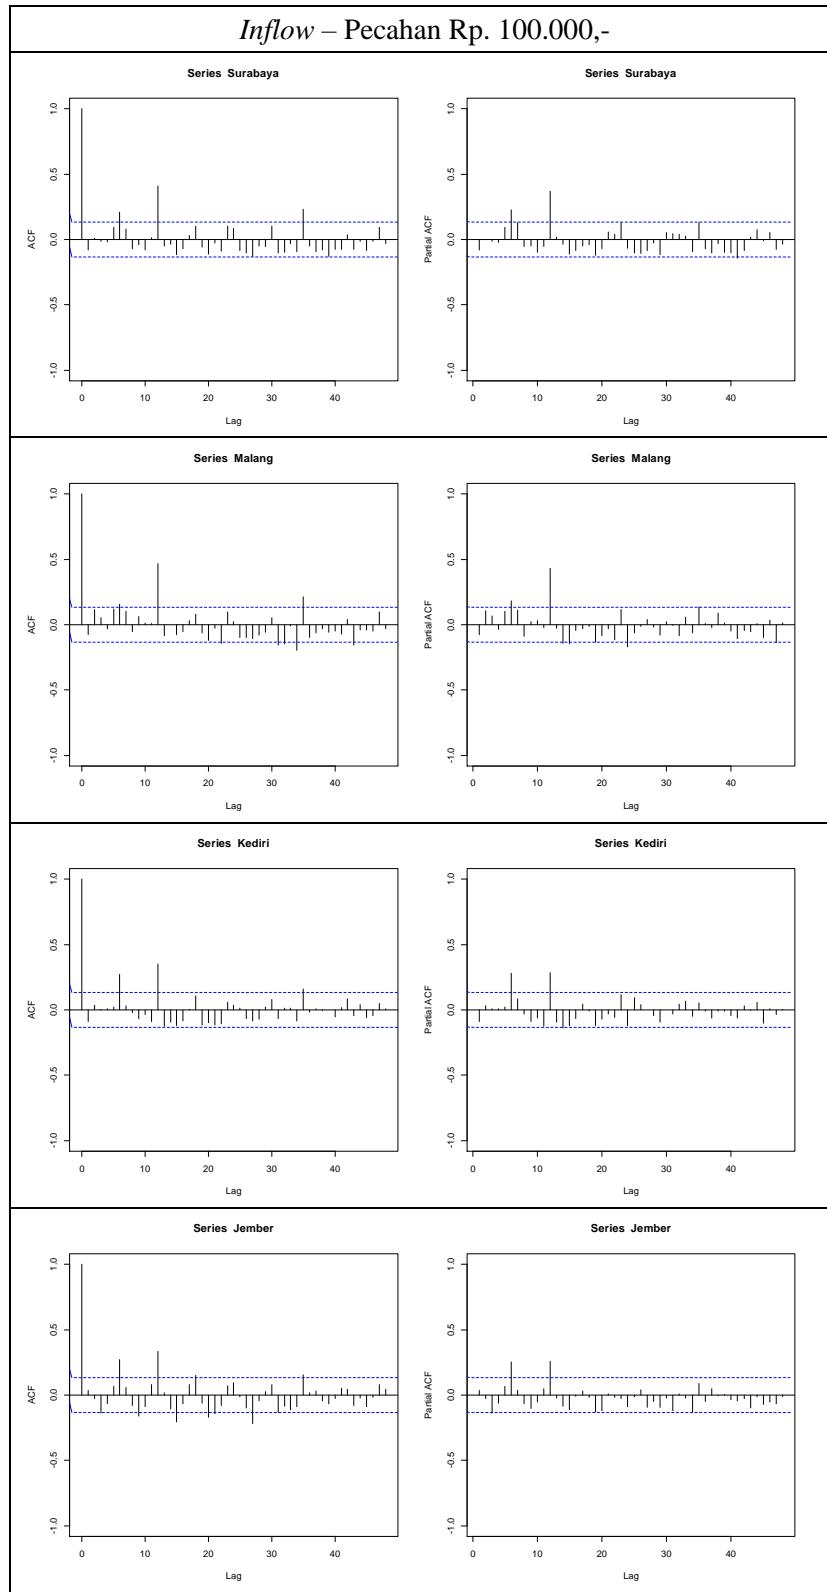
Lampiran 34. Output Hasil Pengujian Asumsi *White Noise* Pada Residual Model TSR Data *Outflow* (lanjutan)

Pecahan Rp. 2.000,-	Pecahan Rp. 1.000,-
> LB.TSR1	> LB.TSR1
statistics p.value	statistics p.value
6 7.515265 0.27580860	6 8.88979 0.179871718
12 14.626570 0.26249602	12 28.96666 0.003985143
18 15.678764 0.61495529	18 32.88765 0.017220450
24 39.653891 0.02328977	24 39.75174 0.022736751
30 40.633783 0.09316104	30 51.74862 0.008105786
> LB.TSR2	> LB.TSR2
statistics p.value	statistics p.value
6 2.093000 0.9109497	6 13.81073 3.182334e-02
12 7.099148 0.8509924	12 46.95861 4.739224e-06
18 8.626042 0.9677866	18 57.84104 4.546955e-06
24 9.751580 0.9954970	24 63.47735 2.030072e-05
30 9.953061 0.9997846	30 71.16466 3.384339e-05
> LB.TSR3	> LB.TSR3
statistics p.value	statistics p.value
6 0.7721594 0.9927995	6 27.58488 1.124735e-04
12 7.1302407 0.8488880	12 79.21021 5.837220e-12
18 8.0682065 0.9776039	18 97.88970 5.385692e-13
24 15.1491219 0.9163193	24 110.35848 4.881651e-13
30 15.4757264 0.9867607	30 118.72035 1.670108e-12
> LB.TSR4	> LB.TSR4
statistics p.value	statistics p.value
6 1.488024 0.9602861	6 52.01206 1.854434e-09
12 5.316996 0.9465446	12 60.75898 1.640935e-08
18 11.019819 0.8935138	18 96.73567 8.740786e-13
24 15.794723 0.8953425	24 103.00017 9.207524e-12
30 24.663837 0.7411983	30 112.83815 1.576705e-11

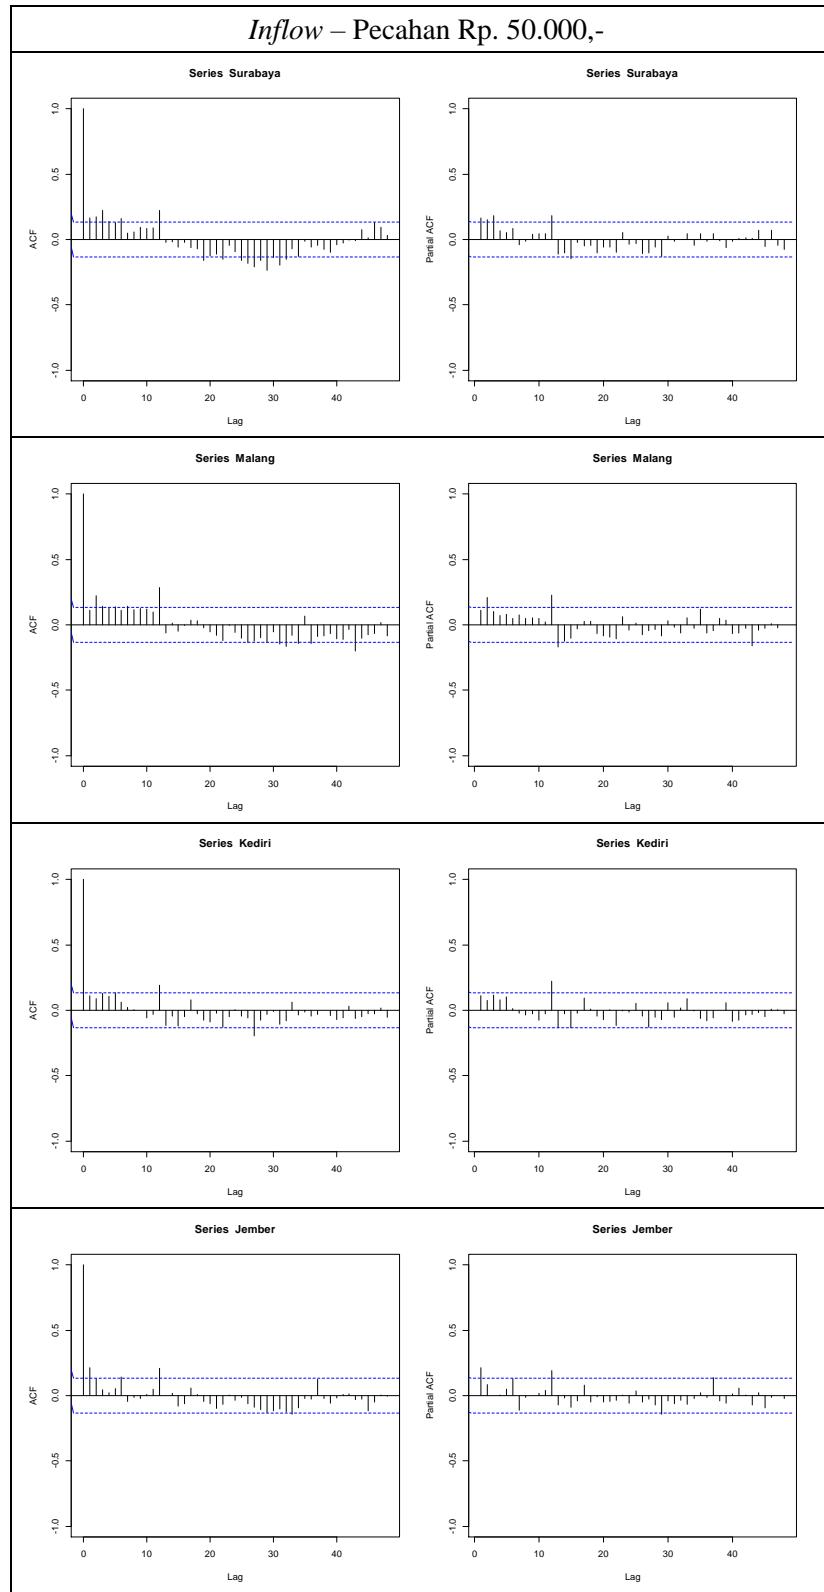
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX



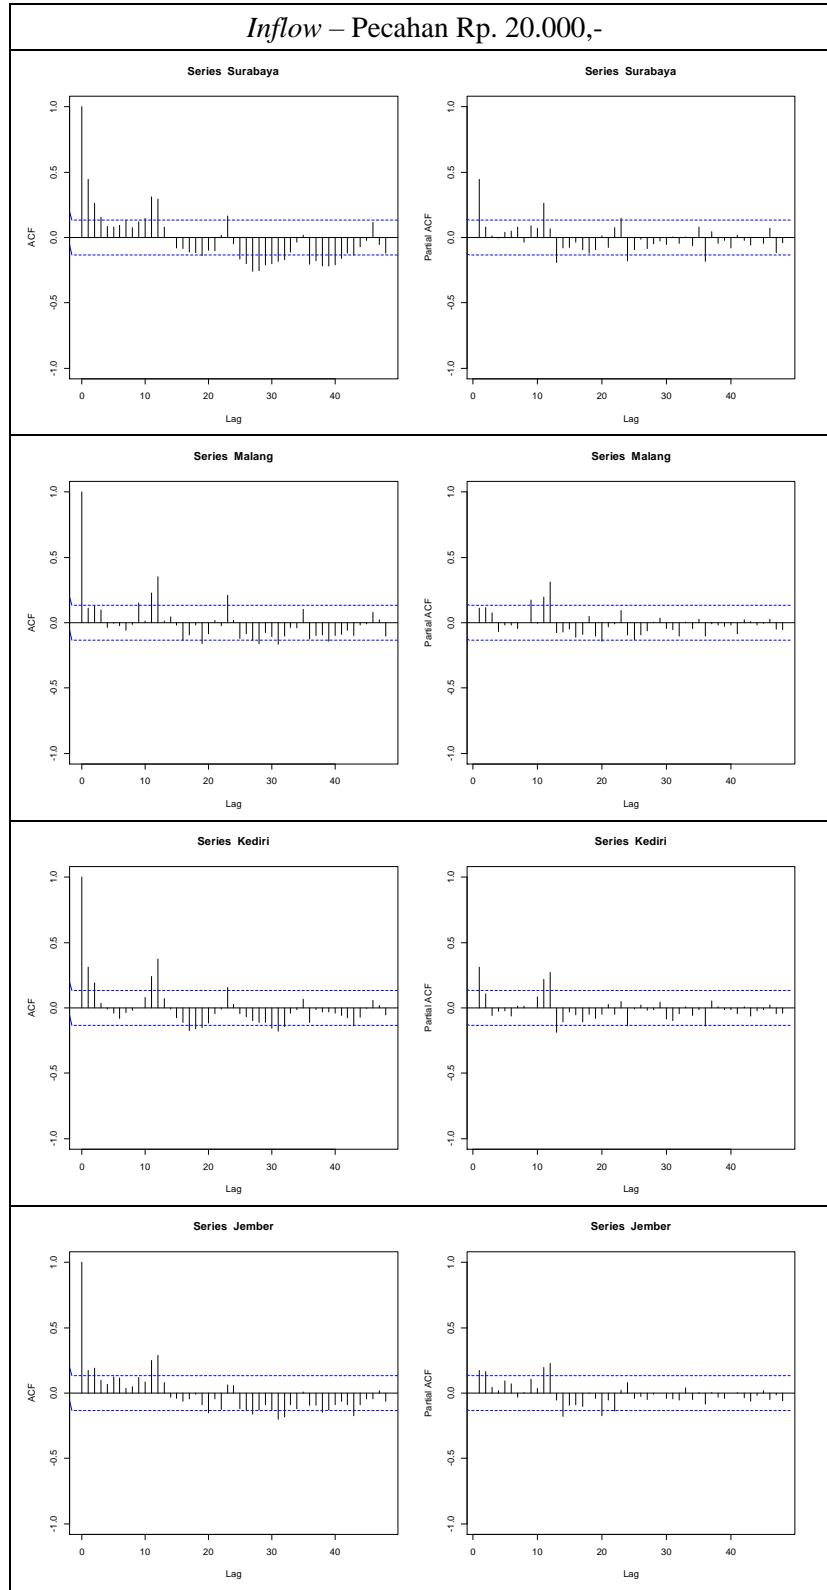
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



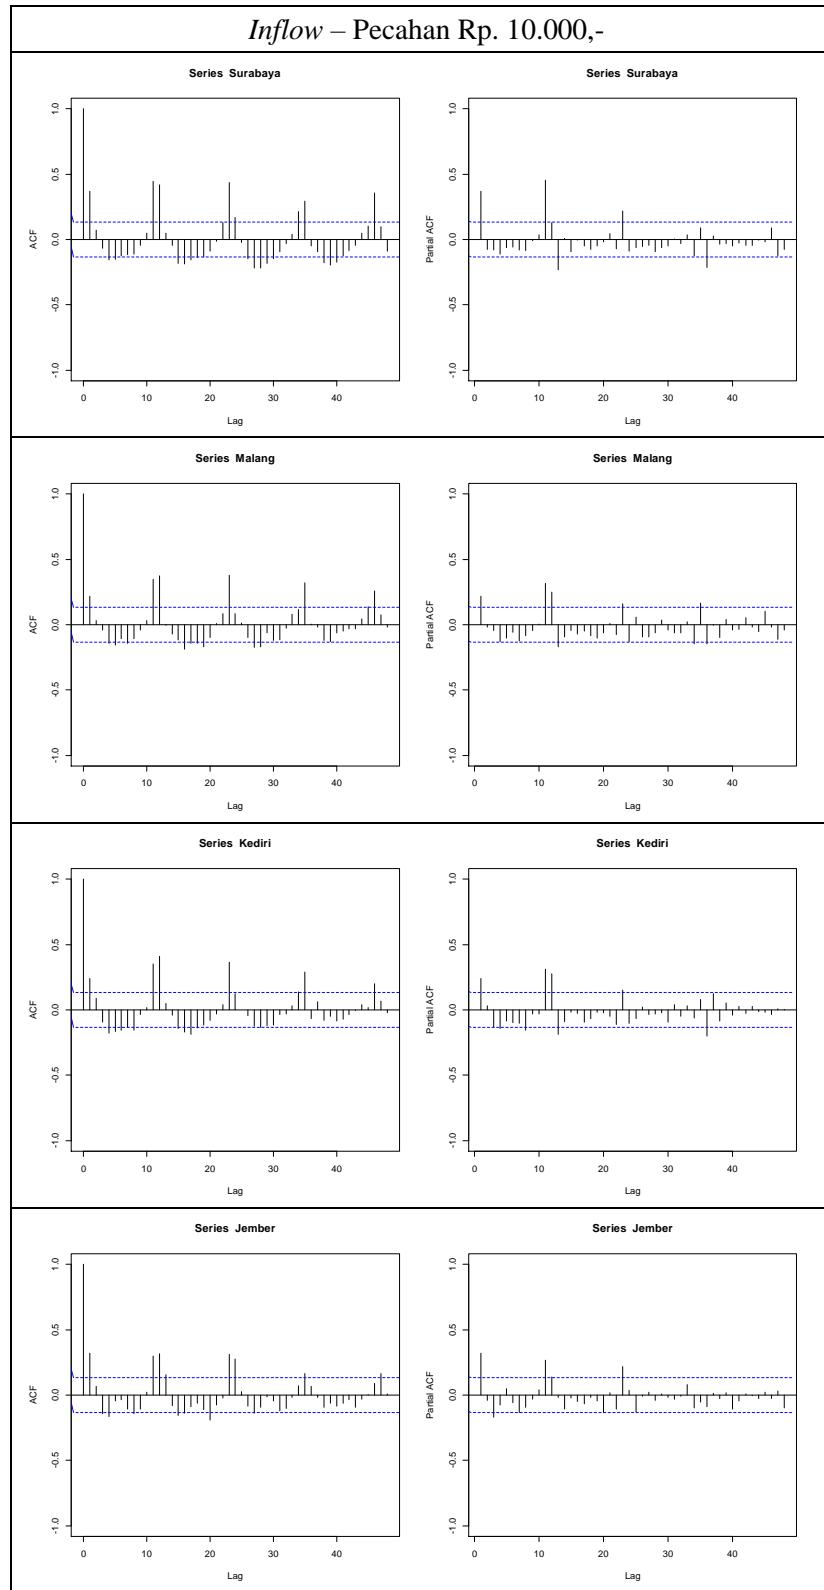
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



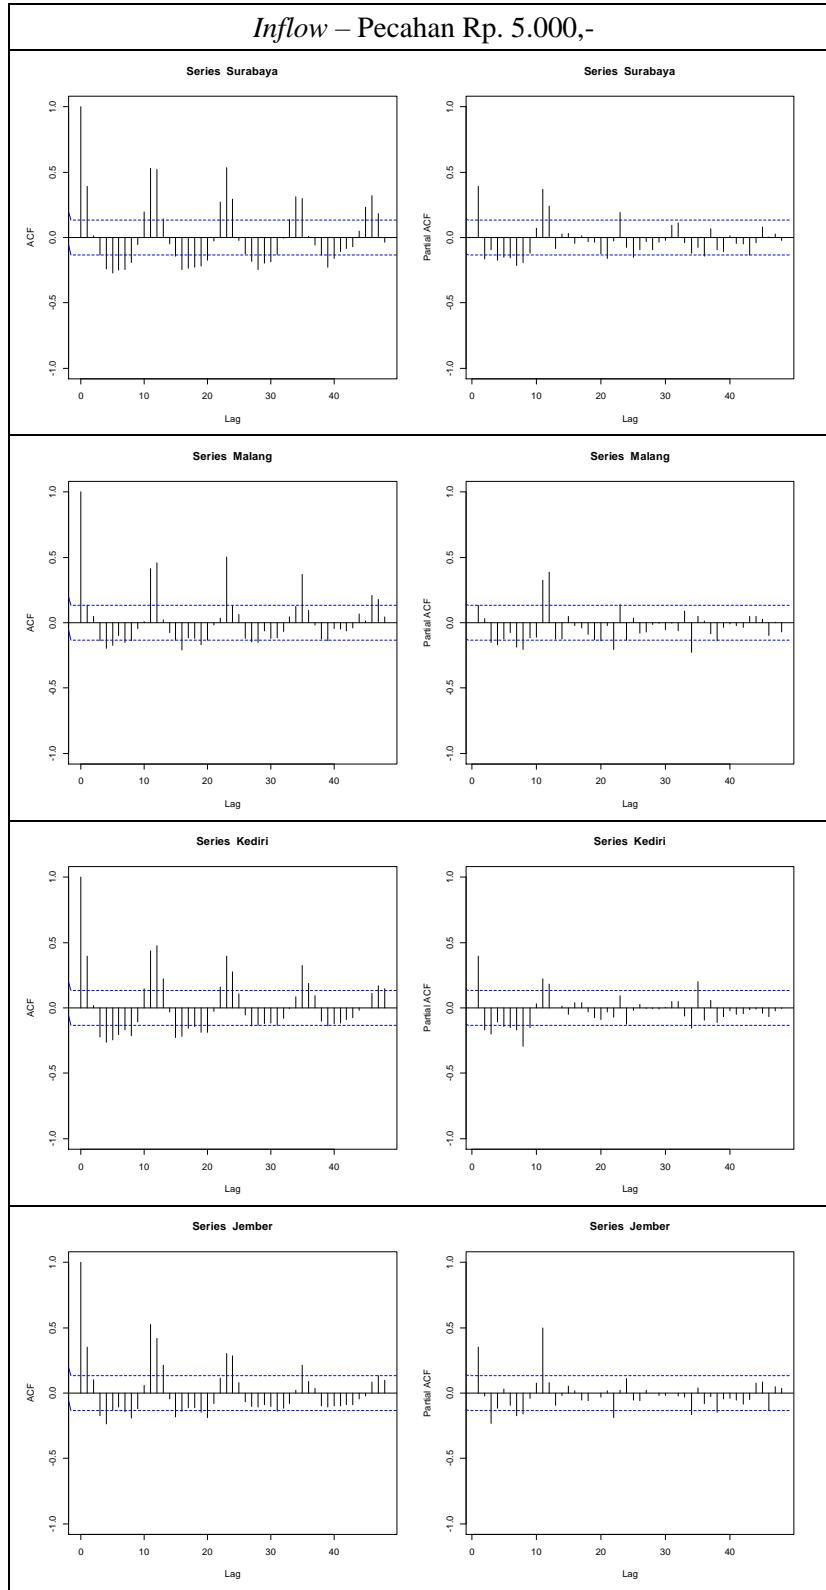
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



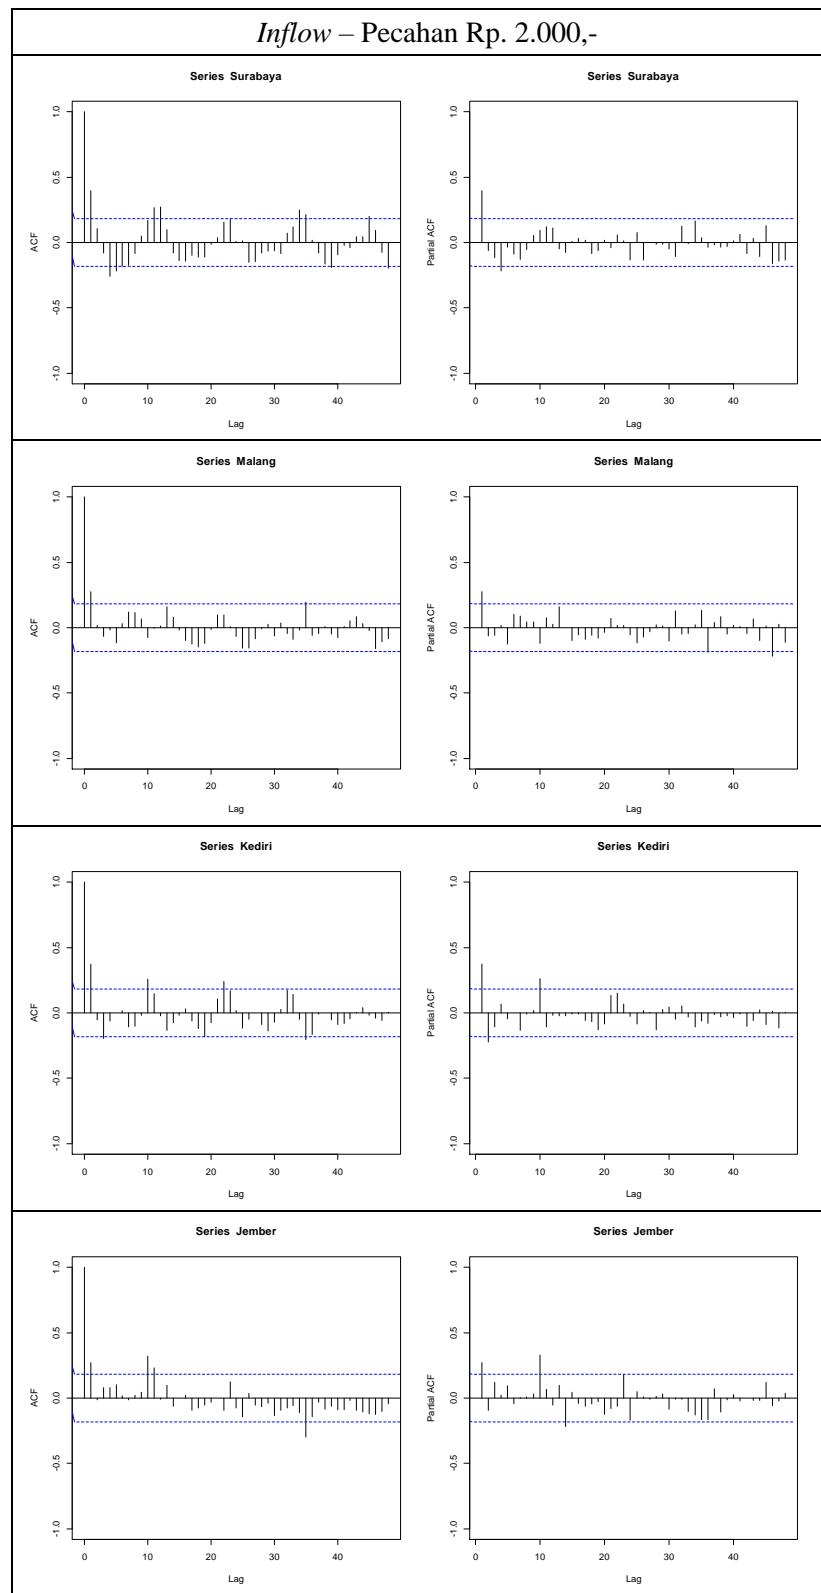
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



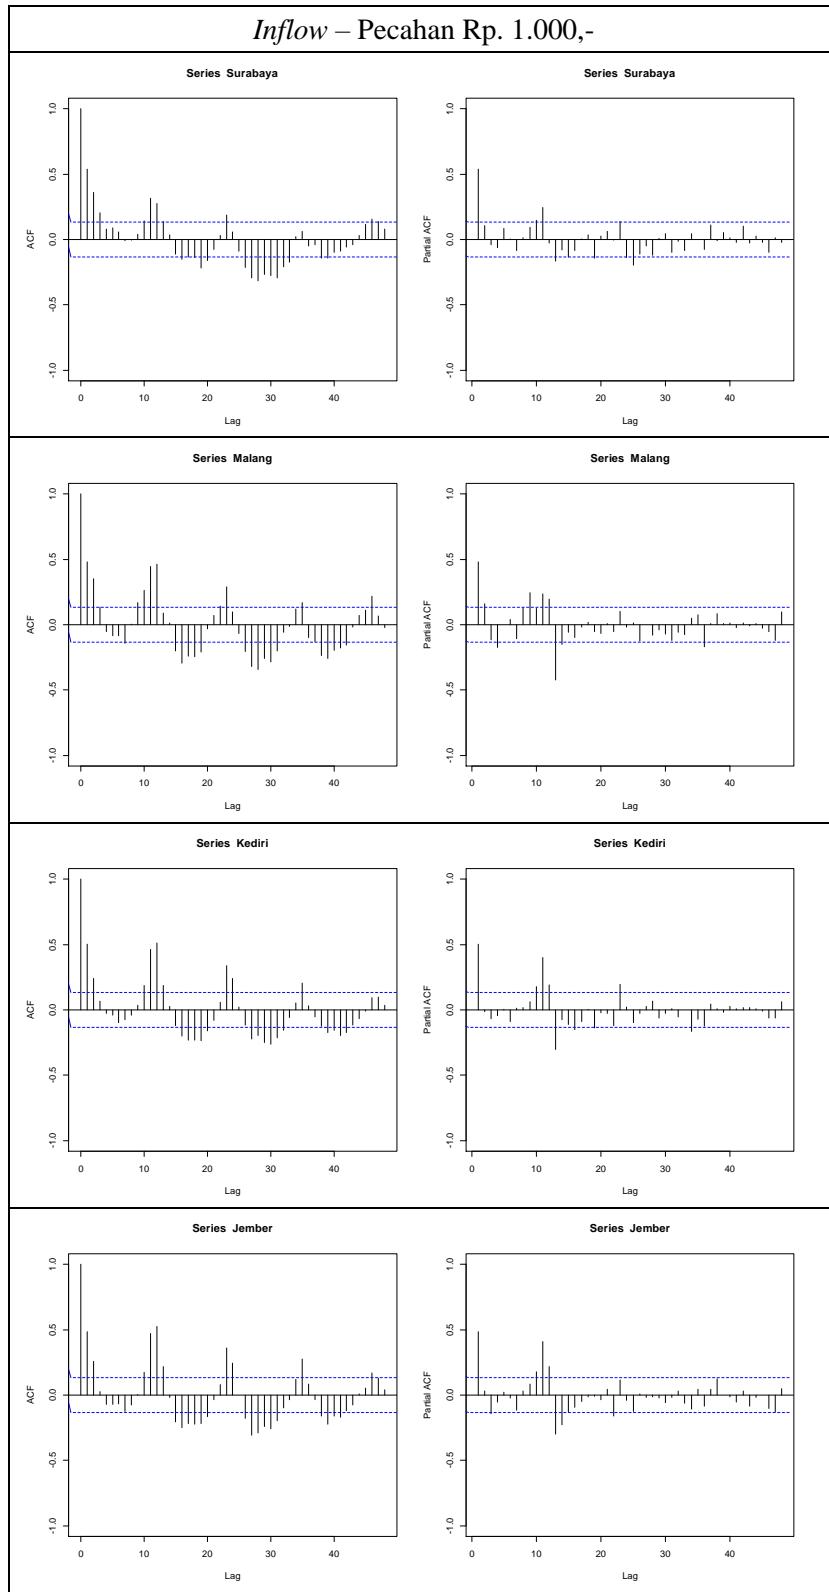
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



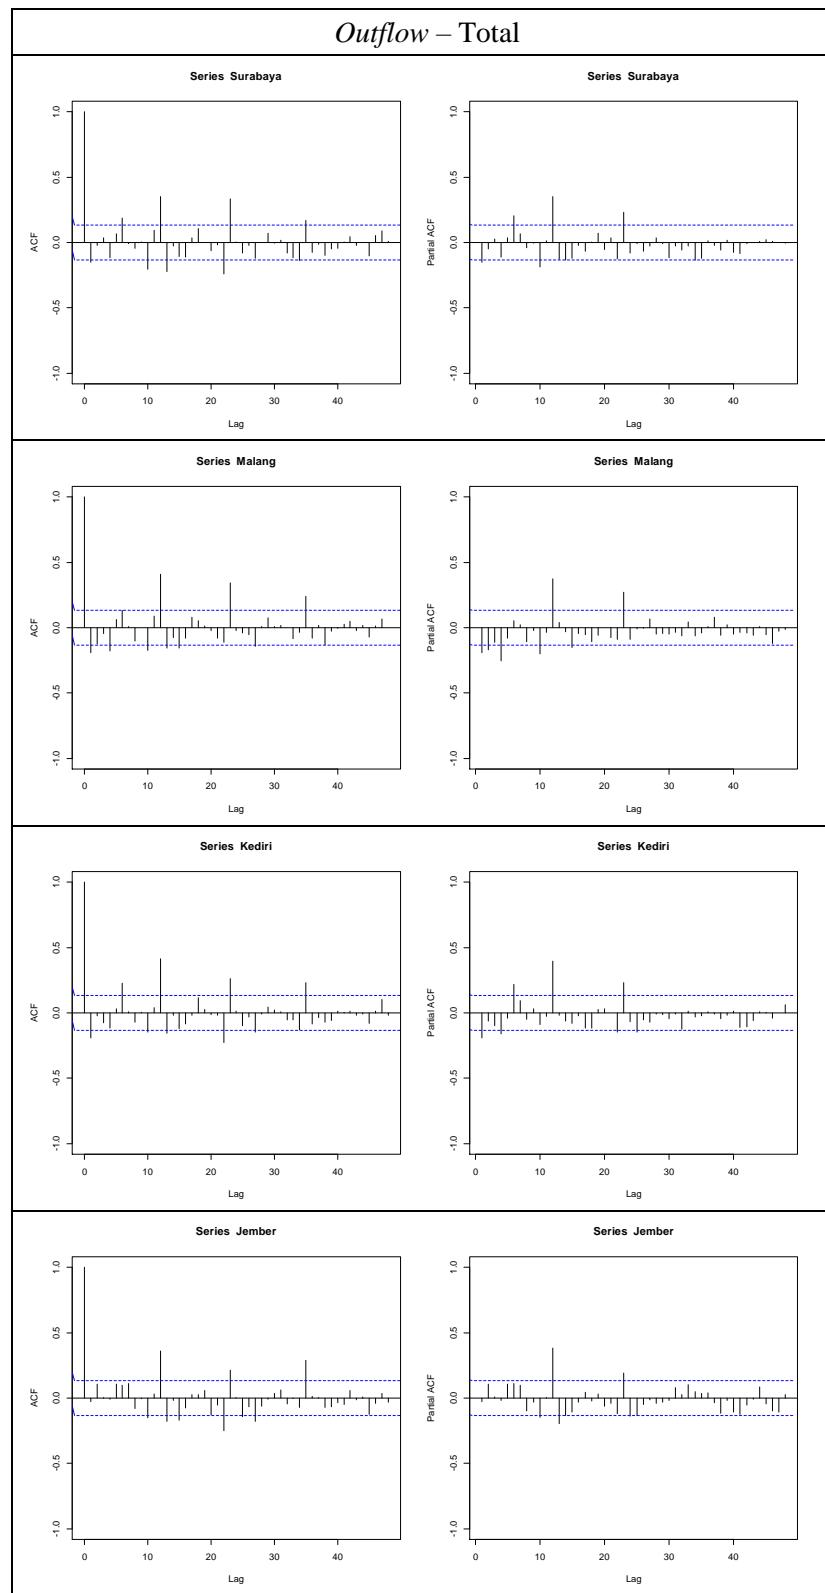
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



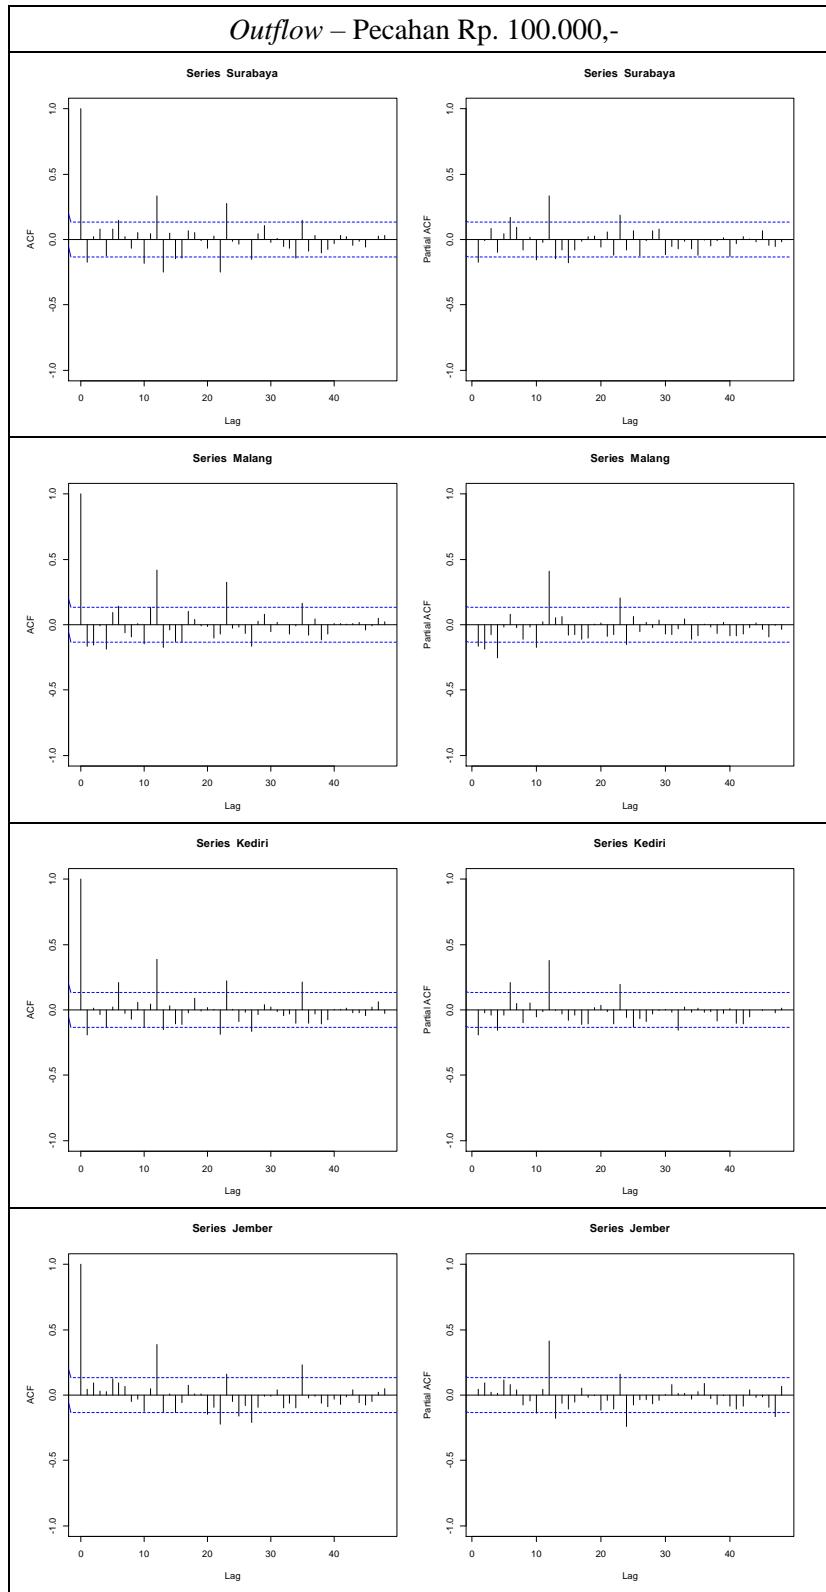
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



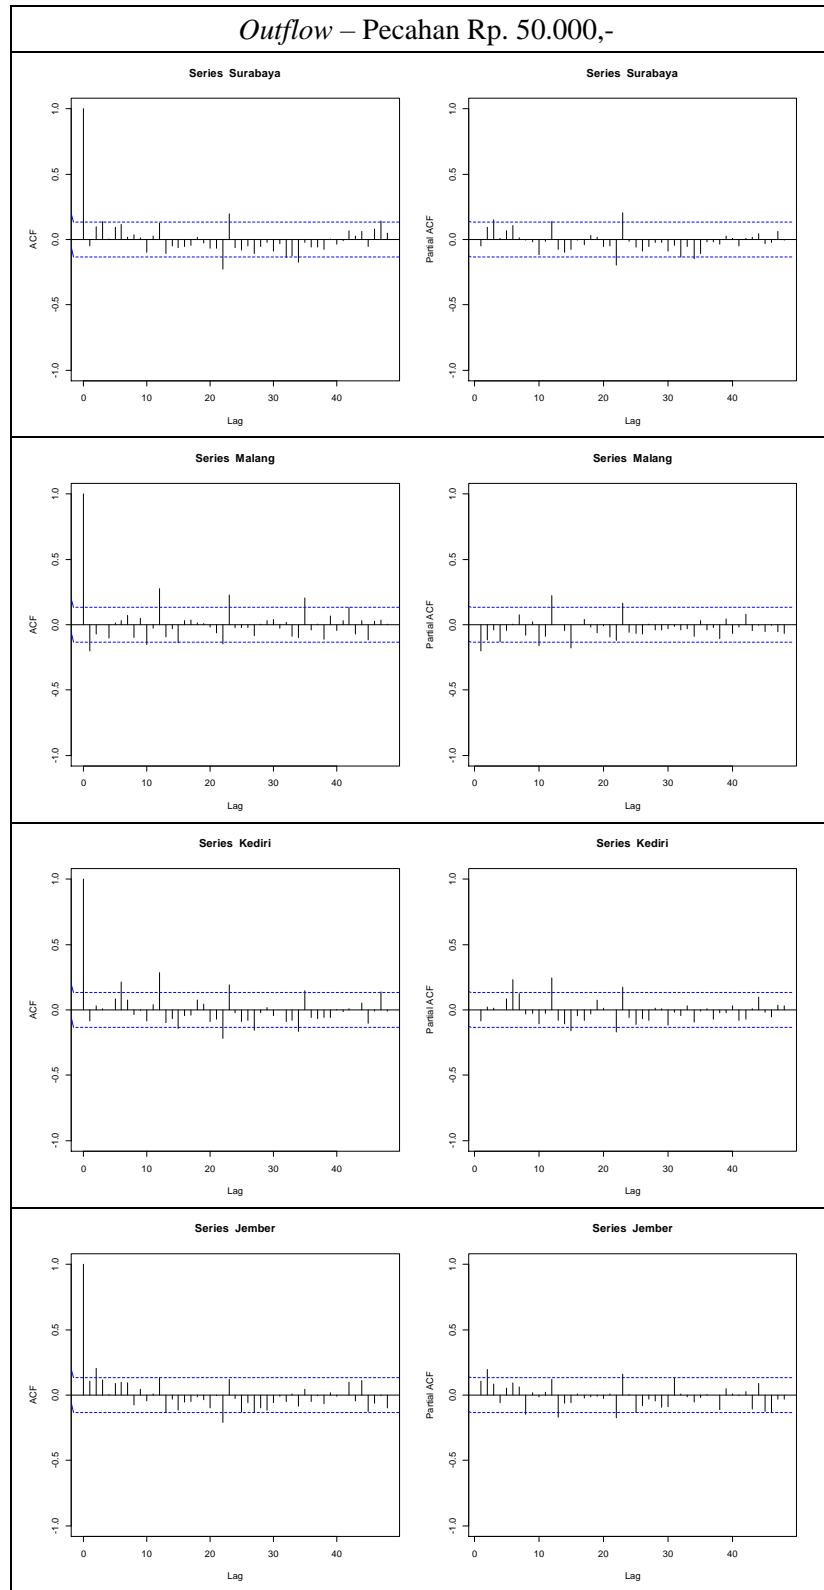
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



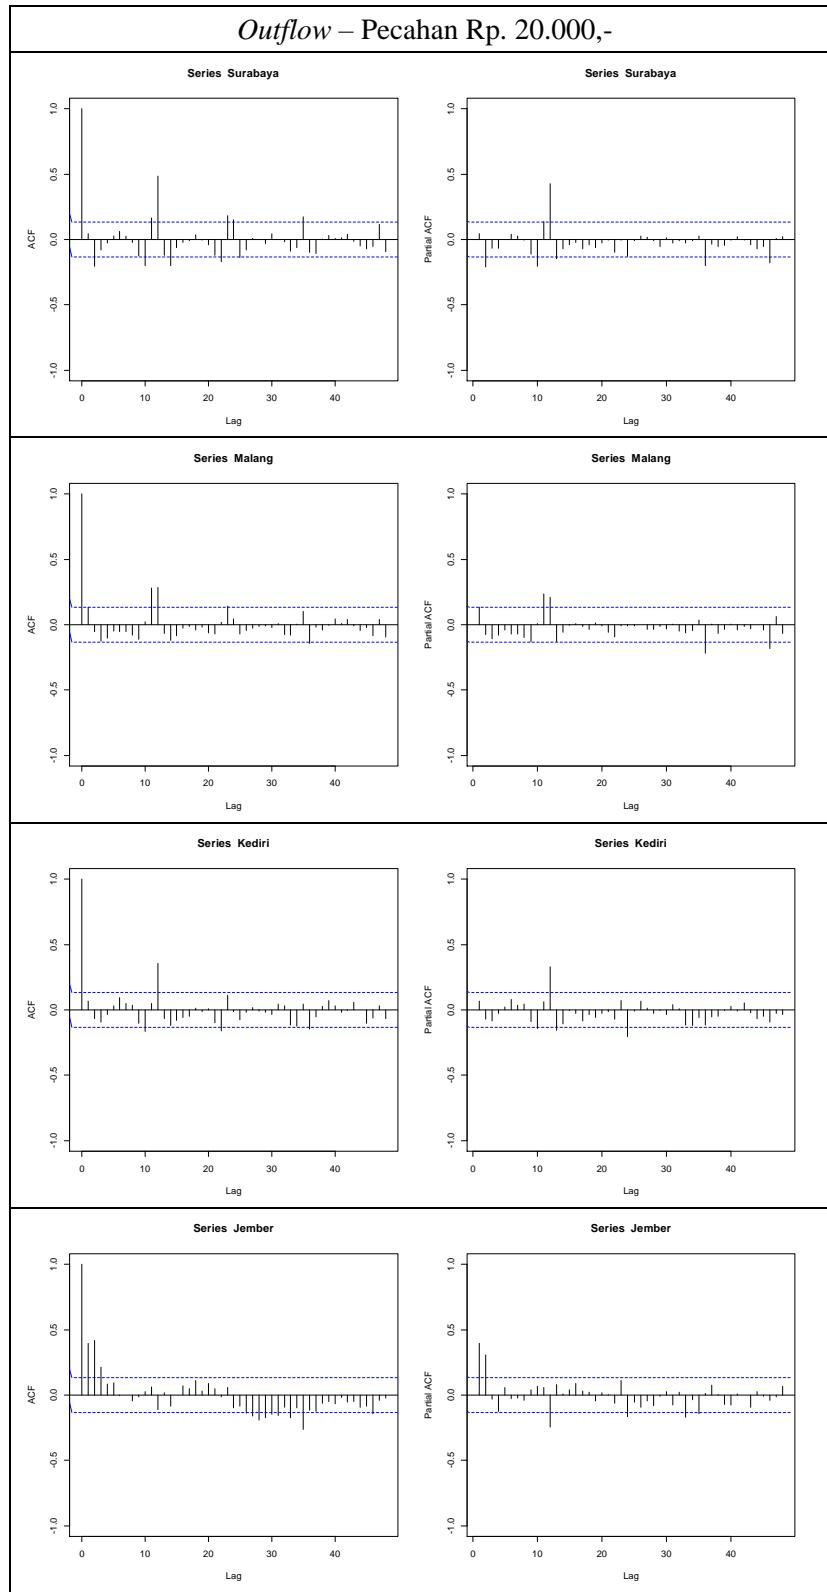
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



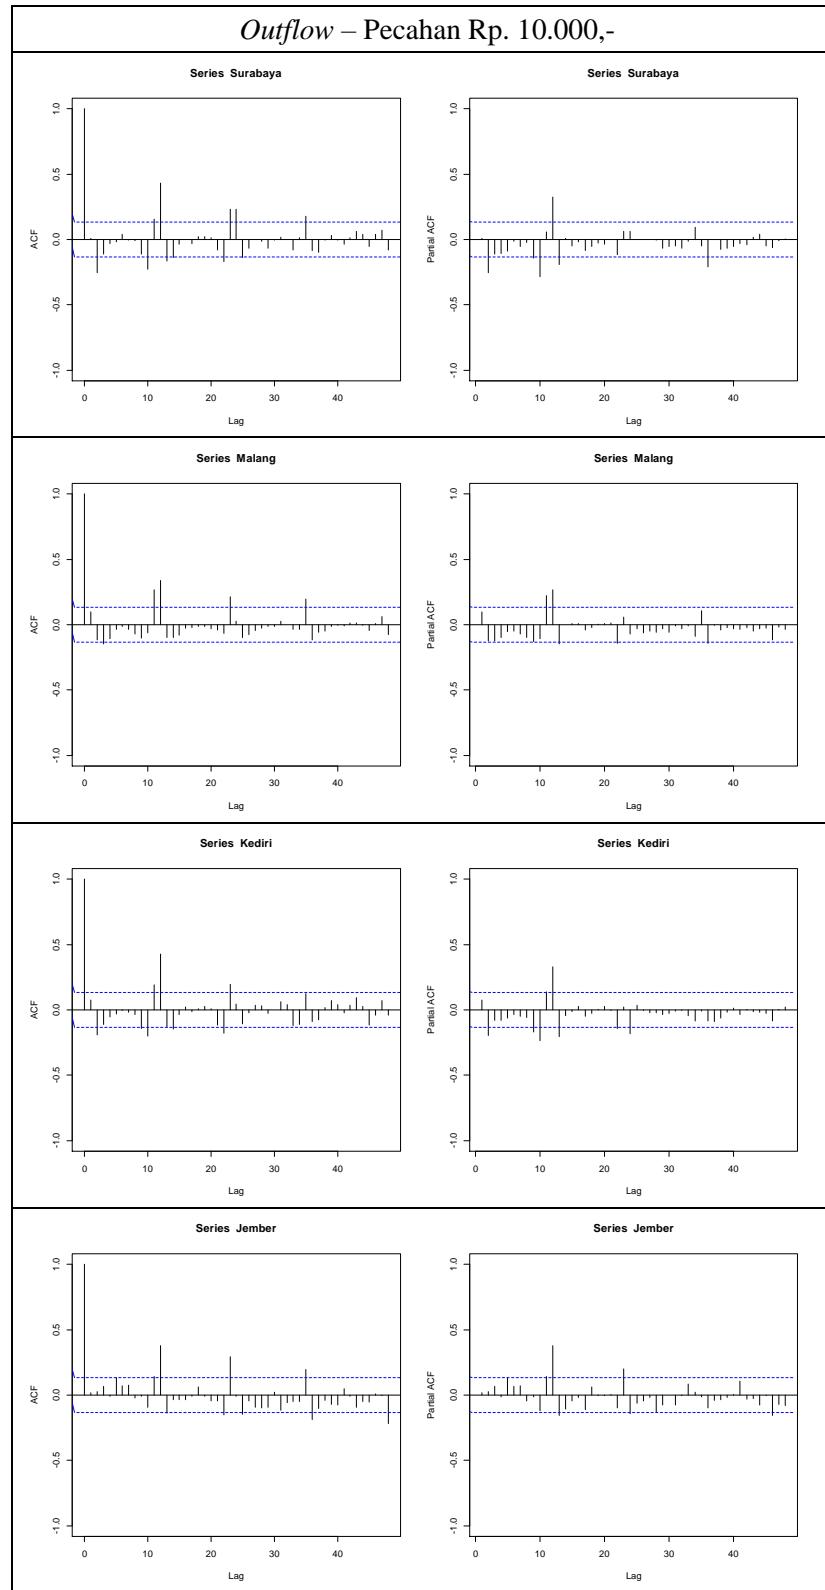
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



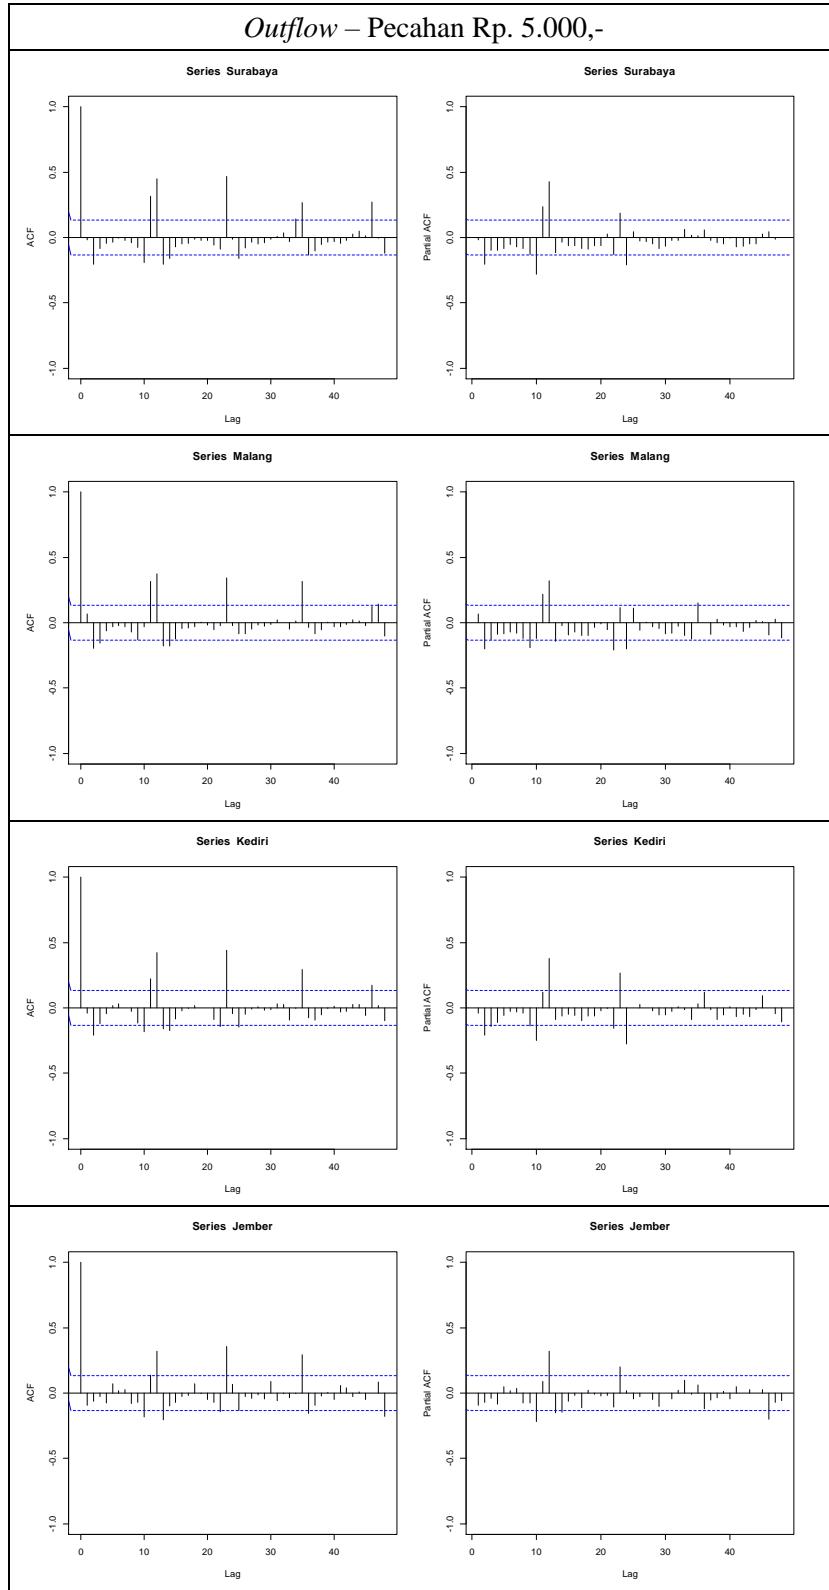
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



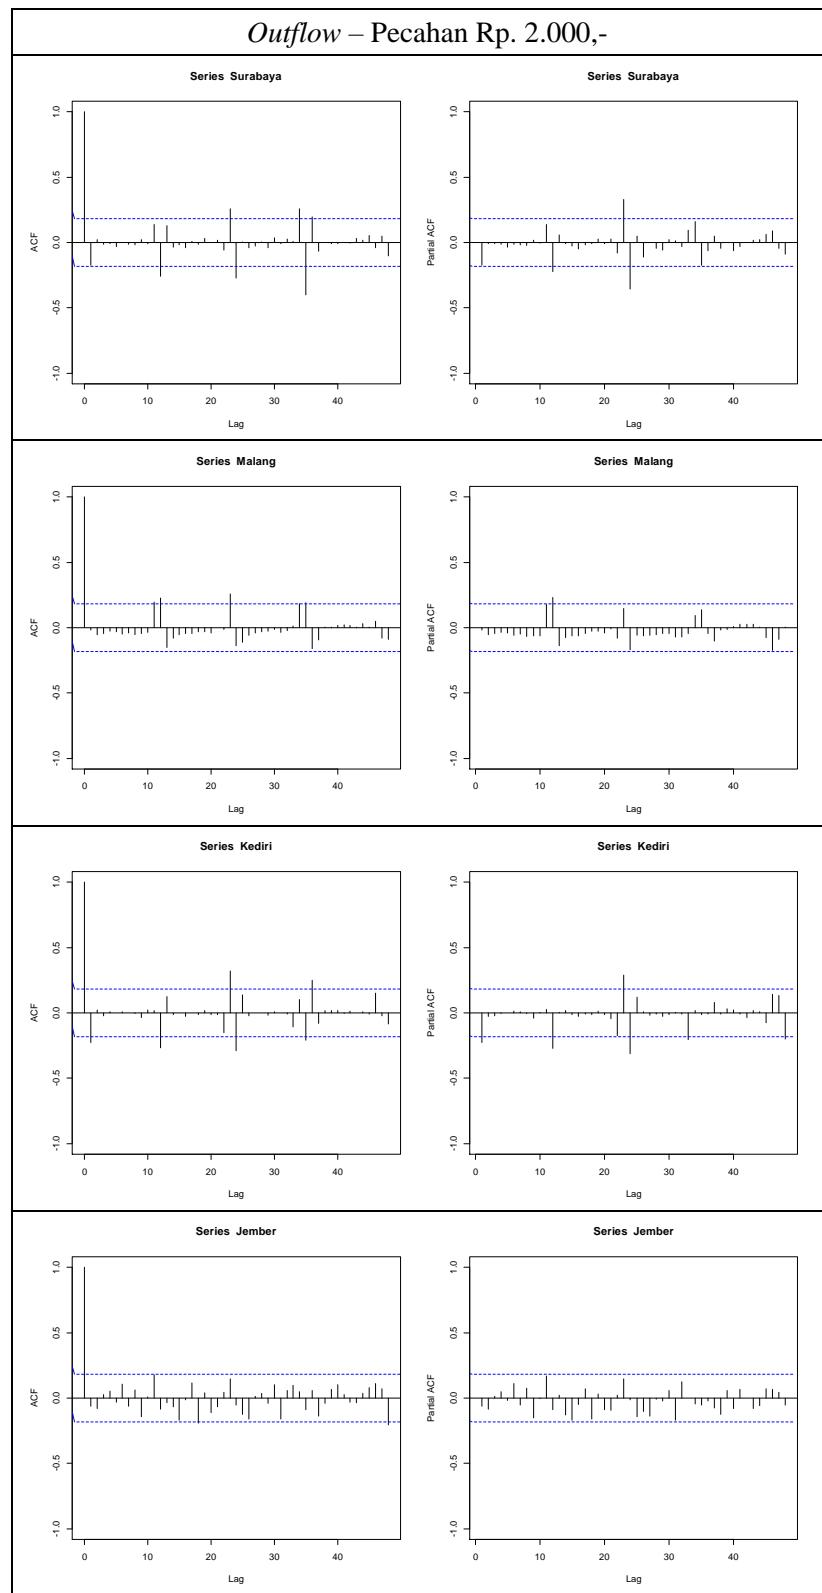
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



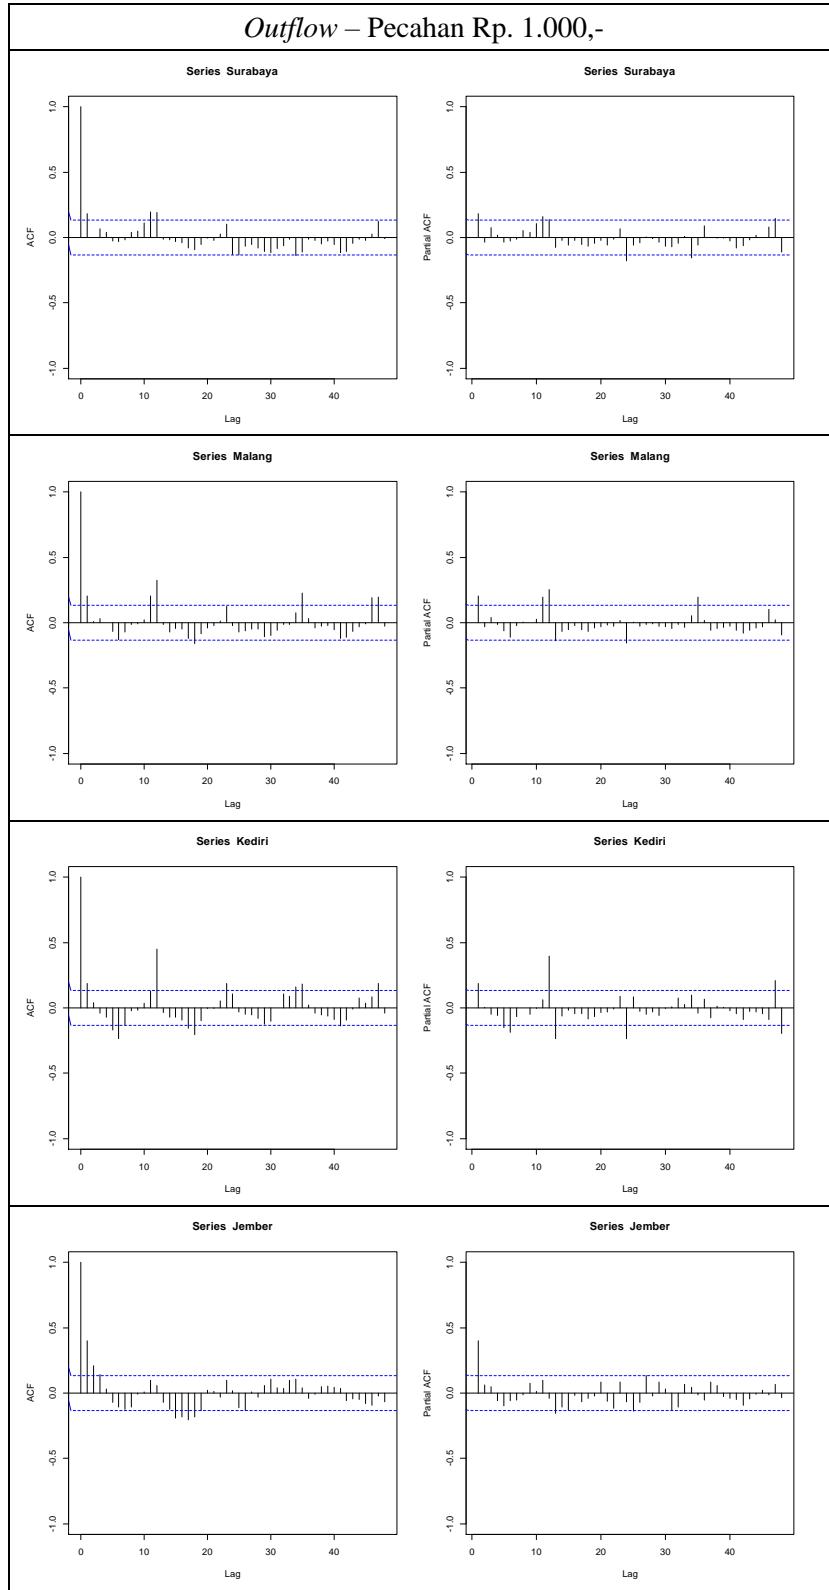
Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



Lampiran 35. Gambar Plot ACF dan PACF Pemodelan ARIMAX (lanjutan)



Lampiran 36. Output Hasil Pemodelan ARIMAX Data *Inflow*

Total Semua Pecahan
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients:
Estimate Std. Error z value Pr(> z) ar12 0.462808 0.066315 6.9790 2.973e-12 *** ar15 -0.149650 0.069500 -2.1532 0.0313 *
> coeftest(modelARIMA2) KP BI Malang z test of coefficients:
Estimate Std. Error z value Pr(> z) ar12 0.22234 0.13326 1.6685 0.095216 . ma12 0.35271 0.12723 2.7722 0.005567 **
> coeftest(modelARIMA3) KP BI Kediri z test of coefficients:
Estimate Std. Error z value Pr(> z) ar6 0.133639 0.064447 2.0736 0.038113 * ar12 0.375682 0.065802 5.7093 1.135e-08 *** ar14 -0.143387 0.067897 -2.1118 0.034701 * ar15 -0.187426 0.067297 -2.7850 0.005352 **
> coeftest(modelARIMA4) KP BI Jember z test of coefficients:
Estimate Std. Error z value Pr(> z) ar6 0.177938 0.065843 2.7025 0.006882 ** ar12 0.316533 0.069075 4.5825 4.595e-06 *** --- Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
Pecahan Rp. 100.000,-
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients:
Estimate Std. Error z value Pr(> z) ar6 0.156656 0.064233 2.4388 0.01473 * ar12 0.483831 0.066075 7.3225 2.435e-13 ***
> coeftest(modelARIMA2) KP BI Malang z test of coefficients:
Estimate Std. Error z value Pr(> z) ar12 0.657205 0.067813 9.6915 < 2.2e-16 *** ar24 -0.272184 0.073294 -3.7136 0.0002043 ***
> coeftest(modelARIMA3) KP BI Kediri z test of coefficients:
Estimate Std. Error z value Pr(> z) ar6 0.235000 0.066789 3.5185 0.000434 *** ar12 0.388675 0.069240 5.6134 1.983e-08 ***
> coeftest(modelARIMA4) KP BI Jember z test of coefficients:
Estimate Std. Error z value Pr(> z) ar6 0.213926 0.066350 3.2242 0.001263 ** ar12 0.335289 0.068739 4.8777 1.073e-06 *** --- Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Lampiran 36. Output Hasil Pemodelan ARIMAX Data *Inflow* (lanjutan)

Pecahan Rp. 50.000
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients: Estimate Std. Error z value Pr(> z) ar3 0.247231 0.065522 3.7732 0.0001611 *** ar12 0.283179 0.070022 4.0442 5.251e-05 *** ar15 -0.205504 0.074198 -2.7697 0.0056112 ** > coeftest(modelARIMA2) KP BI Malang z test of coefficients: Estimate Std. Error z value Pr(> z) ar2 0.165290 0.060277 2.7422 0.006104 ** ar12 0.304912 0.065091 4.6844 2.808e-06 *** ar13 -0.158671 0.064333 -2.4664 0.013649 * ar43 -0.231391 0.071877 -3.2193 0.001285 ** > coeftest(modelARIMA3) KP BI Kediri z test of coefficients: Estimate Std. Error z value Pr(> z) ar12 0.21624 0.07018 3.0811 0.002062 ** > coeftest(modelARIMA4) KP BI Jember z test of coefficients: Estimate Std. Error z value Pr(> z) ar12 0.260603 0.069263 3.7625 0.0001682 *** ar29 -0.188419 0.071327 -2.6416 0.0082513 ** ar37 0.161362 0.077409 2.0845 0.0371102 * --- Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
Pecahan Rp. 20.000,-
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.381827 0.059645 6.4017 1.537e-10 *** ar12 0.214410 0.070243 3.0524 0.00227 ** ar36 -0.302839 0.063893 -4.7398 2.139e-06 *** > coeftest(modelARIMA2) KP BI Malang z test of coefficients: Estimate Std. Error z value Pr(> z) ar9 0.199564 0.070079 2.8477 0.0044039 ** ar11 0.274425 0.064843 4.2321 2.315e-05 *** ar12 0.411459 0.064866 6.3432 2.251e-10 *** ar20 -0.263544 0.076144 -3.4611 0.0005379 *** > coeftest(modelARIMA3) KP BI Kediri z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.282678 0.064165 4.4055 1.055e-05 *** ar11 0.213609 0.066132 3.2301 0.001238 ** ar12 0.426837 0.073721 5.7899 7.044e-09 *** ar13 -0.158897 0.076137 -2.0870 0.036890 * ar36 -0.205504 0.071838 -2.8607 0.004227 ** > coeftest(modelARIMA4) KP BI Jember z test of coefficients: Estimate Std. Error z value Pr(> z) ar11 0.437408 0.075852 5.7666 8.089e-09 *** ar12 0.357893 0.064968 5.5088 3.613e-08 *** ar20 -0.231933 0.065621 -3.5344 0.0004087 *** ar22 -0.350594 0.074486 -4.7068 2.516e-06 ***

Lampiran 36. Output Hasil Pemodelan ARIMAX Data *Inflow* (lanjutan)

Pecahan Rp. 10.000	
> coeftest(modelARIMA1) KP BI Surabaya	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar11 0.327828 0.063626 5.1524 2.571e-07 ***	
ar12 0.261141 0.065605 3.9805 6.877e-05 ***	
ar23 0.288510 0.073124 3.9455 7.964e-05 ***	
> coeftest(modelARIMA2) KP BI Malang	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.161895 0.064909 2.4942 0.012625 *	
ar11 0.321153 0.068012 4.7220 2.335e-06 ***	
ar12 0.236511 0.074131 3.1904 0.001421 **	
ar13 -0.146862 0.065501 -2.2421 0.024954 *	
ar23 0.331066 0.079124 4.1842 2.862e-05 ***	
ar34 -0.155537 0.075672 -2.0554 0.039841 *	
> coeftest(modelARIMA3) KP BI Kediri	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 -0.521159 0.172544 -3.0204 0.0025241 **	
ar11 0.395684 0.058105 6.8098 9.775e-12 ***	
ar12 0.720733 0.093109 7.7407 9.886e-15 ***	
ar13 0.322048 0.103322 3.1169 0.0018275 **	
ar36 -0.259745 0.069303 -3.7479 0.0001783 ***	
ma1 0.625718 0.160898 3.8889 0.0001007 ***	
> coeftest(modelARIMA4) KP BI Jember	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar11 0.393170 0.078650 4.9990 5.764e-07 ***	
ar12 0.430682 0.080320 5.3621 8.228e-08 ***	
ma1 0.181022 0.069393 2.6086 0.00909 **	
ma2 0.150948 0.072639 2.0780 0.03771 *	
Pecahan Rp. 5.000,-	
> coeftest(modelARIMA1) KP BI Surabaya	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.123982 0.056783 2.1835 0.02900 *	
ar11 0.280022 0.060625 4.6189 3.858e-06 ***	
ar12 0.191662 0.069835 2.7445 0.00606 **	
ar23 0.334214 0.067992 4.9155 8.856e-07 ***	
> coeftest(modelARIMA2) KP BI Malang	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar11 0.503368 0.060039 8.3840 < 2.2e-16 ***	
ar12 0.449092 0.055970 8.0238 1.025e-15 ***	
ar22 -0.294734 0.057988 -5.0827 3.721e-07 ***	
> coeftest(modelARIMA3) KP BI Kediri	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar12 0.451279 0.069947 6.4518 1.106e-10 ***	
ar23 0.412943 0.069183 5.9688 2.389e-09 ***	
ar36 -0.152474 0.063943 -2.3845 0.0171 *	
> coeftest(modelARIMA4) KP BI Jember	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.259181 0.041788 6.2023 5.566e-10 ***	
ar11 0.934547 0.065618 14.2422 < 2.2e-16 ***	
ar22 -0.297110 0.072271 -4.1111 3.939e-05 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1	

Lampiran 36. Output Hasil Pemodelan ARIMAX Data *Inflow* (lanjutan)

Pecahan Rp. 2.000
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.224285 0.095595 2.3462 0.0189655 * ar4 -0.347163 0.094495 -3.6739 0.0002389 ***
> coeftest(modelARIMA3) KP BI Kediri z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.361037 0.093714 3.8526 0.0001169 *** ar2 -0.209319 0.094547 -2.2139 0.0268343 * ar10 0.272957 0.094537 2.8873 0.0038855 **
> coeftest(modelARIMA4) KP BI Jember z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.252502 0.090002 2.8055 0.0050233 ** ar10 0.349553 0.092553 3.7768 0.0001589 ***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
Pecahan Rp. 1.000,-
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.510613 0.053160 9.6053 < 2.2e-16 *** ar11 0.200911 0.054994 3.6533 0.0002589 *** ar23 0.184378 0.059035 3.1232 0.0017890 ** ar25 -0.193049 0.056764 -3.4009 0.0006715 ***
> coeftest(modelARIMA2) KP BI Malang z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.286582 0.064387 4.4509 8.550e-06 *** ar2 0.314787 0.062348 5.0489 4.445e-07 *** ar11 0.306896 0.053700 5.7150 1.097e-08 *** ar12 0.342433 0.062174 5.5076 3.637e-08 *** ar13 -0.386464 0.064509 -5.9909 2.087e-09 *** ar14 -0.144739 0.063553 -2.2775 0.02276 *
> coeftest(modelARIMA3) KP BI Kediri Estimate Std. Error z value Pr(> z) ar1 0.430101 0.059458 7.2338 4.698e-13 *** ar11 0.283882 0.059597 4.7633 1.904e-06 *** ar12 0.213628 0.067448 3.1673 0.001539 ** ar13 -0.239928 0.059129 -4.0577 4.957e-05 *** ar16 -0.141268 0.049012 -2.8823 0.003948 ** ar23 0.202127 0.066543 3.0376 0.002385 ** ar34 -0.182339 0.059623 -3.0582 0.002227 **
> coeftest(modelARIMA4) KP BI Jember z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.400575 0.062745 6.3841 1.724e-10 *** ar11 0.316870 0.056283 5.6299 1.803e-08 *** ar12 0.288829 0.066605 4.3365 1.448e-05 *** ar13 -0.213131 0.062714 -3.3985 0.0006776 ***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Lampiran 37. Output Hasil Pemodelan ARIMAX Data *Outflow*

Total Semua Pecahan					
> coeftest(modelARIMA1) KP BI Surabaya					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar1 -0.117034 0.054543 -2.1457 0.03189 *					
ar6 0.130944 0.050888 2.5732 0.01008 *					
ar10 -0.141342 0.057263 -2.4683 0.01358 *					
ar12 0.429664 0.060809 7.0658 1.597e-12 ***					
ar23 0.351951 0.065961 5.3357 9.516e-08 ***					
> coeftest(modelARIMA2) KP BI Malang					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar1 -0.198042 0.048418 -4.0903 4.308e-05 ***					
ar4 -0.109420 0.049361 -2.2167 0.02664 *					
ar12 0.505805 0.057612 8.7794 < 2.2e-16 ***					
ar23 0.408237 0.056621 7.2100 5.596e-13 ***					
> coeftest(modelARIMA3) KP BI Kediri					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar1 -0.157813 0.049214 -3.2067 0.001343 **					
ar6 0.132340 0.048991 2.7013 0.006906 **					
ar12 0.554564 0.060776 9.1247 < 2.2e-16 ***					
ar23 0.327642 0.060769 5.3916 6.985e-08 ***					
> coeftest(modelARIMA4) KP BI Jember					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar10 -0.164052 0.057733 -2.8416 0.004489 **					
ar12 0.515693 0.063679 8.0983 5.575e-16 ***					
ar13 -0.187648 0.058681 -3.1978 0.001385 **					
ar23 0.189245 0.060881 3.1085 0.001881 **					
ar24 -0.186936 0.065388 -2.8589 0.004251 **					
Pecahan Rp. 100.000,-					
> coeftest(modelARIMA1) KP BI Surabaya					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar6 0.107094 0.053971 1.9843 0.047225 *					
ar10 -0.125885 0.060086 -2.0951 0.036163 *					
ar12 0.376992 0.060419 6.2397 4.385e-10 ***					
ar13 -0.225525 0.060365 -3.7360 0.000187 ***					
ar15 -0.152969 0.058355 -2.6213 0.008758 **					
ar23 0.275471 0.064153 4.2940 1.755e-05 ***					
> coeftest(modelARIMA2) KP BI Malang					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar1 -0.233608 0.051004 -4.5802 4.646e-06 ***					
ar2 -0.129098 0.052755 -2.4471 0.01440 *					
ar4 -0.128469 0.050820 -2.5279 0.01147 *					
ar12 0.481463 0.058674 8.2058 2.292e-16 ***					
ar23 0.338918 0.059949 5.6534 1.573e-08 ***					
> coeftest(modelARIMA3) KP BI Kediri					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar1 -0.159015 0.052394 -3.0350 0.002405 **					
ar6 0.114956 0.052676 2.1823 0.029084 *					
ar12 0.539447 0.064565 8.3551 < 2.2e-16 ***					
ar23 0.311300 0.066452 4.6846 2.806e-06 ***					
> coeftest(modelARIMA4) KP BI Jember					
z test of coefficients:					
Estimate Std. Error z value Pr(> z)					
ar12 0.562381 0.065641 8.5675 < 2.2e-16 ***					
ar13 -0.164303 0.059791 -2.7479 0.005997 **					
ar23 0.169093 0.060122 2.8125 0.004916 **					
ar24 -0.282593 0.066543 -4.2467 2.169e-05 ***---					
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1					

Lampiran 37. Output Hasil Pemodelan ARIMAX Data *Outflow* (lanjutan)

Pecahan Rp. 50.000,-
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients: Estimate Std. Error z value Pr(> z) ar22 -0.299776 0.068007 -4.4080 1.043e-05 *** ar23 0.278515 0.067816 4.1069 4.010e-05 *** ar34 -0.239712 0.072634 -3.3003 0.000966 *** > coeftest(modelARIMA2) KP BI Malang z test of coefficients: Estimate Std. Error z value Pr(> z) ar10 -0.145383 0.067030 -2.1689 0.03009 * ar12 0.394111 0.068752 5.7324 9.903e-09 *** ar15 -0.155532 0.069049 -2.2525 0.02429 * ar23 0.293419 0.069393 4.2284 2.354e-05 *** > coeftest(modelARIMA3) KP BI Kediri z test of coefficients: Estimate Std. Error z value Pr(> z) ar6 0.176077 0.056840 3.0978 0.0019497 ** ar12 0.311124 0.064141 4.8506 1.231e-06 *** ar15 -0.150057 0.061481 -2.4407 0.0146585 * ar22 -0.240871 0.065915 -3.6543 0.0002579 *** ar23 0.223144 0.065578 3.4027 0.0006672 *** > coeftest(modelARIMA4) KP BI Jember z test of coefficients: Estimate Std. Error z value Pr(> z) ar2 0.182047 0.063232 2.8790 0.0039889 ** ar13 -0.143698 0.067369 -2.1330 0.0329234 * ar22 -0.235523 0.067499 -3.4893 0.0004843 *** ar23 0.167429 0.066934 2.5014 0.0123709 *
Pecahan Rp. 20.000,-
> coeftest(modelARIMA1) KP BI Surabaya z test of coefficients: Estimate Std. Error z value Pr(> z) ar10 -0.150062 0.059220 -2.5340 0.01128 * ar12 0.599546 0.059154 10.1353 < 2e-16 *** ar13 -0.150998 0.059246 -2.5487 0.01081 * > coeftest(modelARIMA2) KP BI Malang z test of coefficients: Estimate Std. Error z value Pr(> z) ar11 0.338690 0.064148 5.2799 1.293e-07 *** ar12 0.369179 0.066312 5.5673 2.586e-08 *** ar36 -0.230331 0.071829 -3.2067 0.001343 ** > coeftest(modelARIMA3) KP BI Kediri z test of coefficients: Estimate Std. Error z value Pr(> z) ar10 -0.222182 0.064923 -3.4223 0.000621 *** ar12 0.587801 0.072197 8.1416 3.902e-16 *** ar13 -0.149161 0.066569 -2.2407 0.025045 * ar24 -0.213388 0.079485 -2.6846 0.007261 ** > coeftest(modelARIMA4) KP BI Jember z test of coefficients: Estimate Std. Error z value Pr(> z) ar1 0.278193 0.061128 4.5510 5.340e-06 *** ar2 0.271496 0.061833 4.3908 1.129e-05 *** ar12 -0.152700 0.058091 -2.6286 0.008573 ** ar24 -0.126420 0.057097 -2.2141 0.026819 * ar35 -0.182856 0.057451 -3.1828 0.001458 **

Lampiran 37. Output Hasil Pemodelan ARIMAX Data *Outflow* (lanjutan)

Pecahan Rp. 10.000,-	
> coeftest(modelARIMA1) KP BI Surabaya	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar2 -0.109067 0.055632 -1.9605 0.049937 *	
ar10 -0.178107 0.059524 -2.9922 0.002770 **	
ar12 0.530479 0.067428 7.8673 3.622e-15 ***	
ar13 -0.126321 0.062112 -2.0338 0.041975 *	
ar36 -0.212003 0.070901 -2.9901 0.002789 **	
> coeftest(modelARIMA2) KP BI Malang	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar11 0.370205 0.065518 5.6504 1.601e-08 ***	
ar12 0.433718 0.064630 6.7108 1.935e-11 ***	
ar22 -0.166527 0.070753 -2.3536 0.01859 *	
ar36 -0.140927 0.068666 -2.0524 0.04013 *	
> coeftest(modelARIMA3) KP BI Kediri	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar11 0.223191 0.062646 3.5628 0.000367 ***	
ar12 0.492094 0.060600 8.1204 4.648e-16 ***	
ar13 -0.176264 0.059169 -2.9790 0.002892 **	
ar22 -0.250985 0.066858 -3.7540 0.000174 ***	
> coeftest(modelARIMA4) KP BI Jember	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar12 0.389419 0.062192 6.2615 3.812e-10 ***	
ar13 -0.151644 0.061076 -2.4829 0.01303 *	
ar23 0.307893 0.066059 4.6609 3.148e-06 ***	
Pecahan Rp. 5.000,-	
> coeftest(modelARIMA1) KP BI Surabaya	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar2 -0.111557 0.047905 -2.3287 0.0198749 *	
ar12 0.448461 0.063766 7.0329 2.023e-12 ***	
ar23 0.434307 0.057080 7.6087 2.768e-14 ***	
ar24 -0.255371 0.066200 -3.8576 0.0001145 ***	
> coeftest(modelARIMA2) KP BI Malang	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar2 -0.121584 0.047411 -2.5645 0.0103339 *	
ar11 0.274799 0.050227 5.4712 4.471e-08 ***	
ar12 0.202531 0.056185 3.6047 0.0003125 ***	
ar35 0.457391 0.067861 6.7401 1.583e-11 ***	
> coeftest(modelARIMA3) KP BI Kediri	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar2 -0.118409 0.049058 -2.4136 0.015794 *	
ar12 0.396434 0.059800 6.6293 3.373e-11 ***	
ar23 0.471611 0.059089 7.9813 1.448e-15 ***	
ar24 -0.210778 0.066327 -3.1779 0.001484 **	
> coeftest(modelARIMA4) KP BI Jember	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar10 -0.136774 0.061788 -2.2136 0.02686 *	
ar12 0.296444 0.061796 4.7971 1.609e-06 ***	
ar13 -0.149499 0.061692 -2.4233 0.01538 *	
ar23 0.404235 0.073845 5.4741 4.397e-08 ***	
ar46 -0.159653 0.073478 -2.1728 0.02980 *	

Lampiran 37. Output Hasil Pemodelan ARIMAX Data *Outflow* (lanjutan)

Pecahan Rp. 2.000,-	
> coeftest(modelARIMA1) KP BI Surabaya	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 -0.249787 0.082664 -3.0217 0.002513 **	
ar23 0.429535 0.084640 5.0748 3.878e-07 ***	
> coeftest(modelARIMA3) KP BI Kediri	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar12 -0.246092 0.095455 -2.5781 0.009935 **	
ar23 0.344341 0.120987 2.8461 0.004426 **	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1	
Pecahan Rp. 1.000,-	
> coeftest(modelARIMA1) KP BI Surabaya	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.141665 0.062293 2.2742 0.022957 *	
ar11 0.190911 0.064662 2.9524 0.003153 **	
ar12 0.220865 0.067667 3.2640 0.001099 **	
ar24 -0.209065 0.066663 -3.1361 0.001712 **	
ar34 -0.166501 0.064750 -2.5714 0.010128 *	
ar47 0.197926 0.070385 2.8120 0.004923 **	
> coeftest(modelARIMA2) KP BI Malang	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.146328 0.060244 2.4289 0.0151438 *	
ar11 0.166648 0.062069 2.6849 0.0072560 **	
ar12 0.318980 0.068604 4.6496 3.326e-06 ***	
ar24 -0.221279 0.070143 -3.1547 0.0016067 **	
ar35 0.258572 0.067149 3.8507 0.0001178 ***	
> coeftest(modelARIMA3) KP BI Kediri	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.278189 0.062018 4.4856 7.270e-06 ***	
ar6 -0.126803 0.053732 -2.3599 0.018279 *	
ar12 0.540060 0.067457 8.0059 1.186e-15 ***	
ar13 -0.256377 0.063653 -4.0278 5.631e-05 ***	
ar24 -0.206645 0.073523 -2.8106 0.004944 **	
ar47 0.199936 0.067230 2.9739 0.002940 **	
ar48 -0.135444 0.068105 -1.9888 0.046729 *	
> coeftest(modelARIMA4) KP BI Jember	
z test of coefficients:	
Estimate Std. Error z value Pr(> z)	
ar1 0.397350 0.062257 6.3824 1.743e-10 ***	

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1	

Lampiran 38. Output Hasil Uji Asumsi *White Noise* Residual Model ARIMAX Data Inflow

Total Semua Pecahan	Pecahan Rp. 50.000,-	Pecahan Rp. 10.000,-
> LB.ARIMAX1 statistics p.value 6 9.164151 0.1645546 12 10.372120 0.5833501 18 11.713844 0.8616537 24 14.714918 0.9288236 30 24.780121 0.7356455 > LB.ARIMAX2 statistics p.value 6 7.195536 0.3031423 12 12.723775 0.3894335 18 15.658076 0.6163967 24 20.235427 0.6833122 30 29.055133 0.5147017 > LB.ARIMAX3 statistics p.value 6 3.563671 0.7354802 12 5.819504 0.9249058 18 13.839724 0.7394780 24 18.481463 0.7790480 30 21.684784 0.8652621 > LB.ARIMAX4 statistics p.value 6 0.9985085 0.9856688 12 2.7820583 0.9968969 18 5.7167855 0.9972160 24 8.2781369 0.9987824 30 14.2353239 0.9933976	> LB.ARIMAX1 statistics p.value 6 9.937836 0.12729439 12 13.193952 0.35510251 18 14.846141 0.67250322 24 24.201657 0.45011556 30 41.404514 0.08040124 > LB.ARIMAX2 statistics p.value 6 7.694724 0.2613325 12 15.781932 0.2014294 18 18.615820 0.4158304 24 25.897125 0.3584055 30 37.337495 0.1675100 > LB.ARIMAX3 statistics p.value 6 21.78811 0.001322698 12 23.06362 0.027190693 18 32.74749 0.017903521 24 38.99621 0.027334209 30 47.52736 0.022087042 > LB.ARIMAX4 statistics p.value 6 17.56295 0.00742247 12 18.74425 0.09489025 18 23.01040 0.19019061 24 26.31409 0.33742262 30 32.90638 0.32661948	> LB.ARIMAX1 statistics p.value 6 41.90271 1.921918e-07 12 44.68018 1.168938e-05 18 45.89272 3.075522e-04 24 51.96682 7.902218e-04 30 65.84293 1.709399e-04 > LB.ARIMAX2 statistics p.value 6 3.864772 0.6949704 12 5.236233 0.9496194 18 10.888946 0.8990097 24 21.967170 0.5812264 30 28.643656 0.5363680 > LB.ARIMAX3 statistics p.value 6 17.35961 0.008048641 12 21.34286 0.045579609 18 33.95144 0.012770555 24 44.87465 0.006027027 30 50.66233 0.010573936 > LB.ARIMAX4 statistics p.value 6 2.052403 0.91481655 12 6.710678 0.87612606 18 10.843646 0.90087341 24 33.633392 0.09139851 30 36.941618 0.17885172
Pecahan Rp. 100.000,-	Pecahan Rp. 20.000,-	Pecahan Rp. 5.000,-
> LB.ARIMAX1 statistics p.value 6 9.45645 0.1494879 12 13.33042 0.3454891 18 15.44633 0.6311271 24 18.48629 0.7788019 30 25.56376 0.6971983 > LB.ARIMAX2 statistics p.value 6 7.911661 0.2446470 12 10.689659 0.5556854 18 13.614796 0.7538347 24 18.769224 0.7641823 30 26.826619 0.6323602 > LB.ARIMAX3 statistics p.value 6 7.576595 0.27079210 12 13.041972 0.36599737 18 21.247697 0.26710114 24 34.296172 0.07954128 30 39.097922 0.12355006 > LB.ARIMAX4 statistics p.value 6 1.318116 0.9706494 12 3.418494 0.9917989 18 6.211590 0.9952613 24 10.908418 0.9896502 30 18.459937 0.9506019	> LB.ARIMAX1 statistics p.value 6 1.692288 0.9457151 12 10.540560 0.5686475 18 15.177244 0.6497630 24 30.156111 0.1796314 30 38.413004 0.1394313 > LB.ARIMAX2 statistics p.value 6 5.727631 0.4543820 12 7.752019 0.8041966 18 14.047309 0.7260021 24 23.429102 0.4946001 30 30.337969 0.4484458 > LB.ARIMAX3 statistics p.value 6 9.354466 0.1546026 12 10.169560 0.6010881 18 20.004648 0.3325581 24 24.549942 0.4305364 30 29.670094 0.4826392 > LB.ARIMAX4 statistics p.value 6 6.348344 0.3853202 12 10.957044 0.5326035 18 17.736900 0.4731073 24 20.388013 0.6745104 30 24.540134 0.7470576	> LB.ARIMAX1 statistics p.value 6 1.773893 0.9392752 12 4.048125 0.9825522 18 6.023327 0.9961016 24 15.433567 0.9074291 30 22.429805 0.8379564 > LB.ARIMAX2 statistics p.value 6 81.74102 1.554312e-15 12 82.49360 1.377454e-12 18 87.57020 3.931411e-11 24 113.51175 1.366685e-13 30 134.90719 2.997602e-15 > LB.ARIMAX3 statistics p.value 6 19.00248 4.159447e-03 12 37.86897 1.613205e-04 18 55.70815 9.908828e-06 24 72.79742 8.178135e-07 30 85.87871 2.729195e-07 > LB.ARIMAX4 statistics p.value 6 13.74082 0.03266919 12 18.41140 0.10375793 18 22.17538 0.22429190 24 32.45751 0.11604711 30 37.01409 0.17673404

Lampiran 38. Output Hasil Uji Asumsi *White Noise* Residual Model ARIMAX

Data *Inflow* (lanjutan)

Pecahan Rp. 2.000,-	Pecahan Rp. 1.000,-
> LB.ARIMAX1 statistics p.value 6 2.522055 0.8659913 12 7.253093 0.8404448 18 9.982653 0.9324711 24 19.335399 0.7338740 30 22.046974 0.8523298	> LB.ARIMAX1 statistics p.value 6 11.96104 0.06284357 12 12.63812 0.39588312 18 15.95910 0.59540204 24 26.68831 0.31918994 30 34.65461 0.25542460
> LB.ARIMAX2 statistics p.value 6 8.795437 0.1854136 12 19.360167 0.0801994 18 22.951430 0.1924635 24 27.492266 0.2820355 30 32.065679 0.3644791	> LB.ARIMAX2 statistics p.value 6 1.920096 0.9268987 12 8.762209 0.7230956 18 13.711237 0.7477120 24 15.554091 0.9034949 30 22.347583 0.8411033
> LB.ARIMAX3 statistics p.value 6 1.236431 0.9750470 12 7.028518 0.8557232 18 10.947254 0.8965816 24 14.073842 0.9449650 30 16.769412 0.9752383	> LB.ARIMAX3 statistics p.value 6 6.185332 0.4027527 12 9.336714 0.6739332 18 12.250668 0.8340293 24 24.829760 0.4150587 30 35.544059 0.2233835
> LB.ARIMAX4 statistics p.value 6 1.959216 0.9234110 12 10.222126 0.5964806 18 14.193336 0.7164037 24 17.066309 0.8458202 30 19.970784 0.9173001	> LB.ARIMAX4 statistics p.value 6 17.67124 0.007108506 12 20.06695 0.065830031 18 25.62241 0.108710161 24 39.21007 0.025954379 30 51.30034 0.009051257

Lampiran 39. Output Hasil Uji Asumsi *White Noise* Residual Model ARIMAX Data *Outflow*

Total Semua Pecahan	Pecahan Rp. 50.000,-	Pecahan Rp. 10.000,-
> LB.ARIMAX1 statistics p.value 6 8.763375 0.1873295 12 11.066403 0.5232366 18 21.977914 0.2329672 24 28.139421 0.2542032 30 34.710859 0.2533132	> LB.ARIMAX1 statistics p.value 6 8.875203 0.1807192 12 12.550869 0.4025119 18 18.235545 0.4402400 24 23.834301 0.4711046 30 30.995709 0.4156181	> LB.ARIMAX1 statistics p.value 6 5.479193 0.4839751 12 14.796438 0.2527579 18 16.158878 0.5814602 24 27.269874 0.2920316 30 31.678861 0.3826103
> LB.ARIMAX2 statistics p.value 6 3.555565 0.7365629 12 8.685532 0.7295295 18 16.955390 0.5261741 24 19.265411 0.7376909 30 22.638099 0.8298403	> LB.ARIMAX2 statistics p.value 6 9.368979 0.1538655 12 13.602741 0.3267922 18 15.462714 0.6299890 24 19.583840 0.7201792 30 21.973531 0.8550051	> LB.ARIMAX2 statistics p.value 6 4.283775 0.6383338 12 5.894619 0.9213007 18 6.165639 0.9954783 24 8.388796 0.9986412 30 9.885592 0.9997994
> LB.ARIMAX3 statistics p.value 6 6.006372 0.4224766 12 9.160935 0.6891265 18 18.334861 0.4338066 24 26.655318 0.3207741 30 34.230919 0.2716951	> LB.ARIMAX3 statistics p.value 6 7.438146 0.2822195 12 8.163727 0.7722083 18 14.809278 0.6750185 24 18.184984 0.7939437 30 23.292749 0.8030361	> LB.ARIMAX3 statistics p.value 6 5.745565 0.4522871 12 14.178824 0.2894350 18 18.113963 0.4481691 24 19.546046 0.7222767 30 21.747022 0.8630867
> LB.ARIMAX4 statistics p.value 6 21.50388 0.001488726 12 26.75200 0.008387824 18 36.32880 0.006402087 24 50.83624 0.001106900 30 58.83065 0.001272583	> LB.ARIMAX4 statistics p.value 6 10.02758 0.12349555 12 19.62720 0.07447496 18 22.25291 0.22094990 24 23.28912 0.50278859 30 37.06469 0.17526663	> LB.ARIMAX4 statistics p.value 6 29.61070 4.660487e-05 12 32.69571 1.079660e-03 18 34.02967 1.248969e-02 24 42.53802 1.122522e-02 30 59.12669 1.172982e-03
Pecahan Rp. 100.000,-	Pecahan Rp. 20.000,-	Pecahan Rp. 5.000,-
> LB.ARIMAX1 statistics p.value 6 6.293709 0.3911056 12 11.096621 0.5206569 18 18.455662 0.4260362 24 25.491245 0.3794729 30 33.668341 0.2942854	> LB.ARIMAX1 statistics p.value 6 0.8504713 0.9906516 12 7.1257494 0.8491928 18 14.6997486 0.6824698 24 19.8252607 0.7066686 30 21.9056863 0.8574527	> LB.ARIMAX1 statistics p.value 6 0.777851 0.9926544 12 3.366816 0.9923535 18 6.363541 0.9944857 24 11.317418 0.9865625 30 12.261256 0.9982821
> LB.ARIMAX2 statistics p.value 6 7.399463 0.2854786 12 12.037102 0.4427045 18 18.971240 0.3935965 24 24.750564 0.4194152 30 29.966185 0.4673866	> LB.ARIMAX2 statistics p.value 6 2.024199 0.9174596 12 4.286275 0.9776991 18 6.965238 0.9904162 24 8.481889 0.9985121 30 9.529395 0.9998638	> LB.ARIMAX2 statistics p.value 6 2.842300 0.8283637 12 4.188898 0.9797814 18 10.919462 0.8977430 24 20.374832 0.6752729 30 21.552005 0.8698375
> LB.ARIMAX3 statistics p.value 6 6.159248 0.4055896 12 9.251955 0.6812727 18 17.535943 0.4865932 24 23.690772 0.4793892 30 31.773043 0.3781567	> LB.ARIMAX3 statistics p.value 6 7.786758 0.2541460 12 12.935600 0.3737389 18 22.287587 0.2194671 24 25.711845 0.3679462 30 26.201671 0.6647989	> LB.ARIMAX3 statistics p.value 6 4.204100 0.6490779 12 8.217082 0.7679444 18 14.497142 0.6961559 24 18.431761 0.7815757 30 19.448998 0.9301029
> LB.ARIMAX4 statistics p.value 6 22.97324 0.0008054908 12 27.26979 0.0070647353 18 32.40404 0.0196843251 24 51.35473 0.0009489321 30 64.85642 0.0002288195	> LB.ARIMAX4 statistics p.value 6 5.611387 0.4680976 12 13.123731 0.3601120 18 19.142636 0.3830898 24 23.526967 0.4888958 30 27.756087 0.5833605	> LB.ARIMAX4 statistics p.value 6 6.221895 0.3987980 12 14.916171 0.2460529 18 17.348709 0.4992656 24 22.209520 0.5667628 30 25.783465 0.6861366

Lampiran 39. Output Hasil Uji Asumsi *White Noise* Residual Model ARIMAX

Data *Outflow* (lanjutan)

Pecahan Rp. 2.000,-	Pecahan Rp. 1.000,-
> LB.ARIMAX1 statistics p.value 6 2.962025 0.8135977 12 9.815993 0.6320997 18 11.300834 0.8811573 24 15.774531 0.8960418 30 16.947097 0.9732037	> LB.ARIMAX1 statistics p.value 6 2.080562 0.9121421 12 4.738378 0.9661513 18 6.596802 0.9931087 24 13.528452 0.9565939 30 15.691836 0.9852035
> LB.ARIMAX2 statistics p.value 6 2.093000 0.9109497 12 7.099148 0.8509924 18 8.626042 0.9677866 24 9.751580 0.9954970 30 9.953061 0.9997846	> LB.ARIMAX2 statistics p.value 6 1.853570 0.9326610 12 2.108390 0.9992208 18 5.915396 0.9965278 24 7.214967 0.9996229 30 7.466336 0.9999910
> LB.ARIMAX3 statistics p.value 6 2.270928 0.8931721 12 3.552695 0.9902248 18 4.338375 0.9995751 24 8.534085 0.9984354 30 9.396841 0.9998827	> LB.ARIMAX3 statistics p.value 6 2.786763 0.8350949 12 3.963973 0.9840777 18 8.305503 0.9737331 24 19.585315 0.7200973 30 23.014873 0.8146480
> LB.ARIMAX4 statistics p.value 6 1.488024 0.9602861 12 5.316996 0.9465446 18 11.019819 0.8935138 24 15.794723 0.8953425 30 24.663837 0.7411983	> LB.ARIMAX4 statistics p.value 6 3.306531 0.76950621 12 9.647799 0.64682810 18 19.512690 0.36091167 24 30.067927 0.18251063 30 41.281099 0.08234051

Lampiran 40. Output Hasil Uji Distribusi Normal Residual Model ARIMAX Data *Inflow*

Total Semua Pecahan
<pre>One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.093723, p-value = 0.04498 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.09027, p-value = 0.05919 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.097048, p-value = 0.0342 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.090329, p-value = 0.05891 alternative hypothesis: two-sided</pre>
Pecahan Rp. 100.000,-
<pre>One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.079678, p-value = 0.1288 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.086485, p-value = 0.07901 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.073202, p-value = 0.1974 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.081047, p-value = 0.1171 alternative hypothesis: two-sided</pre>

Lampiran 40. Output Hasil Uji Distribusi Normal Residual Model ARIMAX

Data Inflow (lanjutan)

Pecahan Rp. 50.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.081327, p-value = 0.1148 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.068361, p-value = 0.265 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.043, p-value = 0.8193 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.077614, p-value = 0.1481 alternative hypothesis: two-sided
Pecahan Rp. 20.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.096723, p-value = 0.03514 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.1167, p-value = 0.005572 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.075503, p-value = 0.1703 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.10403, p-value = 0.01864 alternative hypothesis: two-sided

Lampiran 40. Output Hasil Uji Distribusi Normal Residual Model ARIMAX

Data *Inflow* (lanjutan)

Pecahan Rp. 10.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.1144, p-value = 0.007011 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.1127, p-value = 0.008278 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.11309, p-value = 0.007972 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.13545, p-value = 0.0007223 alternative hypothesis: two-sided
Pecahan Rp. 5.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.098638, p-value = 0.0299 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.15112, p-value = 0.0001038 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.12291, p-value = 0.002929 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.1111, p-value = 0.009669 alternative hypothesis: two-sided

Lampiran 40. Output Hasil Uji Distribusi Normal Residual Model ARIMAX

Data *Inflow* (lanjutan)

Pecahan Rp. 2.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.065472, p-value = 0.7802 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.096178, p-value = 0.3165 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.093102, p-value = 0.3541 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.12557, p-value = 0.08873 alternative hypothesis: two-sided
Pecahan Rp. 1.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.078872, p-value = 0.1361 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.097222, p-value = 0.0337 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.065386, p-value = 0.3142 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.054431, p-value = 0.5442 alternative hypothesis: two-sided

Lampiran 41. Output Hasil Uji Distribusi Normal Residual Model ARIMAX Data *Outflow*

Total Semua Pecahan
<pre>One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.097585, p-value = 0.03269 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.12732, p-value = 0.001819 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.1114, p-value = 0.009391 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.080005, p-value = 0.1259 alternative hypothesis: two-sided</pre>
Pecahan Rp. 100.000,-
<pre>One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.058657, p-value = 0.4471 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.10538, p-value = 0.01651 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.098979, p-value = 0.02904 alternative hypothesis: two-sided</pre>
<pre>One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.070154, p-value = 0.2382 alternative hypothesis: two-sided</pre>

Lampiran 41. Output Hasil Uji Distribusi Normal Residual Model ARIMAX

Data *Outflow* (lanjutan)

Pecahan Rp. 50.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.071775, p-value = 0.2158 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.12242, p-value = 0.003085 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.089148, p-value = 0.06456 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.070736, p-value = 0.2299 alternative hypothesis: two-sided
Pecahan Rp. 20.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.13058, p-value = 0.001265 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.12013, p-value = 0.003921 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.10717, p-value = 0.014 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.13171, p-value = 0.001113 alternative hypothesis: two-sided

Lampiran 41. Output Hasil Uji Distribusi Normal Residual Model ARIMAX

Data Outflow (lanjutan)

Pecahan Rp. 10.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 $D = 0.16223$, p-value = $2.309e-05$ alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 $D = 0.18501$, p-value = $7.572e-07$ alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 $D = 0.12769$, p-value = 0.001746 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 $D = 0.090834$, p-value = 0.05663 alternative hypothesis: two-sided
Pecahan Rp. 5.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 $D = 0.17537$, p-value = $3.398e-06$ alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 $D = 0.18664$, p-value = $5.824e-07$ alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 $D = 0.14449$, p-value = 0.0002421 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 $D = 0.095813$, p-value = 0.0379 alternative hypothesis: two-sided

Lampiran 41. Output Hasil Uji Distribusi Normal Residual Model ARIMAX

Data *Outflow* (lanjutan)

Pecahan Rp. 2.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.1999, p-value = 0.0007731 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.20046, p-value = 0.0007395 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.21433, p-value = 0.000238 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.069574, p-value = 0.7148 alternative hypothesis: two-sided
Pecahan Rp. 1.000,-
One-sample Kolmogorov-Smirnov test - KP BI Surabaya data: resiARIMAX1 D = 0.14225, p-value = 0.0003195 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Malang data: resiARIMAX2 D = 0.14889, p-value = 0.0001386 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Kediri data: resiARIMAX3 D = 0.09949, p-value = 0.02779 alternative hypothesis: two-sided
One-sample Kolmogorov-Smirnov test - KP BI Jember data: resiARIMAX4 D = 0.10068, p-value = 0.02508 alternative hypothesis: two-sided

Lampiran 42. Output SAS MCCF dan MPCCF Residual Model TSR Data *Inflow*

Total Semua Pecahan														
Schematic Representation of Cross Correlations														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	-..-	---	---	+.+--	++++
resi2	++++	-.-.	-...-	----	----	++++
resi3	++++	--.--	----+.	++++
resi4	++++	--..	----	----++-	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations														
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	+--.	---+.--	+..
resi2	-+..	.+..	-+..-+-+.
resi3	--+--++-+..
resi4	...+--+.-

+ is > 2*std error, - is < -2*std error, . is between

Pecahan Rp. 100.000,-														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	-..-	---	+.++--	++++
resi2	++++	-.-.-+	++++
resi3	++++	-.-.+	++++
resi4	++++	----+-	++++

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations														
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1--+.---	+..
resi2	-+..	.+..	-+..++-	+..
resi3	...+++-	+..
resi4+--+.

+ is > 2*std error, - is < -2*std error, . is between

Pecahan Rp. 50.000,-														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	+....	+....	++++
resi2	++++	-....	-+..	-+..	-+..	-+..	-+..	-+..	-+..	-+..	-+..	-+..	+++
resi3	++++	-.-.	++++
resi4	++++++	++..

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations														
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	+--.	+--.+.	+...
resi2	-+..	.+..	-+..+	+..
resi3	--+-++	+..
resi4+	-....-+.

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 42. Output SAS MCCF dan MPCCF Residual Model TSR Data *Inflow*
(lanjutan)

Pecahan Rp. 20.000,-															
Schematic Representation of Cross Correlations															
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	++++	++++	++++	+.+++	...+	+...	++++	++++		
resi2	+++++	..++-	+..	++++	++++	
resi3	++++	++++	..++	++..	++++	++++		
resi4	++++	...+	..++	+....	+..	++..	++++	++++
+ is > 2*std error, - is < -2*std error, . is between															
Schematic Representation of Partial Cross Correlations															
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12		
resi1	+..+++	+.+		
resi2	...-	.+..	-+..-	+..		
resi3	...++	-.+.	++..		
resi4-	+....		
+ is > 2*std error, - is < -2*std error, . is between															
Pecahan Rp. 10.000,-															
Schematic Representation of Cross Correlations															
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	++++	++++	...+	-...	-....	++++	++++	
resi2	++++	++++	..+.	-....	-....	++++	++++	
resi3	++++	++++	-	-....	-....	++++	++++	
resi4	++++	++++	-.	--	-....	++++	++++	
+ is > 2*std error, - is < -2*std error, . is between															
Schematic Representation of Partial Cross Correlations															
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12		
resi1	+..+	+.+		
resi2	-+-	.+-.		
resi3	...+	-.+.		
resi4		
+ is > 2*std error, - is < -2*std error, . is between															
Pecahan Rp. 5.000,-															
Schematic Representation of Cross Correlations															
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	++++	++++	..++	-.-.	----	----	----	----	----	----	+...	++++	++++	
resi2	++++	++.	++++	++++	
resi3	++++	+++	++..	++++	++++	
resi4	++++	+++	+...	++++	++++	
+ is > 2*std error, - is < -2*std error, . is between															
Schematic Representation of Partial Cross Correlations															
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12		
resi1	++..	-....	-....	-....		
resi2	-+..		
resi3	++-+	-....	-+..	++..		
resi4	...+	+.-.		
+ is > 2*std error, - is < -2*std error, . is between															

Lampiran 42. Output SAS MCCF dan MPCCF Residual Model TSR Data *Inflow*
(lanjutan)

Pecahan Rp. 2.000,-														
		Schematic Representation of Cross Correlations												
variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++..	+...	...-	-...	-...	
resi2	++..	-++	
resi3	..++	..++	-...++	..++	
resi4	..++	..++++	...++	
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	+...	...-	-+-	
resi2	...-+	
resi3	.++-	
resi4	..++	
+ is > 2*std error, - is < -2*std error, . is between														
Pecahan Rp. 1.000,-														
variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	+++.	+-..	----	----	----	----	----	----	----	+..+	++++	++++	
resi2	++++	++++	-..+	-..+	++++	++++
resi3	++++	++++	.++.	-..+	-..+	++++	++++
resi4	++++	++++	++++	+++.	-...+	++++	++++	
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	+-..	...+	...+	+-..	+-..	
resi2	-.-+	-..+-+	-..-	..+	..+	..+	
resi3	-..+	-..+	...+++	..+	..+	
resi4	-.-+	-.-+-.	-..+	
+ is > 2*std error, - is < -2*std error, . is between														

Lampiran 43. Output SAS MCCF dan MPCCF Residual Model TSR Data *Outflow*

Total Semua Pecahan														
		Schematic Representation of Cross Correlations												
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	----	-..-	+++.	----	++++
resi2	++++	-----	-.-.	++.	-.-.	++++
resi3	++++	-----	-.-.	+++.	-.-.	++++
resi4	++++	----.	-.-.	-.-.	++++
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	----.	-..-	-..-	+	...
resi2	-...	-----	-.-.	-..-	+	...
resi3	-...	-----	-.-.	++.	-..-
resi4	-.-+	...+	-.-.	-..-	-..-	+
+ is > 2*std error, - is < -2*std error, . is between														
Pecahan Rp. 100.000,-														
Schematic Representation of Cross Correlations														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	----	-..-	++..	----	++++
resi2	++++	-----	-.-.	++..	-..-	++++
resi3	++++	-----	-.-.	+++.	-..-	++++
resi4	++++	-.-.	-..-	-..-	++++
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	---	-..-	+..	-..-	+	...
resi2	-...	-.-.	-..-	-..-	-..-	-..-	-..+	+	...
resi3	-+-.	-..-	-..-	++..	+	...
resi4	..-++.	-..-	-..-	-..-	-..-	+	...
+ is > 2*std error, - is < -2*std error, . is between														
Pecahan Rp. 50.000,-														
Schematic Representation of Cross Correlations														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	+++++	+...+.++
resi2	++++	---+.	-..-++.
resi3	++++	----+.	-..-	++++
resi4	++++	---+++.
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	-..+	+..-+.	-+..+..	
resi2	-...	-..-	-..-	+.+-	
resi3	-.+.	+..+.	+.+	
resi4	..-+	-..-	
+ is > 2*std error, - is < -2*std error, . is between														

Lampiran 43. Output SAS MCCF dan MPCCF Residual Model TSR Data

Outflow (lanjutan)

Pecahan Rp. 20.000,-														
Schematic Representation of Cross Correlations														
variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	---	-..-	++..	+++.	
resi2	++++	..+.	---	++..	+++.	
resi3	++++	-..-	++..	+++.	
resi4	++++	...+	...+	...++	
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	-	-+..	-..-	++..		
resi2	+....	---+..	----		
resi3		
resi4	...+	...+	-...-		
+ is > 2*std error, - is < -2*std error, . is between														
Pecahan Rp. 10.000,-														
variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	++++	...+	...+	...+	++++	++++	++..	...+	...+	...+	...+	...+	+++
resi2	++++	++++	++++	++++	++..	++++	++++	++++	++++	...+	...+	...+	...+	+++
resi3	++++	.++	...+	...+	...+	...+	++++	...+	...+	...+	...+	...+	...+	+++
resi4	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	++++	+++
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	...+	-	-+..	-..-	++..		
resi2	++..	..+	..+	---+..	-..+		
resi3		
resi4	...+	...++		
+ is > 2*std error, - is < -2*std error, . is between														
Pecahan Rp. 5.000,-														
variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	...+	---	-..-	++..	+++	
resi2	++++	---	---	-..-	++..	+++	
resi3	++++	---	-..-	++..	+++	
resi4	++++	---	---	---	
+ is > 2*std error, - is < -2*std error, . is between														
Schematic Representation of Partial Cross Correlations														
variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12	
resi1	..+	-...	...+	++..		
resi2+..	-..+		
resi3		
resi4	-....+		
+ is > 2*std error, - is < -2*std error, . is between														

Lampiran 43. Output SAS MCCF dan MPCCF Residual Model TSR Data

Outflow (lanjutan)

Pecahan Rp. 2.000,-														
Schematic Representation of Cross Correlations														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	-....	+++..	
resi2	++++	
resi3	+++.+	---..	+...-	
resi4	++..+	++....	

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12
resi1	-....	-....
resi2-++
resi3+---
resi4---

+ is > 2*std error, - is < -2*std error, . is between

Pecahan Rp. 1.000,-														
Variable/	Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
resi1	++++	+++.+	++++	++..	
resi2	++++	++++-+..	++++	
resi3	++++	++++--+..	++++	
resi4	++++	++++	...+.	...+.-	+++..	

+ is > 2*std error, - is < -2*std error, . is between

Schematic Representation of Partial Cross Correlations													
Variable/	Lag	1	2	3	4	5	6	7	8	9	10	11	12
resi1	+....++..	...+.	
resi2	.+..-	
resi3	...+-	++..
resi4	...++-	+.--

+ is > 2*std error, - is < -2*std error, . is between

Lampiran 44. Output Hasil Estimasi Koefisien Model GSTARX Data *Inflow*

Total Semua Pecahan-GSTAR(1 ₁) Bobot Biner				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.379600203	0.07352769	5.1626839	5.572841e-07
loc1_wlag1loc1	-0.676479262	0.22791982	-2.9680581	3.339739e-03
loc2_lag1loc2	0.396794010	0.06136353	6.4662843	6.757861e-10
loc2_wlag1loc2	-0.308474490	0.10409078	-2.9635142	3.387433e-03
loc3_lag1loc3	0.258866894	0.07183304	3.6037300	3.905364e-04
loc3_wlag1loc3	-0.007926792	0.02279358	-0.3477642	7.283607e-01
loc4_lag1loc4	0.286512902	0.06524507	4.3913339	1.774425e-05
loc4_wlag1loc4	-0.027923144	0.03822530	-0.7304886	4.658943e-01
Pecahan Rp. 100.000, - GSTAR(1 ₁) Bobot NIKS				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.3153378	0.05377107	5.864451	1.701677e-08
loc1_wlag1loc1	-1.2380752	0.16662459	-7.430327	2.587486e-12
loc2_lag1loc2	0.3078170	0.06662000	4.620489	6.626261e-06
loc2_wlag1loc2	-0.1804315	0.03018887	-5.976756	9.467969e-09
loc3_lag1loc3	0.2488135	0.06157489	4.040827	7.438029e-05
loc3_wlag1loc3	-0.3436660	0.07105337	-4.836730	2.528631e-06
loc4_lag1loc4	0.3614381	0.06378772	5.666266	4.701563e-08
loc4_wlag1loc4	-0.1476937	0.03165353	-4.665949	5.426048e-06
Pecahan Rp. 50.000, - GSTAR(1 ₁) Bobot Invers Jarak				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.31929106	0.06447529	4.952147	1.492329e-06
loc1_wlag1loc1	-1.26817870	0.22631805	-5.603524	6.453692e-08
loc2_lag1loc2	0.37937536	0.05141889	7.378131	3.537615e-12
loc2_wlag1loc2	-0.22322504	0.04350781	-5.130689	6.484998e-07
loc3_lag1loc3	0.31920426	0.05940878	5.373015	2.023407e-07
loc3_wlag1loc3	-0.11630755	0.04689344	-2.480252	1.390388e-02
loc4_lag1loc4	0.41130092	0.06088530	6.755340	1.337417e-10
loc4_wlag1loc4	-0.09240112	0.02962803	-3.118707	2.067546e-03
Pecahan Rp. 20.000, - GSTAR(1 ₁) Bobot NIKS				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.52907434	0.07774991	6.804823	1.009122e-10
loc1_wlag1loc1	-0.36392862	0.24036713	-1.514053	1.314948e-01
loc2_lag1loc2	0.12815848	0.06172437	2.076303	3.906598e-02
loc2_wlag1loc2	0.07928214	0.02938097	2.698418	7.525608e-03
loc3_lag1loc3	0.23400868	0.06302322	3.713055	2.615007e-04
loc3_wlag1loc3	0.07239855	0.02628039	2.754850	6.380078e-03
loc4_lag1loc4	-0.01253046	0.05609081	-0.223396	8.234414e-01
loc4_wlag1loc4	0.15805440	0.02481043	6.370483	1.144789e-09
Pecahan Rp. 10.000, - GSTAR(1 ₁) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.372773682	0.07716576	4.83081747	2.597242e-06
loc1_wlag1loc1	-0.086815288	0.24567864	-0.35336930	7.241611e-01
loc2_lag1loc2	-0.045994032	0.07238557	-0.63540329	5.258475e-01
loc2_wlag1loc2	0.162372245	0.03796703	4.27666432	2.864045e-05
loc3_lag1loc3	0.024991574	0.06391704	0.39100015	6.961879e-01
loc3_wlag1loc3	0.229775405	0.05832984	3.93924273	1.107788e-04
loc4_lag1loc4	-0.001544004	0.05676915	-0.02719795	9.783273e-01
loc4_wlag1loc4	0.201805432	0.02768386	7.28964206	5.994094e-12

Lampiran 44. Output Hasil Estimasi Koefisien Model GSTARX Data *Inflow*
(lanjutan)

Pecahan Rp. 5.000, - GSTAR([1,12]_1) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.0949725190	0.08219526	1.155450080	2.492847e-01
loc1_wlag1loc1	-0.2122635658	0.21210455	-1.000749717	3.181571e-01
loc1_lag12loc1	0.4183815084	0.08286247	5.049107168	9.961950e-07
loc1_wlag12loc1	0.7004531235	0.27024963	2.591874517	1.024954e-02
loc2_lag1loc2	-0.2851010702	0.06406798	-4.449977312	1.424938e-05
loc2_wlag1loc2	0.0897637759	0.04398336	2.040857493	4.257880e-02
loc2_lag12loc2	0.1202350584	0.06843225	1.756994128	8.044902e-02
loc2_wlag12loc2	0.3438342681	0.04792251	7.174796341	1.381606e-11
loc3_lag1loc3	0.1641401920	0.05470359	3.000537594	3.037915e-03
loc3_wlag1loc3	-0.0546572609	0.07688992	-0.710850834	4.780048e-01
loc3_lag12loc3	-0.0005418898	0.06110618	-0.008868003	9.929333e-01
loc3_wlag12loc3	0.6544328576	0.07134810	9.172393470	0.000000e+00
loc4_lag1loc4	-0.0311233121	0.06781706	-0.458930448	6.467825e-01
loc4_wlag1loc4	0.0519513253	0.02884982	1.800750671	7.324878e-02
loc4_lag12loc4	-0.0753848014	0.09115205	-0.827022537	4.092099e-01
loc4_wlag12loc4	0.3079711626	0.03236615	9.515223635	0.000000e+00
Pecahan Rp. 2.000, - GSTAR(1) Bobot NIKS				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.31371041	0.10396007	3.0176048	0.003286730
loc1_wlag1loc1	-0.37816164	0.38393804	-0.9849549	0.327201803
loc2_lag1loc2	0.10392504	0.10002884	1.0389508	0.301521294
loc2_wlag1loc2	0.09138213	0.04458767	2.0494934	0.043230100
loc3_lag1loc3	0.26802868	0.09764747	2.7448604	0.007265941
loc3_wlag1loc3	0.32775779	0.22785759	1.4384326	0.153668183
loc4_lag1loc4	0.25391797	0.09810214	2.5883020	0.011192310
loc4_wlag1loc4	0.03748102	0.01788591	2.0955606	0.038838208
Pecahan Rp. 1.000, - GSTAR(1) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.8587475	0.04467111	19.2237770	0.000000e+00
loc1_wlag1loc1	-0.9710317	0.20385330	-4.7633845	3.518612e-06
loc2_lag1loc2	0.2212243	0.08399944	2.6336404	9.067097e-03
loc2_wlag1loc2	0.2514263	0.06808011	3.6930955	2.815613e-04
loc3_lag1loc3	0.5850110	0.05452007	10.7301955	0.000000e+00
loc3_wlag1loc3	0.0717465	0.10166063	0.7057452	4.811177e-01
loc4_lag1loc4	0.9561653	0.07222727	13.2382857	0.000000e+00
loc4_wlag1loc4	-0.1950180	0.04097167	-4.7598243	3.575156e-06

Lampiran 45. Output Hasil Estimasi Koefisien Model GSTARX Data *Outflow*

Total Semua Pecahan-GSTAR(2 ₁) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.16676542	0.07804858	2.1366873	3.378024e-02
loc1_wlag1loc1	-1.44709651	0.24022207	-6.0239949	7.523081e-09
loc1_lag2loc1	0.05154982	0.07569619	0.6810095	4.966157e-01
loc1_wlag2loc1	-0.67223450	0.25634312	-2.6224012	9.370901e-03
loc2_lag1loc2	-0.07646970	0.07029917	-1.0877752	2.779412e-01
loc2_wlag1loc2	-0.10997035	0.05460599	-2.0138881	4.529720e-02
loc2_lag2loc2	0.02404978	0.07017801	0.3426968	7.321693e-01
loc2_wlag2loc2	-0.11480074	0.04518854	-2.5404834	1.179262e-02
loc3_lag1loc3	0.04295087	0.07234604	0.5936865	5.533607e-01
loc3_wlag1loc3	-0.35039199	0.09287567	-3.7726995	2.100376e-04
loc3_lag2loc3	0.08333005	0.07563588	1.1017264	2.718417e-01
loc3_wlag2loc3	-0.27551504	0.10059041	-2.7389792	6.692723e-03
loc4_lag1loc4	0.35710092	0.06949104	5.1388055	6.308276e-07
loc4_wlag1loc4	-0.21035700	0.03417829	-6.1546970	3.759599e-09
loc4_lag2loc4	0.12610320	0.07136329	1.7670598	7.867072e-02
loc4_wlag2loc4	-0.09579582	0.03928892	-2.4382400	1.559025e-02
Pecahan Rp. 100.000, - GSTAR(2 ₁) Bobot NIKS				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.03722376	0.08318789	0.4474461	6.549998e-01
loc1_wlag1loc1	-0.85202030	0.19416025	-4.3882324	1.808801e-05
loc1_lag2loc1	0.12341400	0.07914291	1.5593817	1.204118e-01
loc1_wlag2loc1	-0.62504397	0.20449709	-3.0564932	2.530156e-03
loc2_lag1loc2	0.01990694	0.06726064	0.2959672	7.675476e-01
loc2_wlag1loc2	-0.11456739	0.02873526	-3.9869967	9.234875e-05
loc2_lag2loc2	-0.06072393	0.07592450	-0.7997936	4.247342e-01
loc2_wlag2loc2	-0.06442903	0.05700279	-1.1302786	2.596481e-01
loc3_lag1loc3	0.06867248	0.07112763	0.9654824	3.354138e-01
loc3_wlag1loc3	-0.44881938	0.09729786	-4.6128393	6.902163e-06
loc3_lag2loc3	0.05104334	0.07478526	0.6825320	4.956548e-01
loc3_wlag2loc3	-0.21420257	0.10059698	-2.1293142	3.439262e-02
loc4_lag1loc4	0.41130480	0.06930738	5.9345026	1.202852e-08
loc4_wlag1loc4	-0.28251599	0.03734542	-7.5649431	1.196820e-12
loc4_lag2loc4	0.08451269	0.06959076	1.2144239	2.259497e-01
loc4_wlag2loc4	-0.08310264	0.03893445	-2.1344246	3.396717e-02
Pecahan Rp. 50.000, - GSTAR(1 ₁) Bobot NIKS				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.27360777	0.06200019	4.413015	1.619123e-05
loc1_wlag1loc1	-1.50865262	0.24273407	-6.215249	2.660797e-09
loc2_lag1loc2	-0.12425723	0.06941103	-1.790165	7.484766e-02
loc2_wlag1loc2	-0.08796942	0.08145285	-1.080004	2.813617e-01
loc3_lag1loc3	0.10782540	0.06106543	1.765735	7.887292e-02
loc3_wlag1loc3	-0.49601963	0.09950546	-4.984848	1.283104e-06
loc4_lag1loc4	0.32419439	0.06349268	5.106012	7.285950e-07
loc4_wlag1loc4	-0.14258164	0.03062273	-4.656073	5.667504e-06
Pecahan Rp. 20.000, - GSTAR(2 ₁) Bobot Biner				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.05941949	0.08769279	0.6775869	4.987795e-01
loc1_wlag1loc1	-0.13141303	0.32431575	-0.4052009	6.857423e-01
loc1_lag2loc1	-0.19158911	0.08721566	-2.1967282	2.913394e-02
loc1_wlag2loc1	0.24575396	0.32313515	0.7605300	4.477909e-01
loc2_lag1loc2	0.06483179	0.05613802	1.1548641	2.494585e-01
loc2_wlag1loc2	-0.01246760	0.04240008	-0.2940467	7.690127e-01
loc2_lag2loc2	-0.10817659	0.05619565	-1.9249994	5.558048e-02
loc2_wlag2loc2	-0.01384323	0.04221130	-0.3279509	7.432755e-01
loc3_lag1loc3	0.03172365	0.09127553	0.3475592	7.285194e-01
loc3_wlag1loc3	0.01884848	0.02451780	0.7687670	4.428954e-01
loc3_lag2loc3	0.08701292	0.09091853	0.9570427	3.396462e-01
loc3_wlag2loc3	-0.04843994	0.02439358	-1.9857659	4.836018e-02
loc4_lag1loc4	0.28301714	0.06458493	4.3820925	1.856134e-05
loc4_wlag1loc4	-0.05126336	0.07243238	-0.7077409	4.798909e-01
loc4_lag2loc4	0.28994720	0.06449575	4.4956017	1.146353e-05
loc4_wlag2loc4	-0.04179950	0.07203272	-0.5802849	5.623446e-01

Lampiran 45. Output Hasil Estimasi Koefisien Model GSTARX Data *Outflow*
(lanjutan)

Pecahan Rp. 10.000, - GSTAR([1,12] ₁) Bobot Invers Jarak				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	-0.19483326	0.08945341	-2.178042	3.057272e-01
loc1_wlag1loc1	0.62147236	0.58256036	1.066795	2.873506e-01
loc1_lag12loc1	0.33527643	0.09691999	3.459311	6.617874e-04
loc1_wlag12loc1	1.67966186	0.61856354	2.715423	7.198222e-03
loc2_lag1loc2	0.16315078	0.07706020	2.117186	3.547977e-02
loc2_wlag1loc2	-0.07385951	0.02776405	-2.660257	8.441547e-03
loc2_lag12loc2	0.22827338	0.08848046	2.579930	1.059881e-02
loc2_wlag12loc2	0.08997375	0.03213561	2.799815	5.614331e-03
loc3_lag1loc3	0.20407219	0.07189587	2.838441	5.001096e-03
loc3_wlag1loc3	-0.09708572	0.03265551	-2.973027	3.311027e-03
loc3_lag12loc3	0.11255261	0.07096493	1.586031	1.143120e-01
loc3_wlag12loc3	0.18664559	0.03422124	5.454087	1.443329e-07
loc4_lag1loc4	0.17745095	0.06793985	2.611883	9.687564e-03
loc4_wlag1loc4	-0.03876887	0.01584449	-2.446836	1.527513e-02
loc4_lag12loc4	0.14375708	0.06888569	2.086893	3.816520e-02
loc4_wlag12loc4	0.10297948	0.01693660	6.080294	5.984485e-09
Pecahan Rp. 5.000, - GSTAR(12 ₁) Bobot Biner				
	estimate	std.error	t-value	p-value
loc1_lag12loc1	0.09104568	0.08910307	1.0218019	3.080968e-01
loc1_wlag12loc1	1.29690787	0.61624316	2.1045392	3.656808e-02
loc2_lag12loc2	0.27355162	0.06900301	3.9643432	1.021019e-04
loc2_wlag12loc2	0.42205726	0.16551518	2.5499610	1.151497e-02
loc3_lag12loc3	0.26416017	0.07797629	3.3876985	8.472018e-04
loc3_wlag12loc3	0.01713736	0.01094887	1.5652168	1.190973e-01
loc4_lag12loc4	-0.01347466	0.07527677	-0.1790015	8.581159e-01
loc4_wlag12loc4	0.22824025	0.02855947	7.9917548	1.003642e-13
Pecahan Rp. 2.000, - GSTAR(1 ₁) Bobot Biner				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	-0.212453331	0.08203574	-2.58976550	0.0111481
loc1_wlag1loc1	-0.045662020	0.66039923	-0.06914305	0.9450242
loc2_lag1loc2	-0.054146621	0.08133620	-0.66571371	0.5072419
loc2_wlag1loc2	-0.016029438	0.26876961	-0.05964007	0.9525703
loc3_lag1loc3	-0.058981091	0.08977568	-0.65698293	0.5128145
loc3_wlag1loc3	0.002021145	0.01107381	0.18251580	0.8555752
loc4_lag1loc4	0.022021965	0.09173722	0.24005486	0.8108161
loc4_wlag1loc4	0.021962890	0.02522868	0.87055259	0.3862401
Pecahan Rp. 1.000, - GSTAR(1 ₁) Bobot Biner				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0.163540097	0.06807303	2.4024213	1.714477e-02
loc1_wlag1loc1	0.478656167	0.46292223	1.0339883	3.023142e-01
loc2_lag1loc2	0.221007340	0.05530692	3.9960162	8.875358e-05
loc2_wlag1loc2	-0.021634709	0.11274797	-0.1918856	8.480146e-01
loc3_lag1loc3	0.203468422	0.05553475	3.6638039	3.136469e-04
loc3_wlag1loc3	0.004981318	0.00677197	0.7355789	4.627962e-01
loc4_lag1loc4	0.369406630	0.06034459	6.1216201	4.396486e-09
loc4_wlag1loc4	-0.013067916	0.02718304	-0.4807379	6.311962e-01

Lampiran 46. Koefisien Model *Hybrid* Terbaik Data *Inflow*

Pecahan Rp. 100.000,-: Model *Hybrid GSTARX-FFNN(8,1,1)* Bobot Biner

Parameter Estimates

Predictor	Predicted	
	Hidden Layer 1	Output Layer
		H(1:1)
Input Layer	(Bias)	-.407
	L11	.055
	L12	-.343
	L13	.381
	L14	.310
	W11	-.450
	W12	.258
	W13	.188
	W14	-.300
	(Bias) H(1:1)	.033 .140

Pecahan Rp. 50.000,-: Model *Hybrid GSTARX-FFNN(8,1,1)* Bobot Biner

Parameter Estimates

Predictor	Predicted	
	Hidden Layer 1	Output Layer
		H(1:1)
Input Layer	(Bias)	.222
	L11	.265
	L12	.049
	L13	.023
	L14	.037
	W11	-.236
	W12	-.038
	W13	-.003
	W14	-.020
	(Bias) H(1:1)	-.330 1.572

Lampiran 46. Koefisien Model *Hybrid* Terbaik Data *Inflow* (lanjutan)

Pecahan Rp. 20.000,-: Model *Hybrid* GSTARX-FFNN(8,15,1) Bobot Seragam

Parameter Estimates

Predictor	Predicted															Output Layer Yt	
	Hidden Layer 1																
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)		
Input Layer	(Bias)	.002	-.399	-.122	-.098	-.378	-.138	-.056	-.187	-.264	-.105	-.087	-.399	.271	-.048	.223	
	L11	-.309	.266	.301	.162	-.348	-.431	.353	-.522	.115	-.456	-.218	-.204	-.258	.446	-.419	
	L12	-.107	.413	-.135	-.218	.491	-.054	.406	-.336	.168	.246	.452	.159	.110	-.153	-.342	
	L13	.100	-.233	.302	-.030	-.137	-.323	.221	.332	.348	.284	-.107	-.188	-.148	-.141	-.245	
	L14	-.034	-.428	-.233	.502	.079	-.485	.354	.382	-.149	.450	.410	-.414	-.279	.459	.436	
	W11	.295	.220	-.344	.295	-.099	.046	.381	-.373	-.455	-.181	.292	.265	.233	.384	.390	
	W12	-.114	.303	.395	.140	-.487	.165	-.321	.191	.436	-.269	-.402	.492	.204	-.011	.230	
	W13	-.328	-.315	-.443	.418	.390	.513	.110	.100	.412	.300	-.377	-.364	-.171	-.230	.010	
	W14	.351	.338	.324	-.464	.227	-.226	-.027	-.037	.357	.356	-.116	.375	-.117	.348	-.057	
Hidden Layer 1	(Bias)															.188	
	H(1:1)															-.491	
	H(1:2)															.143	
	H(1:3)															.212	
	H(1:4)															.368	
	H(1:5)															-.095	
	H(1:6)															-.143	
	H(1:7)															-.365	
	H(1:8)															-.470	
	H(1:9)															.374	
	H(1:10)															.071	
	H(1:11)															-.011	
	H(1:12)															-.246	
	H(1:13)															-.467	
	H(1:14)															.553	
	H(1:15)															-.329	

Lampiran 46. Koefisien Model *Hybrid* Terbaik Data *Inflow* (lanjutan)

Pecahan Rp. 2.000,-: Model *Hybrid GSTARX-DLNN(8,10,3,1)* Bobot NIKS

Parameter Estimates

Predictor	Predicted													
	Hidden Layer 1										Hidden Layer 2		Output Layer	
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(2:1)	H(2:2)	H(2:3)	Yt
Input Layer	.122	-.209	-.321	.161	-.453	-.050	-.518	-.295	.215	.289				
L11	.405	.469	-.581	.623	-.034	.401	.042	.444	-.504	-.315				
L12	-.426	.480	-.249	-.188	.451	-.291	.461	-.002	-.148	.169				
L13	.347	-.275	-.132	.036	.333	-.263	.477	-.425	-.281	-.544				
L14	.460	-.271	.425	-.218	-.098	-.519	-.271	-.379	.359	.187				
W11	-.180	-.308	.205	-.234	.607	-.390	.119	.159	.438	.203				
W12	.366	.117	-.042	-.350	.142	-.381	.035	-.241	.325	-.422				
W13	.188	-.121	.127	.461	.219	-.182	.128	-.461	-.179	.167				
W14	.245	.201	-.489	.334	.135	.448	-.058	-.269	-.372	.298				
Hidden Layer 1	(Bias)										.069	.258	-.446	
	H(1:1)										.716	.366	-.097	
	H(1:2)										.383	-.343	.492	
	H(1:3)										-.230	-.256	.144	
	H(1:4)										.234	.598	.150	
	H(1:5)										.092	-.108	-.023	
	H(1:6)										-.334	.312	-.158	
	H(1:7)										-.014	-.186	.547	
	H(1:8)										.114	-.097	-.411	
	H(1:9)										-.518	-.072	.467	
	H(1:10)										-.210	-.096	-.156	
Hidden Layer 2	(Bias)													.049
	H(2:1)													.715
	H(2:2)													.266
	H(2:3)													.076

Lampiran 47. Koefisien Model *Hybrid* Terbaik Data *Outflow*

Total *Outflow*: Model *Hybrid GSTARX-FFNN(16,15,1)* Bobot Seragam

Predictor	Parameter Estimates														
	Predicted														
	Hidden Layer 1														Output Layer
H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)	Yt
Input Layer (Bias)	.529	-.159	.417	.268	-.120	-.143	-.195	-.190	-.376	.251	-.720	-.691	.316	.202	-.011
L11	.584	.051	-.441	.384	-.392	-.111	-.071	.284	-.593	.603	-.223	-.017	-.345	.136	.235
L12	.434	-.428	-.240	.212	.544	.484	.615	-.088	-.362	-.378	.488	-.415	-.351	-.095	-.103
L13	-.469	-.279	.479	-.242	.261	.344	.090	-.111	.416	-.431	.238	.394	-.157	-.258	.421
L14	.248	-.497	-.283	.297	.514	-.008	.034	-.373	.223	-.296	.139	.002	.545	-.182	.447
W11	.259	-.413	.265	.080	-.152	.368	.116	.670	-.377	-.325	.435	.422	.471	-.142	-.812
W12	.389	.253	-.214	-.339	.264	.435	.062	-.371	.646	.264	-.227	.061	-.332	-.286	.136
W13	.212	-.073	-.158	.333	.262	-.254	-.539	.033	-.093	-.391	.046	-.162	-.364	.326	-.809
W14	.485	.249	-.096	.434	-.440	.086	.458	-.461	-.143	.250	.370	.359	.200	-.307	.209
VAR00011	.296	-.315	.040	.486	-.142	.170	-.741	.114	-.420	-.281	-.094	.039	.194	.231	.128
VAR00012	-.282	-.023	-.136	-.388	.613	.068	.456	.233	-.455	.020	.362	-.079	.043	-.108	-.260
VAR00013	.260	.282	.396	-.368	.324	.041	.538	.189	-.167	.166	.184	.239	.064	-.116	-.353
VAR00014	-.086	.369	-.163	-.109	.093	-.399	.287	-.204	.532	.062	-.288	.411	.229	-.454	.196
VAR00015	-.407	-.406	-.335	-.078	-.122	.016	-.515	.029	.231	.364	-.133	.205	.025	-.083	.432
VAR00016	-.046	-.101	.373	-.182	.009	-.309	.061	-.020	-.179	.203	-.104	-.227	.198	-.093	-.477
VAR00017	.348	-.250	.180	-.440	.204	.348	.428	-.597	.026	-.301	.677	-.128	.406	-.144	.234
VAR00018	-.045	-.290	-.467	-.075	.068	-.423	-.482	-.389	-.006	-.291	.174	-.041	-.416	-.339	.383
Hidden Layer 1 (Bias)															-.589
H(1:1)															.302
H(1:2)															.108
H(1:3)															.607
H(1:4)															.308
H(1:5)															.350
H(1:6)															-.378
H(1:7)															.471
H(1:8)															.070
H(1:9)															-.550
H(1:10)															-.312
H(1:11)															-.773
H(1:12)															-.005
H(1:13)															-.379
H(1:14)															.174
H(1:15)															.695

Lampiran 47. Koefisien Model *Hybrid* Terbaik Data *Outflow* (lanjutan)

Pecahan Rp. 100.000,-: Model *Hybrid GSTARX-FFNN(16,15,1)* Bobot Seragam

Predictor	Parameter Estimates															
	Predicted															Output Layer
	Hidden Layer 1															
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)	Yt
Input Layer (Bias)	.763	-.450	.287	.040	-.636	.027	-.194	-.205	.007	-.015	.407	-.095	.253	.054	-.311	
L11	-.109	.181	.294	.216	.095	-.162	.456	-.496	-.384	.512	-.320	.359	.077	-.302	-.626	
L12	.318	-.010	-.107	-.343	-.335	.343	-.187	-.425	-.118	.262	.363	-.168	-.411	.122	-.505	
L13	.532	.210	-.418	.423	.070	.264	.064	.045	.080	-.405	-.006	-.021	.238	.198	-.337	
L14	.185	.505	-.284	-.015	.047	-.314	-.372	-.458	-.684	-.045	.427	.122	-.080	.060	-.381	
W11	-.192	-.568	.396	.295	.182	-.149	.014	-.504	-.570	-.205	.706	-.475	-.035	-.382	-.248	
W12	-.629	.029	-.151	-.040	.429	-.179	.176	-.301	.363	-.174	.055	.159	.163	-.031	-.346	
W13	.193	-.022	-.453	.367	.480	.301	.357	.397	.251	-.590	.161	-.318	-.222	-.198	-.384	
W14	.227	.083	.177	-.460	.500	.511	-.514	-.428	-.397	.343	.199	-.399	-.187	-.372	.011	
VAR00011	.105	-.034	.027	-.468	.021	-.502	-.075	.022	-.052	-.330	-.345	.262	.600	.153	-.198	
VAR00012	.107	.508	.129	.362	.443	-.470	.179	-.346	.437	-.157	-.317	.113	.146	-.196	.161	
VAR00013	-.160	-.314	.113	-.533	.026	.180	.298	-.093	.592	.140	-.481	.252	.037	.370	.151	
VAR00014	-.104	-.009	-.093	.462	.307	-.244	.137	-.082	.196	-.261	-.108	-.153	-.296	-.115	.521	
VAR00015	-.304	.282	.290	-.454	.319	.544	-.286	-.130	.384	.479	-.278	-.062	.466	.242	.041	
VAR00016	.258	-.358	.419	.219	-.214	.052	.319	.215	-.426	.063	.204	-.332	-.065	.354	-.173	
VAR00017	.098	.209	.096	-.129	-.087	-.002	.477	.205	-.229	.262	.815	.243	-.425	-.478	.077	
VAR00018	-.155	.354	.470	.102	-.255	-.335	.232	.161	.144	-.071	-.403	-.109	.160	-.273	-.097	
Hidden Layer 1 (Bias)																
H(1:1)																-.355
H(1:2)																.540
H(1:3)																-.311
H(1:4)																.063
H(1:5)																-.145
H(1:6)																.496
H(1:7)																.059
H(1:8)																-.151
H(1:9)																-.338
H(1:10)																.232
H(1:11)																-.600
H(1:12)																-.642
H(1:13)																.402
H(1:14)																-.491
H(1:15)																.002
																-.053

Lampiran 47. Koefisien Model *Hybrid* Terbaik Data *Outflow* (lanjutan)

Pecahan Rp. 100.000,-: Model *Hybrid GSTARX-FFNN(16,15,1)* Bobot Seragam

Parameter Estimates

Predictor	Predicted		
	Hidden Layer 1		Output Layer
	H(1:1)	H(1:2)	Yt
Input Layer	(Bias)	-.430	-.377
	L11	-.789	.036
	L12	.255	-.279
	L13	-.067	-.301
	L14	-.273	.476
	W11	.626	.612
	W12	.038	-.040
	W13	.596	-.420
	W14	-.075	.357
	(Bias)		-.351
Hidden Layer 1	H(1:1)		-.826
	H(1:2)		-.512

Pecahan Rp. 20.000,-: Model *Hybrid GSTARX-DLNN(16,2,5,1)* Bobot Seragam

Parameter Estimates

Predictor	Predicted						
	Hidden Layer 1		Hidden Layer 2			Output Layer	
	H(1:1)	H(1:2)	H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)
Input Layer	(Bias)	-.100	.624				
	L11	-.172	-.755				
	L12	-.533	-.139				
	L13	.381	-.382				
	L14	-.425	-.935				
	W11	-.185	-.451				
	W12	.333	-.349				
	W13	.078	-.435				
	W14	-.142	.085				
	VAR00019	.839	.549				
	VAR00020	-.378	.259				
	VAR00021	-.223	.429				
	VAR00022	-.370	-.417				
	VAR00023	.339	-.579				
	VAR00024	-.381	.265				
	VAR00025	.169	.113				
	VAR00026	-.149	.352				
Hidden Layer 1	(Bias)		.098	-.089	.051	.062	-.138
	H(1:1)			.159	-.268	.085	.448
	H(1:2)			.290	-.184	.396	-.132
Hidden Layer 2	(Bias)						.179
	H(2:1)						-.298
	H(2:2)						.278
	H(2:3)						-.332
	H(2:4)						.345
	H(2:5)						-.133

Lampiran 47. Koefisien Model *Hybrid* Terbaik Data *Outflow* (lanjutan)

Pecahan Rp. 2.000,-: Model *Hybrid GSTARX-DLNN(8,15,2,1)* Bobot Biner

Parameter Estimates

Predictor	Predicted															Hidden Layer 2	Output Layer		
	Hidden Layer 1																		
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)				
Input Layer	(Bias)	.097	.045	-.460	-.363	.507	.431	-.041	-.381	.275	-.162	.215	.241	.490	-.325	-.204			
	L11	.029	-.100	.205	.265	-.371	-.252	-.050	.180	.051	-.235	-.330	.122	.184	.178	.284			
	L12	.386	-.350	.304	-.317	-.187	.326	.271	-.486	.277	-.259	-.494	-.281	.268	.071	-.167			
	L13	.398	-.096	.134	.494	.391	-.221	.481	-.403	.295	.207	-.201	-.336	.021	.330	-.054			
	L14	-.210	-.165	-.308	.176	.236	-.340	.077	-.478	.090	.284	.012	-.321	-.339	-.324	-.347			
	W11	-.340	-.389	-.018	.187	.168	.480	.428	.149	.467	-.113	.429	.439	-.232	.298	.476			
	W12	.012	.139	.325	-.146	.274	-.293	-.287	.313	-.461	-.209	.472	.291	.404	-.471	.314			
	W13	.086	.494	-.484	-.319	.053	.195	.219	.053	.218	.158	.432	-.242	.436	-.341	-.193			
	W14	-.142	-.276	.207	-.275	-.339	.026	-.080	-.367	-.350	-.466	.007	-.199	-.325	.339	.204			
	Hidden Layer 1	(Bias)														-.164	.508		
		H(1:1)														.003	-.126		
		H(1:2)														.263	.174		
		H(1:3)														.241	-.007		
		H(1:4)														.119	.195		
		H(1:5)														-.156	.123		
		H(1:6)														.175	.239		
		H(1:7)														-.280	-.163		
		H(1:8)														-.257	.362		
		H(1:9)														.333	.481		
		H(1:10)														.115	-.458		
		H(1:11)														-.129	-.133		
		H(1:12)														.277	.427		
		H(1:13)														-.148	.210		
		H(1:14)														-.115	-.193		
		H(1:15)														-.275	-.063		
Hidden Layer 2	(Bias)																.258		
	H(2:1)																.317		
	H(2:2)																-.409		

(Halaman ini sengaja dikosongkan)

Lampiran 48. Surat Pernyataan Pengambilan Data

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Fauzah Hikmawati
NRP : 06211850010009

Menyatakan bahwa data yang digunakan dalam Tesis/ *Disertasi* ini merupakan data sekunder yang diambil dari penelitian/buku/Tugas Akhir/ Thesis/ *Disertasi*/ publikasi lainnya, yaitu:

Sumber : Bank Indonesia
Keterangan : Data *Inflow* dan *Outflow* di Kantor Bank Indonesia wilayah Surabaya, Malang, Kediri, dan Jember

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat permalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Surabaya, 03 Januari 2020

Mengetahui,
Pembimbing Tesis



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

Mahasiswa



Fauzah Hikmawati
NRP. 06211850010009

(Halaman ini sengaja dikosongkan)

BIOGRAFI PENULIS



Penulis memiliki nama lengkap Fauzah Hikmawati yang biasa dipanggil dengan Fazah. Penulis lahir di Gresik, 11 Desember 1993. Penulis merupakan anak terakhir dari empat bersaudara. Penulis bertempat tinggal di RT/RW 006/05 Desa Sekapuk Kecamatan Ujungpangkah, Kabupaten Gresik. Penulis telah menempuh pendidikan Diploma III Statistika di Institut Teknologi Sepuluh Nopember Surabaya dan lulus Diploma III pada tahun 2015. Setelah lulus Diploma III penulis melanjutkan pendidikan di Program Studi Lintas Jalur Sarjana Statistika Institut Teknologi Sepuluh Nopember Surabaya dan memperoleh gelar sarjana sains pada tahun 2017. Penulis melanjutkan studi program magister pada Tahun 2018 di Departemen Statistika ITS melalui beasiswa BPP-DN *Fresh Graduate*. Selama menjalani studi program magister penulis mengikuti kegiatan Digital Talent Scholarship 2018 program Internet of Things (IoT) yang diselenggarakan oleh Kementerian Komunikasi dan Informasi (Kominfo). Penulis memperoleh gelar Magister Statistika pada tahun 2020 dengan judul tesis “Model Hybrid GSTARX-Jordan RNN untuk Peramalan Data *Space-Time* dengan Efek Variasi Kalender”. Apabila ada saran, kritik, atau ada yang ingin didiskusikan dapat menghubungi email fauzah.hikmawati@gmail.com.